

國立交通大學

電機與控制工程學系

碩 士 論 文

應用色彩補償與校正技術於影像品質增強之
研究

A Study of Image Quality Enhancement and Color
Correcting Compensation



研 究 生：謝韶紘

指導教授：林昇甫 博士

中華民國九十六年六月

應用色彩補償與校正技術於影像品質增強之研究

A Study of Image Quality Enhancement and Color
Correcting Compensation

研究生：謝韶紘 Student: Shau-Hung Hsieh

指導教授：林昇甫 博士 Advisor: Dr. Sheng-Fuu Lin

國立交通大學

電機與控制工程學系



Submitted to Department of Electrical and Control Engineering
College of Electrical Engineering and Computer Engineering

National Chiao-Tung University

in Partial Fulfillment of the Requirements

for the Degree of Master

in

Electrical and Control Engineering

June 2007

Hsinchu, Taiwan, Republic of China

中華民國九十六年六月

應用色彩補償與校正技術於影像品質增強之研究

研究生：謝韶紘

指導教授：林昇甫 博士

國立交通大學電機與控制工程學系

摘 要

本論文提出的系統分成兩個部份：系統的第一個部份採用類神經網路判斷影像是否需要校正及補償，在實做上由訓練影像取得具有代表性的統計參數，再將這些參數輸入類神經網路，作為訓練回傳神經網路(back-propagation neural network)的輸入特徵向量。系統的第二部份採用模糊系統建立一個影像曝光校正演算法，在實做上將影像區分成若干區塊，並分別計算亮度因子以取得修正權重，然後分別修正影像中過度曝光(影像過於明亮)及曝光不足(影像過於灰暗)的區塊，最後再將影像經由色彩校正補償使影像具有較佳的視覺效果。

在增強影像品質的處理，影像亮度的校正及影像色彩的補償是很重要的一環。強化影像對比的演算法中，直方圖等化法是常被使用的一個演算法，但直方圖等化法對於明暗對比過於強烈的影像處理效果有限。Retinex演算法是另一個非常好用的演算法，然而若完整地考慮色彩資訊則其龐大的運算量也使得應用受到限制。本論文以Retinex演算法中運算量較少的Single Scale Retinex與直方圖等化法結合，使用類神經網路偵測影像中需要進行色彩校正的部分，並配合模糊系統計算校正及補償的權重，使影像色彩達到較佳的修正。

A Study of Image Quality Enhancement and Color Correcting Compensation

Student: Shau-Hung Hsieh Advisor: Dr. Sheng-Fuu Lin

Department of Electrical and Control Engineering
National Chiao-Tung University

Abstract

There are two main parts in this thesis. The first part of the system detects the color information by using neural network. To implement this part, the statistical parameters can be acquired from the training data, and let the statistical parameters as the input of the back-propagation neural network. The second part of the system does color correction and color compensation. To implement it, the input image is divided into n blocks. For each block, the luminance factor and correcting weighting can be obtained by a fuzzy system. Then the system can use this factor to correct the block which has excessive luminance or not enough.

The luminance correction and color compensation are important procedures of image quality enhancement. Histogram equalization is one theory in common use. But to process images with strong contrast by using histogram equalization is not perfect. Retinex theory is another nice theory. But if consider the color information, retinex theory will has lots of calculation. The implement of this thesis use Single Scale Retinex to cost down calculation, and combine the effect of histogram equalization. The system uses a neural network to detect which region must be compensated. The neural network will transfer parameters to a fuzzy system, and then the fuzzy system can calculate the weights for color correction compensation.

誌 謝

首先以最誠摯的謝意，感謝我的指導教授林昇甫博士，感謝他在這些年研究生涯中的啟蒙與悉心指導，及細心校閱本論文的繆誤之處，使我得以一窺影像處理領域的奧妙。同時感謝本實驗室的士哲學長及同學們，由於他們熱心的協助與討論，總能適時地為我解惑。

同時感謝聯勤兵工整備發展中心裝配翻修廠歐陽光上校，鑑測處吳修志上校、劉奕稔中校、黃種明中校，武化翻修廠張啟泰上校、謝孟學中校，鑑測處陳須美小姐、劉晏汝小姐、醫護所侯秀芳小姐，及鑑測處、武化翻修廠所有的長官、袍澤及同仁們，感謝他們在我徬徨時給予鼓勵，使我能有勇氣得以面對失敗與挫折。

本論文的完成亦感謝台北開放原始碼軟體使用者社群(Taipei Open Source Software User Group, TOSSUG)的陳永昱先生和李俊裕先生在程式語言方面的指教，由於他們熱心的協助，使我對程式語言的運用有更深一層的瞭解。


在這些年的求學生涯中接受了許多人的熱心協助，在這裡同時也要感謝他們。
最後，謹以此文獻給我摯愛的雙親與家人。



目錄

中文摘要	i
Abstract.....	ii
誌謝	iii
目錄	iv
圖目錄	vi
表目錄	ix
第一章 緒論	1
1.1 相關研究.....	1
1.2 研究動機與目的.....	2
1.3 全文架構.....	2
第二章 強化影像品質的方法與原理.....	3
2.1 色彩空間模型.....	3
2.1.1 RGB色彩模型.....	3
2.1.2 YCbCr色彩模型.....	3
2.2 影像強化.....	4
2.2.1 對比延伸法(Contrast Stretching)與S曲線對應增強法	4
2.2.2 直方圖等化	5
2.2.3 Retinex演算法	8
2.3 影像色彩補償.....	10
2.4 神經網路與模糊系統.....	11
2.4.1 回傳神經網路	11
2.4.2 模糊系統	16
2.5 影像品質評估.....	20
2.5.1 均方差(Mean Square Error, MSE).....	20

2.5.2 指標峰值訊雜比(Peak Signal to Noise Ratio, PSNR)	20
第三章 系統架構	22
3.1 系統流程.....	22
3.2 回傳神經網路架構.....	23
3.3 模糊系統架構.....	26
3.4 影像色彩補償.....	30
第四章 實驗結果	31
4.1 實例一：顏色色偏的校正(偏紅).....	31
4.2 實例二：顏色色偏的校正(偏藍).....	41
4.3 實例三：顏色色偏的校正(偏綠).....	47
4.4 實例四：影像亮度的校正.....	45
第五章 結論與未來發展	60
參考文獻	62



圖目錄

圖2.1	階調直方圖等劃法曲線示意圖	5
圖2.2	原始影像	7
圖2.3	影像直方圖分佈：(a)原始影像的直方圖；(b)經直方圖等化處理後的直方圖分佈	7
圖2.4	直方圖等化處理後的輸出影像	8
圖2.5	回傳神經網路架構圖	13
圖2.6	模糊推論的最小值推論法	18
圖2.7	模糊法則同時且平行接受輸入訊號示意圖	19
圖3.1	影像色彩補償與校正系統流程圖	23
圖3.2	邏輯作用函數 $sgm(Z)$ 的圖形	24
圖3.3	神經網路訓練收斂過程	25
圖3.4	色彩校正補償模糊系統架構圖	26
圖3.5	模糊系統輸入的歸屬函數：(a) $avg_f(k)$ 的歸屬函數；(b) $sd_f(k)$ 的歸屬函數	28
圖3.6	模糊系統輸出 $scale(k)$ 的歸屬函數	28
圖3.7	模糊法則的函數圖	29
圖3.8	在(3.1)式中 γ 的歸屬函數	29
圖3.9	以(3.1)式中 γ 為輸出的模糊函數圖	30
圖3.10	色彩補償系統方塊圖	30
圖4.1	訓練神經網路的影像。(a)色彩偏重Red色調影像；(b)影像的RGB色階分佈。	32

圖4.2	訓練神經網路的影像。(a)色彩偏重Green色調的影像；(b)影像的RGB色階分佈。	34
圖4.3	訓練神經網路的影像。(a)色彩偏重Blue色調的影像；(b)影像的RGB色階分佈。	35
圖4.4	(a)原始輸入影像；(b)未解調濾波器函數圖，參數值為5；(c)原始輸入影像的色階分佈圖。	36
圖4.5	類神經網路的收斂圖($MSE = 0.9171$)	38
圖4.6	類神經網路的收斂圖($MSE = 0.8123$)	38
圖4.7	類神經網路的收斂圖($MSE = 0.8362$)	39
圖4.8	影像偏紅的標準差誤差值歸屬函數圖	40
圖4.9	影像偏紅的平均誤差值歸屬函數圖	40
圖4.10	修正影像的濾波器函數(參數值為97)	40
圖4.11	經由解調後還原的影像	41
圖4.12	類神經網路收斂圖($MSE = 0.9011$)	42
圖4.13	類神經網路收斂圖($MSE = 0.8923$)	42
圖4.14	類神經網路收斂圖($MSE = 0.8762$)	43
圖4.15	(a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。	44
圖4.16	影像偏藍的標準差誤差值歸屬函數圖	46
圖4.17	影像偏藍的平均誤差值歸屬函數圖	46
圖4.18	修正影像的濾波器函數(參數值為123.81)	46
圖4.19	經由解調後還原的影像	47
圖4.20	類神經網路的收斂圖($MSE = 0.9099$)	48
圖4.21	類神經網路的收斂圖($MSE = 0.9131$)	48
圖4.22	類神經網路的收斂圖($MSE = 0.8992$)	49
圖4.23	(a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。	50

圖4.24	影像偏綠的標準差誤差值歸屬函數圖	52
圖4.25	影像偏綠的標準差誤差值歸屬函數圖	52
圖4.26	修正影像的濾波器函數(參數值為117.46).....	52
圖4.27	經由解調後還原的影像	53
圖4.28	類神經網路的收斂圖($MSE = 0.8714$)	54
圖4.29	類神經網路的收斂圖($MSE = 0.9035$)	54
圖4.30	類神經網路的收斂圖($MSE = 0.8862$)	55
圖4.31	(a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。	56
圖4.32	影像偏暗的標準差誤差值歸屬函數圖	58
圖4.33	影像偏暗的平均誤差值歸屬函數圖	58
圖4.34	修正影像的濾波器函數(參數值為124.28).....	58
圖4.35	經由解調後還原的影像	59



表目錄

表2.1	模糊法則庫	17
表3.1	色彩校正補償模糊系統的法則庫	26
表4.1	由圖4.1取得的平均值及標準差值	31
表4.2	由圖4.2取得的平均值及標準差值	32
表4.3	由圖4.3取得的平均值及標準差值	32



第一章 緒論

隨著高像素的數位相機及照相手機的發展，人們在生活中和數位影像的關係也愈來愈密切。但是便利的取像器材並不表示任何人取得的影像都是理想的，有些可能是因為光線而造成曝光過度或曝光不足；也有些可能是因為周遭環境的影響導致色彩偏差；也有些可能會因為器材設定不良導致色彩資訊不足等等，這些都是可能造成所取得影像不理想的因子。

有鑑於此，在取得影像之後，後製的處理就成了很重要的一環，經由妥當的處理，可以修正影像的色彩，將不足的色彩資訊經由運算進行補償，讓影像看起來更為理想。

1.1 相關研究

為了重建更精確的影像，許多演算法會分別從硬體或軟體的層面對影像的色彩進行處理。Admas [1]根據局部相異的色彩強度來估計影像中未知的色彩像素值，而Kuno及Sugiura等人[2]則依據邊緣偵測指示器的結果沿著邊緣做內插運算以估計色彩像素值。Cok [3]則提出一個固定色相值的方法，藉由在部份影像內相鄰的區塊使用色彩比值估計未知的紅色和藍色像素值。

Freeman [4]則藉由採用Median Filter處理色彩差值來減少影像的邊緣失真，Hamilton和Adams [5]則在色彩差值中做適應性邊緣(Edge-adaptive)內插運算來估計色彩像素值，Kimmel及Hur、Kang [6]-[7]則結合了平滑色相轉換(Smooth hue transition)和適應性邊緣(Edge-adaptive)兩種方法進行內插運算以修補未知的像素值。

Gunturk等人[8]建立AP演算法，藉由限制內插色彩平面中一致的色彩數值與色彩平面高頻區域相似的特性，建構色彩濾波器矩陣內插運算。而Hirakawa和Malvar則分別提出改良型的Adaptive Homogeneity-directed [9]及High-quality linear interpolation [10]演算法，以增加影像色彩的品質。

純就軟體層面的處理，Rahman和Jobson提出以Retinex演算法[11]-[12]為基礎的濾波處理，將低能見度的影像經由強化，使其能得到更多的影像資訊。

1.2 研究動機與目的

影像增強(Image enhancement)是數位影像處理的重要技術之一，其主要的目的是期望藉由增強技術來改善影像品質，使其內容適合人眼來進行觀察與理解。由於拍攝影片的场景、光線、儀器及人為操作等因素，常使所攝取的影像無法讓人眼順利地直接觀察或理解影像的資訊，例如影像偏亮或偏暗。

因此如直方圖等化等技術便應用於使影像的對比增強，以獲得影像中更多的資訊。而有些器材廠商為了讓取得的影像看起來更接近人們的喜好，也通常會加入專屬的色彩調整模式。然而這些技術卻往往會造成另一個遺失部份色彩資料的問題。

本論文嘗試使用類神經理論及模糊系統建立一個校正影像色彩的演算法，並透過色彩補償使影像能具有更佳的視覺感受，同時也能保留愈多的影像資訊。

1.3 論文架構

本篇論文之架構如下。第二章為介紹相關研究中常用的影像處理技術，及類神經網路理論與模糊系統的簡介。第三章為本篇論文所設計實做的系統架構。第四章為實驗結果與分析討論。第五章則為結論及未來發展。論文最後則為參考文獻。



第二章 強化影像品質的方法與原理

2.1 色彩空間模型

色彩空間(Color space)或稱色彩模型(Color model)，是採用一種標準方式來辨別顏色的方法，由一個三維座標系統與一個子空間組成，在這個子空間系統中的每一個點就代表一種顏色[13]-[14]。現在存在多種用以定義及描述顏色的色彩空間，例如RGB、YIQ、YUV、HSV、HIS、CIE及Munsell等。

2.1.1 RGB色彩模型

在人類的視覺感知系統裡，會將某一個顏色視為由不同程度的紅、綠、藍混合的結果，這是因為人類視網膜上的錐狀細胞對三種顏色特別敏感所致。也因此將紅(Red)、綠(Green)及藍(Blue)這三個顏色定義成「三原色(Primary colors)」，做為描述顏色的基礎。

RGB色彩模型也是電腦處理影像時的標準模型。但由於RGB模型的某些特性，如相同的顏色在不同的亮度中會產生不同的數值，所以RGB色彩模型並不適合應用於一般色彩的分析。因此在一般的應用中，習慣使用R、G、B的比例或將RGB數值除以(R+G+B)的值將它正規化，以減少對光的關聯性。

2.1.2 YCbCr色彩模型

YCbCr色彩模型是由YUV模型修改而來，其中的Y代表亮度(Brightness)，兩個色彩元素中的Cb(Blueness)代表藍色成份與參考值的差距，而Cr(Redness)則代表紅色成份與參考值的差距。這個模型將亮度分離出來，因此也很適合用來進行影像處理的工作。YCbCr色彩模型和RGB色彩模型之間目前有數種換算公式，例如以下是YCbCr 4:2:2規範所定義的公式[15]，

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \frac{1}{256} \cdot \begin{bmatrix} 77 & 150 & 29 \\ -44 & -87 & 131 \\ 131 & -110 & -21 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} + \begin{bmatrix} 0 \\ 128 \\ 128 \end{bmatrix} \quad (2.1)$$

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \frac{1}{256} \cdot \begin{bmatrix} 256 & 0 & 350 \\ 256 & -86 & -178 \\ 256 & 444 & 0 \end{bmatrix} \cdot \begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} + \begin{bmatrix} -175 \\ 132 \\ -222 \end{bmatrix} \quad (2.2)$$

另一個ITU-R BT.601規範則是較常被使用的標準，在ITU-R BT.601規範下將顏色由RGB轉換至YCbCr的公式如以下所描述的(2.3)式[16]：

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 0.257 & 0.504 & 0.098 \\ -0.148 & -0.291 & 0.439 \\ 0.439 & -0.368 & -0.071 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} + \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} \quad (2.3)$$

而將顏色由YCbCr轉回RGB的公式則如(2.4)式：

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} 1.164 & 0.000 & 1.596 \\ 1.164 & -0.392 & -0.813 \\ 1.164 & 2.017 & 0.000 \end{bmatrix} \cdot \begin{bmatrix} Y - 16 \\ Cb - 128 \\ Cr - 128 \end{bmatrix} \quad (2.4)$$

當對影像進行色彩分析時，為了讓系統能在不同的光照下運作，通常需要將亮度分離，利用其他與亮度關係較小的元素來進行色彩分析。在本論文將採用YCbCr色彩模型ITU-R BT.601規範的(2.3)式及(2.4)式來處理亮度的分析，並同時配合RGB色彩模型處理影像。

2.2 影像強化

2.2.1 對比延伸法 (Contrast Stretching) 與 S 曲線對應增強法

對比延伸法[13]是一種透過線性轉換，達到調整影像階調的方法。將輸入影像及輸出影像的色階分別置於座標空間的X軸及Y軸，接著便可以在此座標空間中描繪出一條對應的「階調複製曲線(Tone Reproduction Curve, TRC)」。如果輸出的影像和輸入的影像完全相同時，則這條階調複製曲線將會成為一條通過原點、且呈現45度的直線。

在多數的應用裡，對比延伸法的階調複製曲線將依據輸入影像的特性及對輸出影像的要求而呈現不同斜率的線段組合，而非一條單一斜率的直線。S曲線對應增強法可

以視為對比延伸法的一種變化，因此同樣可採用階調複製曲線來說明。和對比延伸法的最大差異在於，S曲線對應法的階調複製曲線呈現S狀分佈，是一條圓滑的曲線。

2.2.2 直方圖等化

直方圖等化(Histogram Equalization)同樣可以視為對比延伸法的一種變形。從實作的觀點，直方圖等化是將影像的色彩階調進行平均化處理[13]-[14]，使影像色彩被調整為最大動態範圍(Dynamic Range)及均勻的色階分佈。直方圖等化法由於其運算較為簡單快速，因此成為普遍較常使用的影像強化方法。

首先將影像正規化在0到1之間，0表示黑色；而1則表示白色，稍後將討論離散公式並考慮每一個像素值介於 $[0, L-1]$ 區間，其中 L 表示影像可以包含的色階數，如8位元格式的影像可達 $2^8 = 256$ 色階；而16位元格式的影像則可達 $2^{16} = 65536$ 色階。如圖2.1所示，將影像直方圖繪製成機率分佈圖，對每一點的像素值 r' 重新對應到 s' 上，以取得較平均的影像階調分佈。計算公式表示如(2.5)式，

$$s = T(r), \quad 0 \leq r \leq 1 \quad (2.5)$$




圖2.1 階調直方圖等劃法曲線示意圖

在方程式(2.5)式中， r 表示原來的輸入影像，而經由轉換函數 T 處理之後，所得到的輸出影像則為 s 。

由於直方圖等化是透過機率分佈來進行處理，分別令 $p_r(r)$ 及 $p_s(s)$ 代表 r 及 s 的機率密度函數(Probability Density Function, PDF)，可以表示為(2.6)式，

$$p_s(s) = p_r(r) \left| \frac{dr}{ds} \right| \quad (2.6)$$

在此藉由(2.6)式來完成(2.5)式的運算，可以得(2.7)式，

$$s = T(r) = \int_0^r p_r(\omega) d\omega \quad (2.7)$$

其中 ω 是一個虛擬的積分變數。對於離散量則運用總和將(2.7)式轉換為(2.8)式，

$$\begin{aligned} s_k = T(r_k) &= \sum_{j=0}^k p_r(r_j) \\ &= \sum_{j=0}^k \frac{n_j}{n} \quad k = 0, 1, 2, \dots, L-1 \end{aligned} \quad (2.8)$$

s_k 表示對應於影像中值 r_k 在處理後輸出的影像強度值，其中 n 表示影像中所有像素個數， n_k 則表示為影像中某一像素值 r_k 的個數。

圖2.2是未經任何處理的原始影像，可以看出影像的色彩明顯偏暗，導致大部份的細節無法辨識，圖2.3則是原始影像的直方圖分佈，及經由直方圖等化處理後的直方圖分佈情況，而圖2.4則是經由直方圖等化處理後所得到的輸出影像，可以看出其表現出的色彩階調也較原始影像豐富，也能辨識較多的影像細節。



圖2.2 原始影像





圖2.3 影像直方圖分佈：(a)原始影像的直方圖；(b)經直方圖等化處理後的直方圖分佈



圖2.4 直方圖等化處理後的輸出影像



2.2.3 Retinex演算法

Edwin Land發現人的眼睛對色彩的感知，包括來自光譜的反射，及周遭光源的影響。因此Edwin Land提出的Retinex演算法[17]-[18]，用以建立人眼所感知的真實色彩(Perceived color)模型。

因此使用Retinex演算法來重現影像時，必須考慮到周遭環境的資訊參數，以 $I(x_j)$ 表示輸入影像的每一個像素 x_j ， $I^o(x_j)$ 表示經過處理而輸出的相對數值，則可以(2.9)式描述，

$$I^o(x_j) = I(x_j) + \log(\rho^{x_j}) - \log(\rho^{x_j^+}) \quad (2.9)$$

其中 $\log(\rho^{x_j})$ 為像素 x_j 的照明參數，而 $\log(\rho^{x_j^+})$ 則表示像素 x_j 周遭的照明參數。將(2.9)式以更仔細的計算公式描述則寫成(2.10)式，此即為Single Scale Retinex (SSR)的計算公式。[19]

$$R_i(x, y) = \log\{I_i(x, y)\} - \log\{F(x, y) * I_i(x, y)\} \quad (2.10)$$

在(2.10)式中， $R_i(x, y)$ 為Retinex運算後的輸出， $I_i(x, y)$ 為輸入影像的階調值， $F_i(x, y) * I_i(x, y)$ 表示對影像進行迴旋積運算(Convolution operation)， $F(x, y)$ 代表周圍函數(Surround function)，是用來模擬人眼視覺感知的濾波器，實作時則以高斯函數建立的低通濾波器(Low-pass filter)模型代入， $F(x, y)$ 可以描述為(2.11)式，

$$F(x, y) = \kappa e^{-(x^2+y^2)/c^2} \quad (2.11)$$

其中 κ 值是使(2.12)式成立的數值。

$$\iint F(x, y) dx dy = 1 \quad (2.12)$$

在(2.11)式中的 c 則為常數(Gaussian surround space constant)，用來決定濾波器的寬窄程度。當 c 數值愈大時，包含的影像範圍愈大，也可以保留較多的色彩資訊；若 c 值愈小時，則包含的影像範圍也愈小，對影像邊緣部份則產生強化的效果，但卻會遺失較多的色彩資訊。

Rahman等人則將SSR進一步改良，利用不同規模的 $F(x, y)$ 重組演算法，稱之為Multiple-Scale Retinex (MSR) [11]-[12], [20]-[21]。MSR的作法是採用不同的加權比率去處理不同大小的相鄰區域，以試圖保留更多的邊緣及色彩資訊，因此計算公式變成如(2.13)式所示。

$$\begin{aligned} R_i(x, y) &= \sum_{k=1}^K \omega_k R_{k_i}(x, y), \quad i=1,2,\dots,N \\ &= \sum_{k=1}^K \omega_k \{\log I_i(x, y) - \log[F_k(x, y) * I_i(x, y)]\} \end{aligned} \quad (2.13)$$

在(2.13)式中， $R_{k_i}(x, y)$ 即是定義在(2.10)式中的SSR輸出， N 則為光譜帶(Spectral band)的數量，當 $N=1$ 時影像為灰階影像；而 $N=3$ 則為一般的彩色影像。 $F_k(x, y)$ 為第 k 個周圍函數， ω_k 為相對應的加權數，而 K 則是周圍函數的個數。 $F_k(x, y)$ 表示成(2.14)式，

$$F_k(x, y) = \kappa e^{-(x^2+y^2)/\sigma_k^2}, \quad k=1,2,\dots,K \quad (2.14)$$

在此 σ_k 同義於(2.11)式中的常數 c 。由於在進行MSR運算過程中是將三個色頻分開處理，往往在處理過後會產生色偏的現象，因此Rahman等人在MSR計算公式加入色彩修復參數(Color restoration factor) α 嘗試補償輸出的結果，

$$\alpha_i(x, y) = f\left(\frac{I_i(x, y)}{\sum_{n=1}^N I_n(x, y)}\right), \quad i = 1, 2, \dots, N \quad (2.15)$$

對(2.13)式修正後成為，

$$R_i(x, y) = \alpha_i(x, y) \cdot \sum_{k=1}^K \omega_k \{\log I_i(x, y) - \log[F_k(x, y) * I_i(x, y)]\} \quad (2.16)$$

$$i = 1, 2, \dots, N$$

在(2.15)式中，函式 $f()$ 是一個映射函式，在實作時函式 $f()$ 是根據經驗法則來決定的。(2.16)式即是Multiple-Scale Retinex with Color Restoration (MSRCR)的公式，而修正過後的MSRCR演算法雖然能保留較多的色彩資訊，但相對地其繁複的計算公式也帶來了大量的運算成本。



2.3 影像色彩補償

在2.2節中討論了強化影像及亮度修正的方法，然而將自然界的色彩經由數位顯示，礙於數位系統的近似處理，因此將色彩數位化處理後容易產生部份偏差。本節將接續探討影像色彩補償及校正的方法。

一般常見的情況下，RGB色彩模型是數位影像顯示預設採用的色彩模型，因此數位色彩在經由處理後，最後仍會轉換為RGB色彩模型作為輸出。在色彩模型轉換過程中，由於計算公式的近似值影響，會使得色彩產生些微的偏差，因此將處理後的RGB色彩再經由一個 3×3 的色彩微調矩陣運算進行色彩的微調處理，例如可以增加膚色等重要區塊的色彩權重，使這些區塊的顏色經由處理後具有更小的誤差。常見用來計算利用微調矩陣的方法可以採用最小平方法(Least squares method) [22]-[23]。

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} c_{11} & c_{12} & c_{13} \\ c_{21} & c_{22} & c_{23} \\ c_{31} & c_{32} & c_{33} \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.17)$$

其中， (R', G', B') 是 (R, G, B) 經由微調處理後的輸出結果。在(2.17)式中的色彩微調矩陣並非固定的，面對不同的應用環境或不同的取像器材所取得的影像，可能會有不同的色彩微調矩陣。因此通常需要分析影像的許多特徵向量，或是取像器材的硬體特性，以決定一個使顏色誤差為最小的色彩微調矩陣。

2.4 神經網路與模糊系統

類神經網路(Neural networks)和模糊系統(Fuzzy system)的理論基礎及應用非常廣泛[24]-[26]，其目的都在建立一個智慧型系統以供解決各方面的問題需求。在本論文中將類神經網路應用於對輸入影像進行局部切割處理並予以分類，以估測影像中需要補償的區塊，同時採用模糊系統建構補償參數系統。

2.4.1 回傳神經網路

回傳演算法(Back-propagation algorithm)又稱為廣義 δ 法則(Generalized delta rule)，是一種多層認知網路學習法則，而且是具有動態回授(Dynamic feedback)的演算法則[24]-[25]。本論文採用回傳神經網路(Back-propagation neural network)來訓練及測試需要色彩補償處理的區塊。回傳神經網路是利用指導性學習法則來進行訓練(Supervised training)，因此需要事先知道相對於訓練輸入的目標向量(Target vector)，在實作上通常將訓練的輸入向量及目標向量兩者合稱為一個訓練對。對神經網路輸入一組訓練向量後就可以計算輸出值，再將輸出值和目標值比較得到誤差值，接著類神經網路再依據所求得的誤差值來修正學習方向。將所有的訓練對輸出後，若誤差總和在容忍範圍(期望值)內則表示完成訓練，否則必須重複訓練直到收斂為止。

回傳神經網路可以由許多不同的角度層面來解釋。若由數學理論解釋回傳神經網路時，可以將學習法則視為最小均方演算法(Least mean squares method, LMS)的非線性擴展。若由函數近似(Function approximation)的角度解釋，可以將它視為S型函數的合成，也可以將它解釋為輸入與輸出的非線性映射關係，利用學習的過程尋找適當的鍵結值及臨界值以達成映射的目的。若由神經網路系統架構解釋回傳神經網路，可以將它視為認知器的層狀延伸。若應用回傳神經網路於圖樣辨識(Pattern recognition)時，則可以視為具有複雜決策邊界(Decision boundary)的分類器(Classifier)。

回傳神經網路的架構可以區分為三大部份，分別為一層輸入神經元、一層輸出神經元，及數量可由單層到數層不等的隱藏層。當來源訊號由輸入神經元進入類神經網路後，接著傳遞到隱藏層經由作用函數(Activation functions)進行運算，再將運算的結果導向輸出神經元，然後就可以得到輸出結果。回傳神經網路的學習過程，則可以區分為順向傳送(Forward transfer)及反向傳送(Backward transfer)兩大部份。順向傳送的輸入訊號，是由輸入神經元進入後逐層經隱藏層運算，然後再將結果傳向輸出神經元，傳送過程中每一層的神經元只能影響其下一層的神經元，並無法影響其上一層的神經元。若運算後的誤差值不符預期的誤差容忍參數(Error tolerance parameter)，則運算結果不會進入輸出神經元，而是啟動反向傳送程序，由原來的連接通路反向將誤差值傳回，同時並修改各層神經元的權重值(Weights)，使誤差值縮小收斂至預期的誤差容忍參數。

在實作上，回傳神經網路的鍵結值計算常用的方法為梯度下降演算法(Gradient descent algorithm)，這是一種簡單且較容易實作的最佳化方法。除此之外，也可以採用牛頓法(Newton's algorithm)、共軛方向法(Conjugate direction algorithm)或準牛頓法(Quasi-Newton algorithm)等，然而對平行且分散式處理的類神經網路應用裡，這些最佳化方法並不一定完全適合，如牛頓法需要計算Hessian矩陣的反置矩陣即會增加回傳神經網路在運算量的成本消耗。

如圖2.5中所示為回傳神經網路的系統架構。根據圖中回傳神經網路系統的架構將各參數的定義描述如下：

1. H_l 為第 l 層的神經元個數，若 $l=0$ 表示為輸入層， $l=1$ 到 $l=L-1$ 表示為隱藏層，而 $l=L$ 則為輸出層。
2. $x_p^{(l)}(k)$ 定義為第 l 層第 p 個神經元的輸出，其中 $l=0, \dots, L$ ， $p=1, \dots, H_l$ ，而參數 k 表示第 k 個輸入向量。
3. $z_q^{(l+1)}(k)$ 定義為第 $l+1$ 層第 q 個神經元的淨輸入，其中 $l=0, \dots, L-1$ ，而參數 k 表示第 k 個輸入向量。
4. $w_{pq}^{(l+1)}$ 定義為由第 l 層第 p 個神經元到第 $l+1$ 層第 q 個神經元的鍵結值， $w_{0q}^{(l+1)}$ 定義為第 $l+1$ 層第 q 個神經元的臨界值，其中 $l=0, \dots, L-1$ ， $p=1, \dots, H_l$ 和 $q=1, \dots, H_{l+1}$ 。

5. $d_n(k)$ 定義為對應於第 k 個輸入向量，輸出層第 n 個神經元的目標值，其中 $n = 1, \dots, H_L$ 。




圖2.5 回傳神經網路架構圖

定義神經網路的各參數之後，接著將回傳神經網路的疊代步驟描述於下，其中各神經元之間的作用函數採用(2.18)式的邏輯訊號函數(Sigmoid activation function)，而它的偏導數如(2.19)式。

$$y(t) = \text{sgm}(z(t)) = \frac{1}{1 + e^{-z(t)}} \quad (2.18)$$

$$\frac{\partial \text{sgm}(z(t))}{\partial z(t)} = y(t)[1 - y(t)] \quad (2.19)$$

步驟一：首先需要設定初始值。在實作上則隨機地將初始鍵結值與臨界值設為一個很小的數值。

步驟二：由輸入神經元輸入第 k 個輸入向量：

$$X(k) = [x_1(k), \dots, x_{H_0}(k)]^T \quad (2.20)$$

步驟三：經由作用函數計算順向訊號的傳遞：

$$x_q^{(l+1)} = \text{sgm} \left(w_{0q}^{(l+1)}(t) + \sum_{p=1}^{H_l} w_{pq}^{(l+1)}(t) x_p^{(l)}(k) \right) \quad (2.21)$$

其中 $q = 1, \dots, H_{l+1}$ ， $l = 0, \dots, L-1$ 。

步驟四：根據運算後的順向訊號計算輸出層的誤差訊號 δ 值：

$$\delta_q^{(L)}(k) = (d_q(k) - x_q^{(L)}(k)) (1 - x_q^{(L)}(k)) x_q^{(L)}(k) \quad (2.22)$$

其中目標向量為 $D(k) = [d_1(k), \dots, d_q(k)]^T$ ， $q = 1, \dots, H_L$ 。

步驟五：接著計算隱藏層的誤差訊號 δ 值：

$$\delta_p^{(l)}(k) = \left(\sum_{q=1}^{H_{l+1}} w_{pq}^{(l+1)}(t) \delta_q^{(l+1)}(t) \right) (1 - x_p^{(l)}(k)) x_p^{(l)}(k) \quad (2.23)$$

其中 $p = 1, \dots, H_l$ ， $l = L-1, \dots, 1$ 。而(2.23)式則提供了計算隱藏層誤差的遞迴(Recursive)公式。

步驟六：鍵結值與臨界值的學習與運算，在這個步驟中必須採用鏈狀法則(Chain rules)來計算它的鍵結值變化量。

當 $t+1$ 次疊代運算之後，得到鍵結值為：

$$w_{pq}^{(l+1)}(t+1) = w_{pq}^{(l+1)}(t) + \alpha \Delta w_{pq}^{(l+1)}(t) \quad (2.24)$$

而臨界值則成為：

$$w_{0q}^{(l+1)}(t+1) = w_{0q}^{(l+1)}(t) + \alpha \Delta w_{0q}^{(l+1)}(t) \quad (2.25)$$

其中，學習係數 α 滿足 $0 < \alpha < 1$ ，而鍵結值的變化量則可由以下公式計算得：

$$\Delta w_{pq}^{(l+1)}(t) = \delta_q^{(l+1)}(k) x_p^{(l)}(k) \quad (2.26)$$

而臨界值的變化量則為：

$$\Delta w_{0q}^{(l+1)}(t) = \delta_q^{(l+1)}(k) \quad (2.27)$$

其中 $p = 1, \dots, H_l$ ， $q = 1, \dots, H_{l+1}$ ， $l = L-1, \dots, 0$ 。

步驟七：接著回到步驟二，反覆學習直到對於每一個輸入向量，所產生的誤差均小於事先給定的期望值 ε ，其中 ε 為正實數。

$$\sum_{n=1}^{H_L} [d_n(k) - x_n^{(L)}(k)]^2 < \varepsilon, \quad \forall k \quad (2.28)$$

回傳神經網路可以處理非線性問題，和只有單一且順向的神經網路相比較，回傳神經網路的學習效率較高、正確率也較高。但是回傳神經網路仍存在可能發生的問題，回傳神經網路鍵結值的計算，常用的最佳化方法是梯度下降演算法(Gradient descent algorithm)，但是梯度下降演算法並不保證能找到整體的誤差極小值(Global error minimum)，它可以停滯在局部的誤差極小值(Local error minimum)之中。學習係數 α 也會影響學習效果，若 α 值設定過小，會使學習速度緩慢；若 α 值過大反而會引起鍵結值振盪。一般的作法是在原先的學習法則中加入動量項(Momentum term)：

$$w_{pq}^{(l+1)}(t+1) = w_{pq}^{(l+1)}(t) + \alpha \Delta w_{pq}^{(l+1)}(t) + \beta \Delta w_{pq}^{(l+1)}(t-1) \quad (2.29)$$

其中動量係數 β 滿足 $0 < \beta < 1$ ，而動量項主要的作用是用來決定前一次的鍵結值變化量對當前鍵值結移動方向所造成的影響。

此外，即使非線性的隱藏層能增加回傳神經網路的辨識能力，在一般狀況採用愈多層及愈多神經元數量的隱藏層更可以使回傳神經網路系統的學習與辨識結果更佳優良，但是，過多的隱藏層反而容易造成神經網路產生過度適合(Over-fitting)的現象，使得它的推廣能力(Generalization)反而降低。而且隱藏層中神經元的個數及各參數配置卻是影響學習結果及速度快慢的最大變數，因此必須妥善配置隱藏神經元的個數與參數值。

由於回傳神經網路為指導性學習的網路，需要儘可能增加學習的訓練對數量及涵蓋範圍，回傳神經網路才會產生較佳的輸出結果。因此，謹慎設置初始鍵結值、學習係數、隱藏層神經元的個數等參數，及妥善安排訓練神經網路的訓練對是非常重要的。

2.4.2 模糊系統

模糊系統是結合了專家經驗與語意式(Semantic)的控制法則，不使用明確的數值變數控制系統，而是採用語意式的模糊變數來描述系統及行為，組成系統的法則庫(Fuzzy rule base)，操作人員則使用自然語言(Natural language)與機器進行對話。

設計一個模糊系統，大致有以下幾個步驟[25]-[28]。

步驟一：分析系統中有那些是需要觀察量測的狀態，及那些是需要控制的輸出，然後定義輸入輸出變數及系統狀態參數。

步驟二：分析受控訊號，然後定義受控訊號的歸屬函數(Membership function)的形狀和個數。歸屬函數常用的形狀有三角型、梯型及高斯(Gaussian)型，其中三角型與梯型較容易計算、運算量通常也較小；而高斯型則為連續的平滑曲線，且具有較佳的非線性特性，但往往因方程式的階次較高而使計算較複雜。而歸屬函數的語言變數型態又常區分為負量偏大(NL, Negative large)、負量適中(NM, Negative medium)、負量偏小(NS, Negative small)、零偏量(ZO, Zero)、正量偏小(PS, Positive small)、正量適中(PM, Positive medium)及正量偏大(PL, Positive large)等七類。

一般語言變數(Language variable)的數量為奇數個，雖然增加語言變數的個數可以使系統趨向線性化以增加效益，但遠不足以應付因法則庫膨脹造成需要大量複雜推論所帶來成本負擔的增加。例如在表2.1中的輸入訊號 x, y 各有七個歸屬函數時，法則庫共有 $7^2 = 49$ 條模糊法則。倘若將輸入訊號 x, y 各增加兩個歸屬函數，使其為各有九個歸屬函數時，則法則庫將增加至 $9^2 = 81$ 條模糊法則，法則庫的數量增加將近一倍，如此也將造成運算成本的增加。因此語言變數個數的選擇以適度為原則即可。

步驟三：由所設定的變數及歸屬函數建立法則庫，法則庫是由一系列「IF~THEN~」來描述輸入輸出關係的模糊定義所組成。法則可以由專家經驗獲得，也可以藉由樣本數據的學習與分類的方法訓練而來。以雙輸入單輸出的系統來分析，模糊法則庫可由表2.1的形式來說明，第 i 條法則表示如(2.30)式：

$$R_i: \text{ If } x \text{ is } A_{ij} \text{ and } y \text{ is } B_{ij}, \text{ Then } z \text{ is } C_{ij}, \quad (2.30)$$

with $i = 1, \dots, n$. and $j = 1, \dots, m$.

其中 x, y 為輸入訊號， z 為輸出訊號， A_{ij} 、 B_{ij} 及 C_{ij} 代表表2.1中的語言變數， m 代表語言變數的個數，而 n 則為法則數的總數。在表2.1中的輸入訊號 x, y 各有七個歸屬函數，因此可得知最多會有 $7^2 = 49$ 條模糊法則。

表2.1 模糊法則庫

		y							
		z	NL	NM	NS	ZO	PS	PM	PL
x	NL	PL	PL	PL	PL	PL	PL	PL	PL
	NM	PL	PL	PM	PM	PM	PM	PM	PM
	NS	PM	PM	PM	PS	PS	PS	PS	PS
	ZO	PS	ZO	ZO	ZO	ZO	NS	NS	NS
	PS	NS	NS	NS	NM	NM	NM	NM	NM
	PM	NM	NM	NM	NM	NM	NL	NL	NL
	PL	NL	NL	NL	NL	NL	NL	NL	NL

步驟四：將輸入訊號經由歸屬函數得到相對應的模糊量值，這個過程稱之為模糊化(Fuzzification)。模糊化的原因是為了將輸入訊號轉為模糊系統可以接受的輸入形式，在一般的情況下，模糊量值是介於0到1之間的數值。

步驟五：當輸入訊號進到系統後，會觸發一條到多條的法則，由觸發強度反映到輸出部份的模糊集合以求出各法則的推論結果，這個過程稱之為模糊推論(Fuzzy inference)。表2.1中，第一條法則的觸發強度(Firing strength)為 $\alpha_1 = A_1(x) \wedge B_1(y)$ ，其中 $A_1(x)$ 為輸入變數 x 在歸屬函數 A_1 的歸屬度， $B_1(y)$ 為輸入變數 y 在歸屬函數 B_1 的歸屬度，符號 \wedge 表示交集運算子，也代表模糊系統的推論法。一般常用的推論法為最小值推論法，如圖2.6所示， α_1 取 $A_1(x)$ 與 $B_1(y)$ 的最小值，即 $\alpha_1 = \min\{A_1(x), B_1(y)\}$ 。




圖2.6 模糊推論的最小值推論法

同理可以得到表2.1中所有49條模糊法則的觸發強度，如圖2.7，所有的法則是同時且平行接受到輸入訊號的，然後符合模糊敘述的法則會被觸發，再反映到輸出單元計算推論結果。第一條法則的推論結果為 $C_1'(z) = \alpha_1 \wedge C_1(z)$ ，而第二條法則的推論結果為 $C_2'(z) = \alpha_2 \wedge C_2(z)$ ，同理可以求得第3到49條法則的推論結果，然後再由所有法則的推論結果進行統合運算(Aggregation)，就可以得最後的推論結果 $C(z)$ ，其中 $C(z)$ 表示如(2.31)式。

$$C(z) = C_1'(z) \vee C_2'(z) \vee \cdots \vee C_i'(z) \vee \cdots \vee C_{49}'(z) \quad (2.31)$$

而在(2.31)式中的 \vee 則表示聯集運算子。

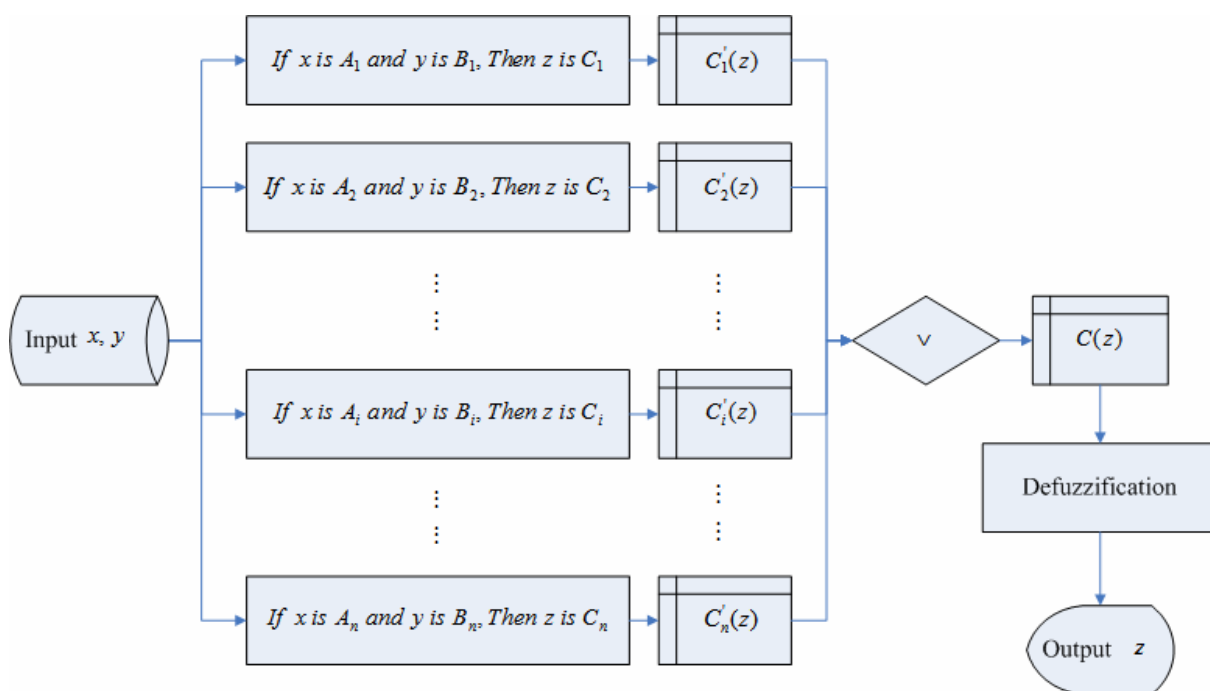


圖2.7 模糊法則同時且平行接受輸入訊號示意圖

步驟六：在步驟五中得到模糊推論的結論 $C(z)$ 仍然是歸屬函數的形式，因此必須經由解模糊化(Defuzzification)的運算過程來求得實際的系統輸出。常用的方法有重心法(Center of Gravity Defuzzification, CGD)及最大均值法(Mean of Maxima Defuzzification, MMD)兩種方法。重心法是一種加權平均的計算法，它是最為常用、也似乎最合理的解模糊化運算，重心法又可以分為以下兩種：

(1) 連續積分式重心法：假設輸出歸屬函數 $C(z)$ 的論域落於區間 $[a, b]$ ，則輸出為：

$$z_{CGD} = \frac{\int_a^b C(z)zdz}{\int_a^b C(z)dz} \quad (2.32)$$

(2) 離散式重心法：若 $C(z)$ 是一個離散的模糊集合，且 $C(z)$ 的論域落於區間 $[z_L, z_R]$ ，每一步驟為 Δ ，並分為 q 段，則輸出為：

$$q = \frac{z_R - z_L}{\Delta} + 1$$

$$z_{CGD} = \frac{\sum_{j=1}^q z_j C(z_j)}{\sum_{j=1}^q C(z_j)} \quad (2.33)$$

最大均值法是一種離散式的計算法，它根據所定的激發強度 α 或歸屬函數的歸屬度最大值以上的部份，對歸屬函數進行切割，若 s 表示大於或等於 α 的歸屬函數個數，則最大均值法的公式表示為：

$$z_{MMD} = \sum_{j=1}^s \frac{y_j}{s} \quad (2.34)$$

2.5 影像品質評估

通常在評估一張影像的品質時，可以區分成人眼觀測的統計及數值化的比較。由於針對影像品質的處理最終目的在使瀏覽者能有更佳的視覺感受，因此人眼觀測是最為直接的判斷方式，然而囿於個人主觀感受的差異，所以必須採用多人的觀測結果作為統計分析。

數值化的評估，常被使用的則均方差(Mean Square Error, MSE)、訊雜比(Signal to Noise Ratio, SNR)及指標峰值訊雜比(Peak Signal to Noise Ratio, PSNR)等。

2.5.1 均方差(Mean Square Error, MSE)

均方差 MSE 的計算是將輸出影像減去輸入影像的每一個像素值，然後再將差值平方的總和取平均值，如(2.35)式：

$$MSE = \frac{1}{N} \sum (I^o - I^i)^2 \quad (2.35)$$

其中 I^i 為輸入影像， I^o 為輸出影像，而 N 則為影像的像素個數。 $(I^o - I^i)$ 的數值相當於代表雜訊的意思，因此一般當 MSE 愈小時，表示輸出影像與輸入影像的差距愈小，也就是結果愈佳。

2.5.2 指標峰值訊雜比(Peak Signal to Noise Ratio, PSNR)

指標峰值訊雜比(Peak Signal to Noise Ratio, PSNR)中的Peak指的是影像中的像素最大值，計算 $PSNR$ 是利用影像中像素的最大值與影像中雜訊的比值來作為評估的依據，如(2.36)式，當 $PSNR$ 值愈大時表示輸出影像與輸入影像愈接近，也就表示失真愈少。

$$PSNR = 10 \times \log \left(\frac{I_{Max}^2}{MSE} \right) = 10 \times \log \left(\frac{I_{Max}^2}{\frac{1}{N} \sum (I^o - I^i)^2} \right) \quad (2.36)$$

其中 MSE 為(2.35)式所計算得的均方差，而 I_{Max} 為影像的像素最大值，對於一個以 n bits 表示像素值的PCM (Pulse-code modulation)影像，則 $I_{Max} = 2^n - 1$ 。

在一般的應用通常以8 bits表示影像的像素值，因此最大值 I_{Max} 為 $2^8 - 1 = 255$ 。則(2.36)式的 $PSNR$ 可以表示如(2.37)式。

$$PSNR = 10 \times \log \left(\frac{255^2}{MSE} \right) = 10 \times \log \left(\frac{255^2}{\frac{1}{n} \sum (I^o - I^i)^2} \right) \quad (2.37)$$



第三章 系統架構

本章將探討在本論文中所實作的系統架構，並說明系統的運作流程。在3.1節中將說明本論文所提出的系統流程圖。在3.2節中將說明本系統的回傳類神經網路系統及模擬訓練的結果。在3.3節中將說明本系統中模糊系統及所設計的模糊法則庫。在3.4節中則說明採用類神經系統及模糊系統微調影像色彩的系統模型。

3.1 系統流程

如圖3.1所示為本論文所提出的影像色彩校正與補償系統流程圖。當讀取輸入的來源影像後，首先將影像切割成 n 個區塊。在實作中分別嘗試數種不同大小的區塊分割後，發現若取用過小的區塊時，則所包含的影像資訊可能不足，使得無法進行下一步的特性分析，因此需要藉由統計及分析大部份的影像資訊，以選擇較為合適的區塊大小。

接著分析影像的特性，取得各區塊影像色彩資訊及亮度資訊的特徵向量值 (Eigenvector)。然後將取得的特徵向量輸入類神經網路系統，經由運算後判斷是否有色彩失真 (Color distortion) 的現象。若結果為偽 (False)，表示影像色彩品質為佳，則將來源影像直接輸出，並結束本程序。若結果為真 (True)，表示影像的色彩有失真的現象，需要進行校正補償，此時將類神經網路的輸出及影像特徵資訊導向模糊系統，經由模糊系統計算修正權重，然後進行影像色彩的校正與補償，以得到最後輸出的影像。

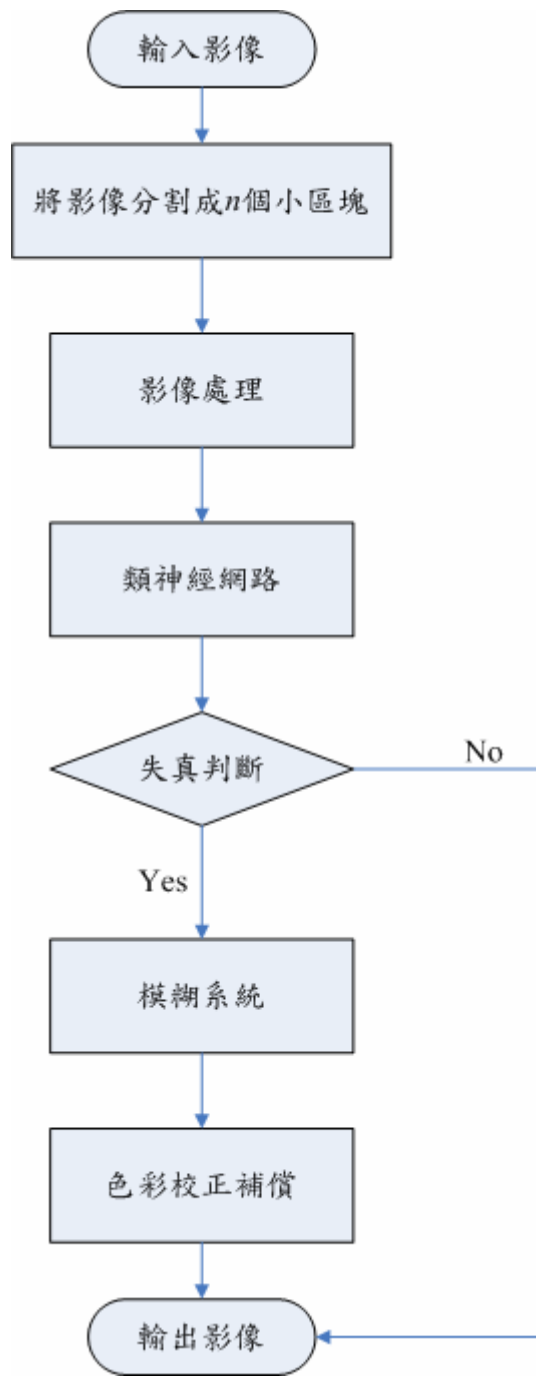


圖3.1 影像色彩補償與校正系統流程圖

當對影像進行修正處理時，本系統的實作採用結合Retinex演算法及直方圖等化的方式，計算公式如(3.1)式所示，

$$\begin{aligned}
 I^o &= \gamma \times \text{Retinex}(I^i) + (1 - \gamma) \times \text{Hist Eq.}(I^i) \\
 0 &\leq \gamma \leq 1
 \end{aligned}
 \tag{3.1}$$

在(3.1)式中， I^i 為輸入影像， $I^{o'}$ 為修正後的輸出，其中 $Retinex(I^i)$ 表示對輸入影像進行Retinex演算法的結果， $Hist Eq.(I^i)$ 表示對輸入影像進行直方圖等化的結果，而 γ 則表示兩者線性總和的權重。最後再 $I^{o'}$ 經由補償處理，使影像色彩具有較小的誤差量及較佳的視覺效果以作為最後的輸出影像。

3.2 回傳神經網路架構

本論文實作使用的回傳神經網路含有四層隱藏層，第一層隱藏層有30個神經元、第二層隱藏層有20個神經元、第三層隱藏層有15個神經元，而第四層隱藏層則有10個神經元。神經網路的初始鍵結值及臨界值以亂數的方式設定為由-1到1之間的數值(包含-1與1)。每個神經元之間的作用函數則都採用邏輯作用函數(Sigmoid activation function)，如(3.2)式：

$$sgm(Z) = \frac{1}{1 + e^{-Z}} \quad (3.2)$$

其中 Z 代表輸入層的權重總和減去臨界值後的數值。圖3.2為邏輯作用函數的圖形。




圖3.2 邏輯作用函數 $sgm(Z)$ 的圖形

神經網路的輸入層設計成8個神經元，分別為來源影像色彩資訊及亮度因子的平均值(\bar{R} 、 \bar{G} 、 \bar{B} 、 \bar{Y})與標準差(R_{SD} 、 G_{SD} 、 B_{SD} 、 Y_{SD})，其中 \bar{R} 、 \bar{G} 、 \bar{B} 、 R_{SD} 、 G_{SD} 及 B_{SD} 分別代表影像中RGB色彩資訊的平均值(Average)與標準差(Standard deviation)，而 \bar{Y} 及 Y_{SD} 則代表亮度因子的平均值與標準差。輸出層則輸出影像色彩資訊的權重值及代表色彩是否失真的旗標(Flag)，若旗標為1表示色彩失真；若旗標為0則表示色彩並無失真。

實驗中所使用的影像是使用相機拍攝及網路下載的方式取得的，在取得影像之後，由其中取800張隨機的影像資料作為訓練的輸入，及取200張隨機影像作為測試影像，對類神經網路系統先進行訓練模擬。圖3.3即為類神經網路進行訓練模擬的收斂過程，當系統的 $MSE = 0.589367$ 時呈現收斂狀態。




圖3.3 神經網路訓練收斂過程

3.3 模糊系統架構

本論文的模糊系統採用「雙輸入、單輸出」的架構，由類神經網路輸出的色彩資訊權重值，再經運算處理以作為模糊系統的兩個輸入值，分別為平均值誤差量 $avg_f(k)$ 及標準差誤差量 $sd_f(k)$ ，而輸出值 $scale(k)$ 則作為校正參數。圖3.4為模糊系統的架構圖。

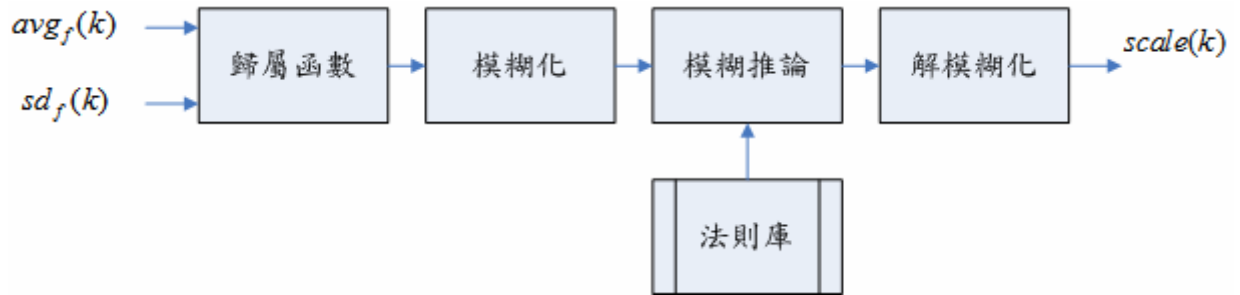


圖3.4 色彩校正補償模糊系統架構圖

此模糊系統的輸入與輸出均設定為各有5個歸屬函數，分別是NL(負量偏大)、NS(負量偏小)、ZO(零偏量)、PS(正量偏小)及PL(正量偏大)。其模糊法則庫則表示如表3.1。

表3.1 色彩校正補償模糊系統的法則庫

		$sd_f(k)$				
		NL	NS	ZO	PS	PL
$avg_f(k)$	NL	PL	PL	PS	ZO	ZO
	NS	PL	PS	PS	ZO	ZO
	ZO	PS	PS	ZO	NS	NS
	PS	ZO	ZO	NS	NS	NL
	PL	ZO	NS	NS	NL	NL

此模糊系統共有 $5^2 = 25$ 條模糊法則，由表3.1可以將第一條法則描述為：

$$\begin{aligned} \text{Rule 1: if } avg_f(k) = NL \text{ and if } sd_f(k) = NL, \\ \text{than } scale(k) = PL \end{aligned} \quad (3.3)$$

同理，依序可以將其餘的法則描述如下：

$$\begin{aligned} \text{Rule 2: if } avf_f(k) = NL \text{ and if } sd_f(k) = NS, \\ \text{than } scale(k) = PL \end{aligned} \quad (3.4)$$

$$\begin{aligned} \text{Rule 3: if } avf_f(k) = NL \text{ and if } sd_f(k) = ZO, \\ \text{than } scale(k) = PS \end{aligned} \quad (3.5)$$

$$\begin{aligned} \text{Rule 4: if } avf_f(k) = NL \text{ and if } sd_f(k) = PS, \\ \text{than } scale(k) = ZO \end{aligned} \quad (3.6)$$

$$\begin{aligned} \text{Rule 5: if } avf_f(k) = NL \text{ and if } sd_f(k) = PL, \\ \text{than } scale(k) = ZO \end{aligned} \quad (3.7)$$

$$\begin{aligned} \text{Rule 6: if } avf_f(k) = NS \text{ and if } sd_f(k) = NL, \\ \text{than } scale(k) = PL \end{aligned} \quad (3.8)$$

$$\begin{aligned} \text{Rule 7: if } avf_f(k) = NS \text{ and if } sd_f(k) = NS, \\ \text{than } scale(k) = PS \end{aligned} \quad (3.9)$$

$$\begin{aligned} \text{Rule 8: if } avf_f(k) = NS \text{ and if } sd_f(k) = ZO, \\ \text{than } scale(k) = PS \end{aligned} \quad (3.10)$$


$$\begin{aligned} \text{Rule 9: if } avf_f(k) = NS \text{ and if } sd_f(k) = PS, \\ \text{than } scale(k) = ZO \end{aligned} \quad (3.11)$$

$$\begin{aligned} \text{Rule 10: if } avf_f(k) = NS \text{ and if } sd_f(k) = PL, \\ \text{than } scale(k) = ZO \end{aligned} \quad (3.12)$$


上述(3.3)式到(3.12)式共描述了第一條到第十條模糊法則，同理即可由表3.1描述模糊系統中所有的模糊法則。

模糊系統採用三角形狀的歸屬函數，輸入的歸屬函數如圖3.5所示，圖3.5(a)為平均值誤差量 $avg_f(k)$ 的歸屬函數，而圖3.5(b)為標準差誤差量 $sd_f(k)$ 的歸屬函數。圖3.6則為 $scale(k)$ 的歸屬函數，在實作中則作為Retinex演算法中濾波器參數值的歸屬函數。此外，在實作中以圖3.5的歸屬函數作為初始設定，然後由類神經網路輸出的資訊權重對歸屬函數進行微調使更符合應用的狀態。

實作中的模糊推論採用在2.4.2節中圖2.6所描述的最小值推論法，而解模糊化則採用(2.32)式所描述的重心法。圖3.7則為模糊系統後的模糊法則以函數圖形表示的示意圖。



(a) $avg_f(k)$ 的歸屬函數



(b) $sd_f(k)$ 的歸屬函數

圖3.5 模糊系統輸入的歸屬函數：(a) $avg_f(k)$ 的歸屬函數；(b) $sd_f(k)$ 的歸屬函數




圖3.6 模糊系統輸出 $scale(k)$ 的歸屬函數




圖3.7 模糊法則的函式圖

由於本系統的實作採用了(3.1)式所描述的線性總和公式，同時在(3.1)式中的 γ 值也採用模糊系統來進行估算，由於 γ 值介於0和1之間，不宜直接採用圖3.6所示的歸屬函數，因此調整後的圖3.8則為 γ 參數的歸屬函數圖，模糊法則庫則同樣採用表3.1的定義，而圖3.9則為將模糊系統後的模糊法則以函數圖形表示的示意圖。

此外，模糊推論的方法同樣採用在2.4.2節中圖2.6所描述的最小值推論法，而解模糊化的方法也同樣採用(2.32)式所描述的重心法。

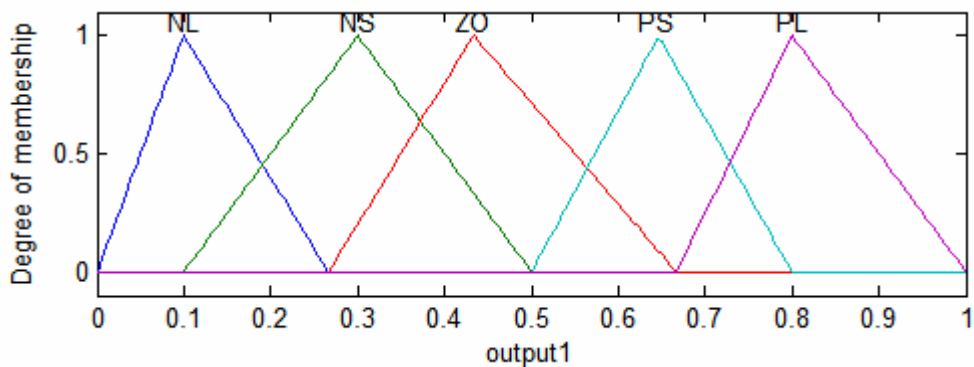


圖3.8 在(3.1)式中 γ 的歸屬函數




圖3.9 以(3.1)式中 γ 為輸出的模糊函數圖

3.4 影像色彩補償

圖3.10為影像色彩補償的系統方塊示意圖，在圖3.10中的 I^i 為輸入影像， I^o 為輸出影像，而 $(e, \Delta e)$ 則表示輸出影像與輸入影像之間的平均誤差值與標準差誤差值。在系統結構中，以將類神經網路及模糊系統建立一個具有回授的系統，藉由回授將修改後的影像和原始的輸入影像進行比較，達到對影像色彩進行微調修正的方式，使修正後的色彩可以達到最佳化的結果。

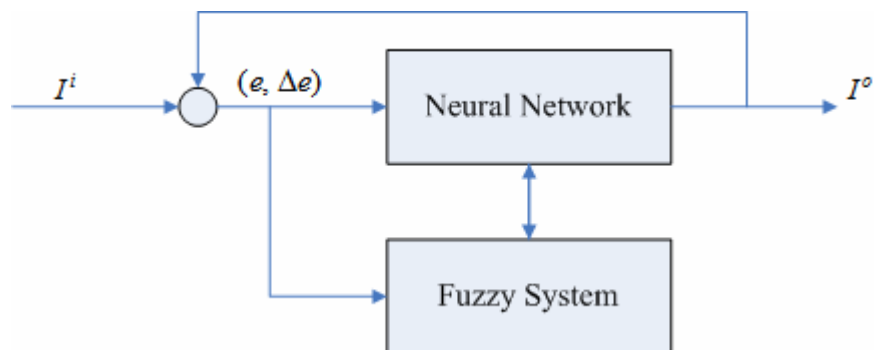


圖3.10 色彩補償系統方塊圖

第四章 實驗結果

本系統的實作以Microsoft® Windows XP為作業平台，並且採用MATLAB® 7 (R14)當開發工具，以類神經理論對影像進行分析辨識，再用模糊理論運算所得的校正參數將影像色彩進行優化處理。將所取得的影像資料經由分類後，依不同的色彩偏差及明亮度區分為四類作探討。4.1節為原始影像色彩偏紅色的實例驗證。4.2節為原始影像色彩偏藍的實例驗證。節4.3為原始影像色彩偏綠的實例驗證。4.4節為原始影像明亮度不足的實例驗證。

4.1 實例一：顏色色偏的校正(偏紅)

用來訓練類神經網路的影像是由所取得的影像中隨機抽選的，且包含不同色偏的影像如圖4.1至圖4.3。經由分析計算可以得知影像所有像素值亮度因子及色彩資訊的平均值與標準差值，如表4.1到表4.3。

表4.1 由圖4.1取得的平均值及標準差值

	Luminance factor	R color tone	G color tone	B color tone
Average	138.48	195.77	120.73	115.92
Standard deviation	56.89	55.47	73.53	78.77

表4.2 由圖4.2取得的平均值及標準差值

	Luminance factor	R color tone	G color tone	B color tone
Average	131.45	103.58	162.13	72.72
Standard deviation	56.61	69.56	66.87	55.03

表4.3 由圖4.3取得的平均值及標準差值

	Luminance factor	R color tone	G color tone	B color tone
Average	119.32	113.30	108.51	199.33
Standard deviation	58.46	70.40	73.30	50.99



(a)

圖4.1 訓練神經網路的影像。(a)色彩偏重 Red 色調影像；(b)影像的 RGB 色階分佈。

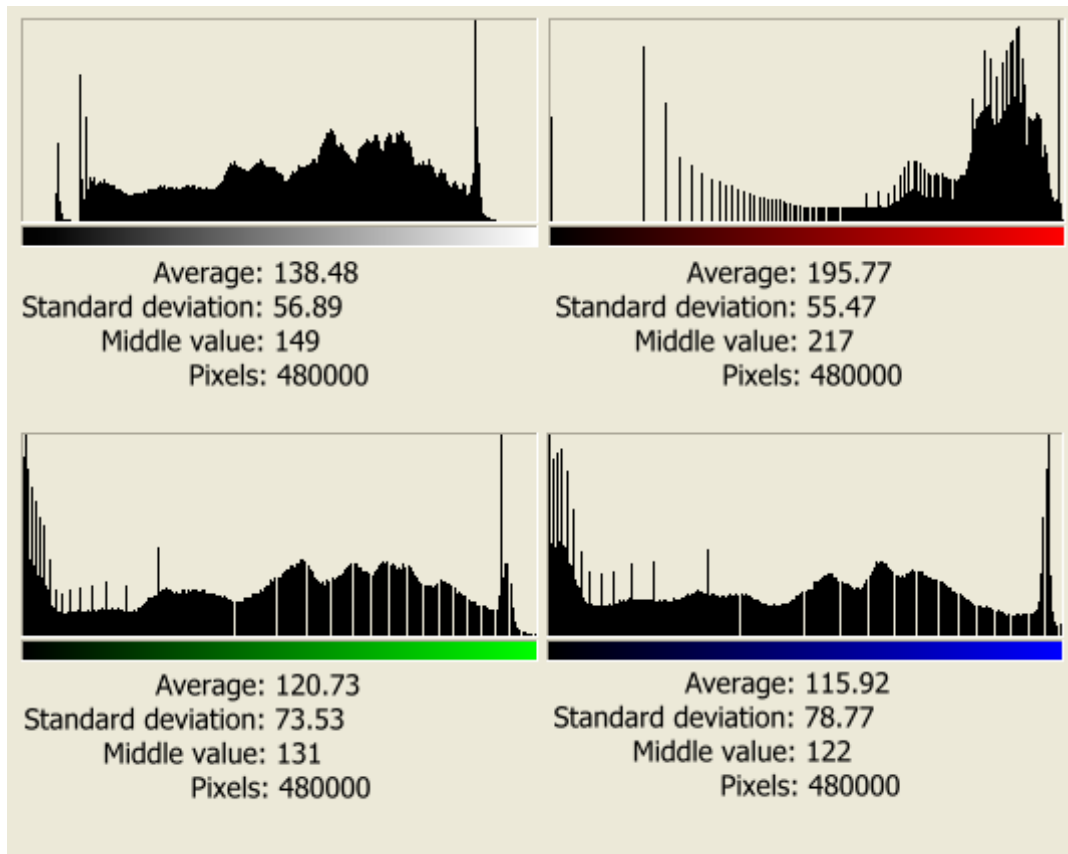
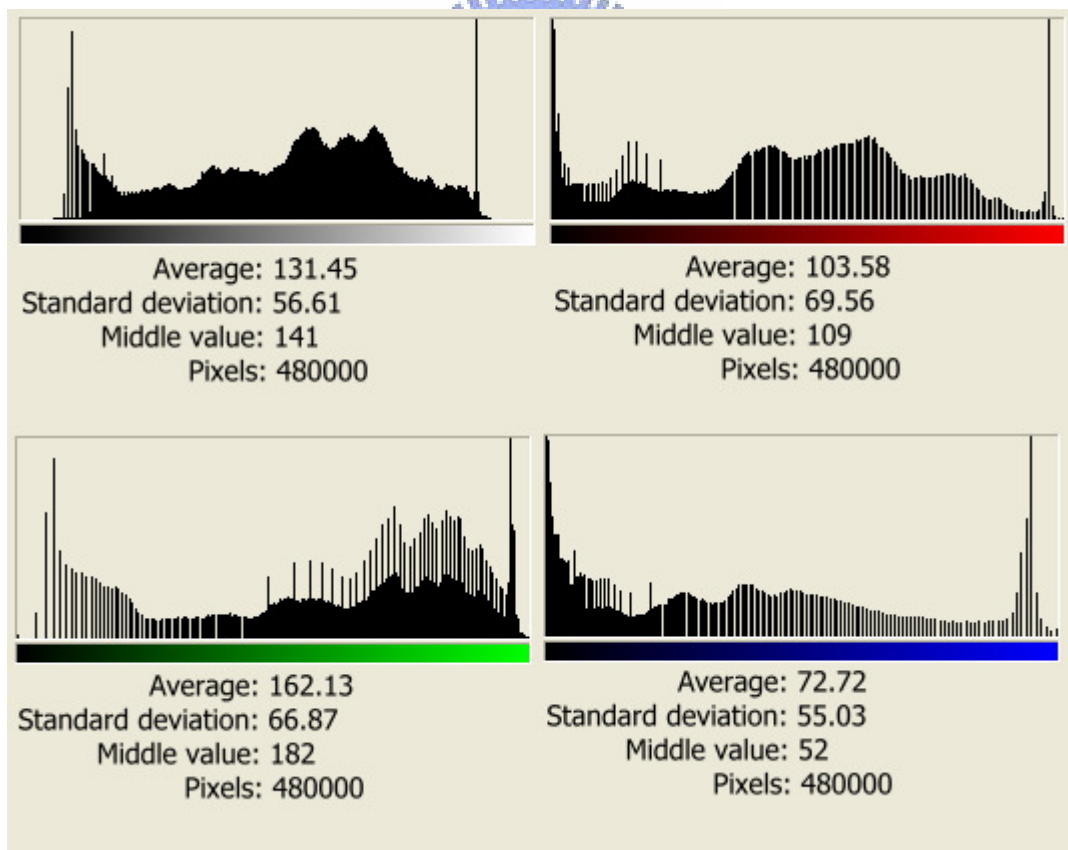


圖4.1 (續) 訓練神經網路的影像。(a)色彩偏重 Red 色調影像；(b)影像的 RGB 色階分佈。



(a)

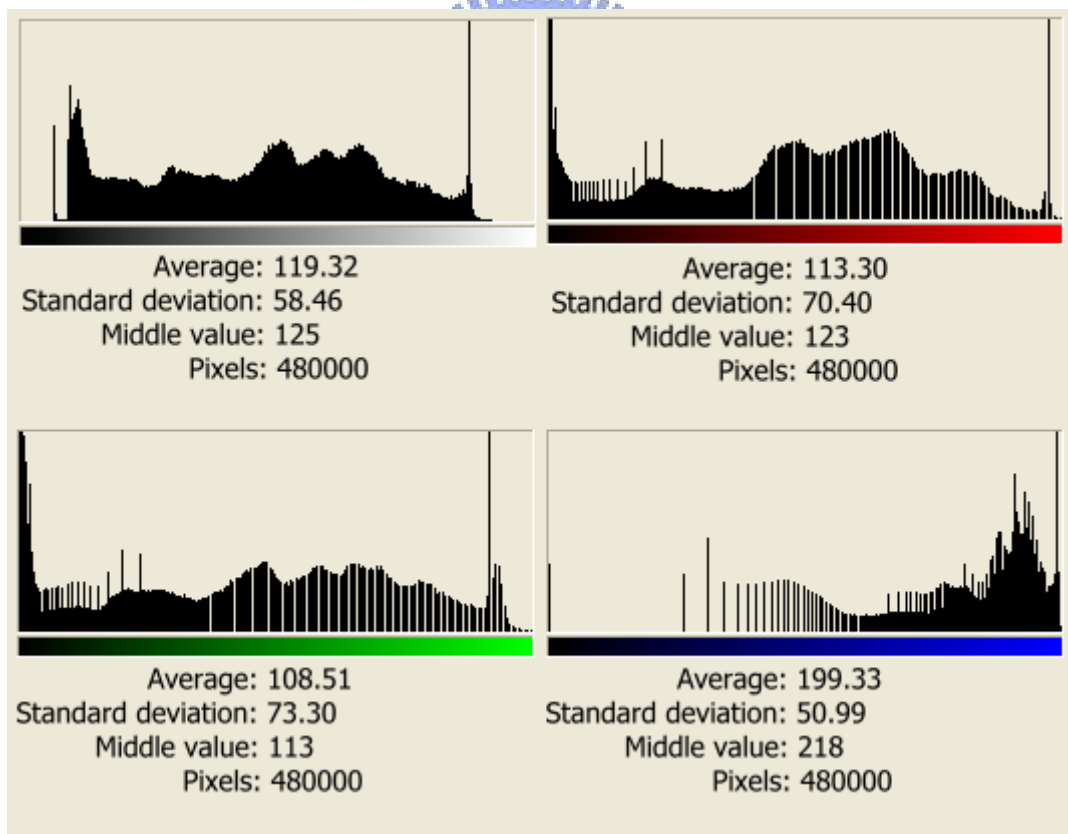


(b)

圖4.2 訓練神經網路的影像。(a)色彩偏重 Green 色調的影像；(b)影像的 RGB 色階分佈。




(a)



(b)

圖4.3 訓練神經網路的影像。(a)色彩偏重 Blue 色調的影像；(b)影像的 RGB 色階分佈。

將上述所取得的平均值及標準差輸入至類神經網路系統，其中類神經網路系統架構如3.2節所描述。共使用800組隨機的影像資料進行類神經網路系統的訓練處理，且以圖4.4作為驗證的影像，並以200組隨機的影像資料進行類神經網路系統的測試，系統的收斂圖如圖4.5至圖4.7。其中圖4.5的收斂值 $MSE = 0.9171$ 。圖4.6的收斂值 $MSE = 0.8123$ 。圖4.7的收斂值 $MSE = 0.8362$ 。



(b)

圖4.4 (a)原始輸入影像；(b)未解調濾波器函數圖，參數值為5；(c)原始輸入影像的色階分佈圖。




圖4.4 (續) (a)原始輸入影像；(b)未解調濾波器函數圖，參數值為5；(c)原始輸入影像的色階分佈圖。




圖4.5 類神經網路的收斂圖($MSE = 0.9171$)




圖4.6 類神經網路的收斂圖($MSE = 0.8123$)




圖4.7 類神經網路的收斂圖($MSE = 0.8362$)

由類神經網路系統的輸出可以得知，原始影像圖4.4(a)經影像色彩前置處理辨識的結果為具有紅色(Red)成份的偏差。接著再將此一結果輸入到模糊系統中，以原始影像圖4.4(a)經運算處理後所得的色偏標準差誤差值12.93與平均值誤差值11.82作為模糊系統的輸入。再由圖4.8的標準差誤差值歸屬函數圖與圖4.9的平均誤差值歸屬函數圖，及表3.1的模糊法則進行模糊推理運算，其中圖4.8及圖4.9的歸屬函數則是以圖3.5的歸屬函數設定為基礎，再由類神經網路的輸出對模糊系統進行微調後產生的。解模糊化後得模糊推理的輸出值為97及線性總和的權重值為0.3，以這數值作為校正影像的參數，因此可以得到濾波器函數如圖4.10。再經由解調(Demodulation)及色彩補償後所還原的影像如圖4.11，此即為最後輸出的影像。




圖4.8 影像偏紅的標準差誤差值歸屬函數圖




圖4.9 影像偏紅的平均誤差值歸屬函數圖




圖4.10 修正影像的濾波器函數(參數值為 97)



圖4.11 經由解調後還原的影像

4.2 實例二：影像色偏的校正(偏藍)

訓練類神經網路的影像採用由圖4.1至圖4.3所取得的平均值及標準差值。共使用800組隨機的影像資料進行類神經網路系統的訓練處理，且以圖4.15作為驗證的影像，並以200組隨機的影像資料進行類神經網路系統的測試，系統的收斂圖如圖4.12至圖4.14。其中圖4.12的收斂值 $MSE = 0.9011$ 。圖4.13的收斂值 $MSE = 0.8923$ 。圖4.14的收斂值 $MSE = 0.8762$ 。




圖4.12 類神經網路收斂圖($MSE = 0.9011$)

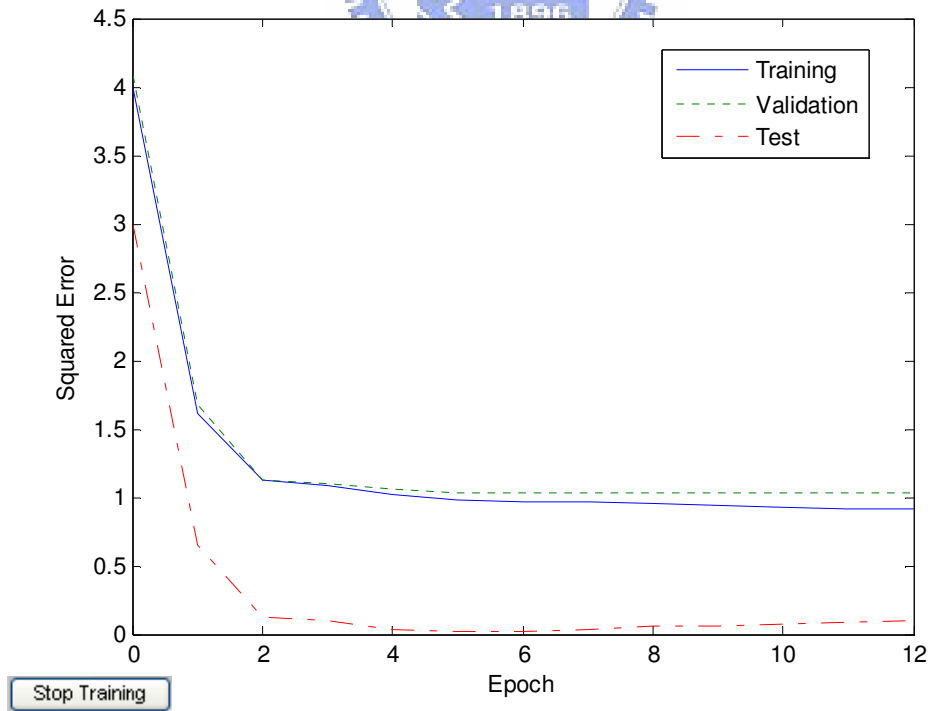


圖4.13 類神經網路收斂圖($MSE = 0.8923$)





圖4.14 類神經網路收斂圖 ($MSE = 0.8762$)





(a)



(b)

圖4.15 (a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。

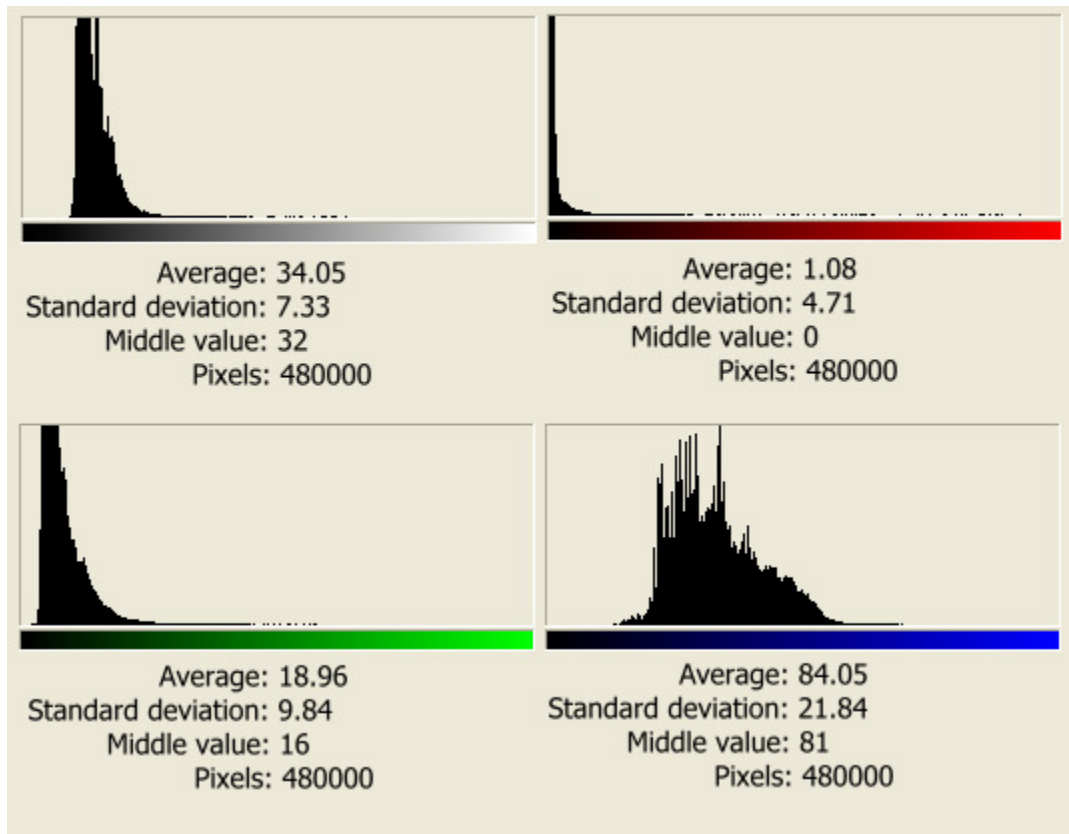


圖4.15 (續) (a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。

由類神經網路系統的輸出可以得知，原始影像圖4.15(a)經影像色彩前置處理辨識的結果為具有藍色(Blue)成份的偏差。接著再將此一結果輸入到模糊系統中，以原始影像圖4.15(a)經運算處理後所得的色偏標準差誤差值13.35與平均值誤差值64.05作為模糊系統的輸入。再由圖4.16的標準差誤差值歸屬函數圖與圖4.17的平均誤差值歸屬函數圖，及表3.1的模糊法則進行模糊推理運算，其中圖4.16及圖4.17的歸屬函數則是以圖3.5的歸屬函數設定為基礎，再由類神經網路的輸出對模糊系統進行微調後產生的。解模糊化後得模糊推理的輸出值為123.81及線性總和的權重值為0.37，以這數值作為校正影像的參數，因此可以得到濾波器函數如圖4.18。再經由解調及色彩補償後還原的影像如圖4.19，此即為最後輸出的影像。




圖4.16 影像偏藍的標準差誤差值歸屬函數圖




圖4.17 影像偏藍的平均誤差值歸屬函數圖




圖4.18 修正影像的濾波器函數(參數值為 123.81)




圖4.19 經由解調後還原的影像

4.3 實例三：顏色色偏的校正(偏綠)

訓練類神經網路的影像採用由圖4.1至圖4.3所取得的平均值及標準差值。共使用800組隨機的影像資料進行類神經網路系統的訓練處理，且以圖4.23作為驗證的影像，並以200組隨機的影像資料進行類神經網路系統的測試，系統的收斂圖如圖4.20至圖4.22。其中圖4.20的收斂值 $MSE = 0.9099$ 。圖4.21的收斂值 $MSE = 0.9131$ 。圖4.22的收斂值 $MSE = 0.8992$ 。




圖4.20 類神經網路的收斂圖($MSE = 0.9099$)




圖4.21 類神經網路的收斂圖($MSE = 0.9131$)





圖4.22 類神經網路的收斂圖($MSE = 0.8992$)





(a)



(b)

圖4.23 (a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。

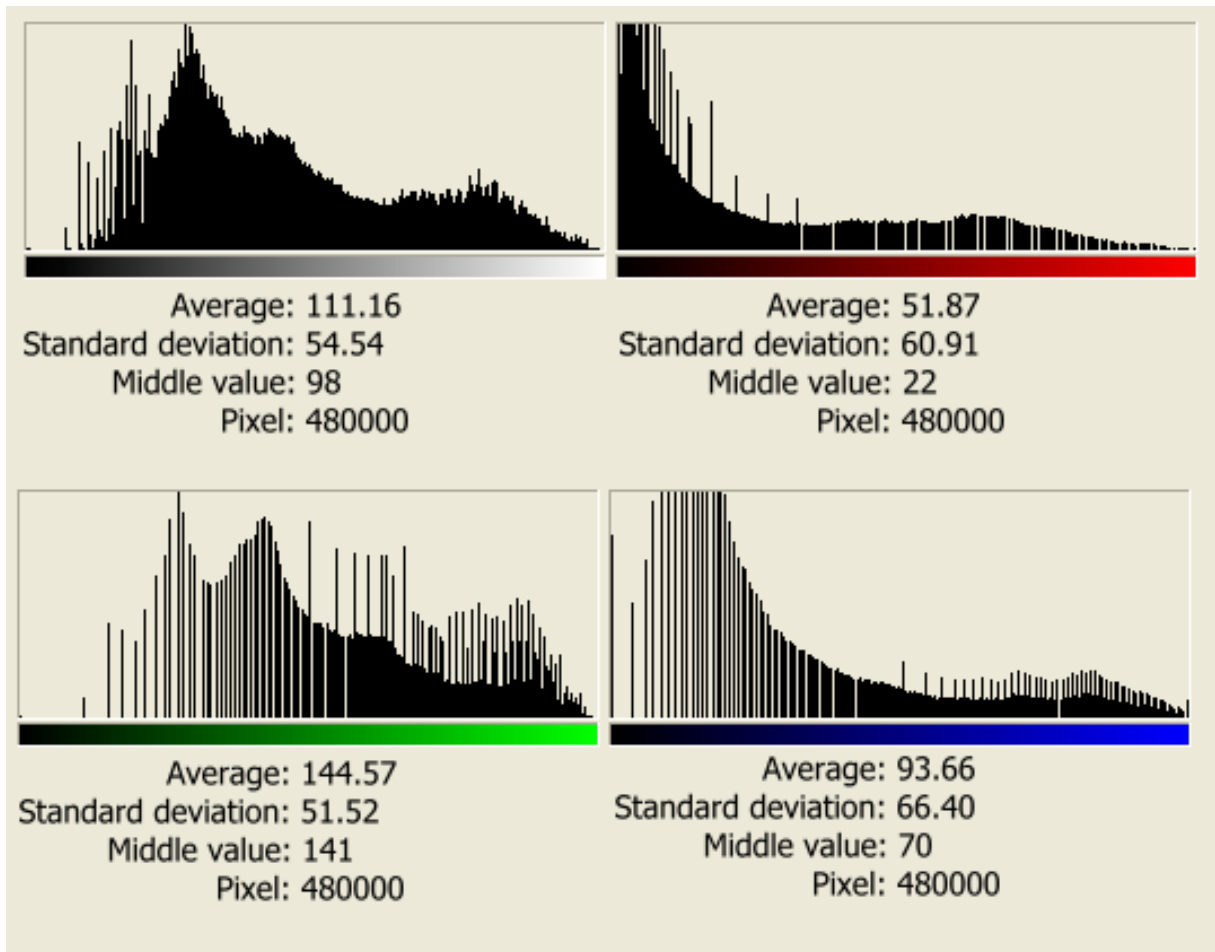


圖4.23 (續) (a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。

由類神經網路系統的輸出可以得知，原始影像圖4.23(a)經影像色彩前置處理辨識的結果為具有綠色(Green)成份的色偏。接著再將此一結果輸入到模糊系統中，以原始影像圖4.23(a)經運算所得的色偏標準差誤差值3.02與平均值誤差值33.41作為模糊系統的輸入。再由圖4.24的標準差誤差值歸屬函數圖與圖4.25的平均誤差值歸屬函數圖，及表3.1的模糊法則進行模糊推理運算，其中圖4.24及圖4.25的歸屬函數則是以圖3.5的歸屬函數設定為基礎，再由類神經網路的輸出對模糊系統進行微調後產生的。解模糊化後得模糊推理的輸出值為117.46及線性總和的權重值0.43，以這數值作為校正影像的參數，因此可以得到濾波器函數如圖4.26。再經由解調及色彩補償後還原的影像如圖4.27，此即為最後輸出的影像。




圖4.24 影像偏綠的標準差誤差值歸屬函數圖




圖4.25 影像偏綠的平均誤差值歸屬函數圖




圖4.26 修正影像的濾波器函數(參數值為 117.46)



圖4.27 經由解調後還原的影像



4.4 實例四：影像亮度的校正

訓練類神經網路的影像採用由圖4.1至圖4.3所取得的平均值及標準差值。共使用800組隨機的影像資料進行類神經網路系統的訓練處理，以圖4.31輸入類神經網路進行驗證測試，並且以200組隨機的影像資料進行類神經網路系統的測試，系統的收斂圖如圖4.28至圖4.30。其中圖4.28的收斂值 $MSE = 0.8714$ 。圖4.29的收斂值 $MSE = 0.9035$ 。圖4.30的收斂值 $MSE = 0.8862$ 。




圖4.28 類神經網路的收斂圖($MSE = 0.8714$)




圖4.29 類神經網路的收斂圖($MSE = 0.9035$)






圖4.30 類神經網路的收斂圖($MSE = 0.8862$)





(b)

圖4.31 (a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。

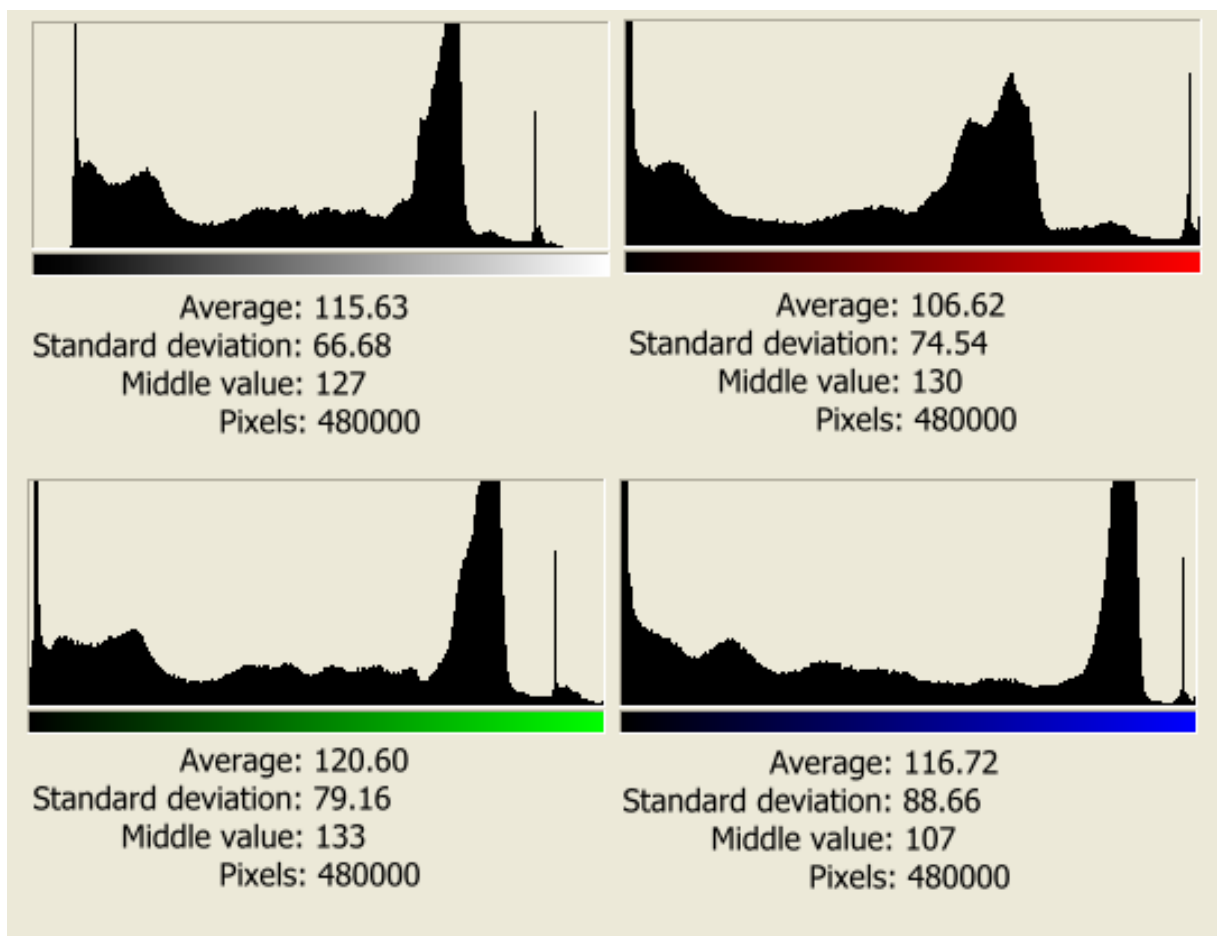


圖4.31 (續) (a)解調前的原始影像；(b)未解調的濾波器函數圖，參數值為5；(c)原始影像的色階分佈圖。

由類神經網路系統的輸出可以得知，原始影像圖4.31(a)經影像色彩前置處理辨識的結果為局部亮度偏暗的影像。接著再將此一結果輸入到模糊系統中，以原始影像圖4.31(a)運算所得的色偏標準差誤差值37.97與平均值誤差值9.01作為模糊系統的輸入。再由圖4.32的標準差誤差值歸屬函數圖與圖4.33的平均誤差值歸屬函數圖，及表3.1的模糊法則進行模糊推理運算，其中圖4.32及圖4.33的歸屬函數則是以圖3.5的歸屬函數設定為基礎，再由類神經網路的輸出對模糊系統進行微調後產生的。解模糊化後得模糊推理的輸出值為124.28及線性總和的權重值0.45，以這數值作為校正影像的參數，因此可以得到濾波器函數如圖4.34，再經由解調及色彩補償後還原的影像如圖4.35，此即為最後輸出的影像。




圖4.32 影像偏暗的標準差誤差值歸屬函數圖




圖4.33 影像偏暗的平均誤差值歸屬函數圖




圖4.34 修正影像的濾波器函數(參數值為 124.28)



圖4.35 經由解調後還原的影像

第五章 結論與未來發展

本篇論文提出一個數位影像色彩校正與補償的系統。系統的第一個階段採用類神經網路偵測影像的色彩偏差及亮度偏差。類神經網路的用途在建立一個人工智慧系統，經由訓練後的類神經網路能模擬人類大腦中神經元架構及行為模式，因此將影像色彩資訊輸入類神經網路後，可藉由類神經網路判斷輸入的影像是否需要色彩校正，及決定需要校正的區域。接著在第二階段由模糊系統建立色彩校正補償演算法，模糊系統的邏輯是模擬人類心智、推理等行為建立的法則，因此模糊系統的邏輯接近人類的思考行為，藉由模糊系統的推理能力，能更精準地計算校正補償參數，以確實對必須校正的影像進行處理。

色彩校正補償的部份設計採用模糊系統架構而成。根據模糊系統輸出的結果作為校正補償時的濾波器係數，然後經由反覆的修正使校正補償後的影像具有更佳的視覺感觀。同時在色彩補償的部份嘗試加入色偏校正，目的在使校正後的影像具有更佳的視覺感觀。


在性質上，類神經網路比較相當於人工智慧的硬體架構，而模糊系統則相當於人工智慧的軟體部份，經由結合類神經網路與模糊系統，可以將類神經網路的學習能力應用在模糊系統，並將模糊系統的推理應用在類神經網路上，使所建立的系統更符合人工智慧系統。

類神經網路的偵測效果非常依賴事前的訓練，因此在訓練資料的搜集、影像色彩特徵的選取都顯得非常重要，同時訓練類神經網路也需要花費相當長的時間。未來的發展在期望找到更具代表性的特徵向量，以減少訓練類神經網路的時間。此外，調整類神經網路隱藏層的神經元個數及層數，使神經網路能加快運算及收斂的速度，並提高神經網路的擴充性也是未來發展的工作之一。

而模糊系統的表現好壞，與歸屬函數、模糊邏輯法則及推理機制有關，因此如何更正確地建立決定決策的模糊法則，及如何調整初始法則和其歸屬函數，也是本系統重要的一環。因此另一件未來發展的工作，則是如何藉由類神經網路的適應性來產生模糊

系統的法則，並經由結構、參數的調整來自動調整模糊系統的法則及歸屬函數，以使整體的系統更為強化。

某些特殊的影像，如在燈會、煙火等活動中所拍攝的影像，由於這類影像在各區塊間亮度因子的差異往往非常大，就單一區塊的校正結果通常堪稱理想，但組合成整張影像再經過色彩補償後就可能變得非常不協調。因此未來的發展也期望能針對這類影像的特性，開發一個更完整的補償演算法，使這類影像在經由校正補償後，可以使人的眼睛觀看到更多的影像資訊，同時也使影像保有一定程度的視覺感觀效果。



參考文獻

- [1] J. Adams, "Interactions between color plane interpolation and other image processing functions in electronic photography," *Proc. SPIE Cameras and System for Electronic Photography and Scientific Imaging*, vol. 2416, pp. 144-151, 1995.
- [2] T. Kuno, H. Sugiura, and N. Matoba, "New interpolation method using discriminated color correlation for digital still camera," *IEEE Trans. on Consumer Electronics*, vol. 45, no. 1, pp. 259-267, Feb, 1999.
- [3] D. Cok, "Signal processing method and apparatus for producing interpolated chrominance values in a sampled color image signal," U.S. Patent 4 642 678, 1987.
- [4] T. W. Freeman, "Median filter for reconstructing missing color samples," U.S. Patent 4 724 395, 1998.
- [5] J. Hamilton and J. Adams, "Adaptive color plane interpolation in single sensor color electronic camera," U.S. Patent 5 629 734, 1997.
- [6] R. Kimmel, "Demosaicking: Image reconstruction from color CCD samples," *IEEE Trans. on Image Processing*, vol. 7, no. 3, pp. 1221-1228, 1999.
- [7] B. S. Hur and M. G. Kang, "High definition color interpolation scheme for progressive scan CCD image sensor," *IEEE Trans. on Consumer Electronics*, vol. 47, no. 1, pp. 179-186, Feb. 2001.
- [8] B. K. Gunturk, Y. Altunbasak, and R. M. Mersereau, "Color plane interpolation using alternating projections," *IEEE Trans. on Image Processing*, vol. 11, no. 9, 2002.
- [9] K. Hirakawa and T. W. Parks, "Adaptive homogeneity-directed demosaicing algorithm," *IEEE Trans. on Image Processing*, vol. 14, pp. 360-369, Mar. 2005.
- [10] H. S. Malvar, L. W. He and R. Cutler, "High-quality linear interpolation for demosaicing of Bayer-patterned color images," *IEEE Int. Conf. Acoustics, Speech and Signal Processing*, vol. 3, pp. 485-488, May 2004.
- [11] Z. Rahman, D. J. Jobson, G. A. Woodell, and G. D. Hines, "Image enhancement, image quality, and noise," in *Proc. Photonic Devices and Algorithms for Computing VII*, SPIE, vol. 5907, 2005.
- [12] G. D. Hines, Z. Rahman, D. J. Jobson, G. A. Woodell, and S. D. Harrah, "Real-time Enhanced Vision System," in *Proc. Enhanced and Synthetic Vision 2005*, SPIE, vol. 5802, 2005.
- [13] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, Prentice-Hall, New Jersey, 2002.

- [14] 繆紹綱，數位影像處理－運用MATLAB，台灣，東華書局，2005年。
- [15] K. Saarinen, "Comparison of decimation and interpolation methods in case of multiple repeated RGB-YCbCr colour image format conversions," *IEEE International Symposium on Circuits and Systems, 1994. ISCAS '94.*, London, UK, May 30 – Jun. 2, 1994, vol. 3, pp. 269-272.
- [16] J. Huang and Y. Wang, "Compression of color facial images using feature correction two-stage vector quantization," *IEEE Trans. on Image Processing*, Issue 1, pp. 102-109, Jan. 1999.
- [17] E. Land, "An alternative technique for the computation of the designator in the retinex theory of color vision," *Proc. of the National Academy of Science*, 83, pp. 3078-3080, 1986.
- [18] E. Land, "Recent advance in retinex theory," *Vision Research* 26 (1), pp. 7-21, 1986.
- [19] D. J. Jobson, Z. Rahman, and G. A. Woodell, "Properties and performance of a center/surround retinex," *IEEE Trans. on Image Processing*, vol. 6, no. 3, pp. 451-462, March 1997.
- [20] Z. Rahman, D. J. Jobson, and G. A. Woodell, "Retinex processing for automatic image enhancement," in *Proc. Human Vision and Electronic Imaging VII, SPIE Symposium on Electronic Imaging*, vol. 4662, pp. 390-401, 2002.
- [21] Z. Rahman, D. J. Jobson, G. A. Woodell, and G. D. Hines, "Image enhancement, image quality, and noise," in *Proc. Photonic Devices and Algorithms for Computing VII*, SPIE, vol. 5907, 2005.
- [22] Gaurav Sharma, *Digital Color Imaging Handbook*, CRC Press, pp. 269-384, 2002.
- [23] IEC/4WD 61966-2-1: Color Measurement and Management in Multimedia System and Equipment – Part 2-1: Default RGB Color Space – sRGB
- [24] 林昇甫、洪成安，神經網路入門與圖樣辨識，台灣，全華科技圖書，1996年。
- [25] J. Wesley and H. Lefteri, *MATLAB supplement to Fuzzy and Neural approaches in engineering*, New York, Wiley-Interscience, 1997.
- [26] 王文俊，認識Fuzzy，台灣，全華科技圖書，1997年。
- [27] 林宗漢，「使用類神經網路偵測影像色偏及模糊系統修正影像色偏之研究」，國立交通大學，碩士論文，民國94年7月。
- [28] 汪惠健，模糊理論與應用，台灣，台灣培生教育，2006年。