

鑑定相機來源之數位鑑識研究

蔡銘箴

交通大學資訊管理研究所

賴政良

佛光大學資訊學研究所

吳冠輝

交通大學資訊管理研究所

劉蓉

交通大學資訊管理研究所

摘要

在電腦應用，網際網路無遠弗屆的時代，許多的媒體都以數位的形式記錄、呈現及傳播，數位設備的普及，相對地也面臨許多新興的數位需求，而數位鑑識即是其中之一。

鑑定相機來源之數位鑑識是研究數位相機與其所拍攝出之影像之關係，針對不同相機所拍攝出的影像，結合影像處理技術與支撐向量機 SVM (support vector machine) 方法，計算出影像的特徵值，並將這些特徵進行訓練及分類，用以鑑別該影像之來源相機；同時，依據分析結果提出特徵值分類訓練的改進方法以提高影像來源的鑑識率，實驗結果也說明其有效性。

相機來源之辨識方法係利用各家廠商間相機的內部成像演算法之不同，以影像特徵值的分類來歸納出隱藏在影像中的特徵，此研究除了在不同廠牌的相機間具有優異辨識率外，也探討在同廠牌且型號接近情況下，該方法是否仍具有辨識能力，並針對結果提出以影像特徵值來鑑識相機來源之可能限制。

關鍵字：數位鑑識、影像特徵、支撐向量機



Digital Forensic for the Identification of the Camera Sources

Min-Jen Tsai

Institute of Information Management, National Chiao Tung University

Cheng-Liang Lai

Institute of Informatics, Fo Guang University

Guan-Hui Wu

Institute of Information Management, National Chiao Tung University

Jung Liu

Institute of Information Management, National Chiao Tung University

Abstract

In this digital era, all kinds of media data are recorded and presented digitally. The popularity of digital devices also brings up the needs for new digital data applications, and digital forensics is one of them.

This study is to analyze the relationship between digital cameras and images produced by them. Digital image processing technology is first applied in the identification procedures in order to get images' features. Those features are later trained and classified to identify the images' original sources by using SVM(support vector machine) techniques. In addition, the identification features are further analyzed for improvements for enhancing the precision rate of the identification.

Since camera manufacturers have various designs of image formation processes for digital cameras, the distinctive digital image feature will be identified and analyzed. This research not only identifies the camera sources among different manufactures, but also those of the same manufacturer with similar models. Therefore, the potential limits of this identification method will be verified by the research results.

Keywords: Digital Forensics, Image Features, Support Vector Machine



壹、緒論

隨著數位多媒體設備製作技術的進步，價格也日趨平民化，取得或製作數位影像益形容易。在過去類比的時代，相片必須經由拍攝、沖洗的過程產生，才能得知影像的內容，由於製作過程不易仿製，真實度高，因此，檢方可以藉由相片的內容來做事件發生的證明（proof of evidence）；然而在今日的數位時代，數位影像拍攝不需經由沖洗即可呈現內容，並且可藉由價廉且功能充分的軟體工具來修改或創作，因此，數位影像的內容是否仍是完全可信？尤其是在牽涉到法律蒐證的時候，如果證據是由數位相機所取得，那麼這張影像是否如提供者所說：在某個時間、某個地點、用某台數位相機拍攝的？

以上的問題雖是日常的例子，卻是調查機關與法律執行時所迫切面臨的問題，尤其許多的消費者已用數位相機來取代以往的 35mm 軟片的相機，現在卻缺乏能夠幫助他們找到有效證據的辨識技術。雖然有關相機型號、影像的拍攝時間等訊息，會被相機記錄在影像的標頭(Header)，但這些資訊一旦再經過壓縮或透過合適的工具，就可以更改或消除，因此，以 Header 作為鑑識的依據是不可靠的，故無法作為鑑定的依據。

其他的解決途徑包含了數位浮水印的技術，儘管其具有鑑別的功能，但是大多數被拍攝下來的影像並沒有包含浮水印。即使有浮水印的嵌入，可見的或不可見的浮水印皆可遭有心人士的攻擊而導致浮水印訊號的減弱，甚至移除，以致可判定的資訊並未達到可充分辨識證據的功用[5]。因此，在數位浮水印技術能支援有效的數位所有權管理（Digital Right Management）的應用之前，有必要發展其他的技術，以科學化、系統化的方法來辨識影像來源與可信度等資訊。

影像鑑識（Image forensics），最近在歐美也開始引起資訊技術及管理學界的高度重視，是一門包含廣泛的研究。其精神，類似美國在九一一後所喚起的反恐安全意識，讓生物辨識的相關研究顯得格外重要；譬如指紋測試、眼球虹膜鑑定、語音鑑定及臉像掃描測試的生物辨識系統，提供各國警政單位，可用以偵測辨識嫌疑犯身分，作為協助破案的工具。當然，儘管是利用「獨一無二」的生物特徵來做辨識，結果也並非絕對完美，例如髒污與受傷的手指都可能影響生物指紋的辨識，眼球虹膜鑑定也不像指紋的辨識系統普及，軟體系統也都有可能在判定時產生誤差；甚至已有些國家立法禁止以生物特徵的方法來辨識身份，以免不肖份子以切除肢體的方式，脅迫人身的安全。

在這份研究中，我們嘗試以相機所拍攝之影像本身內含的特徵，做為相機鑑識的依據，也就如同找出其生物特徵，因此我們針對「給予一張圖片，是否能辨識出其拍攝影像的來源相機」作研究主題，針對不同相機所拍攝出的影像，結合影像處理技術與 SVM(support vector machine)方法，計算出影像的特徵值，並將這些特徵進行訓練及分類，用以鑑別該影像之來源相機；由於無法實際取得他人的相機做比較，只能以影像的特徵來做鑑識，雖然每一台相機都有其獨特的特徵，但由於同品牌同型號所使

用的核心架構、模組與操作軟體相同，在本研究中，則視為同一物件以簡化其比較。因此，我們將採用根據影像特徵的「影像特徵向量法」，以其找出影像之來源相機。

貳、文獻探討

一、相機來源鑑定

鑑定相機來源之數位鑑識是個新的研究題材，過去曾有相關研究提出以壞點分佈判定法 (defective pixel) [2][6]來辨識影像的來源相機，但該方法因目前的相機都已在壞點處理上有相當水準，故無法適用於現在新型的相機；本研究參考[7]，結合影像處理技術與資料探勘技術，計算出與相機成像相關的特徵值，並將這些不同相機的影像特徵值透過訓練，建立分類器 (Classifier)，再將其他未知來源的影像輸入預測，獲得鑑識率，細節則在下節中詳述。

二、影像特徵擷取

辨別一張影像的來源相機，常用的方法是使用一組特徵值 (Feature)，這組特徵指標能夠指定辨識出某一台特定的相機。如此，便可以用這些特徵指標來判斷影像的來源相機。雖然不同相機產生影像的過程都不盡相同，但可確定一張影像受到以下兩個部分的影響極大[1]：CFA (Color Filter Array)結構配置(configuration)、色彩處理和轉換。

因此，不論原始影像的內容為何，在處理 RGB 色頻裡的數位內容時，就會隱藏某些該相機特有的特徵和特性。為了捕捉不同相機所拍攝的圖片的影像特徵，我們將每一台相機所拍攝的影像進行影像處理計算，並利用資料探勘的方法加以分類，建立預測模型，作為鑑定預測之用。

在本研究中，共使用 33 個指標來辨識影像來源，並將這些特徵分為三個類別：色彩特徵類 (Color features)、影像品質類 (Image Quality features) 和小波域類 (Wavelet Domain)，表示各個特徵值時，以 C 開頭代表色彩特徵類，Q 開頭代表影像品質類，而小波域類則用 W 開頭表示，以下是各類別特徵之詳細說明 (計算公式詳見附錄)：

(一) 影像色彩特徵

平均像素值 (Average pixel value)：這個測量方法(Measure)是以「灰階世界假設」為基礎，假設影像的顏色變化相當平均的情況下，將 RGB 三原光取平均值，將可獲得三個特徵測量指標值 C1、C2、C3。

三原光成對相關係數 (RGB pairs correlation)：這個指標值是在比較不同原光之間的關聯性，因此，三個原光依據排列組合，就產生三種關聯：分別是 RG、RB、GB，可獲得三個特徵測量指標值 C4、C5、C6。

鄰近分佈質心 (Neighbor distribution center of mass): 這個測量指標分別針對每一個原光, 首先是繪製「像素計數圖」: 橫軸是從 0~255, 縱軸是計數, 該圖表會呈現每個像素值的數量。

接著將該圖再轉換成「鄰近像素計數圖」: 橫軸仍是 0~255, 但縱軸的數值則改為將鄰近像素的值相加後的數值, 例如: 在像素計數圖中, 像素值為 0 的像素有 100 個、1 有 50 個、2 有 30 個、3 有 120 個, 在轉換為鄰近像素圖後, 1 的數值就是把 0 與 2 的數值相加: $100+30=130$, 而 2 的數值則是 $50+120=170$, 其他以此類推。最後一步是求質心的過程: 將鄰近像素計數圖按 0 至 255 累加, 當累加值超過鄰近像素計數圖之總值的二分之一時, 該像素值就是我們所求的「質心」值, 這樣的求值過程, 主要是可以了解相近數值的像素彼此之間的分布情形, 對於同一場景, 不同的相機所拍攝的影像會有非常相似的分布情形, 而差別之處則是分布之間會有的位移關係。這個特徵測量指標可獲得三個指標值 C7、C8、C9。

RGB 成對能量比 (RGB pairs energy ratio): 這是一個相當重要的指標, 在參考文獻[1]中, 曾提出利用判定壞點的方法來辨識來源相機, 文中就提及本指標, 它是用於白點校正 (White point correction) 上。這個特徵測量指標可獲得三個指標值 C10、C11、C12

(二) 影像品質特徵

為了獲得影像間更細微的差異, 採用了影像品質特徵[2], 這些特徵包含以像素誤差、相關性以及頻譜域等三類為基礎, 這些特徵值都是以公式直接運算的, 因此, 以下直接列出各項特徵值:

Mean Square Error, MSE, Q1

Mean Absolute Error, MAE, Q2

Minkowski Difference, $\gamma = \infty$, Q3

Structural Content, Q4

Normalized cross correlation, Q5

Czekonowski correlation, Q6

Spectral magnitude error, Q7

Spectral phase error, Q8

Spectral phase-magnitude error, Q9

Block spectral magnitude error, Q10

Block spectral phase error, Q11

Block spectral phase-magnitude error, Q12

(三) 頻率域之影像特徵

要成功地表示影像, 除了在一般的空間域 (spatial domain) 外, 還有頻率域 (frequency domain) 的表示法, 雖然傅立葉轉換 (Fourier Transform) 或數位餘弦轉換是常用的頻率域的方法, 本研究加入小波轉換 (Wavelet Transformation): 一張影像透過一次小波轉換

後，可以產生 4 個子頻，而在這 4 個子頻中，我們採用含有高頻資訊的三個子頻，這是影像較為細微的細節部份，故取用之。

在此，要取得小波域影像特徵值時，一張影像分成 RGB 三原光，每種原光都以小波轉換成多個子頻，我們取三個子頻，並將每個子頻取平均值，故在這個類別裡，我們會獲得 9 個特徵值 W1、W2、W3、W4、W5、W6、W7、W8、W9，由於小波域的濾波器的選擇很多，必須有系統地來應用[8]。所以 C1-C12，Q1-Q12，再加上 W1-W9 總共有 33 個指標。

三、分類與預測

資料的分類 (classification) 與迴歸(regression) 是電腦科學的重要課題之一，其應用越來越普遍，比如 handwritten digits recognition, speech recognition, text classification, face recognition, web mining, intrusion detection 等。傳統的分類方法有類神經網路(Neural Networks), 決策樹(Decision Trees), 最近相鄰法(nearest neighbor methods)等。近五年來 Support Vector Machine 為一新的方法，它已被驗證在許多應用上有相當好之結果。SVM 同時也較 Neural Networks 具有較佳的理論基礎，因為 Neural Networks 難證明其收斂性。

本研究採用由台灣大學資訊工程系的林智仁教授所開發的 LibSVM[3]軟體；SVM (Support Vector Machine) 演算法 (decomposition methods) 在 1997 年被提出，其方法是否收斂，一直是個很困難的問題，林教授在 2000 年及 2001 年 *IEEE Trans. on Neural Networks* 期刊所發表之論文理論證明了此一演算法以及目前被廣泛使用之軟體 SVM light 所用之演算法都具有收斂性。林教授也同時開發了應用軟體 LIBSVM 供全世界學者使用。該軟體也被收錄於人工智慧領域常見問題及軟體和其他機器學習與模型辨識領域之重要網站(擷錄自中央研究院研究成果簡介)。這個軟體目前最常拿來用於「分類(classification)」，例如，如果有一堆已經分好類的東西，但是分類的依據是未知的，當再度收到新的資料時，可以藉由 LibSVM 預測(predict)新的資料應該是屬於哪一個類別，同時驗證其準確率[4]。


支撐向量機 SVM 是以核心函數(Kernel Function)為基礎的學習方法，可以用在分類與非線性迴歸上。在分類方面的應用，其主要概念是在高維度的特徵空間中建構出一個最佳的區分超平面(Separating Hyperplanes)。透過此平面能夠有效的分類 Positive example 和 Negative example。但大部分資料分類的例子多屬於非線性分割的問題，這時如果我們利用簡單的線性超平面去分類是很難達成的。因此，我們必須藉著由物件空間(Instance space)中的資料轉換到特徵空間(Feature space)中，則呈現非線性分割的狀態。在運用分類軟體的實驗過程中，一般所採用的支撐 SVM 的核心函數為多項式核心函數(Polynomial Kernel Function)，或許可從選用不同的核心函數觀察其結果差異。亦或是針對多項式核心函數改變其維度參數值，但因維度值越高，則整個運算過程相對較為複雜，一般而言在有限的時間與成本下，會選擇較為適當的參數值。所以或許可從改變維度參數值的角度，是否會對 SVM 在分類準確率上有所影響，做進一步的討論。

參、實驗架構與流程

一、實驗設計

本研究之實驗設計主要分為兩部分：

第一部份之實驗特色在於針對影像內容（包含有無影像後處理）、影像擷取特徵、SVM 訓練模型之照片多寡、及相機之廠牌型號這五大方向作交叉實驗驗證，其相關性，如圖 1(a)所示，根據此原則，依序設計出 9 組不同實驗案例來逐一討論(圖 1(b))並分析對辨識率的影響。



個案	實驗設計內容
Case 1-1	2 台不同廠牌型號數位相機，影像相似度高
Case 1-2	3 台同廠牌，不同型號，1 台不同廠牌型號，影像相似度高
Case 1-3	3 台同廠牌，不同型號，1 台不同廠牌型號，影像相似度高
Case 1-4	3 台同廠牌，不同型號，1 台不同廠牌型號，每台各兩組影像資料
Case 1-5	3 台同廠牌，不同型號，1 台不同廠牌型號，訓練資料數量少、影像相似度高
Case 1-6	3 台同廠牌，不同型號，1 台不同廠牌型號，訓練資料數量多、影像相似度高
Case 1-7	3 台同廠牌，不同型號，1 台不同廠牌型號，影像特徵有分類、影像相似度高
Case 1-8	3 台同廠牌，不同型號，1 台不同廠牌型號，影像特徵有分類、影像相似度高
Case 1-9	2 台不同廠牌不同型號，影像經過破壞

(b)

圖 1：(a)第一部份之實驗設計架構圖及(b)個案內容

由於在實際應用上，很難要求數位相機拍攝內容的相似度高，針對此要求，第二部份之實驗特色在於假設各台相機所拍攝的數位影像內容的相似度完全不同，針對相機之廠牌、型號、感測元件以及參與分類的相機數量這四個方向，設計出兩個主要不同的案例來討論，並交叉分析其差異處對辨識率的影響，其實驗設計內容如下圖所示：

個案	實驗設計內容
Case 2-1	20 台同廠牌或不同廠牌，不同型號及感測元件之數位相機，影像相似度低
Case 2-2	同廠牌不同型號，不同感測元件各 3 台數位相機與手機相機，影像相似度低

圖 2：第二部份之實驗設計

二、實驗流程

本研究之實驗流程除了部分參考文獻[7]之外，另外本文新增加了 SVM 最佳參數搜尋步驟，除了避免以試誤法(try and error)來找尋參數之外也提升了實驗之辨識率，詳細之實驗步驟如下：

步驟一、蒐集不同相機所拍攝出來不同的影像內容，程式中設定如果相片解析度大於 1600×1200 者則裁減相片的大小尺寸，其餘則保持原解析度尺寸。

步驟二、經由程式將相片以影像處理技術計算每一張影像的特徵值，並將其記錄下來。

步驟三、在計算完影像特徵值後，我們利用隨機亂數將全部影像分為兩類分別為 SVM 訓練模型資料(SVM Train Data)與 SVM 實驗驗證資料(SVM Test Data)。舉一個分類兩台相機的例子，如果我們每台相機拍攝 150 張影像，欲將其中之 60 張當成訓練模型資料。那就是個別從相機本身的 150 張先隨機選擇其中的 60 張作為建立該相機的影像特徵模型，等建立完成之後再個別將剛剛未被選取的影像資料 90 張納入實驗驗證資料，兩台合計共 180 張作為實驗分類用途，如表1。

表 1：分類與預測鑑定樣本數

	原影像張數	訓練模型張數	實驗驗證張數
Nikon CoolPix 5000	150 張	Random 60 張	90 張
SONY-P1	150 張	Random 60 張	90 張
總計	300 張	120 張	180 張

步驟四、以資料探勘軟體 LibSVM 進行剛剛個別選取之 60 張訓練模型資料分別進行特徵值運算、分類後完成建立個別相機之訓練模型(train model)。

步驟五、利用參數搜尋工具程式，根據各台訓練模型之資料共 120 張影像進行預測分類並完成最佳參數分佈圖的繪製，如圖 3。




圖 3：最佳參數預測分佈圖

步驟六、參考最佳參數預測分佈圖(圖 3)後擇定最佳參數值帶入實驗驗證之參數進行分類鑑識，最後獲得實驗驗證資料的辨識率。

步驟七、為了減少步驟三因隨機取樣而造成鑑識結果誤差，我們重複進行前述實驗步驟（步驟三~五）10 次，並以平均的辨識率作為真正表列之辨識結果數據。

肆、實驗結果

本研究之實驗設計如上文所述分為兩個部分，第一部分著重於針對影像內容相似與否、SVM 模型建立相片數量(Train Data)、影像特徵值、影像後處理以及相機品牌型號等五個重點方向來探討對於辨識率之間的關係。實驗的第二部分則更接近實務層面，在影像內容都完全不一樣的狀況下針對品牌、型號、感測元件、相機數量等四個重點方向來作實驗驗證。各實驗假設及結果分述如下：

一、實驗第一部份


(一) 個案 1-1

實驗環境：參考文獻[7]，與該文章作者聯繫後在作者的同意之下我們獲得與文獻[7]相同的影像資料。其影像資料庫樣本如圖 4 分別以相機 Nikon E2100 與 SONY-P51 所拍攝。





圖 4(a): Nikon-E2100



影像圖 4(b): SONY-P51 影像

表 2：個案 1-1 之實驗結果

表 2(a):參考文獻[7]之實驗結果

		實驗分類		辨識率(%)
		Nikon	Sony	
原始類別	Nikon	89.9	0.1	99.88
	Sony	2.2	87.8	97.6

表 2(b):驗證之實驗結果

		實驗分類		辨識率(%)
		Nikon	Sony	
原始類別	Nikon	90.0	0.0	100
	Sony	1.6	88.4	98.2

結果說明：從圖表數據中，可看出使用文獻[7]之影像資料搭配本文所採用的實驗流程方法得到非常好的辨識率。由於辨識率已幾乎接近 100%而且比文獻中數據效果更好，證實本文所採行的方法除了確實可行之餘，更改善了分類辨識率。

(二) 個案 1-2

實驗環境：本實驗設計動機在於假設在理想條件下每一台數位相機所拍攝內容相似度極高(如圖 5(a),(b),(c),(d))，探討數位影像相似度是否會提升或降低照片分類辨識率。在本實驗中採用了四台數位相機分別為 SONY-T7、SONY-P9、SONY-P1 與 Nikon-E995，分別各拍攝了 150 張照片其中 60 張照片當 Train Data 另外 90 張照片當 Test Data 來作分類實驗。




圖 5(a)：Nikon-E995




圖 5(b)：SONY-P1




圖 5(c)：SONY-P9



圖 5(d)：SONY-T7

表 3：個案 1-2 之實驗結果

		實驗分類				辨識率(%)
		Nikon-E995	SONY-P1	SONY-P9	SONY-T7	
原始類別	Nikon-E995	90	0	0	0	100
	SONY-P1	0	90	0	0	100
	SONY-P9	0	0	90	0	100
	SONY-T7	0	0	0	90	100

結果說明：表 3 之實驗數據乃針對相同分類步驟重複作十次平均後的結果，其辨識正確率十次都高達 100%。我們可以從辨識率數據中看出數位影像拍攝的內容在相似度極高的狀況下對於辨識率會有很大的提升效果，而這個論點是以往文獻所未提及的。

(三) 個案 1-3

實驗環境：個案 1-2 之實驗假設在影像內容相似度極高的狀態下，這是一個很理想的狀況，但是在實務應用上卻很少會有這樣的狀況。為了瞭解數位影像內容差異是否會影響辨識率，我們採用與個案 1-2 完全相同的數位相機與拍攝張數，唯獨這四台相機所拍攝內容完全不一致(如圖 6(a),(b),(c),(d))來作分類實驗，希望能跟個案 1-2 作一比較。




圖 6(a)：Nikon-E995



圖 6(b)：SONY-P1



圖 6(c)：SONY-P9



圖 6(d)：SONY-T7

表 4：個案 1-3 之實驗結果

		實驗分類				辨識率(%)
		Nikon-E995	SONY-P1	SONY-P9	SONY-T7	
原始類別	Nikon-E995	86.5	0	3.2	0.3	96.11
	SONY-P1	0	84.9	1.7	3.4	94.33
	SONY-P9	1.9	6.4	80.1	1.6	89
	SONY-T7	0.2	3.7	2.6	83.5	92.77

結果說明：從表 4 之實驗數據中我們可以發現數位相片之拍攝內容不同確實會影響照片分類之正確率。在採用本研究方法比較後，相同廠牌間之數位相機辨識率會略低於不同廠牌的相機，畢竟各家產品的成像處理方法不同，有助於相機的辨識。

(四)個案 1-4

實驗環境：在分析個案 1-2 及 1-3 之後，我們已經可以初步得到一些結論就是影像內容相似度確實對於分類辨識率會有一定程度的影響。為了要交叉驗證相片之影像內容對於辨識率的影響度，我們同個案 1-2、1-3 使用相同四台數位相機，針對這四台相機各兩組(一組相似度高另一組完全不相似)的影像資料作分類。

表 5：個案 1-4 之實驗結果

		實驗分類								辨識率(%)
		Nikon-E995		SONY-P1		SONY-P9		SONY-T7		
原始類別		相似	不相似	相似	不相似	相似	不相似	相似	不相似	
	Nikon-E995 (相似)	90	0	0	0	0	0	0	0	100
	Nikon-E995 (不相似)	2.9	83	0	0	0	3.5	0	0.6	92
	SONY-P1 (相似)	0	0	90	0	0	0	0	0	100
	SONY-P1 (不相似)	0	0	3.1	80.6	0	3	0	3.3	90
	SONY-P9 (相似)	0	0	0	0	90	0	0	0	100
	SONY-P9 (不相似)	0	1.3	0.4	4.6	1.3	80.1	0.1	2.2	90
	SONY-T7 (相似)	0	0	0	0	0	0	90	0	100
	SONY-T7 (不相似)	0	0	0	3.9	0.4	1.6	0.5	83.6	93

結果說明：從表 5 之實驗數據中，我們可以發現數位相片之影像內容的相似與否，除了會影響照片分類之正確率之外，甚至同樣一台數位相機，也會因為拍攝內容的取材不同，而產生同樣是同一台相機所拍攝出來的相片，卻有不同的分類結果。

(五) 個案 1-5

實驗環境：在驗證數位影像內容絕對會影響分類辨識率之後，接下來要探討第二個方向就是 SVM Train Data 的數量多寡對於分類辨識率的影響。本實驗個案中，我們沿用之前個案所使用相同四台數位相機，也採用這四台數位相機彼此相似度極高的影像資料來訓練 SVM 並作分類驗證。我們從 Train Data 等於 5 張、10 張、15 張到 60 張然後用另外 90 張相片資料作 Test Data 來作分類的實驗。




圖 7：個案 1-5 中 Train Data 數量對於分類辨識率的影響(影像相似)

結果說明：從圖 7 之實驗圖表中我們可以發現如果在理想狀態下每一台數位相機都拍攝到相似度極高的影像內容時，我們只需要 5 張影像資料就可以有 96% 以上的辨識率，於 45 張之後就有將近 100% 的分類辨識率。

(六) 個案 1-6

實驗環境：在個案 1-5 中我們瞭解到以高辨識率為前提下，影像內容相似與否也會影響到 SVM Train Data 的數量。針對完全不相似的影像內容，我們同樣做出了以下的實驗數據。從圖 8 之實驗圖表中我們可以發現如果在實際上針對完全不相似的影像內容作分類時，我們必需要超過 55 張影像資料當 Train Data 才能保證有 90% 以上的辨識率。相較於個案 1-5 的實驗數據確實有很大的落差，因此，在影像內容相似度低時，訓練的相片量就必須增加才能增加準確率，這符合經驗法則的期待。




圖 8：個案 1-6 中 Train Data 數量對於分類辨識率的影響(影像不相似)

(七) 個案 1-7

實驗環境： 本文採用文獻[7]中影像特徵擷取方法作實驗，其影像特徵大致可以分為三大類共 33 個特徵(如附錄)。本實驗個案中將探討影像特徵類別、數位影像內容與辨識率三者之間的關係。本實驗假設在相同四台數位相機中使用完全不相似的影像內容並且只擷取三個類別中的某一類作特徵提供給 SVM 作分類。

表 6：只擷取影像色彩特徵(Color Feature)對分類辨識率的影響(影像不相似)

		實驗分類				辨識率(%)
		Nikon-E995	SONY-P1	SONY-P9	SONY-T7	
原始類別	Nikon-E995	46.8	12.5	19.2	11.5	52
	SONY-P1	3.1	65.6	15.6	5.7	72.88
	SONY-P9	7.6	23.4	52.1	6.9	57.88
	SONY-T7	12.6	10.9	7.3	59.2	65.77

表 7：只擷取影像品質特徵(Quality Feature)對分類辨識率的影響(影像不相似)

		實驗分類				辨識率(%)
		Nikon-E995	SONY-P1	SONY-P9	SONY-T7	
原始類別	Nikon-E995	59.3	7.5	6.6	16.6	65.88
	SONY-P1	6.4	58	7.5	18.1	64.44
	SONY-P9	3.6	11.2	51.9	23.3	57.66
	SONY-T7	13.2	13.1	10.9	52.8	58.66

表 8：只擷取影像小波頻率域特徵(Wavelet Domain Statistic Feature)對於分類辨識率的影響(影像不相似)

		實驗分類				辨識率(%)
		Nikon-E995	SONY-P1	SONY-P9	SONY-T7	
原始類別	Nikon-E995	90	0	0	0	100
	SONY-P1	0.4	87	2.6	0	96.66
	SONY-P9	5.7	5.9	77.7	0.7	86.33
	SONY-T7	3.6	14.1	2.3	70	77.77

結果說明：從表 6~8 之實驗圖表中我們可以發現在影像內容極不相似的狀態下，實驗使用三類別中單一特徵型態都不能達到良好的分類辨識率。而在這三個類別實驗數據中，又以小波頻率域特徵較能達到良好的分類辨識效果。

(八) 個案 1-8

實驗環境：參考個案 1-7 的實驗作法，只是這次所採用四台數位相機之影像內容是極為相似的資料。本實驗同樣只擷取三個類別中的某一類作特徵提供給 SVM 作分類，希望能跟個案 1-7 的實驗作比較。

表 9：擷取影像色彩特徵(Color Feature)對於分類辨識率的影響(影像相似)

		實驗分類				辨識率(%)
		Nikon-E995	SONY-P1	SONY-P9	SONY-T7	
原始類別	Nikon-E995	90	0	0	0	100
	SONY-P1	0	87.9	2.1	0	97.66
	SONY-P9	0	0.2	89.8	0	99.77
	SONY-T7	0	0	0	90	100

表 10：擷取影像品質特徵(Quality Feature)對於分類辨識率的影響(影像相似)

		實驗分類				辨識率(%)
		Nikon-E995	SONY-P1	SONY-P9	SONY-T7	
原始類別	Nikon-E995	90	0	0	0	100
	SONY-P1	0	90	0	0	100
	SONY-P9	0	0.5	89.5	0	99.44
	SONY-T7	0.3	0.2	0	89.5	99.44

表 11：擷取影像小波頻率域特徵(Wavelet Domain Statistic Feature)對於分類辨識率的影響(影像相似)

		實驗分類				辨識率(%)
		Nikon-E995	SONY-P1	SONY-P9	SONY-T7	
原始類別	Nikon-E995	90	0	0	0	100
	SONY-P1	0	90	0	0	100
	SONY-P9	0	0	89.2	0.8	99.11
	SONY-T7	0	0	0.2	89.8	99.77

結果說明：從表 9~11 之實驗圖表中我們可以發現在影像內容極為相似的狀態下作分類實驗，只需要三類別中任一特徵型態都能達到良好的分類辨識率。

(九) 個案 1-9

實驗環境：這個個案主要是要探討數位影像資料如果經過人為的修改或破壞之後是否仍具有分類辨識能力。本實驗使用與個案 1-1 同樣的相機並且使用相同的相片影像內容來作分類。我們針對影像尺寸作後製處理(Resize)然後利用 SVM 作分類。

表 12：原始相片大小（1600×1200），並未做任何處理

		實驗分類		辨識率(%)
		Nikon-E2100	SONY-P51	
原始	Nikon-E2100	90.0	0.0	100
類別	SONY-P51	2.6	87.4	97.11

表 13：相片大小經過影像軟體修正為（1280×960）

		實驗分類		辨識率(%)
		Nikon-E2100	SONY-P51	
原始	Nikon-E2100	58	32	64.44
類別	SONY-P51	23	64	71.11

表 14：相片大小經過影像軟體修正為（800×600）

		實驗分類		辨識率(%)
		Nikon-E2100	SONY-P51	
原始	Nikon-E2100	82	8	91.11
類別	SONY-P51	9	81	90

表 15：相片大小經過影像軟體修正為（320×480）

		實驗分類		辨識率(%)
		Nikon-E2100	SONY-P51	
原始	Nikon-E2100	69	21	76.66
類別	SONY-P51	18	72	80

結果說明：從表 12~15 之實驗圖表中我們可以發現影像大小尺寸如果經過影像處理軟體的後製作後，將會影響影像分類辨識率。本實驗雖然在大小尺寸成等比例縮放，但辨識率卻呈現非線性變化。可見市售的影像處理軟體，在比例縮放時，已更動了影像的特徵值，這在數位辨識上，是不得不注意的要項。

二、實驗第二部份

(一) 個案 2-1

實驗環境：如同圖 2 所示之實驗環境設定，我們使用 20 台同廠牌或不同廠牌，不同型號及感測元件之數位相機來作分類辨識，影像的內容並不相似。

表 16：個案 2-1 之實驗結果

	實驗類別														辨識率 (%)							
	Canon-20D	Canon-300D	Canon-G3	Canon-Ixus700	Fuji-F410	Minolta-X20	Nikon-D50	Nikon-E995	Olympus-C300	Olympus-E300	Panasonic-FX8	Pentax-S	SONY-N1	SONY-P1		SONY-P51	SONY-P8	SONY-P9	SONY-T1	SONY-T3	SONY-T7	
原始類別	Canon-20D	77.6	0	0.1	0.2	0.6	0	0	0.5	0	2.3	1.5	0	0.2	0.6	0.3	0.6	5.5	0	0	0	86.2
	Canon-300D	0	87.8	0	0.7	0	0.1	0	0	0.9	0.3	0	0.1	0	0	0.1	0	0	0	0	0	97.5
	Canon-G3	1.1	0	80.8	2	0.1	2	0	0.1	0	0.2	0	0	0.2	0	3	0	0.4	0	0.1	0	89.7
	Canon-Ixus700	0	1.1	0.5	74.6	3.9	0	0	0	2.2	0.3	3.5	0.2	1.1	0.4	0.1	0	0.3	0	1.4	0.4	82.8
	Fuji-F410	4.6	0	0.9	4.4	72.9	0	0.1	4	0.2	0.4	0.8	1.1	0.1	0	0.2	0	0.2	0	0.1	0	81
	Minolta-X20	0	0	0.1	0	0	83.4	0	0	0	0	0	0	0	0	6.5	0	0	0	0	0	92.6
	Nikon-D50	0	0.5	0.1	0	0	0	88	0	0	0	0	0	0	0	0.4	0	0	0	0	0	97.7
	Nikon-E995	0.8	0	0	0.4	0.8	0	0	81	0	0.4	0.4	1.2	1.9	0	0.6	0	2.2	0	0.2	0.1	90
	Olympus-C300	3.2	0	0.1	1.6	0	0	0.5	0.4	70.5	0.2	1	0.3	3.5	6.6	0	0	0.5	0.1	0.8	0.7	78.3
	Olympus-E300	3.4	2.2	2.4	0.1	1.1	1.2	0	1.7	0.1	71.8	0.7	0.1	0.4	0	1.3	0	3.4	0.1	0	0	79.7
	Panasonic-FX8	2.1	1.7	0	1.4	0.9	0.3	0	1.2	0.9	1.7	65.7	1.7	3.6	6.1	0.2	0	1.2	0	1.3	0	73
	Pentax-S	0.9	0.5	0.5	2	0.5	0.1	0	0.5	0.1	0.1	1.8	67.7	3.5	6.5	0	0	4.7	0	0.3	0.3	75.2
	SONY-N1	0.3	1	0.1	1.4	0.2	0	0	1.5	1.9	0	5.6	4.6	67.4	1.7	0.2	0	1.7	1.9	0.3	0.2	74.8
	SONY-P1	1.8	0	0.2	0.4	0.4	0	0	0	3.4	0	4	1.5	0.1	75.6	0	0	0.9	0	1	0.7	84
	SONY-P51	1.5	0.2	3	0.3	0.3	8.8	5.1	1.2	0	1.8	0	0	0.8	0	64.8	0	1.2	0	0	0.4	72
	SONY-P8	0.8	0.1	0	0	0.2	0	0	0	0	0.3	0.1	0	0.2	0	0.5	0	87.7	0	0	0.1	97.4
	SONY-P9	0.5	0	0.4	0.1	0	0	0	0	0	0.1	0	0.1	0.4	0.1	0.6	0	86.8	0	0.2	0.7	96.4
SONY-T1	0	0.8	1	2.2	0.2	0	0.1	1.2	0	0.3	0	0.3	0.5	0	0.1	0.1	0	81.9	1.2	0.1	91	
SONY-T3	0.4	0	0.6	1.3	0	0	0	0.1	0.2	0	0.8	1.3	0.4	6	0	0	0.6	0	75.6	2.7	84	
SONY-T7	0	0.7	0	0.3	0	0	0	0	0	0	0	0	0	0	0	0	1	0	3.8	84.2	93.5	

結果說明：從表 16 之實驗圖表中，我們可以發現在多台相機且廠牌不相同、型號不相同的情況下，因為實驗誤差的關係，分類辨識率會隨著相機數增加而降低分類辨識率。

(二) 個案 2-2

實驗環境：人手一支手機相機已經是非常普遍的現象，然而數位照片的取得方式不再只侷限於數位相機。本實驗使用 6 台同廠牌相機(3 台數位相機、3 台手機相機)各拍攝 150 張相片，選取其中的 60 張當 Train Data 以及 90 張當 Test Data。

表 17：個案 2-2 之實驗結果

			實驗分類						辨識率 (%)
			數位相機			手機相機			
			感測元件 (CCD)			感測元件 (CMOS)		感測元件 (CCD)	
原始類別			SONY-P1	SONY-P9	SONY-T7	SONY-K600i	SONY-K750i	SONY-S700i	
	感測元件 (CCD)	SONY-P1	90	0	0	0	0	0	100
		SONY-P9	0	89	1	0	0	0	98.9
		SONY-T7	0	2	88	0	0	0	97.8
	感測元件 (CMOS)	SONY-K600i	0	0	1	88	1	0	97.8
		SONY-K750i	0	0	0	0	89	1	98.9
	感測元件 (CCD)	SONY-S700i	0	0	1	0	2	87	96.7

結果說明：從表 17 之實驗圖表中，我們可以發現使用不相同的影像擷取設備(數位相機或手機相機)，以及不同的感測元件(CCD 或 CMOS)的分類結果，仍有良好之辨識率。而和表 16 相比，SONY 數位相機的辨識率都有所提高，這是因為相機的比較數目減少的原因；同時，手機的感測元件和數位相機不同，對於影像的特徵值擷取，也有幫助。

伍、研究前提與限制，相關討論

本研究試圖能夠利用多個實驗個案數據針對影像內容、影像特徵擷取類別、相機廠牌型號、SVM 模型訓練影像數量、感測元件與參與分類相機數量...等方向來分析對於分類辨識率的影響。雖然在個案實驗中的高辨識率能驗證本文所使用的方法流程確實能夠有效的追溯影像的來源相機，但也產生了以下幾點研究限制。

從個案 1-2 的實驗數據，我們雖然可以認定在影像內容相似度極高的理想狀態下，每次實驗都有高達 100% 的分類辨識率，但是對照個案 1-4 的實驗數據結果，也發現同一台數位相機針對拍攝出來的兩種不同影像內容，可能無法完全辨識出其實是源自於同一台相機的作品。這個結果，讓我們得到了：影像內容確實會影響辨識率的實驗成果，也就是影像相似度與否對於相機辨識率確實影響甚巨。這限制可能是因本文採用影像特徵值擷取方法之特性所致。

從個案 1-9 的實驗數據，我們可以發現，如果一張數位影像資料經過影像處理軟體的後製處理，將不適合進行分類辨識的實驗。尤其以目前在影像處理軟體人手可得

的情況之下，如果我們想要得到一個正確無誤的分類辨識實驗數據，則必須先針對參與實驗的數位影像照片先作影像真偽辨識的前處理，否則任一張非原始影像都有可能造成實驗數據的誤差。

從個案 2-1 的實驗結果我們可以發現，越多台數位相機參與辨識實驗會因為實驗統計資料之誤差值造成辨識率下降的自然現象。因此在本文所使用的分類方法之下，宜盡量減少參與分類的相機數量或是必需相對地提高訓練相片的數量，將可以提高分類辨識率的品質；在本實驗中，每台相機仍維持共拍攝 150 張影像，60 張為訓練資料，90 張為驗證資料；根據個案 1-5 與 1-6 的討論，在相機數增加的情況下，訓練資料也必須同時增加才能維持適當的辨識率，不過，若維持本實驗的條件，將可得到辨識率預期的最低水準。

由第三點的實驗限制中我們可以瞭解參與分類相機數量的多寡會影響實驗辨識率。同理，在個案 1-5 與 1-6 數據顯示 SVM 模型訓練需要的影像數量也同樣會影響辨識率。所以針對 SVM Train Data 數量之最佳值，我們尚無法結論出最佳的實驗張數應該為多少，因為從個案 1-7 與 1-8 的實驗數據中，我們瞭解這與影像內容之相似度有極大的相關性。就算影像內容相似度這個因素考慮進來了，也還有同廠牌與不同廠牌的因素在裡面，考慮到數位相機廠商為了節省成本與市場區隔，會有許多類似的同系列相機款式；這些款式之間大多具有相同的 CCD 感測器與接近的款式型號，差別只在於其他搭配不同硬體，我們針對這些類似型號的相機，在有限的資源下進行實驗，並從結果發現：本鑑識方法確實會在類似相機型號下，其拍攝的照片辨識率會出現下降之現象，雖然更精確的研究需要更多廠牌以及更多款式的相機，但藉由本研究已發現此鑑識方法之可能的限制。

在個案 2-2 中，手機相機與數位相機可以明顯有所區分，這主要是因手機的體積限制，兩者尚無共用零件的情況；然而，在硬體技術的進步下，未來可能手機相機與數位相機有共用零件，軟體與硬體的情況產生，屆時辨識率就有可能受到影響。

陸、結論與建議研究方向

一、結論

綜合本研究之各項實驗過程和實驗結果，我們針對本鑑定影像來源方法，提出以下幾項結論：

文獻[7]中，作者採用了至少擷取了 33 至多 57 個特徵值來做分類，在本文中只使用了其中 33 個特徵值，並且我們改善了原有的流程，加入了部分新增的步驟來鑑別影像，除了達到了比參考文獻更好的辨識率，更足以證明本研究之方法是較經濟的。

本文中提出在實驗流程中，引入最佳參數搜尋工具的步驟，除了對於影像辨識率有極大提升作用外，也有效縮短了以往利用試誤法(trial and error)來決定參數的時間。

相較於以往同類型之研究論文，本文除了驗證出廠牌型號會影響分類辨識率之外

也創新提出影像內容、感測元件、影像特徵擷取與影像後處理...等因素對於分類辨識率有一定程度的影響。本文除了提出了影響辨識率的新因素之餘，也實驗驗證出本文所使用的分類方法及流程可以得到極高的辨識率，因此本文之實驗結果有極高之價值。

為因應時代走勢，本文除了實驗驗證數位相機的影像分類，同時也針對時下人手一機之手機相機作交叉實驗分析與討論。實驗結果顯示我們可以依據影像照片找出來源相機之廠牌型號，並且對於同廠牌的相機也具有良好之辨識效果。

二、建議研究方向

針對未來的數位影像鑑識研究，我們提出未來之研究方向為：

除了本文採用文獻[7]之影像特徵向量擷取方法，未來可研究更具有鑑別力的特徵值擷取方法，以克服不論是軟體或硬體方面的研究限制問題。

除了本文所採用的 SVM 之外，未來可以發展新的分類工具或是加入其他分類方法以彌補 SVM 之不足與提高辨識率。

研究各個特徵值之間的相關性，例如，雖然色彩特徵值的單獨辨識率並不理想，但與其他特徵值合併使用後，仍具有可靠的辨識能力，在此，便可討論色彩特徵值與其他特徵值的相關性，或是更細部地針對每一個特徵值之間的相關性進行研究。

取得更多的數位相機，以本研究方法進行綜合分析，並藉由實驗進行交叉比對，獲得更詳細的辨識結果。

藉由與廠商合作，瞭解相機更細部的軟、硬體設計流程，研究以影像特徵向量法之外的方法進行辨識，例如從本研究發現，小波域特徵與影像品質特徵的個別鑑識率最佳，可從這兩個類別進行更細部之研究。

致謝

感謝諸位評審委員對本文所提供的協助與寶貴建議。本文承蒙國科會提供研究經費(NSC 94-2416-H009-018 和 NSC 95-2416-H009-027)，特此致謝。

參考文獻

1. Adams, J., Parulski, K. and Spaulding, K. "Color processing in digital cameras," *Micro, IEEE* (18) Nov.-Dec. 1998, pp:20-30
2. Avcibas, I., Memon, N. and Sankur, B. "Steganalysis using image quality metrics," *IEEE Transactions on Image Processing* (12:2) Feb. 2003, pp:221-229
3. Chang, C.C. and Lin, C.J. "LIBSVM: a library for support vector machines," software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm> 2001

4. Cho, S.B. and Won, H.H."Machine Learning in DNA Microarray Analysis for Cancer Classification," *Asia-Pacific Bioinformatics Conference in Information Technology* 2003
5. Cox, I.J., Miller, M.L. and McKellips, A.L., "Watermarking as Communications with Side Information," *Proceedings of the IEEE* (87:7) Jul. 1999, pp:1127-1141
6. Geradts, Z.J., Bijhold, J., Kieft, M., Kurosawa, K., Kuroki, K., and Saitoh, N."Methods for identification of images acquired with digital cameras." *Proc. SPIE Enabling Technologies for Law Enforcement and Security* (4232) 2001, pp: 505-512
7. Kharrazi, M., Sencar, H.T. and Memon, N."Blind Source Camera Identification," *IEEE International Conference on Image Processing* Oct. 2004 pp:24-27
8. Tsai, M.J."Filter Bank Selection for the Ownership Verification of Wavelet Based Digital Image Watermarking," *IEEE International Conference on Image Processing* Oct. 2004, pp:24-27



附錄：影像特徵值計算公式

$C(i, j)$ 表示影像陣列中橫列第 i 個，縱行第 j 個像素， $\hat{C}(i, j)$ 表示經處理（如被攻擊過）或另一層影像陣列， m, n 表示影像的長、寬；本研究中，影像的長寬固定為 1600、1200（200 萬像素）， N 表示影像之總像素個數：

特徵類別	特徵值	公式
色彩類特徵	RGB 各層之影像平均值 <u>C1(紅色層)</u> <u>C2(綠色層)</u> <u>C3(藍色層)</u>	$C1 = \frac{\sum_{i,j=1}^{m,n} R(i, j)}{N}; \quad C2 = \frac{\sum_{i,j=1}^{m,n} G(i, j)}{N}; \quad C3 = \frac{\sum_{i,j=1}^{m,n} B(i, j)}{N}$
	RGB 中各兩層間之相關係數 <u>C4(紅、綠兩層)</u> <u>C5(紅、藍兩層)</u> <u>C6(綠、藍兩層)</u>	$C4 = \frac{\frac{1}{N} \sum_{i,j=0}^{m,n} (R(i, j) - \overline{R(i, j)}) (G(i, j) - \overline{G(i, j)})}{\sqrt{\frac{1}{N} \sum_{i,j=0}^{m,n} (R(i, j) - \overline{R(i, j)})^2} \cdot \sqrt{\frac{1}{N} \sum_{i,j=0}^{m,n} (G(i, j) - \overline{G(i, j)})^2}}$ $C5 = \frac{\frac{1}{N} \sum_{i,j=0}^{m,n} (R(i, j) - \overline{R(i, j)}) (B(i, j) - \overline{B(i, j)})}{\sqrt{\frac{1}{N} \sum_{i,j=0}^{m,n} (R(i, j) - \overline{R(i, j)})^2} \cdot \sqrt{\frac{1}{N} \sum_{i,j=0}^{m,n} (B(i, j) - \overline{B(i, j)})^2}}$ $C6 = \frac{\frac{1}{N} \sum_{i,j=0}^{m,n} (G(i, j) - \overline{G(i, j)}) (B(i, j) - \overline{B(i, j)})}{\sqrt{\frac{1}{N} \sum_{i,j=0}^{m,n} (G(i, j) - \overline{G(i, j)})^2} \cdot \sqrt{\frac{1}{N} \sum_{i,j=0}^{m,n} (B(i, j) - \overline{B(i, j)})^2}}$
	RGB 中各層之分佈質心 <u>C7(紅層)</u> <u>C8(綠層)</u> <u>C9(藍層)</u>	原座落值 R_i ， $i = 0 \sim 255$ 其中 R_i 代表整張影像中，紅色亮度值為 i 的個數。 新座落值 $R_j = R_{j-1} + R_{j+1}$ ， $j = 1 \sim 254$ $C7$ 為新座標 R_j 中之中位數值 j $C8$ 為新座標 G_j 中之中位數值 j $C9$ 為新座標 B_j 中之中位數值 j
	RGB 中各兩層間之能量比 <u>C10(紅、綠兩層)</u> <u>C11(紅、藍兩層)</u> <u>C12(綠、藍兩層)</u>	$C10 = \frac{\sum_{i,j=1}^{m,n} (R(i, j)^2)}{\sum_{i,j=1}^{m,n} (G(i, j)^2)}; \quad C11 = \frac{\sum_{i,j=1}^{m,n} (R(i, j)^2)}{\sum_{i,j=1}^{m,n} (B(i, j)^2)}; \quad C12 = \frac{\sum_{i,j=1}^{m,n} (G(i, j)^2)}{\sum_{i,j=1}^{m,n} (B(i, j)^2)}$

影像品質類特徵	Mean Error (MSE) <u>Q1</u>	$Q1 = \frac{1}{3} \left(\frac{\sum_{i,j=1}^{m,n} (R(i,j) - \hat{R}(i,j))^2}{N} + \frac{\sum_{i,j=1}^{m,n} (G(i,j) - \hat{G}(i,j))^2}{N} + \frac{\sum_{i,j=1}^{m,n} (B(i,j) - \hat{B}(i,j))^2}{N} \right)$ 其中 $\hat{R}(i,j)$ 為 $R(i,j)$ 影像經過 高斯濾波器 (Gaussian lowpass filter) , $\hat{G}(i,j)$ 為 $G(i,j)$ 影像經過 高斯濾波器 $\hat{B}(i,j)$ 為 $B(i,j)$ 影像經過 高斯濾波器 高斯濾波器 $mask = \begin{bmatrix} 0.0113 & 0.0838 & 0.0113 \\ 0.0838 & 0.6193 & 0.0838 \\ 0.0113 & 0.0838 & 0.0113 \end{bmatrix}$
	Mean Error (MAE) <u>Q2</u>	$Q2 = \frac{1}{3} \left(\frac{\sum_{i,j=1}^{m,n} R(i,j) - \hat{R}(i,j) }{N} + \frac{\sum_{i,j=1}^{m,n} G(i,j) - \hat{G}(i,j) }{N} + \frac{\sum_{i,j=1}^{m,n} B(i,j) - \hat{B}(i,j) }{N} \right)$
	Minkowski Metrics <u>Q3</u>	$Q3 = \frac{1}{3} \left[\max(R(i,j) - \hat{R}(i,j)) + \max(G(i,j) - \hat{G}(i,j)) + \max(B(i,j) - \hat{B}(i,j)) \right]$
	Structural Content <u>Q4</u>	$Q4 = \frac{1}{3} \left(\frac{\sum_{i,j=1}^{m,n} R(i,j)^2}{\sum_{i,j=1}^{m,n} \hat{R}(i,j)^2} + \frac{\sum_{i,j=1}^{m,n} G(i,j)^2}{\sum_{i,j=1}^{m,n} \hat{G}(i,j)^2} + \frac{\sum_{i,j=1}^{m,n} B(i,j)^2}{\sum_{i,j=1}^{m,n} \hat{B}(i,j)^2} \right)$
	Normalized cross-correlation <u>Q5</u>	$Q5 = \frac{1}{3} \left(\frac{\sum_{i,j=1}^{m,n} R(i,j)\hat{R}(i,j)}{\sum_{i,j=1}^{m,n} \hat{R}(i,j)^2} + \frac{\sum_{i,j=1}^{m,n} G(i,j)\hat{G}(i,j)}{\sum_{i,j=1}^{m,n} \hat{G}(i,j)^2} + \frac{\sum_{i,j=1}^{m,n} B(i,j)\hat{B}(i,j)}{\sum_{i,j=1}^{m,n} \hat{B}(i,j)^2} \right)$
	Czekonowski correlation <u>Q6</u>	$Q6 = 1 - \frac{2 \times \left(\sum_{i,j=1}^{m,n} \min(R(i,j), \hat{R}(i,j)) + \sum_{i,j=1}^{m,n} \min(G(i,j), \hat{G}(i,j)) + \sum_{i,j=1}^{m,n} \min(B(i,j), \hat{B}(i,j)) \right)}{\sum_{i,j=1}^{m,n} (R(i,j) + \hat{R}(i,j) + G(i,j) + \hat{G}(i,j) + B(i,j) + \hat{B}(i,j))}$

Spectral magnitude error <u>Q7</u>	Fast Fourier Transform = FFT(R) , $FR = \text{fft}(R)$, $F\hat{R} = \text{fft}(\hat{R})$ $JR = \sqrt{\left(\sum_{i,j=1}^{m,n} \left(FR(i,j) - F\hat{R}(i,j) \right)^2 \right)}$ $JG = \sqrt{\left(\sum_{i,j=1}^{m,n} \left(FG(i,j) - F\hat{G}(i,j) \right)^2 \right)}$ $JB = \sqrt{\left(\sum_{i,j=1}^{m,n} \left(FB(i,j) - F\hat{B}(i,j) \right)^2 \right)}$ $Q7 = \frac{1}{3}(JR + JG + JB)$
Spectral phase error <u>Q8</u>	經過 FFT 之後的 Phase , 表示為 $PR = \text{Angle}(FR)$, $P\hat{R} = \text{Angle}(F\hat{R})$ 同理可得 PG 、 $P\hat{G}$ 、 PB 與 $P\hat{B}$ $AR = \sqrt{\left(\sum_{i,j=1}^{m,n} \left(PR(i,j) - P\hat{R}(i,j) \right)^2 \right)}$ $AG = \sqrt{\left(\sum_{i,j=1}^{m,n} \left(PG(i,j) - P\hat{G}(i,j) \right)^2 \right)}$ $AB = \sqrt{\left(\sum_{i,j=1}^{m,n} \left(PB(i,j) - P\hat{B}(i,j) \right)^2 \right)}$ $Q8 = \frac{1}{3}(AR + AG + AB)$
Spectral phase-magnitude error <u>Q9</u>	$\alpha = 2.4916 \times 10^{-5}$ $Q9 = \frac{1}{3}(\alpha \cdot JR + (1 - \alpha) \cdot AR + \alpha \cdot JB + (1 - \alpha) \cdot AB + \alpha \cdot JG + (1 - \alpha) \cdot AG)$
Block spectral magnitude error <u>Q10</u>	$Q10 = \text{median} J_m^l$ $J_m^l = \frac{1}{K} \sum_{k=1}^K \left(\sum_{u,v=0}^{b-1} \left[\Gamma_k^l(u,v) - \hat{\Gamma}_k^l(u,v) \right]^r \right)^{1/r}$
Block spectral phase error <u>Q11</u>	$Q10 = \text{median} J_\phi^l$ $J_\phi^l = \frac{1}{K} \sum_{k=1}^K \left(\sum_{u,v=0}^{b-1} \left[\phi_k^l(u,v) - \hat{\phi}_k^l(u,v) \right]^r \right)^{1/r}$
Block spectral phase-magnitude error <u>Q12</u>	$Q10 = \text{median} J^l$ $J^l = \lambda J_m^l + (1 - \lambda) J_\phi^l$

影像頻率類特徵	紅色層小波轉換 各頻帶平均係數 <u>W1(Vertical)</u> <u>W2(Horizonral)</u> <u>W3(Diagonal)</u>	$W1 = \frac{\sum_{i,j=1}^{m/2, n/2} R_V(i, j)}{N/4}; \quad W2 = \frac{\sum_{i,j=1}^{m/2, n/2} R_H(i, j)}{N/4}; \quad W3 = \frac{\sum_{i,j=1}^{m/2, n/2} R_D(i, j)}{N/4}$
	綠色層小波轉換 各頻帶平均係數 <u>W4(Vertical)</u> <u>W5(Horizonral)</u> <u>W6(Diagonal)</u>	$W4 = \frac{\sum_{i,j=1}^{m/2, n/2} G_V(i, j)}{N/4}; \quad W5 = \frac{\sum_{i,j=1}^{m/2, n/2} G_H(i, j)}{N/4}; \quad W6 = \frac{\sum_{i,j=1}^{m/2, n/2} G_D(i, j)}{N/4}$
	藍色層小波轉換 各頻帶平均係數 <u>W7(Vertical)</u> <u>W8(Horizonral)</u> <u>W9(Diagonal)</u>	$W7 = \frac{\sum_{i,j=1}^{m/2, n/2} B_V(i, j)}{N/4}; \quad W8 = \frac{\sum_{i,j=1}^{m/2, n/2} B_H(i, j)}{N/4}; \quad W9 = \frac{\sum_{i,j=1}^{m/2, n/2} B_D(i, j)}{N/4}$