

國立政治大學商學院統計學系

碩士學位論文

圖像資料結構化與分類的探討

A Study of Image Structurization and Classification

指導教授：陳麗霞 博士

余清祥 博士

研究生：莊于萱 撰

中華民國 110 年 07 月

摘要

資料以各種形態存在於我們生活中，寫過的每一篇文章，甚至拍過的每一張照片，透過適當的數位化皆可由量化分析挖掘出其中的重要訊息。過去資料分析大多侷限在數字格式，隨著電腦相關技術的發展，資訊解讀擴展至文字、圖像、音樂等各種類型的資料，我們的生活因為資訊傳遞快速、即時判讀而更加便利，影像辨識、自動駕駛等應用就是眾所周知的應用。資料格式多元、傳遞交換便捷，都是大數據時代的特點，使得資訊安全及品質愈形重要，如何解讀龐雜的大數據，更是政府及個人必備的關鍵能力。不具固定格式資料稱為非結構資料，而解讀這類型資料的首要挑戰為數位化格式，但轉檔方式與研究目標、資料屬性關係密切，很難訂出一個絕對標準。

以圖像辨識為例，資料應轉換成三原色（紅綠藍，RGB：Red、Green、Blue）或是圖像形狀及大小，至今仍無定論；即便是以顏色紀錄，是否也需考量色彩飽和度、亮度等資訊？有鑑於圖像資料尚無統一的格式化，本文以視覺感受的方式定義變數，比較冷暖色、RGB、灰階、邊緣檢測、分割圖像等方法，協助分類不同風格的圖像。由於圖像辨識結果多半與其屬性有關（Data Dependent），本文分析三種類型的圖像資料：臺灣報紙頭版、美國 Vogue 雜誌封面、十九世紀油畫（現實派、印象派），其內容包含文字、照片（及圖片）、繪畫，再結合統計分析、機器學習模型，藉由電腦模擬與交叉驗證，探討不同的圖像格式方法、模型及其參數的分類準確性。研究結果顯示，分類準確性隨著解析度上升而提高，100×100 即有不錯的效果；而圖像格式化中以分割圖像法最佳，用於不同圖像資料及分析模型的分類準確性較高。

關鍵詞：圖像辨識、資料結構化、圖像風格、分割圖像、解析度

Abstract

Data exists in various forms, including articles we write and photos we take. We can dig out important information through appropriate digitization and quantitative analysis. Data analysis was usually limited to data with digital format and now has expanded to all kinds of data, such as text, images, and music. Rapid data transmission and real-time analysis brings convenience to our lives, and image recognition and autonomous driving are two famous applications. The ability of analyzing messy and complicated data is a key ability in Big Data era. However, more than 90% of data are unstructured data and it needs to convert them into digital format before plugging into data analysis. But the conversion method is closely related to the research objectives and data attributes. Taking image recognition as an example, there is no consensus if the image data should be converted into three primary colors (red, green and blue, RGB) or their shape and size should also be considered.

This study aims to explore different structurization methods for image data and evaluate which method, after plugging into classification models, has the highest accuracy in classifying images . We consider three types of image data: Taiwanese newspapers, Vogue magazine, and nineteenth century oil paintings, since the classification results are often data-dependent. We will apply statistical and machine learning models to explore classification accuracy of different image format methods. The analysis results show that the classification accuracy increases when the resolution becomes higher, and 100×100 resolution can provide sufficiently satisfactory results. We found that the splitting method has highest accuracy in image classification, for three types of image data and different classification models.

Keywords: Image Recognition, Data Structurization, Image Style, Splitting method, Resolution

目次

第一章 緒論.....	1
第一節 研究動機.....	1
第二節 研究目的.....	2
第二章 文獻探討.....	3
第一節 文獻回顧.....	3
第二節 資料介紹.....	5
第三章 研究方法.....	9
第一節 色彩空間.....	10
第二節 Canny Algorithm.....	13
第三節 顏色檢測.....	16
第四節 分類模型.....	20
第四章 圖像分析.....	25
第一節 探索性資料分析.....	25
第二節 參數設定.....	35
第三節 圖像風格分類-二分類.....	37
第四節 圖像風格分類-多分類.....	40
第五章 結論與建議.....	44
第一節 結論.....	44
第二節 未來建議.....	45
參考文獻.....	47

表次

表 3-1、HSV 空間顏色範圍	16
表 3-2、色系比例範圍對照表	17
表 4-1、各種資料的分類準確性比較.....	41
表 4-2、台灣四大報多分類之混淆矩陣.....	42
表 4-3、Vogue 雜誌多分類之混淆矩陣.....	43
表 4-4、十九世紀油畫多分類之混淆矩陣.....	43



圖次

圖 2-1、2015 年 1 月 12 日臺灣四大報報紙頭版.....	6
圖 2-2、1970~2009 年 Vogue 雜誌各時期封面特色	7
圖 2-3、莫內-《印象·日出》(左)、米勒-《拾穗》(右)	8
圖 2-4、本文圖像資料結構化方法示意圖	9
圖 3-1、RGB 顏色空間示意圖	11
圖 3-2、HSV 顏色空間示意圖	12
圖 3-3、Splitting Feature 示意圖	19
圖 3-4、Level-wise Tree 示意圖	21
圖 3-5、Leaf-wise Tree 示意圖	21
圖 3-6、CNN 概念圖	22
圖 3-7、卷積層示意圖	23
圖 3-8、Pooling 示意圖	23
圖 3-9、全連接層	24
圖 4-1、台灣四大報之色系比例 (左)、黑色比例 (右)	26
圖 4-2、台灣四大報之 RGB 平均值 (左)、HSV 平均數 (右)	27
圖 4-3、台灣四大報之 RGB 標準差 (左)、HSV 標準差 (右)	28
圖 4-4、Vogue 雜誌之色系比例 (左)、黑色比例 (右)	29
圖 4-5、Vogue 雜誌之 RGB 平均值 (左)、HSV 平均數 (右)	30
圖 4-6、Vogue 雜誌之 RGB 標準差 (左)、HSV 標準差 (右)	31

圖 4-7、十九世紀油畫之色系比例（左）、黑色比例（右）	32
圖 4-8、十九世紀油畫之 RGB 平均值（左）、HSV 平均數（右）	33
圖 4-9、十九世紀油畫之 RGB 標準差（左）、HSV 標準差（右）	34
圖 4-10、解析度與分類準確度	35
圖 4-11、Splitting Feature 分割次數模擬結果.....	36
圖 4-12、圖像風格二分類結果	38
圖 4-13、不同分類模型的比較	39
圖 4-14、CNN 與其他模型的比較.....	40



第一章 緒論

第一節 研究動機

電腦科技使我們的生活更加便利，全面性的數位化不止提升效率，更改變人際關係、工作學習、資訊交通等，因此有人稱現在是大數據時代。傳統的量化分析大多侷限在數值類型的資料，因為電腦等相關科技的發展，資料分析已可應用於圖像、文字、音樂等紀錄，這些資料稱為非結構資料 (Unstructured Data)。事實上，每天接觸的大多數都是非結構資料，未必具有一定的格式，蘊含資訊卻比數字格式的資料 (結構資料，Structured Data) 豐富，應用的層面也相對廣泛。像是人臉辨識、自動駕駛就是兩個知名應用範例，可以減少人力運作成本、減少人為疏失的錯誤判斷，同時也能夠提高執行效率及工作規模，因此許多產業積極投入非結構資料的研究發展。

過去非結構資料的應用受限於兩個因素：紀錄交換、分析判斷。由於非結構資料沒有固定的儲存格式，即便是同一個組織或機構，也可能因為各時間點的紀錄格式不同，資料合併統整會遭遇意料之外的難題。事實上，即便是結構資料也會因為格式改變而引發問題，2000 年的千禧蟲之亂 (Year 2000 Problem，簡稱 Y2K) 就是一個知名的典範，年度紀錄改變 (兩碼到四碼) 就能引起全球動亂。不同組織間的資料傳遞帶來更多元的挑戰，以個人電腦常見的兩個系統 (IBM 個人電腦、蘋果電腦) 為例，即便是透過微軟開發之 Office 軟體製作的文書檔案，像是 MS Word 或是 Power point 等文件，在 IBM 和蘋果兩個電腦作業系統下經常遭遇相容性的問題。

分析非結構資料時的注意事項與上述資料格式改變類似，會因為問題目標、資料屬性而調整，通常首要步驟在於資料的量化，亦即經過資料結構化 (Structurization) 處理，將非結構化資料轉變成可判讀的形式。比方說，在文字資料前處理中，會將文章中的字、詞作為結構化之變數，而變數值可能為詞頻、字詞

相似度等。如此作法，不但可將非結構資料轉為統一格式，同時也將資料以量化的方式，以利後續分析。而在圖像資料中，並不像文字資料一樣具有相同的基本單位，所以如何定義圖像結構化的方法，也成為分析圖像資料關鍵步驟。

第二節 研究目的

本文以圖像資料作為研究目標，探索較為合適的結構化方法，以便進行圖像風格的判斷。除了一般認知的圖像紀錄方式，像是光的三原色（紅綠藍，Red、Green、Blue）之外，本文也參考過去文獻，加入其他研究的圖像結構化方法，再配合自己的想法，藉此找出圖像資料中最佳結構化方法。另外，為了確保研究結果盡量與資料屬性無關（亦即 Data Dependent 的問題），本文使用三種類型的圖像資料：臺灣報紙頭版、美國 Vogue 雜誌封面、十九世紀油畫（現實派、印象派），其內容包含文字、照片（及圖片）、繪畫三種類型。

現今許多圖像結構化的方法，經常使用圖像中的顏色、形狀作為結構化的變數，但在不同研究中，結構化的作法皆有不同。本文同樣想以顏色、色彩的觀感、形狀等，作為圖像結構化方法的出發點，並且考慮到圖像色調展現的風格、圖像位置的資訊，根據圖像的特點，改進變數的量化方法，比較冷暖色、RGB、灰階、邊緣檢測、分割圖像等方法，協助分類不同風格的圖像。除了考慮結構化的方法外，圖像在不同解析度下的準確率不同，故以模擬的方式找出最適參數。接著使用監督式學習的模型，進行結構化方法的比較。由此方式找出圖像資料最佳結構化的方法，最後再與 Convolutional Neural Network（CNN）方法比較。

第二章 文獻探討

本章將整理圖像分析的相關研究，介紹哪些資料結構化方法曾經被採用。過去圖像研究大多會考慮顏色（如：光三原色、灰階等），也有研究會因為目標及應用需要，提出不同的結構化方法，像是醫學上判斷腫瘤或傷口的形狀。除了過去相關研究外，本文的圖像結構化也從較為直覺的方式著手，像是顏色、形狀作為結構化方法的出發點，並且考慮圖像的位置能夠提供圖像的資訊，提出圖像切割法的想法。

第一節 文獻回顧

探討圖像結構化方法前需先了解，資料以何種方式儲存於電腦中。Susstrunk 等人（1999）以光譜波長定義光的三原色（Red、Green、Blue），將圖像映射在電腦三原色（稱 RGB）空間中，使得電腦能夠透過 RGB 空間顯示圖像。考慮紅、綠、藍顏色波長長度不同問題，所以將波長標準化，其中數值標準化轉換介於 0 至 255 之間，最終將圖像以三維矩陣的方式表示。由此，圖像技術的發展皆可透過 RGB 空間的轉換而成，而 RGB 空間轉換也成為圖像分析基本的一環。因為三原色(RGB)可以組成不同顏色，所以可以將 RGB 視為一種顏色的代表，Chen(2001)使用 RGB 空間的方式，將 RGB 值 0 至 255 視為 256 個變數，計算這 256 個變數在圖像矩陣出現的次數，以總數的方式作為顏色變數的定義。

除了以轉換成 RGB，有些研究會將圖像以 Hue, Saturation, Lightness（HSV）格式呈現，HSV 空間代表著圖像的色調、飽和度、明度，突顯圖像色彩的特性。HSV 空間的變數呈現類似 RGB，也是將圖像視為三度空間，施振祥(2010)使用 HSV 的方法，將 HSV 矩陣中，0 至 255 作為 256 個變數，計算 0 至 255 共出現幾次，作為顏色特徵的變數。陳俊華（2012）將 HSV 空間以矩陣展開的方式，作為顏色變數，透過 SVM 方法對圖像進行分類。Lee（2016）計

算 HSV 三空間的平均值做為顏色的變數，使用於畫作風格分類，這樣的作法不但能減少資料的維度，又能夠表達圖像中顏色的特性。

除了顏色的特性外，圖像的形狀，也能夠表現圖像的特色，而在過去也有許多方法提及，使用邊緣檢測的方法將圖像的形狀框出。Salman (2017) 為了判斷醫藥用植物材料，使用邊緣 (Edging) 檢測對 22 種藥材進行視覺判斷，藉由先將藥材大概輪廓描繪出來，再依照將形狀做為判斷藥材類型的依據。Rabby (2018)，使用圖像分析用於水果辨識與水果品種分類；使用 Sobel、Canny Algorithm 等邊緣檢測的方法，除了可以判斷水果的可能形狀，也可用於能判斷出水果的位置。Ramamurthy (2019)，使用圖像邊緣檢測、再加入 HSV 顏色資訊，將皮膚上可能為傷口或是病變的位置框出，把這種方法套用於影像資料，結果顯示可偵測 9 成以上有異樣的皮膚。

除了 RGB、HSV 之類資料轉檔，圖像結構化也需考慮解析度 (Resolution)。圖像通常以二維方式紀錄，每一區塊與相鄰區塊皆為連續，解析度愈高、資料完整性也愈高。以二維圖像為例，如果每個維度都切割成 100 等分，圖像就可視為 $100 \times 100 = 10,000$ 個變數 (或子區域) 組成的資料，再在每個子區域考量結構化。孔萬增 (2007) 將人臉圖像切割成數個大小相同、互不重疊的子樣本，接著對子樣本進行變數選擇，在每個子樣本使用主成分分析 (Principal Component Analysis, PCA)，經過變數 PCA 降維後再代入分類模型。任大勇 (2019) 針對花朵圖像進行切割，將分割子區域進行色彩計算，在透過圖片降噪手法，能夠更精準地辨識圖像。

本文將根據 RGB、顏色空間等方法將圖像資料轉檔，再代入幾種分類模型 (統計、機器學習模型)，以分類準確率為衡量標的，目標在於找到較為合宜的圖像結構化方法。在結構化方法中參考上述顏色與形狀的想法，除了 RGB、HSV 空間的顏色特性，也加入色系與色彩豐富度的資訊；另外，本文也會使用邊緣檢測之類的方法，將圖像的形狀與排版等資訊加入，同時考慮圖像空間的分佈，使用分割圖像，

表達圖像位置的概念。而在過去文獻中，鮮少提到解析度參數的問題，故本文一併將解析度的問題加入文章中討論。

第二節 資料介紹

本文目的在於找到圖像資料結構化的方法，故本文採用不同方法實驗於三種不同類型的圖像資料，其中，又區分圖像內容中包含文字資訊、照片資訊、人物資訊或者圖畫作品，在此以台灣四大報頭版圖片、Vogue 雜誌封面、油畫為實驗資料，透過這三種資料進行研究，使用不同變數方法來找出適合的結構化方式，最後再對各方法進行比較。同時，透過多種資料討論，使用的圖像資料結構化方法，是否有出現資料依賴性的問題。

一、台灣四大報 (Newspapers)

於 1988 年報禁解除後，台灣報社琳瑯滿目，《蘋果日報》於 2003 年創社後，與《中國時報》、《自由時報》、《聯合報》稱為「台灣四大報」。四大報紙為綜合報紙，在頭版排版上各具有不同特色。《中國時報》、《自由時報》、《聯合報》排版較為固定，頭版報導多為政治新聞。《聯合報》經常使用真實場景未經特效處理的照片，標題字型具多樣性。《中國時報》頭版面包含多則重要新聞。《自由時報》經常於頭版使用天氣圖、小標題。《蘋果日報》多使用照片與彩色標題，篇幅多報導犯罪新聞¹。本文採用 2014~2019 年間台灣四大報頭版圖片，報紙頭版圖片中，包含頭條標題、文字報導、事件照片與動畫圖片等，四家報社各自擁有獨有的風格。

¹ 參考報紙消費者對頭版新聞形式與內容喜好度研究 (柯裕嘉, 2011)。



圖 2-1、2015 年 1 月 12 日臺灣四大報報紙頭版

在此以 2015 年 1 月 12 日頭版新聞為例說明四大報頭版的特色（圖 2-1），當日各家媒體均報導禽流感事件，使用了相同的照片於頭版中，但各家報紙呈現的版面與風格截然不同。《中國時報》以圖作為主軸，加入些許文字內容敘述，《蘋果日報》以圖表佔滿全部版面，《自由時報》以報導文字內容為頭版版面，《聯合報》雖與《中國時報》相同，圖片佔大部分版面，加上些許文字敘述，但可明顯得看出使用得圖片相較於《中國時報》樸素。圖 2-1 的頭版報導，可以明顯看出四家報紙的版面呈現的不同，讀者可由目視比較出各報的主要特色，預期透過合適的圖像結構化，模型應可偵測出各報的差異。

二、美國 Vogue 雜誌

Vogue 是 Condé Nast Publications Inc 於 1892 年所發行的時尚雜誌，起初為週刊，後為月刊，Vogue 雜誌一直在時尚界引領風潮，透過雜誌更能知道女性時尚的起伏與變遷，Vogue 不斷的改革與創新，使得超過百年的歷史，雜誌記錄著世代的時尚風格，本文採用 1970 年代至 2000 年代，十年為一個時代，一年為十二個月份，四個時代總共 480 份雜誌封面作為資料。雜誌封面以人物為主軸，根據四個時代的雜誌封面，對於時尚風格轉變作為研究目標。

由美國耶魯大學人文實驗室，實驗 Vogue 雜誌封面由 1892 年至 2021 年每十年抽樣，觀察雜誌封面覆蓋圖。實驗指出 1970 年代、1980 年代，封面人物定位相同，並且頭部角度呈現一致。與後來數十年的雜誌封面呈現鮮明的對比²。透過實驗發現，雜誌封面人物的姿勢也傳遞著女姓在社會上的角度。水平躺著會讓人聯想到順從的行為，而直立的角度則顯示出優勢³。由 Vogue 雜誌中，不僅僅能夠發現時尚風格的演變，亦能從中探討歷史上女性地位的趨勢。




圖 2-2、1970~2009 年 Vogue 雜誌各時期封面特色

三、西方油畫 (Painting)

本論文使用西方油畫作為研究素材。其中，我們挑選了 19 世紀盛行的畫風，現實主義 (Realism)、印象派 (Impressionism) 作為研究圖像。現實主義畫作為 1840 年代，工業革命時期。畫作風格為繪畫的真實樣貌來反映生活，並通過藝術形象的典型化，揭示生活的本質和規律⁴。其主要代表作家為柯洛 (西元 1796~1875)、米

² 參考 Vogue Cover Averages (Leonard, 2013)。

³ 參考 Female image in Vogue magazine: A pictorial analysis of facial and body language (Wong, 2014)。

⁴ 參考西班牙藝術夜空裡的星光-寫實主義的委拉斯蓋茲與浪漫主義的哥雅 (龔如森, 2016)。

勒（西元 1814~1875）。印象派繪畫特色在於借助光與色的變換來表現所捕捉到的現象，以瞬間的印象作畫，描繪的筆法較為粗放⁵。代表的作家為竇加（西元 1834~1917）、莫內（西元 1862~1925）。其中畫派隨著時間演變成為不同時期。以印象派為例，可分為印象派（西元 1860~19 世紀末）、新印象派（西元 1886~）、後印象派（西元 1878~20 世紀初）。在不同時期中，又各具有不同特色。本文使用的三位畫家竇加、莫內皆屬於印象派（西元 1860~19 世紀末）。其特色在於理性又客觀的描繪光線變化的效果⁶。

以兩幅畫作比較現實主義、印象派的特色（圖 2-3），左圖為莫內的《印象·日出》，右圖為米勒的《拾穗》。莫內的《印象·日出》表現出印象派畫作⁷，注重光影的表現，並且以色彩微妙的變化展現物景。米勒的《拾穗》具體表現當時的實景⁸，由這兩幅畫作比較，可以明顯看出畫風的差異。有鑑於現實主義、印象派兩個畫派的風格較為容易辨識，本文以兩種畫派為圖像辨識的研究素材，其中現實主義有三位畫家：柯洛 400 幅畫作、米勒 129 幅畫作、馬奈 112 幅畫作；印象派則有兩位畫家：竇加、莫內各 400 幅畫作。



圖 2-3、莫內-《印象·日出》（左）、米勒-《拾穗》（右）

⁵ 參考 Impressionism (Phoebe, 1997)。

⁶ 參考印象派繪畫 (劉振源, 1900)。

⁷ 參考從《印象·日出》談印象派油畫之美 (黃衍翠, 2010)。

⁸ 參考米勒《拾穗》賞析 (胡毅, 2015)。

第三章 研究方法

本文研究方法中，提及圖像資料結構化方法與風格分類模型方法。圖像資料結構化方法，以圖像像素值顏色、圖像內容中物件的形狀、圖像位置資訊作為三個將圖像資料結構化方法的方向。在圖像像素值顏色方法中，使用三種方法來表達圖像像素值顏色的資訊。圖像映射在色彩空間中，將圖像資訊轉為像素值矩陣，在本文採用 RGB、HSV 顏色空間作為代表。圖像像素顏色也使用顏色空間(RGB、HSV)的平均數、標準差，並且添加暖色系、冷色系的資訊，衍生為 Color Feature 的顏色變數。圖像內容中物件形狀，採用兩種方法表達。灰階 (Gray) 圖片，是將圖片中明亮程度表達出圖像內容物的樣貌，故使用灰階作為圖像物件形狀變數。使用邊緣值檢測 (Canny Algorithm)，透過計算將圖像物件形狀的可能邊緣描繪出來，以線條方式表達物件外框的形狀。最後，考慮圖像資料當中，區塊的不同，蘊含不同程度的資訊，所以將圖像均勻的切成數個子區域，並透過計算將子區域的資訊合併，成為 Splitting Feature。下方為本文使用的方法示意圖。

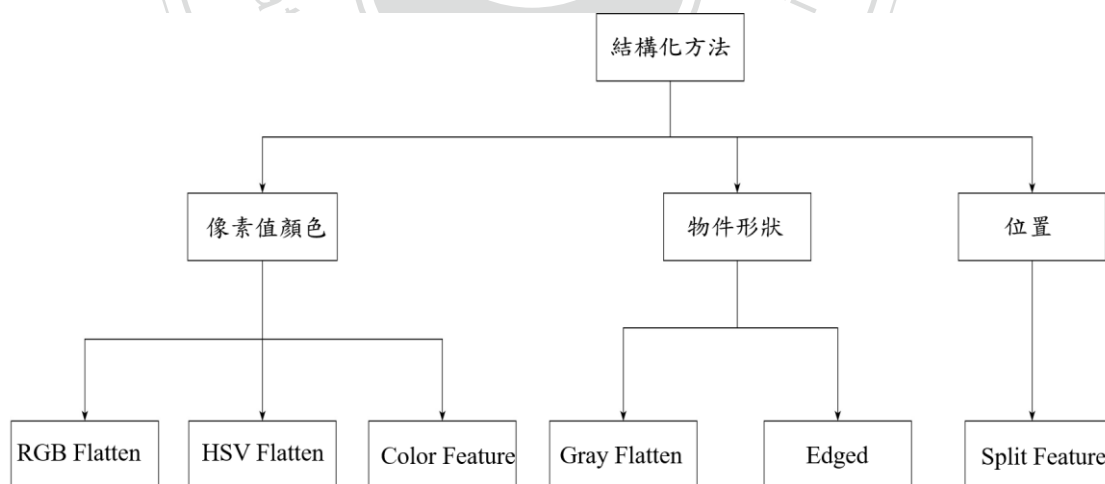


圖 2-4、本文圖像資料結構化方法示意圖

在風格分類方法上，採用監督式學習模型（Supervised Model）作為分類的依據。將圖像資料結構化方法作為進入模型的變數，在此會比較 RGB Flatten、HSV Flatten、Color Feature、Gray Flatten、Edged、Splitting Feature，共 6 種方法。以統計學習模型（羅吉斯回歸）、機器學習模型（Light GBM）進行模型比較。為了討論圖像風格分類以結構化的方法進行結果優劣，採用深度學習模型（卷積神經網路），針對非結構化方式，進行風格分類。

第一節 色彩空間

一、Gray Flatten（灰階）

圖片除了顯示黑色與白色外，還可以顯示不同程度的灰色，黑白照片就是用灰階來表達，灰階值指的是不同程度的亮度，亮度通常以 8 位元（8 bit）方式儲存，亮度值的範圍介於 0~255，代表亮度具有 256 個不同程度的階層，亮度值為 0 時，代表最暗的黑色，亮度值為 255 時，代表最亮的白色。由於灰階圖片是以不同程度的亮度值組成，故能在圖片中顯示真實的景物。在灰階圖片中，透過照片的亮度，來呈現圖像的樣貌。而灰階圖片透過電腦顯示的方式，為一維矩陣。放入模型中的變數呈現為將灰階矩陣展開表示。例如一張灰階像素值為 100×100 ，矩陣展開後為 10000 個變數，稱為灰階方法。

二、RGB 顏色空間（三原色）

電腦螢幕在顯示顏色時，會透過紅、綠、藍三色以不同比例組合而成，這個概念與肉眼所看見的顏色是以光的三原色混合而成相仿。螢幕上看到的彩色圖，指的是將紅色、綠色、藍色通道相疊，來實現混合，紅色、綠色、藍色通道分別代表一

灰階圖，任一顏色皆會以一組 RGB 值表示，所謂的 RGB 值，就是在紅綠藍三通道中，以各通道的亮度組合而成。RGB 空間亦可用三維向量表示，紅色、綠色、藍色各通道，分別代表一組分量 R、G、B，三維空間中各點皆能表示一種顏色。




圖 3-1、RGB 顏色空間示意圖

RGB 顏色空間在電腦表示為三維的矩陣，其代表意義為圖像映射到紅色、綠色、藍色的向量空間中，三空間下的亮暗程度。其想法與物理三原色雷同，使用三原色的亮暗能夠組成色彩。若使用 RGB 顏色空間的顏色資訊做為圖像資料結構的方法，其將 RGB 顏色空間三維矩陣各向量空間展開。例如，一張彩色圖片像素值為 100×100 ，映射到 RGB 顏色空間中成為 $3 \times 100 \times 100$ 之矩陣，故轉換成圖像資料結構化方法，會產生 30000 個變數，此種方法為包含顏色資訊的 RGB Flatten。

三、HSV 顏色空間（色調、飽和度、亮度）

基於人的眼睛對色彩識別，從視覺角度定義出 HSV 顏色空間。HSV 顏色空間是 A. R. Smith 在 1978 年創建的一種顏色空間，可分為色調（Hue）、飽和度（Saturation）、亮度（Value），色調代表色彩訊息，範圍為 0-360 度，0 度為紅色、120 度為綠色、240 度為藍色，飽和度，指的是色彩的純度，範圍為 0-1 的比例，純度越高越能表示色彩，越低則逐漸變灰，亮度代表顏色的明亮程度，範圍為 0-1 的比例，在三維空間中，HSV 顏色空間可以以六菱椎表示，H、S、V 各可代表一組分量，各點皆能表示一顏色。




圖 3-2、HSV 顏色空間示意圖

HSV 顏色空間相較於 RGB 顏色空間更能具體的反應出顏色資訊，直觀的表達色彩、色調和鮮豔程度，為了更方便取得圖像於像素值顏色的資訊，故同時考慮 HSV 顏色空間下的方法。HSV 顏色空間在電腦表示與 RGB 顏色空間相同為三維的矩陣，若使用 HSV 顏色空間資訊成為圖像結構的方法，其將 HSV 顏色空間三維矩陣各別向量空間展開後在進行合併。例如，一張彩色圖片像素值為 100×100，故轉換為圖像結構化方法時，會產生 30000 個變數，此種方法稱為 HSV Flatten。

第二節 Canny Algorithm

在數字圖像中，雖然邊緣只占圖像一小部份，但卻包含了大量的資訊量，Canny Algorithm 是 John F. Canny 於 1986 年發表，一種用於圖像邊緣值檢測的方法。原理是將圖像轉為灰階，利用灰階的變化，找出邊緣值。其中，牽涉到圖像中含有雜訊問題，容易在計算時，誤將雜訊認為是邊緣值。故在計算灰階值變化前，必須先使用 Gaussian Blur 對圖像做平滑處理，避免雜訊影響邊緣值的判斷，再透過 Sobel 濾波器對邊緣做強度與方向的計算，尋找梯度方向最大的梯度值，再使用雙域值檢測，檢測像素點是否符合邊緣值的可能，最後將邊界點連線，就能有效找出圖像的邊緣。

一、Gaussian Blur

高斯平滑是一種圖像模糊的濾波器，透過 Gaussian Function 轉換，將每一像素值進行降噪，處理過程中必須選定 kernel size，與周圍 (kernel size 大小) 的像素值，進行卷積的計算，此方法的好處，不但可以有效去除雜訊，又不會改變原始圖像。在此選定 kernel size 為 3，故圖像中每一像素值皆會與鄰近像素值作用。以該像素值為中心 (0,0)，分別選用左上 (-1,-1)、上 (0,-1)、右上 (1,-1)、左 (-1,0)、右 (1,0)、左下 (-1,1)、下 (0,1)、右下 (1,1)，其位置標記透過二維高斯函數轉換，並經過標準化後為 Gaussian filter。計算後的 Gaussian Filter 與經過灰階處理的圖像進行卷積計算，如此一來可以將圖像模糊化，kernel size 選取範圍越大，經過處理過後，圖像呈現越模糊。經過模糊化的圖像，目的在於，未來進行邊緣值計算時，減少雜訊被誤判為邊緣值的機率。

二維高斯函數為：

$$G(u, v) = \frac{1}{2\pi\sigma^2} e^{-(u^2+v^2)/(2\sigma^2)}$$

(u, v) 為矩陣中距離中心位置， σ 為標準差。

$$\begin{bmatrix} (-1, -1), & (0, -1), & (1, -1) \\ (-1, 0), & (0, 0), & (1, 0) \\ (-1, 1), & (0, 1), & (1, 1) \end{bmatrix} \xrightarrow{\text{Gaussian Function}} \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$$

(u, v)

Gaussian Filter

二、梯度方向幅值

為了後續計算，透過 Sobel 濾波器，計算梯度強度與方向， $I(x, y)$ 為中心點的像素值，對 (x, y) 周圍的像素值，進行一階偏導數計算 G_x 、 G_y ：

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

計算出 x 、 y 方向偏導數後，接著計算梯度大小 G ：

$$G = \sqrt{G_x^2 + G_y^2}$$

計算梯度方向 θ ：

$$\theta = \arctan\left(\frac{G_y}{G_x}\right)$$

三、非最大抑制器 (Non-Maxima Suppression)

非最大抑制器的目的在於將模糊的邊界變得清晰，保留每個像素點上梯度強度的最大值，刪除其他的梯度值，操作步驟如下：

- (1) 尋找最大梯度方向，將方向分為 0、45、90、135 度四個方向。
- (2) 逐步計算四正負方向各之最大梯度值。
- (3) 將最大梯度值保留，其餘點被抑制，即刪除為 0。

四、雙域值檢測

通過非最大抑制器後，圖像邊緣仍然存在著一些雜訊和顏色變化，容易將非邊緣值誤判為邊緣值，故採用雙域值檢測的手法，設定雙域值判定是否為邊緣值，高域值用於判定是否為強邊緣，判斷依據為該點的梯度值是否高於高域值，同理，低域值用於區分弱邊緣和抑制像素點，如該梯度值大於低域值，並且小於高域值，即為弱邊緣，非強邊緣或有效邊緣，其設定該點皆為 0。透過雙域值檢測，選取高低域值，保留強邊緣，並找出弱邊緣，再對弱邊緣相鄰位置是否包含強邊緣，若包含強邊緣，即保留該弱邊緣值，其餘為 0，由此方法設定，即可有效找出圖像之邊緣。

第三節 顏色檢測

相較於 RGB 顏色空間，想要合理的判斷出顏色，轉換成 HSV 顏色空間，能夠較易以數值範圍將顏色判斷出。因顏色空間屬於連續型變化，無法精準地將顏色做切割，故以下範圍是通過實驗計算出的模糊範圍。表 3-1，將顏色在 H、S、V 空間中的範圍，以最大值 (M)、最小值 (m) 列出：

表 3-1、HSV 空間顏色範圍

		黑	灰	白	紅	橙	黃	綠	青	藍	紫	
H	m	0	0	0	0	156	11	26	35	78	100	125
	M	180	180	180	10	180	25	34	77	99	124	155
S	m	0	0	0	43	43	43	43	43	43	43	
	M	255	43	30	255	255	255	255	255	255	255	
V	m	0	46	221	46	46	46	46	46	46	46	
	M	46	220	255	255	255	255	255	255	255	255	

舉例來說，若要使用 HSV 顏色空間選取紅色範圍，必須設定該點像素值，色調(H)向量空間數值介於 0 至 10 的範圍或者 156 至 180 的範圍，並且飽和度(S)向量空間介於 43 至 255 的範圍，並且亮度 (V) 向量空間介於 46 至 255 的範圍中，當像素值符合以上條件，其該點顏色為紅色。其他顏色的選取方法皆雷同，可以透過表 3-1 進行顏色判斷。若像素值符合該定義的顏色範圍，就能將圖像以自動的方式，判斷出顏色。找出圖像中的顏色，以便後續針對圖像資料結構化方法分析中，能夠有更多資訊提供分析使用。

一、Color Feature

此方法目的在於解析圖像所使用色彩資訊，達到解釋色彩使用上的意義，根據 HSV 空間轉換，可以計算出各顏色的範圍，由此進一步探討圖像中所使用色彩與其統計值，首先，為了了解圖像中使用冷、暖、黑、白色佔圖像中多少比例，冷色由綠、青、藍組成，暖色由紅、橙、黃、紫組成，將每一個像素值 (i) 落在的色系範圍各別計算總數，再除上所有像素 (N)，就能計算出圖像中色系的比例。

以冷色系為例，若 H 像素值落在 (35,124)、S 落在 (43,255)、V 落在 (46,255)，則該像素為冷色系，計算所有落在冷色域之像素個數 (S)，則 $P_{cold} = S/N$ ，如此一來，就能計算出冷色系佔比，以下為數學式：

$$P_{cold} = \sum_{i \in \Omega} i/N, \Omega = \{h_i, s_i, v_i | h_i \in (26,124) \cap s_i \in (43,255) \cap v_i \in (46,255)\}$$

表 3-2、色系比例範圍對照表

Color	H		S		V	
	m	M	m	M	m	M
黑	0	180	0	255	0	46
白	0	180	0	30	221	255
冷	35	124	43	255	46	255
暖	0	10				
	26	34				
	125	180				

色彩空間平均數也可提供圖像色彩資訊，將圖像轉換成 RGB、HSV、GRAY 空間，計算每一張圖片在每一向量空間的平均數與標準差，如此，衍生 R 向量空間的平均數、G 向量空間的平均數、B 向量空間的平均數、R 向量空間的標準差、G 向量空間的標準差、B 向量空間的標準差、H 向量空間的平均數、S 向量空間的平均數、V 向量空間的平均數、H 向量空間的標準差、S 向量空間的標準差、V 向量空間的標準差、冷色系比例、暖色系比例，衍生出 14 個變數。計算色系比例與色彩統計值後，將此方法的變數統稱為 Color Feature。

二、Splitting Feature

Color Feature 的算法是以平均數、標準差、色系，在各顏色向量空間中個別使用統計值表達，雖然能夠描述圖像整體概況，卻無法得知顏色在圖像位置分佈的狀況。考慮到圖像在不同位置下，顏色重要程度不同，所提供的資訊也不同。故本文在 Color Feature 所提供顏色資訊外，還加入了位置資訊，成為了 Splitting Feature。所以 Splitting Feature 為同時包含顏色、位置資訊的圖像結構化方法。

因為 Splitting Feature 除了顏色資訊外，還包含了圖像位置分佈的結構。在做法上，採用等份分割的方式。將圖像等份分割成 $n \times n$ 個相同大小且不重疊的子區域。在每個一子區域下，各別計算子區域的 Color Feature，意旨計算子區域中顏色的代表資訊。在每個子區域的顏色資訊計算完後，再將所有子區域中的顏色資訊合併，成為 Splitting Feature 的變數。以圖 3-3 為例，圖片中為米勒（西元 1850 年）-外出的人，圖 3-3 假設 $n = 4$ ，圖片被分為 16 個相同大小且不重疊的子區域。在計算 16 塊子區域各別的 Color Feature（14 個變數）後，將所有子區域的顏色資訊結合為 224（ 16×14 ）個變數。這樣子的做法不僅不像 RGB Flatten、HSV Flatten 包

含每一像素值資訊，造成資料維度過大問題，亦在 Color Feature 中，增加了更多位置資訊。



圖 3-3、Splitting Feature 示意圖

在 Splitting Feature 方法中，將圖像分為 $n \times n$ 個均等大小子區域，同時衍生出如何決定圖像切割次數 (n) 的問題。為了確定處理圖像分析時，最佳的分割次數，在本文分析中，會使用重複模擬驗證的方式，針對在不同分割次數下，圖像風格判斷的準確率，選擇最佳的準確率來定義出分割圖像的最佳次數。待確立 Splitting Feature 圖像分割的最佳次數後，便能將圖像以 Splitting Feature 方法具有標準的進行圖像資料結構化的處理。

第四節 分類模型

一、邏輯斯迴歸 (Logistic Regression)

邏輯斯迴歸是針對目標變數 (Y) 為類別型變數的分類模型，經常使用在二分類或者多分類的問題上。概念為希望能將資料點透過迴歸線能夠分隔開來，達到分類的效果。其方程式當中的參數 β_i 是透過勝算比 (odds Ratio) 的概念來呈現，也就是每增加一個單位 X 時對整體 Y 增加或是減少的機率為何。

$$\log\left(\frac{p(Y = y_i|X)}{1 - p(Y = y_i|X)}\right) = \beta_0 + \beta_1 X_1 + \dots + \beta_k,$$


其中 X_i 為自變數； β_i 為透過勝算比呈現之參數； $y_i = 0, 1, 2, \dots$

二、Light GBM

Light GBM 採用了基於直方圖的算法將連續的特徵值離散化成了 K 個整數，構造寬度為 K 的直方圖，遍歷訓練數據，統計每個離散值在直方圖中的累積統計量。在選取特徵的分裂點的時候，只需要遍歷排序直方圖的離散值。使用直方圖算法降低了算法的計算代價，XGBoost 採用的預排序需要遍歷每一個特徵值，計算分裂增益，而直方圖算法只需要計算 K 次，提高了尋找分裂點的效率；降低了算法的內存消耗，不需要存儲預排序結果，只需要保存特徵離散化後的值。

Light GBM 採用了一種更為高效的按葉子生長 (leaf-wise) 的策略。該策略每次從當前決策樹所有的葉子節點中，找到分裂增益最大的一個葉子節點，然後分裂，如此循環往復。這樣的機制，減少了對增益較低的葉子節點的分裂計算，減少了很多沒必要的開銷。與 level-wise 的策略相比，在分裂次數相同的情況下，leaf-wise 可以降低誤差，得到更好的精度。Leaf-wise 算法的缺點是可能會生成較深的決策樹。

因此，Light GBM 在 Leaf-wise 上增加了限制最大深度的參數，在保證算法高效的同時，防止過擬合。



9

圖 3-4、Level-wise Tree 示意圖



圖 3-5、Leaf-wise Tree 示意圖

⁹ 參考 Light GBM - Another gradient boosting algorithm (Gupta, 2019)。

三、卷積神經網絡 (Convolutional Neural Network)

卷積神經網絡 (Convolutional Neural Network)，簡稱 CNN，卷積神經網絡經常使用於圖像分類的一種模型。其作法首先將圖像經過卷積層，透過過濾器篩選圖像特徵，再透過池化層放大特徵。本文採用兩層卷積轉換，故透過兩次卷積層、池化層轉換，再接上全連接層，將所有矩陣展開，最後再接上線性層，達到分類的目標¹⁰。




圖 3-6、CNN 概念圖

● 卷積層 (Convolution)

卷積層的目的在於模擬人腦，擷取出圖片特徵。根據圖 3-6，將原始圖片的與特定的特徵檢測器（過濾器）進行乘積。示意圖為 3x3 的過濾器，由最左至右，上至下，將圖片每一區塊皆進行乘積。得到的矩陣，稱為 Convolution Feature。

圖 3-6 為卷積層計算的範例，其假設 Kernel = $\begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix}$ ，將原始圖片矩陣

(Image) 經過 Kernel 卷積計算，輸出為 Convolution Feature。

¹⁰ 參考 Understanding Convolutional Neural Networks for NLP (Britz, 2015)




圖 3-7、卷積層示意圖

- 池化層 (Pooling)

將上一節取得的 Convolution Feature，進入最大池化層。最大池化層，是將鎖定的矩陣範圍內，最大的數值取出。由圖 3-7 示意，每一範圍區域最大值為 4，經過最大池化層，擷取出圖片重要資訊，同時有有降噪的效果。

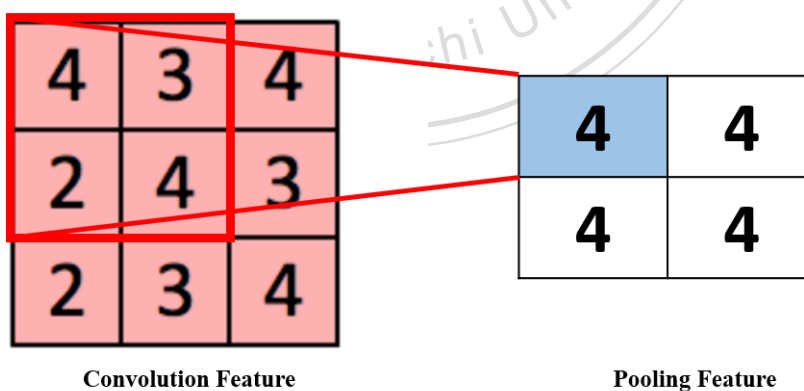



圖 3-8、Pooling 示意圖

- 全連接層 (Fully Connected)

將 Pooling Feature 進行 Flatten，意旨將矩陣展平，作為後續神經網路變數。而 Flatten 後的變數經過輸入層、隱藏層、輸出層，最後輸出成分類。



第四章 圖像分析

本文使用三種方向用於圖像資料結構化方法，分為圖像像素值顏色、圖像中物件形狀、圖像分割位置。圖像像素值顏色包含 RGB Flatten、HSV Flatten、Color Feature。圖像中物件形狀包含 Gray Flatten、邊緣值檢測 (Canny Algorithm)。圖像分割位置變數為 Splitting Feature。本章節使用以上圖像資料結構化方法，實驗於報紙、雜誌、繪畫中，探討圖像資料風格的不同。透過探索性資料分析的方式，使用 Color Feature 變數分析各圖像資料的顏色特性。針對各圖像資料結構化方法，使用統計模型、機器學習模型，以準確率 (Accuracy) 比較圖像資料結構化方法，從中找出最佳的結構化方法。並且與深度學習模型的結果進行比較。其中，遇到參數設定問題：解析度問題、Splitting Feature 中圖像分割問題。本章節使用邏輯斯回歸，模擬 500 次，找出最佳的參數值。本章節目的在於討論圖像風格問題，探討圖像資料結構化方法，用於二分類、多分類判斷圖像資料結構化方法於風格分類上是否有效。

第一節 探索性資料分析

探索性資料分析，又簡稱 EDA，於西元 1977 年，由 John Tukey 提出，其定義為，在研究前，研究者對於資料不做過多假設，透過簡單的算術與容易建構的圖表，提供研究者對資料有初步的認知，經過對資料一次又一次的檢索，從中找出線索，研究者必須保持懷疑與謹慎的心態，並對結果盡量做到客觀。EDA 的目的在於，透過對資料的探索，使研究者重新檢視資料，並探索資料中隱藏的訊息，同時檢查資料是否符合分析前假設。

本節使用顏色變數中的 Color Feature，變數包含 RGB 空間與 HSV 空間的向量平均數和標準差、圖片冷色系比例暖色系比例等圖片特色。針對三種類型圖像資料，台灣四大報 (《中國時報》、《自由時報》、《聯合報》、《蘋果日報》)、Vogue 雜誌 (1970~2009 年)、油畫 (印象派、現實主義) 進行探索性資料分析的觀察。從中，

分析不同風格的圖像在顏色變數中，比較各圖像風格在顏色使用上具有何種特色。同時在分析時，透過視覺化的方式，解釋圖像風格的特色，進一步觀察資料的特性。

一、台灣四大報

台灣四大報，各家報紙分別有 1055 張圖片，針對頭版圖片進行分析。根據 Color Feature 變數，以盒形圖的方式，進行視覺化分析。首先，在圖 4-1（左）可以看到四大報暖色系比例與冷色系比例的差異。其中，《聯合報》使用暖色系色彩的比例比起其他三大報使用程度高，並且《聯合報》在使用冷色系色彩的比例比起其他三大報相對較低。由於報紙文字標題與報導內容大多使用黑色文字居多，故使用黑色占整張報紙的比例觀察每間報社頭版的差異。圖 4-1（右）為報紙頭版圖片使用黑色的比例狀況，《蘋果日報》相對使用較多的黑色，推測《蘋果日報》因為使用較多圖片，故容易造成黑色在整體版面上佔有較大比例。《聯合報》相較其他三大報，黑色占整體頭版面較少的比率。推測比起《自由時報》、《中國時報》，聯合報習慣在頭版面使用較少的文字去描述事件。




圖 4-1、台灣四大報之色系比例（左）、黑色比例（右）

圖 4-2 (左) 為四大報於 RGB 顏色空間中，各向量空間 (R、G、B) 中的平均數。圖中《聯合報》在 RGB 三向量空間中，平均使用的亮度皆高於其他三大報。圖 4-2 (右) 為四大報 HSV 顏色空間中，各向量空間 (H、S、V) 的平均數。《蘋果日報》在飽和度 (Saturation) 向量中，與其他三報相比，飽和度的平均高出許多。推測因《蘋果日報》在頭版版面上，圖片幾乎占滿整個版面，故在飽和度的平均中，呈現較高的平均數。《自由時報》、《中國時報》在亮度 (Value) 向量的平均數於四大報中相對較低，可以呼應圖 4-2 (左)，在 RGB 顏色空間，其中 G、B 向量空間的平均數，皆呈現較低的亮度。




圖 4-2、台灣四大報之 RGB 平均值 (左)、HSV 平均數 (右)

由圖 4-3 為四大報顏色空間的標準差。《蘋果日報》無論是在圖 4-3 (左) RGB 向量空間標準差，或者在圖 4-3 (右) HSV 向量空間標準差，標準差皆高出其他三大報許多。可以間接證明，因為《蘋果日報》使用許多圖片作為頭版版面，而標準差代表著《蘋果日報》使用顏色變數的變化較大，有著多樣的顏色豐富度。相比《自由時報》、《中國時報》、《聯合報》，三大報使用圖片占整個頭版版面較小，大多頭版版面有著頭版報導的文字敘述。

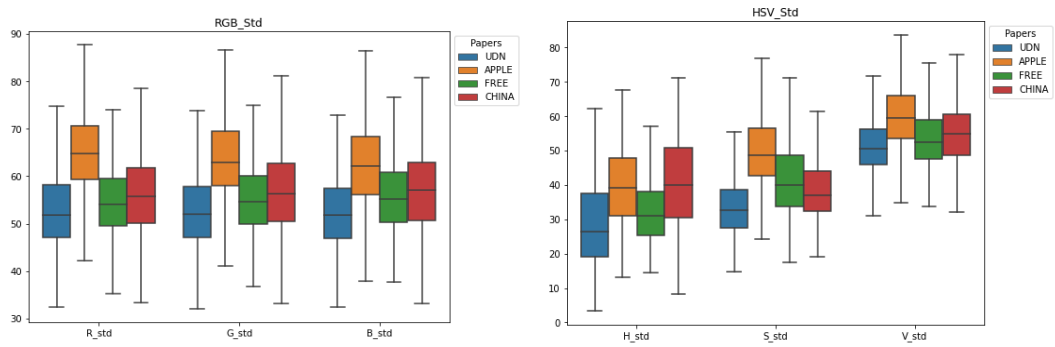


圖 4-3、台灣四大報之 RGB 標準差 (左)、HSV 標準差 (右)

透過以上資料探索的方式，可以觀察出幾項特點。《蘋果日報》在顏色空間中，各向量空間的標準差為最高，故認定為色彩較為豐富的報紙，說明《蘋果日報》使用習慣使用的圖片的比率為四大報之首。《聯合報》在使用色彩上，暖色系比例的色彩占比相較其他報紙較高，而在黑色比例（文字敘述）較少，推測《聯合報》在習慣使用圖片的比例可能為四大報中第二。而《聯合報》在 RGB 向量空間、HSV 中的亮度向量空間中，平均數較高，推測《聯合報》喜好使用亮度較高的圖片。最後，觀察《自由時報》、《中國時報》，兩報紙在無論色系占比、色彩空間的平均數、標準差來說，盒形圖的分布較為相近，故推測兩報紙版面呈現與色彩運用較為相似。

二、Vogue 雜誌

美國 Vogue 雜誌，資料為 1970~2009 年間，每月月刊雜誌封面圖片，每十年為一年代，每年代各有 120 張封面圖。圖 4-4（左）為 Vogue 雜誌在年代間封面色系的差異，雖然 1990 年代封面在暖色系色彩使用比較與其他年代相比較高，而冷色系反之，但四個年代在使用冷暖色系比例在 25 分位數、中位數、75 分位數皆很接近。圖 4-4（右）為 Vogue 雜誌在年代間封面黑色使用的比例，由圖顯示，1970 年代封面相較之後的年代，使用較高黑色的比例。而 1990、2000 年代，封面使用黑色系的比例相對較少。




圖 4-4、Vogue 雜誌之色系比例（左）、黑色比例（右）

圖 4-5（左）為 Vogue 雜誌 RGB 顏色空間中的平均數，1970、1980 年代在 R、G 空間向量平均數相較 1990、2000 年代的整體亮度平均低。推論 1970、1980 年代，封面人物在膚色表現上比較蠟黃，相較 1990、2000 年代，隨著拍攝技術進步，拍攝封面人物的打光技術與拍攝手法更加明亮清晰，所以越接近近代雜誌封面整體亮度越高。圖 4-5（右）為 HSV 顏色空間中的平均數，在色調（Hue）向量空間的平均數中，1970、1980 年代也明顯高出 1990、2000 年代。而飽和度（Saturation）向量空間的平均數中，1970、1980 年代亦高於 1990、2000 年代。可能原因，在

1970、1980 年代，封面背景大部分皆使用同一色系，為了強調封面人物，背景採用低彩度的顏色。1990、2000 年代，在背景圖上做了改變，不僅僅只使用單一低彩度作為背景圖，時常使用真實場景，如草原、海岸等，經過模糊處理之圖片作為雜誌封面的背景圖。




圖 4-5、Vogue 雜誌之 RGB 平均值（左）、HSV 平均數（右）

圖 4-6（左）為 Vogue 雜誌 RGB 顏色空間的標準差，圖 4-6（右）為 Vogue 雜誌 HSV 顏色空間的標準差。整體而言，在 R、B 與色調(Hue)、飽和度(Saturation) 向量空間中，隨著年代增加標準差也越大。代表著 Vogue 雜誌在色彩使用上逐漸改變的趨勢，由原本色彩使用較為單一，轉變為使用較豐富的色彩於雜誌封面中。雜誌封面在 1970、1980 年代，封面的主軸為人臉搭配單一色彩的背景，而 1990、2000 年代，雜誌封面越來越趨向使用人物整體包含服裝、配飾與搭配為封面重點，而背景也一改以往使用單一顏色，開始加入更多實景、設計來凸顯整體封面的時尚美學。

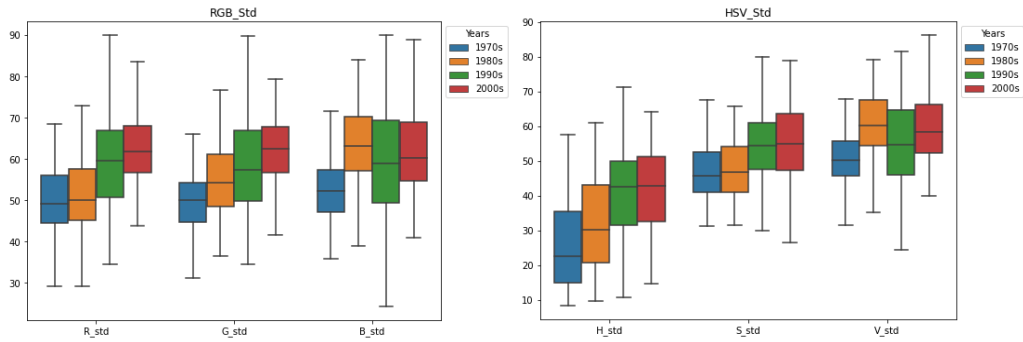


圖 4-6、Vogue 雜誌之 RGB 標準差（左）、HSV 標準差（右）

綜合以上，於 Vogue 雜誌對於顏色變數的探索性資料分析結果，可以將 1970、1980 年代與 1990、2000 年代切分為兩風格差異較大的時期。由圖 4-6（左）RGB 的 B 向量空間與圖 4-6（右）HSV 的亮度（Value）向量空間，以標準差的角度來看。1980 年代可能認為是年代之間的轉折年代。在以上各個視覺化分析的圖表中，大部份顯示 1970、1980 年代與 1990、2000 年代可以區隔為兩個大時代或者有逐年遞增的連續現象。但雜誌風格變化並非一時之間的轉變，最為可能是依照時間而有逐步的改變現象，所以認為 1980 年代最為可能是轉變的開端。由原本使用色彩較為單調，進而改變為使用豐富色彩的近代雜誌風格。

三、十九世紀油畫

本文採用兩種畫派風格，分別為印象派、現實主義畫派。畫派的代表作家為 Monet (印象派) 400 幅、Degas (印象派) 400 幅、Corot (現實主義) 400 幅、Manet (現實主義) 112 幅、Miller (現實主義) 129 幅。圖 4-7 (左) 為畫作使用冷暖色系的比例，其中，Monet 在色彩使用上比較偏好使用暖色系色彩，而 Manet 比起其他畫家，相較偏好使用較多冷色系的色彩。圖 4-7 (右) 為畫作使用黑色占整幅畫的比例，圖中顯示，使用黑色最多為 Miller，而 Manet、Monet 在畫作中使用黑色的比例最少。

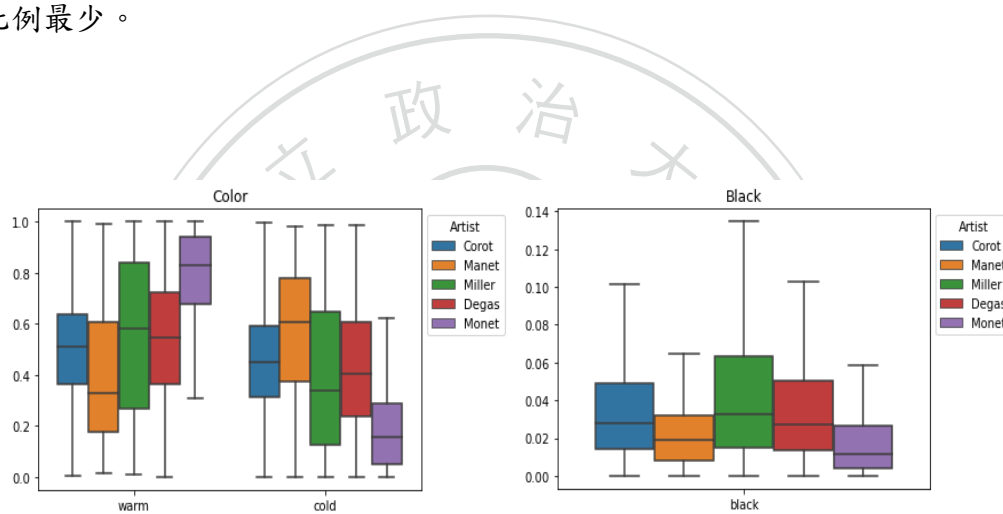


圖 4-7、十九世紀油畫之色系比例 (左)、黑色比例 (右)

圖 4-8 (左) 為畫作之 RGB 空間下的平均數，由圖可看出 Monet 在 RGB 空間向量中平均數為所有作家最高。對應到圖 4-8 (右) 亮度 (Value) 的平均數亦為最低。可見 Monet 在畫作的描繪上，多使用較為明亮的色彩。又 Monet 屬於印象派系，印象派畫作的特色是擅長使用光的亮度來凸顯畫作。而 Monet 的畫作中，大多數為風景畫，使用天空、水景等較為明亮的景物來表現畫作。而相較現實主義的 Manet，兩位畫家在畫作上有較為明顯的對比。圖 4-8 (左) RGB 顏色空間下的平均數為畫家中最低，對應圖 4-8 (右) 的亮度 (Value) 空間中的平均值亦為最低。

在 Manet 的風景畫中，經常表現工業革命下的場景，表達天空時多使用灰暗的色彩代表。而 Manet 另一部分畫作為描繪人像，人像畫作中，經常用黑、灰等暗色系來凸顯重點人物。




圖 4-8、十九世紀油畫之 RGB 平均值（左）、HSV 平均數（右）

圖 4-9（左）為畫作之 RGB 標準差，其中 Corot、Manet 兩位畫家的畫作，在 RGB 顏色空間的標準差為最高，與圖 4-9（右）亮度（Value）之標準差對應。兩位畫家繪畫人物風格多為使用暗色系背景來凸顯人物的描繪，故在亮度上暗色與亮色形成明顯對比。在圖 4-9（右）色調（Hue）向量空間標準差，Monet 畫家為所有畫家中最高，代表 Monet 的畫作，在色彩運用上有較高的豐富度。Monet 的風景畫、景物畫，經常使用多元的色彩作畫，而印象派畫作背景描繪不會僅使用單一色彩，這與現實主義有很大的差別，現實主義在人物畫的背景多使用單一的暗色系色彩，而印象派在背景的描繪上，會有許多色彩穿插其中，在畫作表現上給人更明亮的感受。

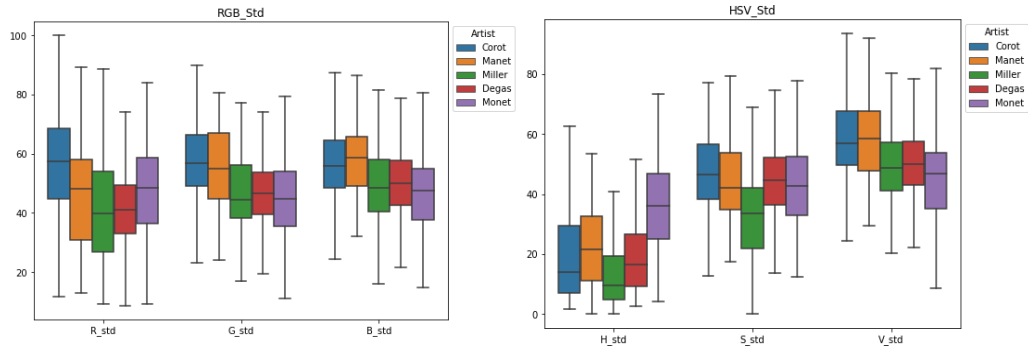


圖 4-9、十九世紀油畫之 RGB 標準差（左）、HSV 標準差（右）

綜合以上，使用顏色變數於畫作的探索性資料分析結果。Monet 的畫作與 Manet 的畫作，在印象派、現實主義兩個派系中，最能表現兩個派系明顯的對比。透過分析與觀察，印象派在使用色彩上多為明亮，背景描繪較使用多元色彩來繪畫。相較於現實主義的畫作風格，現實主義的畫作表現出工業革命之背景，繪畫內容多給人較為灰暗的感受。又人物畫中，經常使用黑、灰等暗色系作為背景，這是與印象派系差異最明顯的地方。由探索性資料分析，雖然能由視覺化的圖中，觀察畫家畫作的風格上的差異，但未能很明顯區隔印象派與現實主義兩個畫派的風格。可能原因為畫作的描繪在色彩運用上較為細膩，難以運用簡單的描述來展現整幅畫作的內容。

第二節 參數設定

一、解析度

圖像資料在儲存時，儲存的大小與解析度皆有不同。在不同解析度下，分析圖像的標準會有不一致的結果。所以在進入圖像分析前，必須先確定使用的圖像資料為相同的解析度，才能使得圖像分析具有相同的標準。本文使用邏輯斯回歸，將資料隨機切成 80%訓練集、20%測試集，針對本文提出的圖像結構化方法進行分析，在不同解析度下，進行模擬 500 次，對驗證結果取平均數。觀察在各種圖像結構化方法中，選取多少解析度可以使得分析結果最為平穩。並且需考慮解析度越大，在圖像分析當中，會佔據大量記憶體與時間，故本文希望能夠選取最小且平穩之解析度，作為本文使用之標準解析度。圖 4-10 使用報紙資料中，《中國時報》、《蘋果日報》為範例，針對不同解析度由 5×5、10×10、15×15...200×200 實驗，由此選擇出最佳的解析度。在各方法下，當解析度在 100×100 時，準確度可達到穩定，準確率的標準差在 0.1 以下，代表每次訓練的結果差異不大，在準確率呈現穩定下，故本文採用 100×100 的解析度，作為讀取圖片的標準解析度。




圖 4-10、解析度與分類準確度

二、Splitting Feature 分割次數

本文提出 Splitting Feature 方法中，包含顏色變數資訊、圖片位置資訊。在位置資訊中，希望切割為多塊大小相同的子區域。如何定義圖片切割次數，成為本小節的問題。確認本文標準解析度為 100×100 後，針對圖像資料進行切割測試，將切割數量分為由 1×1 、 $2 \times 2 \dots 10 \times 10$ 進行實驗，選用邏輯斯回歸進行分析，將資料隨機切成 80% 訓練集、20% 測試集，經過 500 次模擬後，選擇最佳的切割次數，作為 Splitting Feature 方法得切割次數。圖 4-11 為模擬的結果，模擬的資料使用四大報 (Papers) 中由《中國時報》、《蘋果日報》為範例，Vogue 雜誌由 1970s、1980s 為代表，十九世紀油畫 (Painting) 以派系 (印象派、現實主義) 為兩大類。在各種不同圖像資料中，由於分割次數不同，最後準確率也有不同的結果。油畫 (Painting) 資料中，分割為 2×2 時，準確率最高，隨分割次數越多，準確率有下降趨勢。而在 Vogue 雜誌、四大報資料中，分割次數達到 4×4 時，幾乎可以在準確率表現較佳，而隨分割次數再增加，準確率呈現震盪，但震盪幅度約在 0.2 之內。綜合以上的表現，為了在後續進行二分類、多分類時，能夠有公平的標準進行比較，故在本文中，採取 4×4 的分割次數，作為 Splitting Feature 中的分割次數。




圖 4-11、Splitting Feature 分割次數模擬結果

第三節 圖像風格分類-二分類

本小節使用本文提出的圖像資料結構化方法，進行圖像風格判斷，本小節嘗試使用二分類進行比較。根據參數設定的結果，使用 100×100 作為本文的解析度。在圖像資料結構化方法，使用 RGB Flatten、Color Feature、Gray Flatten、邊緣化檢測 (Edged)、Splitting Feature 等方法，進行圖像結構化，其中 Splitting Feature 透過模擬結果，決定使用 4x4 為分割次數。圖像資料使用報紙四大報、Vogue 雜誌封面 (1970s、1980s)、十九世紀油畫 (印象派、現實主義) 作為分類目標。透過邏輯斯回歸作為分類模型，將資料隨機切成 80% 訓練集、20% 測試集，計算分類結果的準確率，經過 500 次模擬後取平均值，比較圖像資料結構化的準確率，找出最佳的結構化方法。

由圖 4-12 二分類結果得知，Splitting Feature 在各資料類型下表現最好。台灣四大報、Vogue 雜誌在二分類結果中，使用 RGB Flatten 方法為次之。而在畫作二分類結果中，Color Feature 方法為次之。其中在台灣四大報中，Split 分類結果準確率皆可達到 90% 以上，在所有資料中表現最好。Vogue 雜誌 1970、1980 年代分類的結果，Splitting Feature、RGB Flatten 方法準確率也可接近 90%，所以認為是不錯的結果。而在畫作資料中，Splitting Feature 方法的準確率只能達到 80% 左右，為三種資料較差的二分類結果。比較各種圖像資料結構化方法後，考慮模型是否會影響準確率，故接著比較多模型的結果。




圖 4-12、圖像風格二分類結果

由以上結果得知，Splitting Feature 的圖像結構化方法在各資料中皆是最佳的結構化方法，故使用 Splitting Feature 方法，實驗在不同模型下，是否會影響分類的準確率。圖 4-13 比較不同分類模型，使用邏輯斯回歸 (Logistic Regression)、Light GBM、隨機森林模型 (Random Forest)、極限梯度提升 (XGBoost) 進行比較，相同使用 500 次模擬結果，比較準確率。根據圖 4-13 的結果，可以看出 Light GBM 與邏輯斯回歸模型為兩種最佳的分類模型。比較 Light GBM、邏輯斯回歸兩者在圖像資料下的準確率，由結果而言，兩者準確率差異小於 0.03 以內，所以認為模型的比較結果是相近的。




圖 4-13、不同分類模型的比較

同時針對深度學習模型（Convolution Neural Network），與本文找出最佳圖像資料結構化方法進行分類模型後的結果比較，由上述結果得知，本文最佳結構化方法為 Splitting Feature 方法，使用最佳模型為邏輯斯回歸、Light GBM。故使用 CNN 模型與之比較。圖 4-14 為模擬 500 次結果，經過比較後得知，使用 Splitting Feature 的結構化方法，經過邏輯斯回歸、Light GBM 模型後的結果，在各種所有類型資料下，圖像風格二分類結果，皆可高於深度學習模型（CNN）至少 0.02 的準確率以上。使用圖像結構化方法的優點在於變數具有解釋力，並且透過變數的選擇，可以大量減少變數的維度，進而減少分析運算的空間與時間。在比較過後，最佳資料結構化方法與深度學習模型計算的分類結果相近甚至高出許多。故認為本文使用圖像資料結構化方法是可以得出不錯的結果。




圖 4-14、CNN 與其他模型的比較

第四節 圖像風格分類-多分類

經過圖像風格二分類比較過後，本文嘗試針對圖像風格進行多分類。本小節使用台灣四大報報紙頭版(《蘋果日報》、《自由時報》、《中國時報》、《聯合報》)、Vogue 雜誌封面(1970 年代、1980 年代、1990 年代、2000 年代)與十九世紀油畫作家 Monet (印象派)、Degas (印象派)、Corot (現實主義)、Miller (現實主義)。根據圖像二分類結果，得到最佳圖像資料結構化方法為 Splitting Feature 方法，故本小節使用 Splitting Feature 為圖像資料結構化方法。由於考慮到計算時間問題，故採用邏輯斯回歸作為分類模型，並且將資料隨機切成 80%訓練集、20%測試集，經過模擬 500 次，比較分類結果。

由表 4-1 可以得知三種資料報紙、雜誌、油畫，在圖像風格多分類的準確率。在報紙資料中，針對四大報的排版進行分類，而在分類結果準確率顯示最佳，可達 91.4%。針對雜誌四個年代進行分類，分類結果準確率為 72.7%，分類結果在三種資料當中準確率次之。在圖像多分類結果為最差的資料為油畫，針對畫家進行分類，

準確率為 64.7%。計算模擬 500 次分類結果的標準差，可知標準差皆小於 4%，可知分類的結果非常穩定，並不會受到訓練集的資料不同，而產生差異大的結果。

表 4-1、各種資料的分類準確性比較

	報紙	雜誌	油畫
準確率	0.914	0.727	0.647
標準差	0.009	0.041	0.027

一、台灣四大報混淆矩陣

針對圖像風格多分類，探討其中分類錯誤的部份。表 4-2 為台灣四大報真實與預測結果的混淆矩陣。以整體而言，各家報紙分類的準確率最佳為《中國時報》，其中《中國時報》的準確率為 89.9%，而在四大報中《自由時報》為分類準確率最佳之報紙，《中國時報》準確率可達 93.6%。觀察分類錯誤機率較高的報紙，以《中國時報》、《聯合報》為最容易被混淆的兩種報紙，故推測《中國時報》、《聯合報》在報紙頭版版面中，較為類似，相對於其他報紙，《中國時報》、《聯合報》可能造成分辨不清的狀況。但根據混淆矩陣得分錯率來看，大約 100 份報紙中，只有五份是分不清的結果。故認為本文使用的圖像資料結構化方法在台灣四大報頭版版面分類中，能夠準確得分類出結果。

表 4-2、台灣四大報多分類之混淆矩陣

		預測			
		APPLE	CHINA	FREE	UDN
真實	APPLE	0.911	0.033	0.032	0.025
	CHINA	0.034	0.899	0.014	0.053
	FREE	0.034	0.015	0.936	0.016
	UDN	0.018	0.055	0.014	0.912

二、Vogue 雜誌混淆矩陣

針對 Vogue 雜誌四個年代（1970~2000 年代），觀察圖像風格多分類下的混淆矩陣。由表 4-3 可知，在 1970 年代分類準確率最高，可達 90.4%，1980 年代分類準確率次之，準確率 81%。而在 1990、2000 年代，分類準確率皆在 60% 以下。討論分類錯誤率較高的年代，由混淆矩陣的機率可分為兩個時期討論。第一時期為準確率較高的 1970、1980 年代，在 1970 年代的雜誌封面，最容易被誤認為 1980 年代，而 1980 年代亦同，在 1980 年代的雜誌封面最容易被錯誤判斷為 1970 年代。第二時期為 1990、2000 年代，1990 與 2000 年代被互相判斷錯誤的機會高達 30% 以上，代表 100 張雜誌封面中有 30 幾張會被誤判為彼此的年代，這可以解釋為 1990、2000 年代風格極其相似。在 1990、2000 年代雜誌封面，大部分為封面人物全身照為主軸，由整體衣服搭配展現時尚風格。

表 4-3、Vogue 雜誌多分類之混淆矩陣

		預測			
		1970s	1980s	1990s	2000s
真實	1970s	0.904	0.057	0.026	0.013
	1980s	0.086	0.810	0.049	0.056
	1990s	0.034	0.041	0.565	0.360
	2000s	0.013	0.046	0.346	0.596

三、十九世紀油畫混淆矩陣

觀察畫家作品在圖像風格的多分類結果，畫家的派系分別為 Monet(印象派)、Degas (印象派)、Corot (現實主義)、Miller (現實主義)。由表 4-4 為畫家的畫作風格分類的混淆矩陣，四位畫家中準確率大約在 55%至 65%之間。探討分類錯誤的機率，Corot、Miller 為彼此最容易分類錯誤的畫作，其兩位畫家皆為現實主義畫家。而 Monet 最容易分錯為同為印象派的畫家 Degas，但 Degas 最容易被判斷錯誤的反而是現實主義的 Corot。在畫作的分類上，多分類的準確率比起台灣四大報、Vogue 雜誌資料來說低出許多，故推論本文使用的最佳圖像資料結構化方法 Splitting Feature 可能產生資料依賴性問題。使用排版較固定的台灣四大報與 Vogue 雜誌資料中有較好的結果，而在不規則的油畫資料中，準確率較差。

表 4-4、十九世紀油畫多分類之混淆矩陣

		預測			
		Corot	Miller	Degas	Monet
真實	Corot	0.582	0.201	0.167	0.050
	Miller	0.267	0.569	0.128	0.036
	Degas	0.157	0.129	0.626	0.088
	Monet	0.104	0.057	0.182	0.658

第五章 結論與建議

第一節 結論

本文目的在於探討圖像結構化方法，除了考量 RGB、HSV、GRAY 等紀錄方式，使用 RGB、HSV 等之類的顏色特性為變數，同時也考量色系、色彩豐富度等想法，有系統的評估哪種圖像結構化較為合宜。由於圖像分類的結果經常因資料有不同 (Data Dependent)，本文實證分析使用三種類型資料，涵蓋文字、照片 (及圖片)、繪畫等資訊，包括台灣四大報 (《蘋果日報》、《中國時報》、《自由時報》、《聯合報》，2014~2019 年) 的頭版報導、美國時尚雜誌 Vogue (1970~2009 年)、十九世紀西方油畫 (印象派、現實主義)。圖像經過不同方式結構化後，結合統計分析、機器學習模型，藉由電腦模擬與交叉驗證，探討不同的圖像格式方法、模型及其參數的分類準確性，同時也考慮圖像解析度的參數問題，針對以上問題本文皆進行討論。

首先透過探索性資料分析的方式，比較顏色資訊在圖像資料風格下的差異。在圖像使用暖、冷色系比例，顏色空間的平均數、標準差，皆可看圖像不同風格的差異。尤其在台灣四大報中，《蘋果日報》使用色彩豐富度最多，《中國時報》、《自由時報》版面較為一致。Vogue 雜誌中，1970、1980 年代與 1990、2000 年代可分割為兩大時代，1970、1980 年代風格較為相近，與 1990、2000 年代有明顯的差異。而在畫作中，Monet 與 Manet 分別代表著印象派與現實主義畫派，兩位作者繪畫特色可以由亮度的表現上發現明顯的差異。由 EDA 可以觀察出圖像風格，在使用顏色變數上確實存在著差異。

為了驗證圖像結構化的方法可以區分圖像風格，本文由監督式學習模型驗證結果。考慮解析度問題，在經過 500 次模擬驗證後，決定使用 100×100 的作為圖片解析度參數。使用本文提出的圖像資料結構化方法，表現最佳的為 Splitting

Feature 方法，由圖像風格二分類結果，台灣四大報、Vogue 雜誌可達到 90%左右準確率，而畫作風格分類，也可達到近八成準確率。同時考慮到分類結果可能受模型的算法不同影響，所以本文使用不同分類模型驗證。採用不同模型方法後，邏輯斯回歸與 Light GBM 兩模型具有較高準確率，並且兩模型準確率差異小於 3%以內。比較深度學習模型 CNN，CNN 的準確率幾乎不及本文使用的最佳結構化方法，Splitting Feature 的準確率。故本文找出最佳圖像資料結構化方法 Splitting Feature，一來具有解釋性，二來具有準確率的圖像資料結構化方法，並且搭配統計與機器學習模型驗證，在三種資料的風格分類上，準確率都呈現不錯的結果。

將圖像資料結構化方法實驗於圖像風格多分類，台灣四大報能夠準確的分類出各個報紙的頭版版面，因為報紙各家版面排版有較固定的格式，所以在多分類結果中也有良好的表現。在 Vogue 中，1970 年代、1980 年代最能夠分辨該時代的時尚封面，但在最近的兩個時代，1990 年代、2000 年代，雜誌的封面較易被相互分錯。在油畫畫家分類結果當中，各畫家被分類錯誤的機率皆不低，也不論畫派與否，皆有可能被相互分類錯誤，顯示本文使用的結構化方法在畫家分類上產生較差的結果。推測與油畫內容有許多細節有關，畫作較難以量化的方式去進行描述。由分類結果觀察，使用本文提出的圖像結構化方法，雖然在多分類結果上，準確率有些微下降，但在二分類中，都能得到不錯的結果，證明本文使用的結構化方法，可以得到一定的結果。

第二節 未來建議

本文使用顏色、形狀、位置做為結構化方法，以圖像風格為分類目標。而結果，將圖像進行分割，再透過變數選取的 Splitting Feature，可以在圖像風格分類上有不錯的結果。本文雖然取三種圖像作為實驗對象，但圖像資料的範圍與特色不僅僅侷限於報紙、雜誌、畫作，而分類議題也不只侷限於風格分類。而如今演算法模型可

以應用的圖像領域非常廣泛，人臉識別、物件偵測、字體識別等問題。這些議題在圖像結構化的方法上，並未有像演算法模型這麼好的準確率。在未來，若非結構化資料要同時具有解釋性與準確率，就必須在結構化方法上有所進步。

本文提出使用邊緣化檢測的方法作為描述形狀、輪廓的變數，雖然邊緣化的方法能粗略地將圖像的輪廓描繪出，但經常受到異常值（雜訊）的影響，容易將異常值判斷為圖像之邊緣。本文建議可以針對此方法進行改進，去除雜訊問題，真實的將圖像輪廓描繪出。並且將探討的議題延升至物件偵測、物體識別等問題。比方說，在台灣四大報頭版資料中，如何判別文字的區域、圖片的區域或是人物照片的位置，雖說本文使用的邊緣檢測方法可以將報紙頭版含有資訊描繪出來，但是並不能真正判斷物體的真實意義。若能將物體意義判斷出，那在未來結構化方法可以延伸至更複雜的圖像應用領域。

在畫作風格分類上，可以改進本文使用的畫風風格研究，在風格上經過更細緻的探討。像是印象派可分為印象派、新印象派、後印象派。根據三種時期，呈現的繪畫技巧與作風，也有許多差異。印象派特色為光影的手法呈現畫作效果，代表作家為竇加、莫內等人。新印象派強調點的特色，代表作家為秀拉、席涅克。後印象派並沒有實際組成一個繪畫運動，像是塞尚強調物象存在的形式主義，梵谷重視情感與精神的表現¹¹。而此類的圖像類型在本文有所限制，之後可以結合藝術領域的專家意見，針對畫家的繪畫風格進行剖析，有助於在討論畫作風格分類上有更好的結果。

¹¹ 參考論印象派繪畫的藝術特色（楊賢藝，2006）。

參考文獻

一、中文文獻

1. 孔萬增、朱善安 (2007)。「基於切割子模塊的單樣本人臉識別」，《光電工程》，34 (8)，頁 110-114。
2. 任大勇、賈振紅、楊傑 (2019)。「結合位圖切割和區域合併的彩色圖像分割」，《計算機工程與應用》，55 (2)，頁 162-167。
3. 柯裕嘉 (2011)。「報紙消費者對頭版新聞形式與內容喜好度研究」，國立台灣師範大學圖文傳播學系碩士論文，頁 1-120。
4. 胡毅 (2015)。「米勒《拾穗》賞析」，《時代文學 (下半月)》，第 7 期，頁 75-75。
5. 施振祥 (2010)。「基於顏色和邊緣信息分佈的圖像檢索」，《計算機科學》，37(2)，頁 256-260。
6. 辜衛東、李兵 (2018)。「基於隨機區域合併的自動彩色圖像分割算法」，《計算機科學》，45 (9)，頁 279-282。
7. 黃衍翠 (2010)。「從《日出·印象》談印象派油畫之美」，《時代文學 (上半月)》，第 3 期，頁 229-231。
8. 楊賢藝 (2006)。「論印象派繪畫的藝術特色」，《藝術教育》，第 4 期，頁 94-95。
9. 劉振源 (1900)。「印象派繪畫」，藝術圖書出版社，頁 1-252。
10. 龔如森 (2016)。「西班牙藝術夜空裡的星光-寫實主義的委拉斯蓋茲與浪漫主義的哥雅」，中國文化大學藝術學院美術學系學系碩士論文，頁 1-136。

二、英文文獻

1. Barni, M., Pelagotti, A., and Piva, A. (2005) "Image processing for the analysis and conservation of paintings: opportunities and challenges." *IEEE Signal Process Magazine*, 22, 141–144.
2. Canny, J. (1986) "A computational approach to edge detection." *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8, 679–698.
3. Cheng, Y.C. and Chen, S.Y. (2003) "Image classification using color, texture and regions." *Image and Vision Computing*, 21 (9) , 759–776.
4. Chen, W., Shi, Y.Q., and Xuan, G. (2007) "Identifying computer graphics using HSV color model and statistical moments of characteristic functions." *IEEE International Conference on Multimedia and Expo*, 1123–1126.
5. Christiana, W. (2014) "Female image in Vogue magazine: A pictorial analysis of facial and body language." *Robots Reading Vogue*.
6. Junhua, C. and Jing, L. (2012) "Research on color image classification based on HSV color space." *Second International Conference on Instrumentation, Measurement, Computer, Communication and Control*, 944–947.
7. Kabade, A.L. and Sangam, D.V. (2016) "Canny edge detection algorithm." *International Journal of Advanced Research in Electronics and Communication Engineering*, 5 (5) , 1292–1295.
8. Kaur, B. and Garg, A. (2011) "Mathematical morphological edge detection for remote sensing images." *International Conference on Electronic Computer Technology*, 5, 324–327.

9. Lee, S.G. and Cha, E.Y. (2016) “Style classification and visualization of art painting’s genre using self-organizing maps.” *Human-centric Computing and Information Sciences*, 6, No.7.
10. Rabby, M.K.M., Chowdhury, B., and Kim, J.H. (2018) “A modified canny edge detection algorithm for fruit detection and classification.” *10th International Conference on Electrical and Computer Engineering*, 237–240.
11. Pal, N.R. and Pal, S.K. (1993) “A review in image segmentation techniques.” *Pattern Recognition*, 26 (9) , 1277–1294.
12. Peter, L. (2013) “Vogue Cover Averages.” *Robots Reading Vogue*.
13. Rong, W., Li, Z., Zhang, W. and Sun, L. (2014) “An improved canny edge detection algorithm.” *Proceeding IEEE International Conference on Mechatronics and Automation*, 2 (2) , 577–582.
14. Phoebe, P. (1997) “Impressionism.” *Thames and Hudson*, 1–187.
15. Rohit, G. (2019) “LightGBM - Another gradient boosting algorithm.” , Retrieved March 28, 2019, from: <https://rohitgr7.github.io/lightgbm-another-gradient-boosting/>
16. Süsstrunk, S., Buckley, R., and Swen, S. (1999) “Standard RGB color spaces.” *Color and Imaging Conference*, 127 - 134.
17. Seetharaman, K. (2019) “Melanoma Image Classification Based on Color, Shape, and Texture Features Using Multivariate Statistical Tests.” *Journal of Computational and Theoretical Nanoscience*, 16 (4) , 1717–1724.

18. Song, M. and Civco, D. (2004) "Road extraction using SVM and image segmentation." *Photogrammetric Engineering and Remote Sensing*, 70 (12), 1365–1371.
19. Salman, A., Semwal, A., Bhatt, U., and Thakkar, V. M. (2017) "Leaf classification and identification using Canny Edge Detector and SVM classifier." *Proceedings of the 2017 International Conference on Inventive Systems and Control (ICISC)*, Coimbatore, India, 19–20 January 2017, 1–4.
20. Xin, M. and Wang, Y. (2019) "Research on image classification model based on deep convolution neural network." *EURASIP Journal on Image and Video Processing*, 40.
21. Denny, B. (2015) "Understanding Convolutional Neural Networks for NLP." Retrieved November 7, 2015, from: <http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp/>