國立臺灣師範大學
資訊工程研究所碩士論文

指導教授：　葉梅珍　　博士

基於多核學習之球鞋喜愛度預測方法

Predicting the Popularity of Sneakers by Using Multiple Kernel Learning

研究生：　楊少廷　撰

中華民國　　一百零三　　年　七　月

國立臺灣師範大學資訊工程研究所
碩士學位論文

基於多核學習之球鞋喜愛度預測方法

Predicting the Popularity of Sneakers by Using Multiple Kernel Learning

經考試合格特此證明

審查教授：_____

_____

_____

_____

_____

_____

指導教授：_____

研究所所長：_____

中華民國　　年　　月

摘 要

在此研究中，我們藉由多個不同類型的資訊來描述球鞋產品，以達到預測消費者對於球鞋喜愛度之目的。透過使用 Sole Collector 球鞋網站上所提供之資料建置了 1913 雙球鞋之資料庫，資料包含了球鞋圖片、名稱、及價錢等，並利用其當作訓練集與測試集。對於球鞋產品，本工作做了不同面向的描述，擷取多種特徵，並利用機器學習中的多核學習(Multiple Kernel Learning, MKL)方法結合多個適合各自特徵空間的前計算核(Pre-computed Kernel)，藉由這些前計算核的線性組合訓練出球鞋喜愛度分數預測模型，透過新球鞋之特徵資訊當作輸入，輸出球鞋受消費者喜愛度的預測分數。實驗部分則提供了多核學習與支持向量回歸(Support Vector Regression, SVR)兩方法比較，結果顯示相同核數下，使用後期融合方法(MKL)較前期融合方法(SVR)在預測球鞋喜愛度問題上，有較佳的關聯性。而使用前計算核廣泛上擁有較徑向基函數核(Radial basis function kernel)更好的表現。

關鍵字: 支持向量回歸、多核學習、球鞋、喜愛度

ABSTRACT

In this paper, we explore using different sources of information to describe sneakers based on which we predict the popularity of sneakers. In particular, we utilize Multiple Kernel Learning (MKL) techniques to train a popularity prediction model consisting of multiple pre-computed kernels that were suited to their own feature space. We further evaluate two regression models: support vector regression (SVR) and MKL to predict a popularity score from several features. In the experiment, we collected 1913 sneakers images from Sole Collector for building a dataset for both training the model and evaluating the prediction accuracy of the approach. We show that a late fusion method (i.e. MKL) has a better performance than an early fusion method (i.e. SVR) in predicting the popularity of sneakers. The pre-computed kernels have better result than radial basis function kernel generally.

Keywords: Support Vector Regression; Multiple Kernel Learning; Sneakers; Popularity;

誌　謝

在這兩年的學習生涯中，很幸運地，一路上擁有許多幫助我的貴人，謹以此誌謝表達無上的感激之情。首先我想感謝我的指導教授葉梅珍老師，無論是在專業知識上的引領或是多媒體領域眼界的啟發，都為我帶來了全新的格局及寬闊的視野。老師循循善誘的教學方式，使我更瞭解領域內的最新技術及相關知識。而對於我的問題，老師總是悉心不厭其煩地指導。感謝老師的諄諄教誨，使我的研究所生涯獲益良多。

接著，我想感謝學長姐浩禎、嫕詞、淳卉，在碩一的時候給予了我相當多寶貴的建議，傳承了諸多學業上的經驗。當然還有這段日子陪我一起同甘共苦的夥伴們：尹廷、晏瑋、曉薇、宜璁。很高興在這段時間有你們的勉勵及陪伴，無論在課程或是論文上都給予我許多幫助，擁有你們這群夥伴，真是彌足珍貴的一件事，謝謝你們。

最後，我想感謝我的家人，在學習生涯中，無論遇到什麼挫折皆悉心支持與鼓勵，做為我最溫馨的靠山，謹以此論文獻給他們。

少廷 謹識

2014 年 8 月

目錄

附表目錄

附圖目錄

第一章　簡介

在此章節中，我們將會探討關於本研究題目的背景動機，並由其延伸至欲達成之目的。而透過這些觀察，也引領出關於此題目之想法以及解決此問題的方式。

1.1 研究動機

隨著時代的演進及流行趨勢之改變，球鞋產品已經成為人們不可或缺的造型配件之一。不再侷限於運動場上的專業機能性穿著，在現今提倡運動蔚為風氣的影響下，從民眾平時運動乃至平日穿搭的流行文化，隨著大眾需求之改變，球鞋產品已充斥於人們的日常生活中。而廣大的市場需求及隱藏於背後的商機也為相關產業帶來龐大之商業利益。

其中，不同類型的鞋款於市場的接受度也不盡相同，有些產品一推出即成為熱賣商品，成功吸引廣大消費者的喜愛，造成搶購熱潮並帶起新一波流行話題；而某些產品則乏人問津，較不受顧客之青睞。於是，無論從產業或消費者的眼中，如何從現今的球鞋產品中去預測未來商品受歡迎的程度，成了一個值得探討的問題。例如：業者可藉由現今所掌握到之市場走向，找出目前廣受喜愛的熱賣商品，投以更多相關產品之開發，獲得更多的產業營收；而消費者可藉由此資訊，了解目前的人氣商品，當作流行穿著之參考。

而藉由網際網路的普及，我們越來越容易可以從社群媒體及網站獲得球鞋產品之最新相關資訊，例如：Sole Collector [1]、NiceKicks.com [2]、Sneaker News [3]等，這些知名國外球鞋網站皆提供了許多第一手資訊及各式評論等新聞。而在此類平台中，Sole Collector [1]網站又提供了一項有趣的功能，網站使用者可以對

於過去已上市以及即將上市之鞋款進行點選喜歡與否的投票，在這群潛在消費者表達對於該鞋款的喜好之後，網站也會顯示該項產品受網站使用者歡迎的喜好百分比，而此百分比也可視為球鞋消費市場之縮影，作為市場機制的參考評估，藉以展現出目前球鞋產品之流行趨勢及各類受消費者歡迎的鞋款。

1.2 研究目的

我們想利用過去發售的鞋款資訊去預測消費者對於新鞋款的喜好程度。透過 Sole Collector [1] 網站上的喜好程度當作媒介，各式形形色色的鞋款都擁有自身的喜好百分比，我們將其視為潛在消費者欲購買此商品之喜好程度。圖 1.1 展示了 Sole Collector [1] 的網站介面，其中包含了球鞋圖片、發售日期、球鞋名稱、產品描述、型號、買(COP)或不買(NOT) 選項的百分比等等。而在觀察各類鞋款本身的喜好百分比時，發現到不同類型的鞋類產品經常擁有大不相同的喜好趨勢，無論從產品本身出發的造型與顏色，到不同的產品線如籃球鞋、慢跑鞋、訓練鞋等商品定位差異，亦或是明星代言所引發之名人效應及品牌價值等等，都讓不同球鞋產品擁有大不相同的喜好度差異。

有鑑於此，也發現到某些鞋款經常擁有較高的喜好百分比，是市場上相當熱賣的人氣商品，而部分鞋款相對來說似乎較不受到歡迎。這令我們思忖為何存在著如此差異，哪些因素左右了消費者對於一雙鞋款的喜好，影響喜好的資訊是否有跡可循，而是否能利用目前所擁有的資訊，如產品名稱及鞋款外觀顏色和造型等等，以預測未來尚未上市之鞋款在市場的接受度如何，找出目前的流行趨勢，作為業者將來產品發售前市場策略之評估，這也是本研究所欲探討之目的及議題。

在本論文中使用了顏色、外型等描述特徵詮釋一雙球鞋的特色，並以文字特徵成功將將品牌價值、明星代言等較為無形卻會影響消費者喜好之因素轉化為數據形式，透過多核學習(Multiple Kernel Learning)方法，展示了利用以上方法對於預測新鞋款的喜好程度具有關聯性。

1.3 論文架構

本篇論文的編排架構如下：第一章描述研究動機及目的，第二章對相關研究進行探討，第三章呈現了對於球鞋產品所擷取的特徵介紹，第四章則為機器學習方法，第五章則介紹實驗用的資料庫及實驗結果分析，第六章則為結論及未來展望。

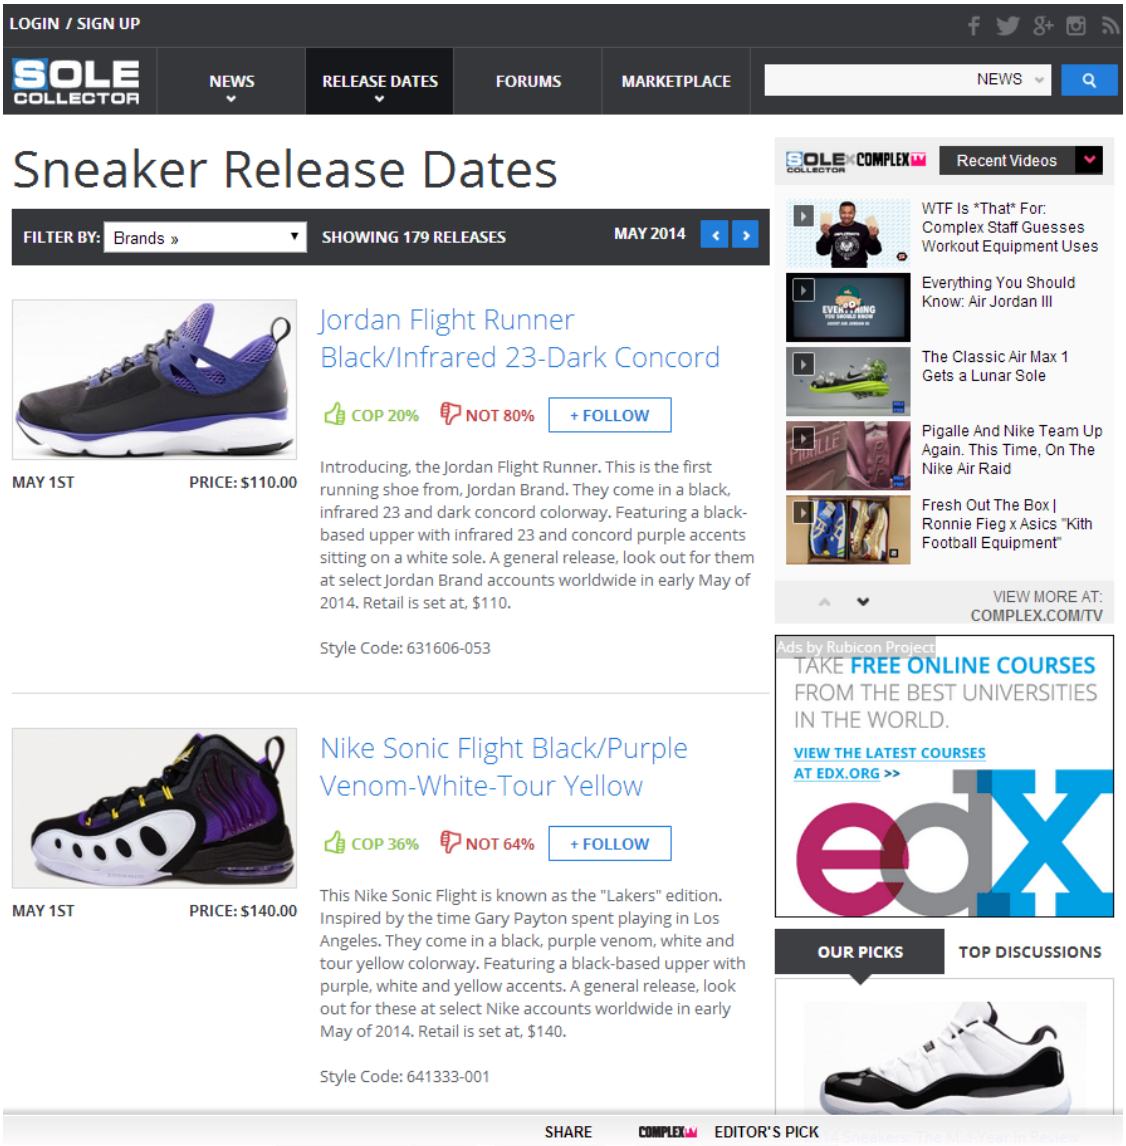

圖 1.1 Sole Collector 網站介面圖

第二章　相關文獻探討

在第一章中提到，本研究將預測球鞋喜愛度問題轉化為機器學習問題，其相關工作，可分為兩部分。其一為根據不同目的去擷取合適的特徵，其二則是使用不同機器學習方法去解決各種類型的預測問題。

在特徵擷取方面，由於本工作認為球鞋產品的名稱包含了有用的資訊，因此必須對文字部分做一處理。Salton et al.提出了詞袋模型(bag-of-words model)的概念 [4]，其在自然語言處理(Natural language processing)及資訊檢索(Information)領域上為常見的表示方式。例如基於此模型做垃圾信件過濾之應用，在信件詞彙中常會出現許多廣告用詞，我們即可利用此特性，將關鍵詞彙出現與否作為垃圾信件和一般信件之分類依據。在此模型中，會將文字中出現的詞彙視為詞袋內單一的物件，由於每個詞彙都是獨立的單位，因此屏除掉了文法、順序等關聯性，但保持了每個詞彙出現的重複性。詞袋模型將每一個出現過的詞彙視為一特徵以訓練分類器來解決分類問題。在本工作中，想使用球鞋名稱內的關鍵詞彙來當作特徵來源之一，如品牌名稱以及不同的代言人等等，由於只考慮關鍵詞彙的出現與否而不考慮其順序關聯性，因此我們採用了詞袋模型方法來達成此目的。

機器學習方面，支持向量回歸 (Support Vector Regression) [5] 廣泛被應用於解決各種回歸問題，其在解決不同類型的問題上得到了不錯的效果。Kavaklioglu 提出使用支持向量回歸方法去預測土耳其電力消耗的問題 [6]。Faynburd 則藉由支持向量回歸方法對金融領域上去預測經濟價格的變動 [7]。Salcedo-Sanz et al. 則運用了支持向量回歸去解決預測風速的問題 [8]。Narwaria et al. 則利用此方法去評估圖像的品質 [9]。

而在本研究中，由於包含了不同的異質特徵，使用單一核做訓練模型的支持向量回歸方法，無法充分利用各自特徵的優點，因此我們使用了多核學習 (Multiple Kernel Learning) [10] 方法來解決此問題。多核學習近年來也常被利用於解決分類及多種回歸問題。Yeh et al. 即使用了多核技術應用於股價預測 [11]。Guillaumin et al. 利用多核學習方法改善了圖像分類的問題 [12]。 Joutou et al. 提出藉由多核學習方法整合多個特徵以達辨識食物圖片的目的 [13]。Deng et al. 結合多核學習及遺傳演算法去預測短期國外匯率問題 [14]。Zhao et al. 則使用多核學習去對工業上的儲氣罐等級做一預測 [15]。Spirovska et al.則討論了多核學習之優點並將其用於生物領域研究上 [16]。而綜合上述之文獻，本研究將預測球鞋的喜愛度分數視為一個回歸問題，藉由多核學習之方法結合異質特徵，訓練出預測模型，藉由輸入新球鞋特徵得到輸出的預測分數，以達成預測新球鞋喜愛度之目的。

第三章　球鞋特徵擷取

本研究所提出之方法為藉由 Sole Collector 網站[1] 所蒐集到之資訊，進而自動預測消費者對於球鞋的喜愛度分數。分數越高代表此雙球鞋越受消費者喜愛，且擁有較高的可能性去購買此商品。反之，分數越低代表相對來說比較不受消費者喜愛。

為達此目標，我們將整個方法分為兩部分討論，首先，使用不同的特徵去對整雙球鞋的資訊進行不同面向的詮釋。接著使用了支持向量回歸(Support Vector Regression)及多核學習(Multiple Kernel Learning)方法去訓練出預測模型來對球鞋喜愛度分數進行預測。

圖 3.1 展示了整個系統的流程圖，包含了球鞋的特徵擷取以及機器學習兩部分，特徵方面使用到了文字及圖像兩類資訊，機器學習則利用 SVR 和 MKL 技術去訓練出喜愛度預測回歸模型。最後，藉由新球鞋的資訊當作輸入，輸出得到該鞋款被預測出之喜愛度分數。

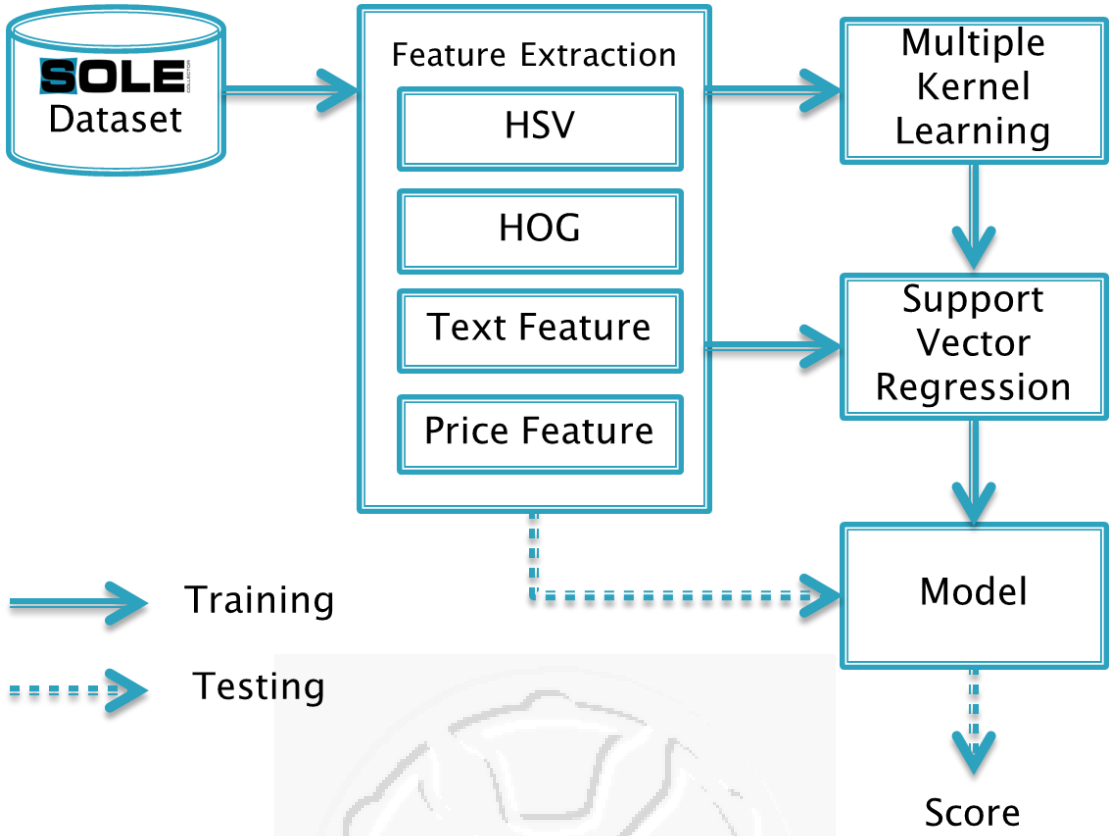
SOLE
Dataset
Feature Extraction
HSV
HOG
Text Feature
Price Feature
Multiple Kernel Learning
Support Vector Regression
Model
Score
Training
Testing

圖 3.1 系統流程圖

3.1 圖像特徵

在眾多設計中，顏色始終扮演著重要的一環，消費者易根據不同顏色投以所好，進而影響購買慾望。在本工作當中，也使用了顏色特徵去描述一雙球鞋，我們想知道顏色對於影響消費者喜愛球鞋的程度為何。為了擷取球鞋圖片的顏色，我們將 RGB 色彩空間轉換到 Hue-Saturation-Value (HSV)色彩空間，並擷取 HSV 色彩空間中的顏色直方圖。HSV 色彩空間類似於人類感覺顏色的方式，其擁有較強感知度的特性在此用來當作評量球鞋顏色的考量。式(3-1)至(3-4)展示了 RGB 與 HSV 之間的轉換關係公式，經由計算生成了 256 維的顏色特徵。圖 3.2 呈現了 HSV 色彩空間的表示法，Hue(色相)是色彩的基本屬性，即顏色的名稱；Saturation(飽和度)指色彩的純度，值越高則色彩越純；V(明度)，代表影響色彩的明亮度。

$$H1 = cos^{-1}\left\{\frac{0.5[(R-G)+(R-B)]}{\sqrt{(R-G)^2-(R-B)(G-B)}}\right\} \qquad (3-1)$$

$$H = \begin{cases} H1 & ,B \le G \\ 360° - H1 & ,B > G \end{cases} \qquad (3-2)$$

$$S = \frac{Max(R,G,B) - Min(R,G,B)}{Max(R,G,B)} \qquad (3-3)$$

$$\mathrm{V} = \frac{Max(R,G,B)}{255} \qquad (3-4)$$

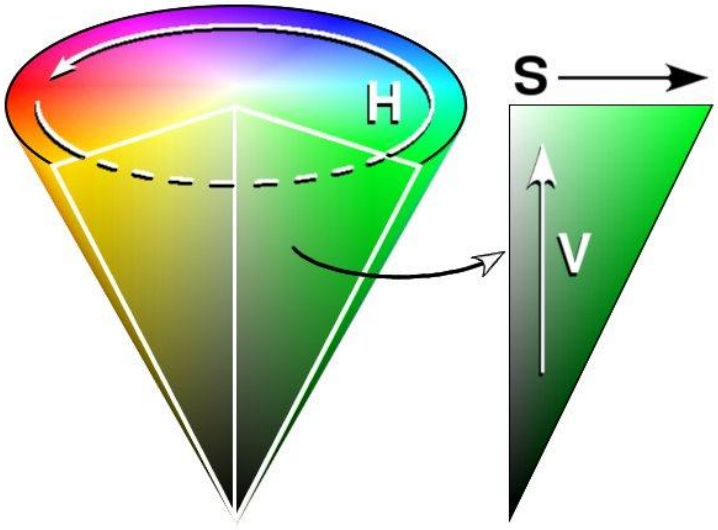

圖 3.2 HSV 空間表示圖

而一個物件的外觀除了以顏色觀點來詮釋，形狀的考量也是切入點之一。以球鞋來說，不同的球鞋產品擁有大不相同的形狀外貌，像是不同的筒高、繁複與否的鞋面構造等等，這些外觀上的差異也是成為影響消費者購買欲望的因素之一。在此工作中，本研究中使用到了 Histogram of Oriented Gradients (HOG) [17]特徵來對球鞋形狀進行描述。其主要想法為圖像中的球鞋外觀和形狀可以被像素強度梯度和邊緣方向得到良好地描述。HOG 表示的是邊緣梯度方向的結構特徵，因此可以描述局部的形狀信息，我們想利用此特點去描述出球鞋產品局部的獨到設計，而位置和方向空間的量化一定程度上也可抑制平移和旋轉帶來的影響，由於一定程度忽略了光照對圖像造成的影響，使得圖像所需要之數據降低，擁有計算量較小之優點。其特徵擷取方法首先將圖像進行灰度化處理，接著分為多個方格連通區域(Cells)，並蒐集方格內各像素點之邊緣方向或梯度方向直方圖，最後藉由組合直方圖即可構成描述特徵，在此研究中擷取了 40 維的形狀特徵。

3.2 文字特徵

除了球鞋本身顏色、外觀造型等有形之資訊，其他較為無形之資訊也納入本工作的考量之一，在討論一項產品受消費者的喜愛度時，無可避免地必須探討所謂品牌迷思以及名人效應對消費者產生之影響。在媒體資訊快速流動的時代，無論行銷策略或是流行趨勢往往展現出一個品牌的價值，不同的品牌也經常擁有各自的忠實消費者。而擁有明星代言之商品，往往較容易獲得消費者之關注，造成市場上熱賣的搶購熱潮，進而影響消費者最後的購買欲望。本論文想知道品牌效應及明星代言產品對於消費者的喜愛度是否具有影響，圖 3.3 顯示了資料庫中不同品牌的平均喜愛度。分別列出了三大球鞋品牌及其他品牌間的喜愛度比較，「Other」類別代表著三大品牌之外的所有品牌之集合。數據分析上顯示「NIKE」、「ADIDAS」、「REEBOK」這三大球鞋品牌確實擁有較「Other」類別較高的喜愛度，而「Total」標籤則代表了整體資料庫的平均喜愛度。

在圖 3.4 當中，也展示了品牌間不同明星代言人球鞋產品的平均喜愛度分數。在此列出了三大品牌內之不同球星代言及未有代言之一般鞋款(Conventional Shoes)比較。結果顯示，明星代言之鞋款較一般鞋款，廣泛來講擁有較高的消費者喜愛分數。而在「Jordan Brand」此項類別中，雖然並無與一般鞋款之喜愛度擁有顯著的差異，但在此類別中，其喜愛度分數的標準差為 22.342，高於一般鞋款之標準差 13.169，代表在此類別中，確實擁有高喜愛分數之球鞋產品。

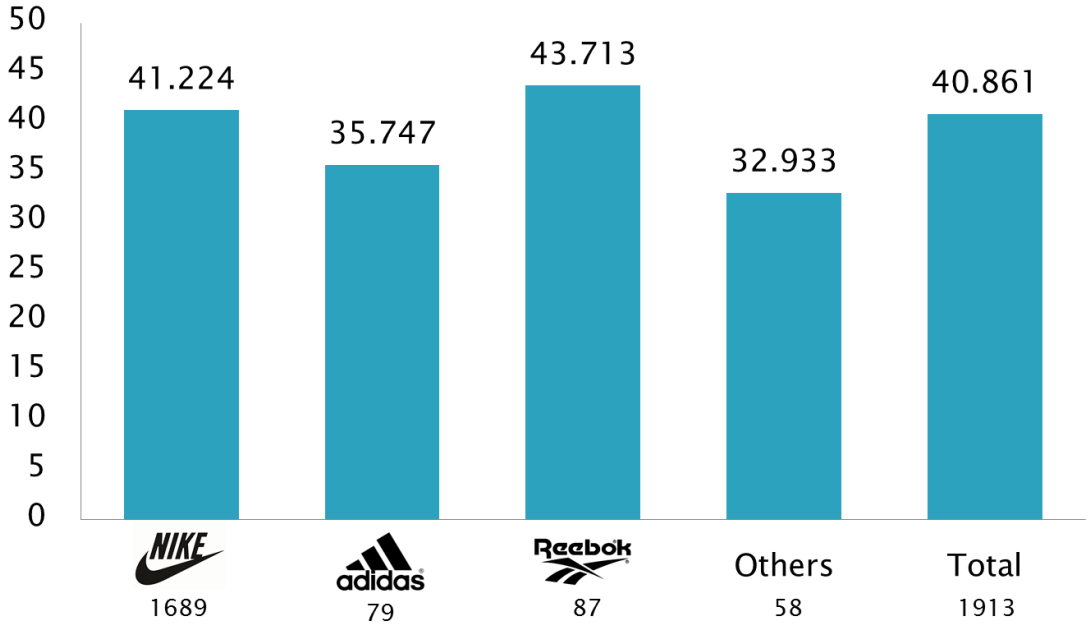

圖 3.3 不同品牌之平均分數

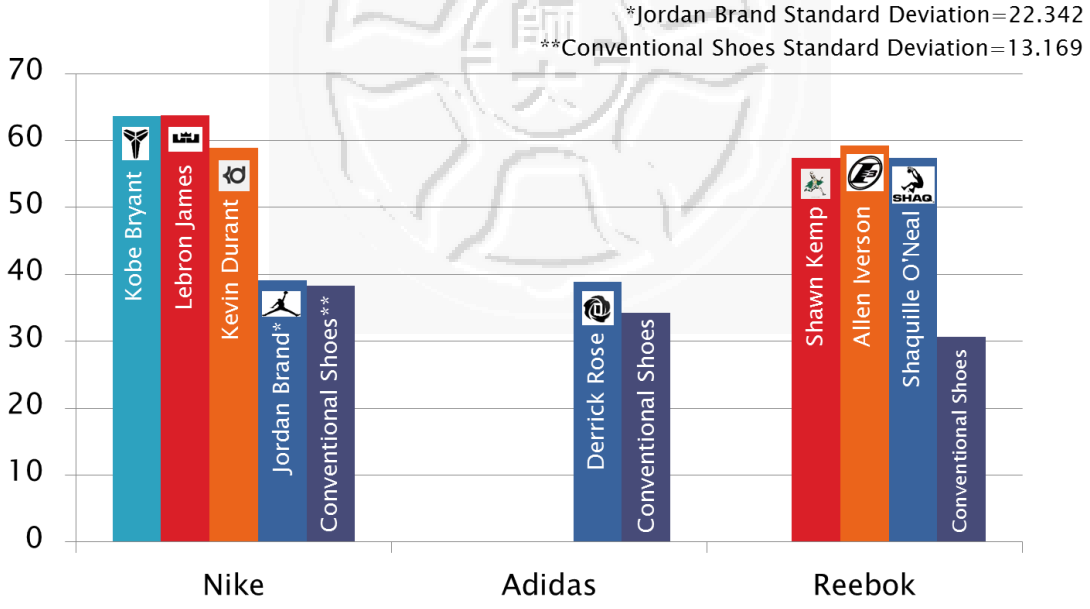

圖 3.4 不同代言人之平均分數

由於一雙球鞋的名稱包含了許多資訊，像是所屬品牌、代言人名稱等等，在此方法中，我們擷取了球鞋的商品名稱當作文字特徵。接著，採用了 Bag-of-Words 之方法，藉由分割出商品名稱內的各個單一詞彙(Word)，建造出共含 873 個詞彙的字典(Dictionary)，藉由商品名稱內所出現之詞彙與字典內的辭彙進行比對，如該詞有出現，即將其對應位置數值設為 1，其他則設為 0。最終建構出 873 維度的稀疏矩陣，並將其視為文字特徵。

此外，每雙鞋款的價錢也是我們認為影響消費者喜愛度的因素之一，消費者可能會根據產品價值與定價間的權衡，影響對於該產品的喜愛度。在此，直接擷取了每雙球鞋的價錢當作價錢特徵。

第四章　機器學習

根據第一章節內之描述，本研究將喜愛度預測問題轉化為機器學習問題。藉由訓練樣本學習其特徵向量，並利用學出來之方程式為新球鞋預測消費者的喜愛度。在本論文中，實作了支持向量回歸(Support Vector Regression)及多核學習(Multiple Kernel Learning)兩種方法。

4.1 支持向量回歸

在此工作中使用了 LIBSVM [18]去建構出回歸模型以預測球鞋喜愛度。支持向量回歸的目標為找出空間中最能準確預測資料的超平面(Hyperplane)，假設訓練集樣本可表示為 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$，$x_i$表示維度 d 之輸入特徵，y_i則代表每雙球鞋的喜愛度分數，即特徵所對應的回歸值。我們的目標是學出一線性回歸模型，令 $\mathrm{f(x)} = \mathrm{w} \cdot x_i + \mathrm{b}, \mathrm{w} \in R^d, \mathrm{b} \in \mathrm{R}$，w 即代表支持向量回歸方法欲找出之超平面。此問題可改寫至下列形式：

$$\min \frac{1}{2} \|w\|^2 \qquad (4-1)$$

$$\text{s.t. } \|y_i - (w \cdot x_i - b)\| \leq \varepsilon, \ \ for\ i = 1, \dots, n \qquad (4-2)$$

其中 $\varepsilon \geq 0$ ，藉以表示支持向量回歸實際與預測值的最大差距，此演算法也稱為$\varepsilon - \mathrm{SVR}$。支持向量回歸中，實際值與預測值間的差值必須小於 ε。

在大多數的實際應用當中，因含有誤差、雜訊等不同因素，因此我們必須加入額外的項，以容許某些案例落在 ε 範圍外：

$$\min \frac{1}{2}\|w\|^2 + C\sum_{i=1}^{n}(\xi_i + \xi_i^*) \qquad (4-3)$$

$$\text{s.t.}\begin{cases} y_i - w\cdot x_i - b \le \varepsilon + \xi_i \\ w\cdot x_i + b - y_i \le \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \ge 0 \end{cases} \qquad (4-4)$$

式(4-3)及(4-4)當中，每個訓練樣本皆有其對應之 ξ 以及 ξ^* ，用以決定訓練樣本是否可落在 ε 之範圍外。C 值則用以權衡過分調適資料(Overfitting)以及不足調適(Underfitting)的問題。

4.2 多核學習

首先對於使用多核學習(MKL)的動機進行說明。支持向量回歸使用核函 $k(x_i, x_j)$ 去計算樣本 x_i 與 x_j 間的相似度。而其表現是根據核函數的好壞所決定，然而實際所應用到的學習問題經常包含了多種不同的異質(Heterogeneous)特徵，每個特徵空間所合適的核函數不一定相同，因此，在此論文中使用了多核學習方法，來解決球鞋喜愛度預測問題。圖 4.1 展示了多核學習架構示意圖，輸入球鞋資料，其由不同的特徵所組成，而每個特徵空間皆有其對應之核函數，藉由這些核函數的組合可以得到合成核，利用其訓練出回歸因子，最後得到輸出，即預測之球鞋受歡迎分數。

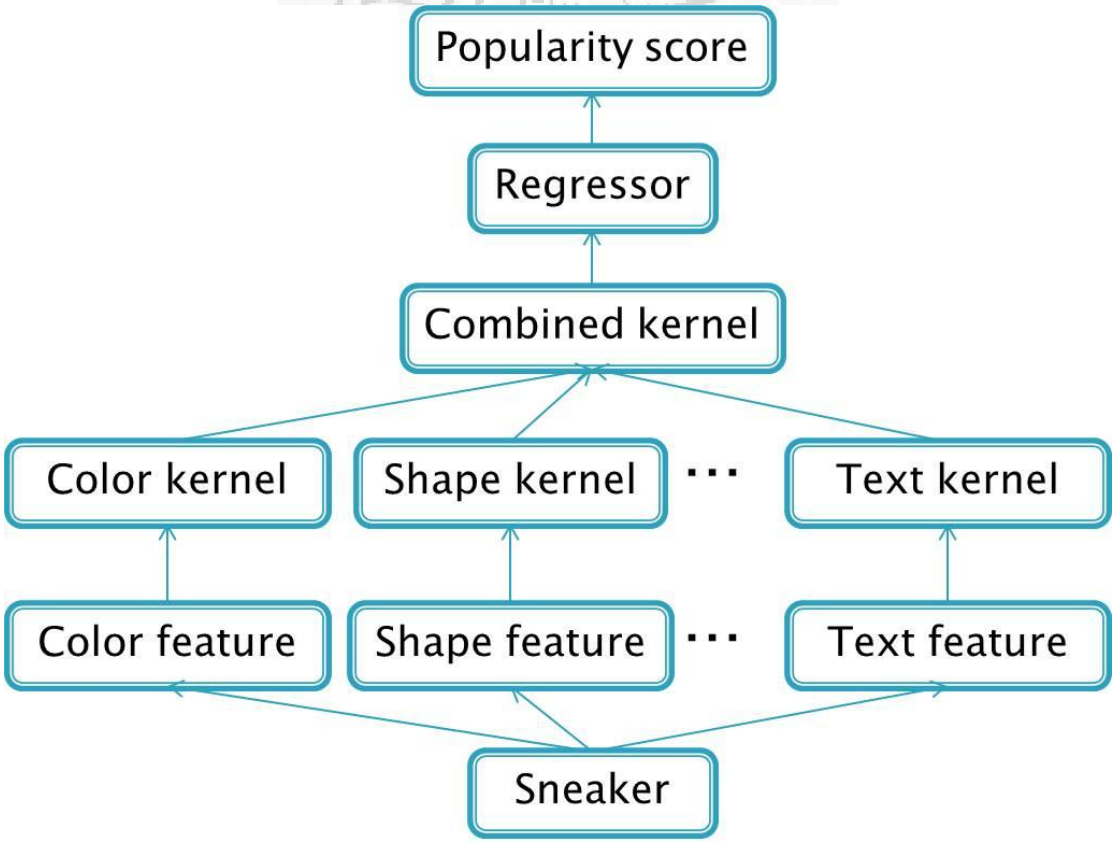

圖 4.1 多核學習架構示意圖

在此工作中，我們使用[19]所描述之方法，去建構出回歸模型以預測球鞋喜愛度。多核學習的目標為藉由訓練資料$\{(x_i, y_i)\}$學出回歸因子(Regressor)以及各個核之權重。線性多核學習針對於學出多個核的線性組合：$\mathrm{K} = \sum_k d_k K_k(x_i, x_j)$. $\{K_k\}$代表基底核(Base kernels)的集合，而$d_k \geq 0$。而其主要問題可描述為：

$$\min_{w,\xi \geq 0, b, \mathbf{d} \geq 0} \sum_k \frac{1}{2} \frac{w_k^T w_k}{d_k} + C \sum_i \xi_i + \lambda r(\mathbf{d}) \qquad (4-5)$$

$$\text{s.t.} \quad y_i \left(\sum_k w_k^T \Phi_k(x_i) + b \right) \leq \epsilon + \xi_i \qquad (4-6)$$

此優化問題是由遺失項(Loss)及調整項(Regularization)所組成，其中ξ代表鬆弛變數(Slack variable)，而$\{\Phi_k\}$表示特徵所對應至之特徵空間。r(**d**)此為調整項用以避免 **d** 至無限大。

4.3 核函數

由於先前蒐集之球鞋特徵為異質特徵，必須使用適合彼此特徵空間的核函數(Kernel function)計算特徵的相似性，才可達到較佳的預測效果。在此段落，將會討論幾個用於本工作的核函數。

根據［20］的研究，發現使用直方圖交集核(Histogram Intersection Kernel)在圖像分類問題上比起其他核擁有較佳的準確率。我們使用直方圖交集核來為顏色及形狀特徵空間計算相似度。

$$K_{color}(X_{color}, Y_{color}) = \sum_{i=1}^{n_c} min\{x_i, y_i\} \qquad (4-7)$$

在文字特徵方面，本論文使用了卡方核(chi-squared) 去計算資料點的相似性。由於採用 Bag-of-Words 方法之文字特徵為較離散(discrete)的形式，相較於 Radial basis function (RBF)核實用於平滑(Smooth)的資料，在此使用卡方核去計算離散特徵間的交集。

$$K_{text}(X_{text}, Y_{text}) = \sum_{i=1}^{n_t} \frac{2x_i y_i}{(x_i + y_i)} \qquad (4-8)$$

而在價錢特徵上，在此將每雙球鞋的價差當成相似度的考量，假使兩雙球鞋價錢的價差是較小的，即認為在市場上，這兩雙鞋擁有相似的產品定位，應擁有較高的相似度。反之，如價差較大，球鞋之產品定位可能大不相同，應得出較小的相似度。式(4-9)為用以計算價錢特徵相似度的核函數，我們引入一自訂參數 C 藉以權衡價差及相似度之值，如果價差小於參數 C 時，即認為兩雙球鞋擁有相似的產品定位，其較小的價錢差異也會影響喜愛度分數；反之，如果兩雙球鞋產品擁有較大的價格差異，其計算出之相似度分數將會小於特定值(在此方法中為 0.5)。在本實驗中，我們將 C 設為 100。

$$K_{price}(x_p, y_p) = \frac{1}{\frac{|x_p - y_p|}{C} + 1} \qquad (4-9)$$

總結來說，本研究藉由在不同的特徵空間上使用不同的核函數，並從訓練資料計算出其各自特徵空間的前計算核矩陣(Pre-computed kernel matrix)。接著，使用多核學習技術訓練出回歸模型，表 4.1 展示了模型內各個特徵空間所佔的權重值。根據表格，我們發現文字特徵及形狀特徵擁有較高的權重，顯示在訓練過程中有較大的影響，而顏色與價錢特徵權重值則相對較低，訓練過程佔較小的影響。

表 4.1 多核學習模型內特徵權重

Feature Space	Weight
Text	529.129
Price	175.914
HOG	295.500
HSV	427.499

第五章　實驗結果與分析

5.1 球鞋資料庫

本實驗之資料庫建置來源為 Sole Collector[1]網站上所提供。每雙球鞋皆收集了其球鞋產品名稱、圖像、及喜愛度分數(範圍為 0 至 100)。在此，共收集了從 2010 年 12 月至 2013 年十月期間發售的 1913 雙球鞋資料。我們將 2010 年 12 月至 2013 年 8 月期間共 1703 雙球鞋資料當作訓練樣本，剩餘 2013 年 9 月及 10 月之 210 雙球鞋資料當作測試樣本。圖 5.1 為資料庫中球鞋圖像之範例。而圖 5.2 展示了資料庫中球鞋喜愛度分數與數量之分布，橫軸則為喜愛度分數區間，縱軸表示區間內之球鞋數量，大多數球鞋產品數量落在 30 及 40 分數區間，而資料庫中最高喜愛度分數之產品為 97 分，最低為 7 分，整體資料庫平均分數為 40.861 分。

圖 5.1 資料庫中之球鞋圖片部分範例

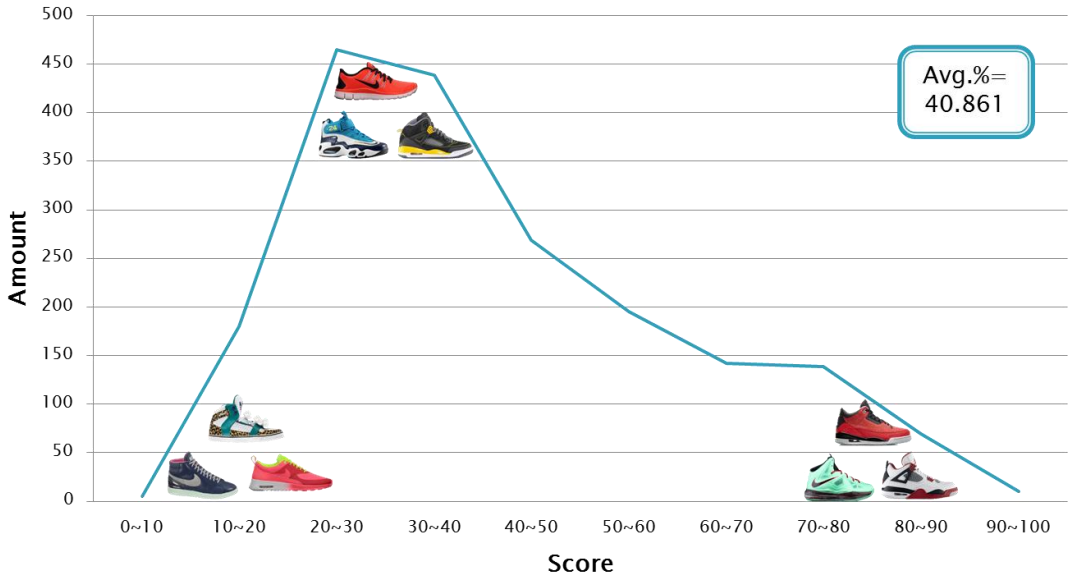

圖 5.2 整體資料庫分數分布

5.2 實驗評估及分析

實驗評量方面，利用了皮爾森相關係數(Pearson correlation coefficient)來衡量預測出的喜愛度分數與實際喜愛度分數的一致性。相關係數為統計分析中的常見概念，其出發點為想用一個數來表示：一、兩者之間的關係度大不大，二、影響的方向為何，如一起變大的趨勢或反之。此係數範圍落在-1 與 1 之間，值為-1 時代表負相關，1 代表正相關，0 則代表沒有關聯，若預測出之結果與實際分數越一致， 皮爾森相關係數應越靠近 1。

圖 5.3 至圖 5.6 顯示了各個單一特徵空間使用不同核函數的結果比較。在文字、形狀(HOG)及顏色(HSV)特徵上，我們使用了 RBF 核、卡方核(Chi-Squared)及直方圖交集核(Histogram Intersection)做比較。在文字及形狀特徵上，我們發現使用卡方核及直方圖交集核比起 RBF 核擁有較好的效果；而在顏色特徵上，則略低於 RBF 核。價錢特徵方面，使用段落 4.3 所提到的核函數，得到較 RBF 核及卡方核更好的結果。

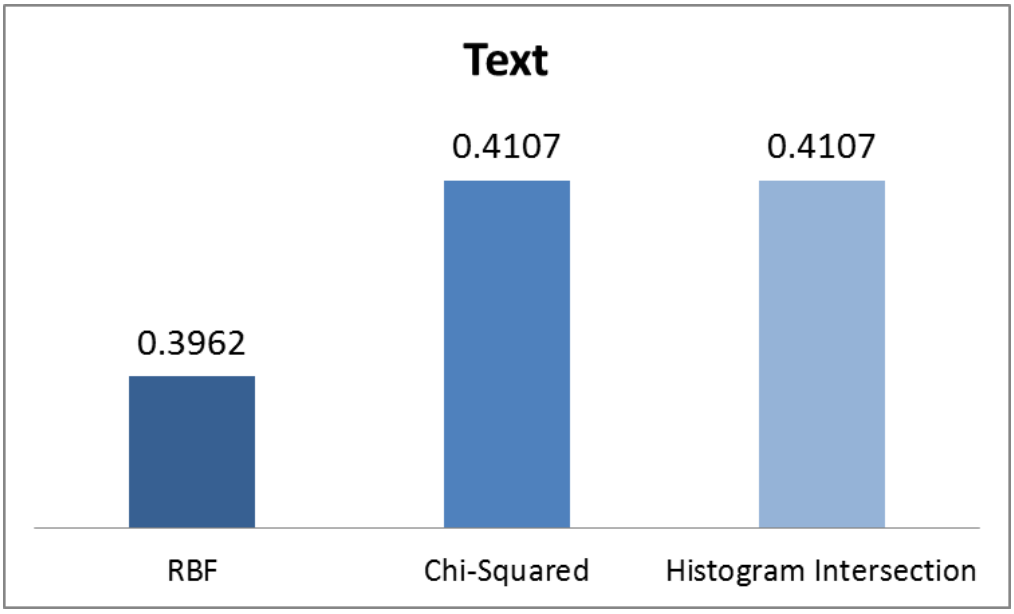

圖 5.3 文字特徵內之不同核函數結果比較

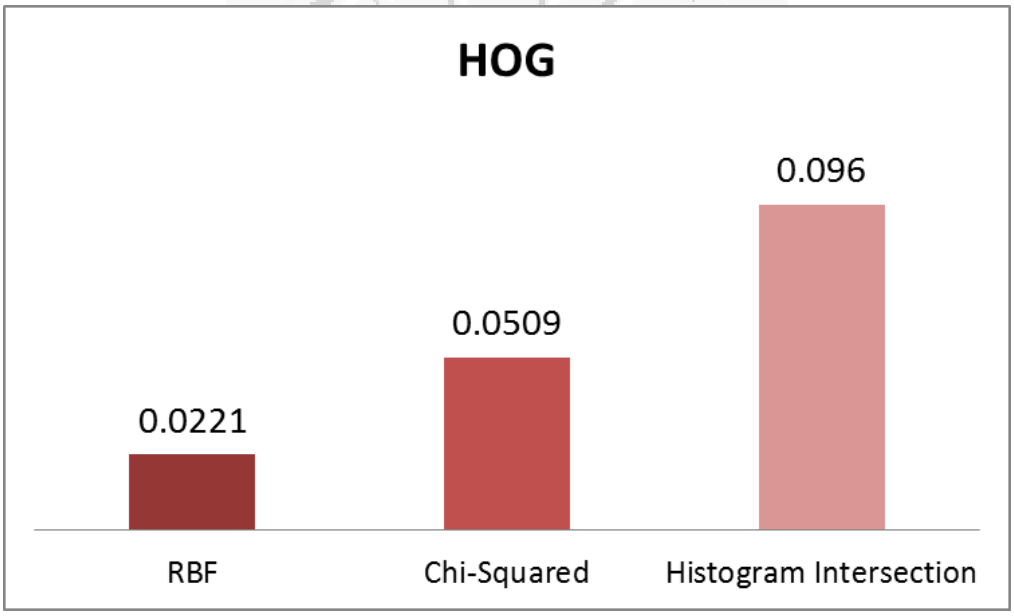

圖 5.4 形狀特徵內之不同核函數結果比較

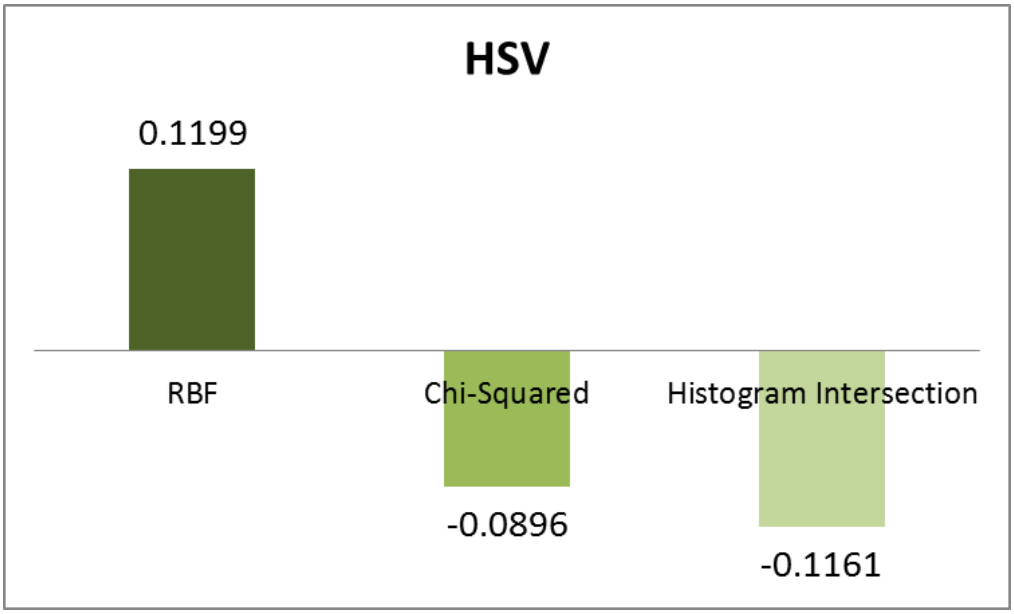

圖 5.5 顏色特徵內之不同核函數結果比較

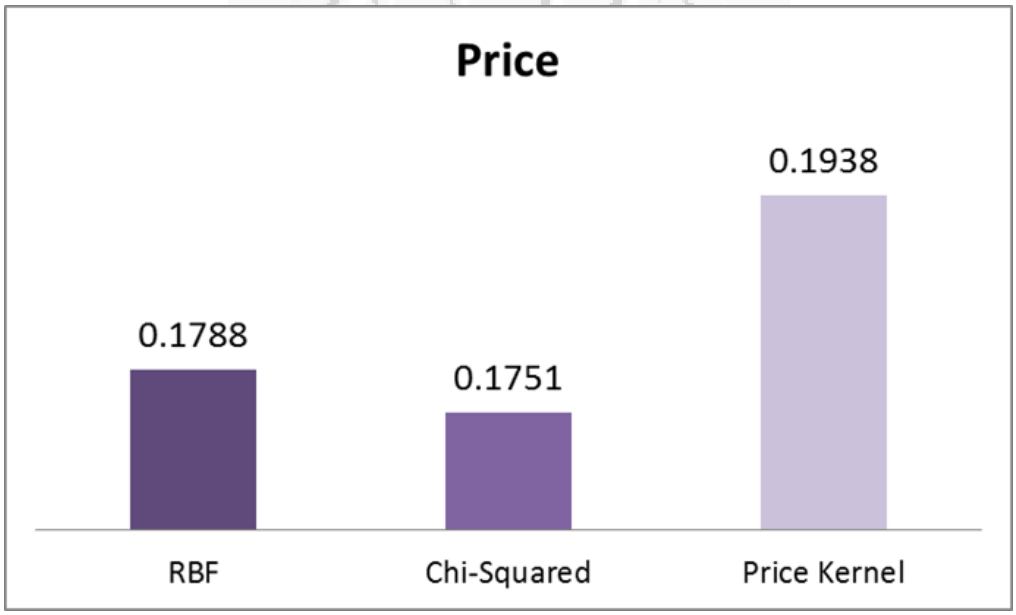

圖 5.6 價錢特徵內之不同核函數結果比較

圖 5.7 展示了使用支持向量回歸(SVR)方法及多核學習(MKL)間的比較，橫軸表示使用的方法，縱軸數值代表皮爾森相關係數。在 SVR 部分，我們將所有特徵藉由串接方式拼接在一起，並使用單一 RBF 核對所有特徵資料進行訓練模型及預測喜愛度分數。MKL 方面則分為兩部分：一、使用多個(四個)不同參數(Gamma Value)之 RBF 核組成訓練模型；二、使用段落 4.3 中提及的四個特徵空間所得之核矩陣，組成訓練模型。結果顯示，使用 MKL 方法比起 SVR 得到較好的預測效果，而其中使用前計算核(Pre-computed Kernel)所組成的模型也比使用多個 RBF 核效果來的好。而雖然多個 RBF 達到了相近的效果，但比起前計算核方法，其需要花費大量時間去選擇及調整參數。

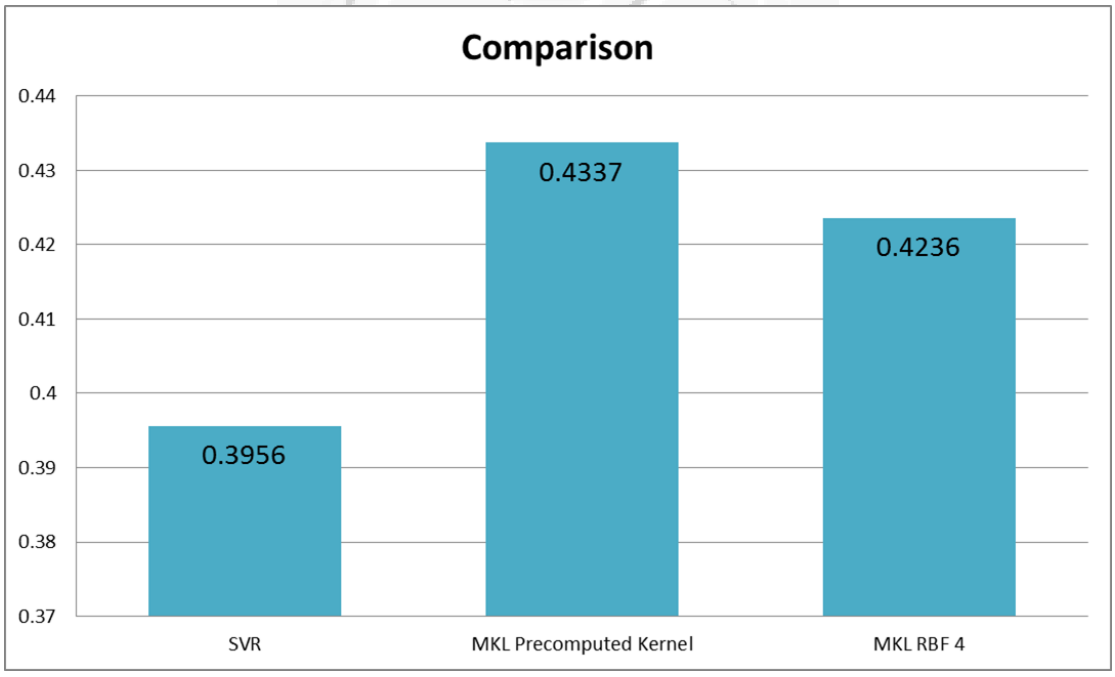

圖 5. 7 SVR 及 MKL 之結果比較

圖 5.8 展示了使用大量 RBF 核組成模型之結果，其橫軸代表使用的 RBF 核數，縱軸為皮爾森相關係數。我們為每個 RBF 核配置其參數(Gamma Value)，並展示了一百個核數內不同數量取樣(每十個作為間距)的結果，而數據顯示，其相關係數大都落在 0.43 至 0.44 之間，而使用較多的 RBF 核數，由於彼此削減其權重，不一定擁有較高的效果。而其中雖有部分數據高於前計算核的結果，但其必須仰賴大量時間調整參數才可達到此效果。

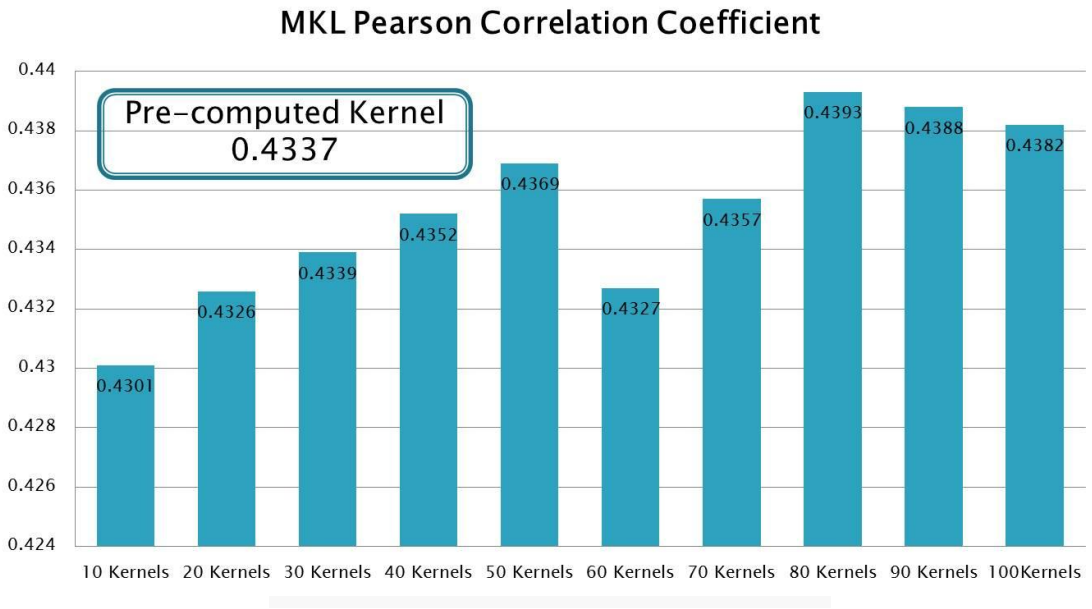

圖 5.8 不同數量 RBF 核之 MKL 比較

5.3 相對分數比較及喜好類別

除了上述之評量方式，本工作也使用了另外三個方法來衡量預測結果。方法一描述如下：在測試集樣本內，總共有 210 雙球鞋，藉由比對每兩兩間之球鞋喜愛度分數，一共可以獲得 21945 個比較關係，其關係共分為大於、小於和等於三種分數關係。接著藉由預測分數及實際分數間，關係相符的數量計算其百分比當作另一評估標準。舉例來說，假使在實際分數中，第 i 雙球鞋的喜愛度大於第 j 雙球鞋，而在預測分數中也是相同情況，就將分數加一，最後藉由一一比對，在預測分數中，得到了 57.37%的準確率，即代表在我們的預測裡擁有 57.37%的比例擁有正確的喜愛度大小關係。

方法二描述如下：首先將實際球鞋分數去做大小排序，將其切分為三個分數區段，依高分至低分三個區段分別視為受歡迎鞋款、普通鞋款及不受歡迎鞋款。藉由此三種分數區段，共可以得到實際球鞋分數中共 210 個對應關係值，而預測出之 210 雙球鞋分數也可得到其對應之關係值，如實際與預測之分數落在相同喜好類別就將分數加一，最後透過一一比對，在預測喜愛度落在哪一喜好類別上，得到了 69.52%的準確率，即擁有約百分之七十的機會正確預測出新鞋款屬於哪種喜好類別。

方法三描述如下：我們將實際分數中為受歡迎鞋款、普通鞋款和不受歡迎鞋款以及其各自對應的預測分數取出，並使用皮爾森相關係數去檢測在各自分數區段的鞋款中，其對應出之預測分數與其關聯性，表 5.1 展現了其實驗結果。其結果顯示在預測受歡迎之高分球鞋上擁有良好的效果。

最後，對於一些預測效果不佳的例子進行討論，藉由觀察實際分數與預測分數間的關係，發現當一球鞋如為新興品牌時，由於我們的字典內並無關於此品牌

的相關文字特徵，僅能使用顏色及外形資訊進行預測，可能會有分數較不準確的情況發生；而新的代言人也可能會有類似情況，由於字典內無法取得關鍵的加分特徵，也會造成預測分數的落差。而在此測試集中共有 13 筆資料發生此情形，造成預測與實際分數差異大於一個標準差(19.03196)之現象。

表 5.1 喜好類別與皮爾森相關係數之比較

Score Sections	Pearson Coefficient
Popular	0.4894
Conventional	-0.1676
Non-Popular	-0.0991
Testing Set	0.4337

第六章　結論與未來工作

6.1 結論

在此篇工作中，藉由使用監督學習方式研究預測新球鞋的消費者喜愛度問題。實驗顯示，使用後期融合方法(MKL)較前期融合方法(SVR)擁有較佳的效果。本研究也藉由喜愛度分數的相關係數分析了各個特徵對於預測工作上的重要性，文字特徵資訊對於消費者的喜愛度上具有一定程度的影響力。

而使用前計算核廣泛上也擁有較 RBF 核更好的喜愛度分數關聯性，雖然使用 RBF 核可以獲得相近的效果，但其必須依賴大量時間去調整參數以達準確率。我們藉由不同面向的資訊描述球鞋產品並透過多核學習方法成功獲得不錯的喜愛度相關性。

6.2 未來工作

本研究藉由不同面向之特徵及其合適的核函數方式學習預測喜愛度分數模型，因此找出更多具效用之特徵及更佳的核函數進行學習，可能對於預測分數上具有幫助。而球鞋產品發售的重複率可能也會影響消費者的喜愛度，如新鞋款一上架消費者可能較有新鮮感，但如果期間內重複上市相同類別的鞋款，可能會由於缺乏驚喜，影響消費者的喜愛觀感。而不同的季節消費者欲購買的顏色及材質可能也不同，因此產品的季節性也是考量之一。

參考文獻

[1] Sole Collector | Sneaker news, release dates & marketplace. http://solecollector.com/

[2] NiceKicks.com – The most read source for sneaker news, release dates & history. http://www.nicekicks.com/

[3] Sneaker News - The ultimate news site for sneakerheads. http://sneakernews.com/

[4] G. Salton and M. McGill. *Introduction to modern information retrieval*, 1983.

[5] H. Drucker, C. J. C. Burges, L. Kaufman, A. Smola, and V. Vapnik. Support vector regression machines. *Advances in neural information processing systems*, pages 155-161, 1997.

[6] K. Kavaklioglu. Modeling and prediction of Turkey's electricity consumption using Support Vector Regression. *Applied Energy*. Volume 88, Issue 1, pages 368–375, January 2011.

[7] R. El-Yaniv and A. Faynburd. Autoregressive short-term prediction of turning points using support vector regression. arXiv:1209.0127, 2012.

[8] S. Salcedo-Sanz, Á . M. Pérez-Bellido, A. Portilla-Figueras, and L. Prieto. Short term wind speed prediction based on evolutionary support vector regression algorithms. *Expert Systems with Applications*, Volume 38, Issue 4, pages 4052-4057, 2011.

[9] M. Narwaria and W. Lin. Objective image quality assessment based on support vector regression. *Neural Networks, IEEE Transactions*, Volume 21, Issue 3, pages 515-519, 2010.

[10] F. R. Bach, G. R. G. Lanckriet and M. I. Jordan. Multiple kernel learning, conic duality, and the SMO algorithm. *ICML*, 2004.

[11] C. Y. Yeh, C. W. Huang, and S. J. Lee. A multiple-kernel support vector regression approach for stock market price forecasting. *Expert Systems with Applications*, Volume 38, Issue 3, pages 2177–2186, March 2011.

[12] M. Guillaumin, J. Verbeek and C. Schmid. Multimodal semi-supervised learning for image classification. *CVPR*, 2010.

[13] T.Joutou and K. Yanai. A food image recognition system with Multiple Kernel Learning. *ICIP*, 2009.

[14] S. Deng, K. Yoshiyama, T. Mitsubuchi, and A. Sakurai. Hybrid method of multiple kernel learning and genetic algorithm for forecasting short-term foreign exchange rates. *Computational Economics*, pages 1-41, 2013.

[15] J. Zhao, Y. Liu, X. Zhang and W. Wang. A MKL based on-line prediction for gasholder level in steel industry. *Control Engineering Practice*, Volume 20, Issue 6, pages 629-641. 2012.

[16] K. Spirovska, and A. M. Bogdanova. Multiple kernel learning methods and their application in yeast protein subcellular localization prediction. *CIIT*, 2012.

[17] N. Dalal and B. Triggs. Histograms of oriented gradients for human detection. *CVPR*, 2005.

[18] C. C. Chang and C. J. Lin. Libsvm: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, Volume 2, Issue 3, 2011.

[19] S. V. N. Vishwanathan, Z. Sun, N. Theera-Ampornpunt and M. Varma. Multiple kernel learning and the SMO algorithm. *NIPS, 2010.*

[20] A. Barla, F. Odone and A. Verri. Histogram intersection kernel for image classification, *ICIP*, 2003.