



(19)中華民國智慧財產局

(12)發明說明書公開本

(11)公開編號：TW 201115482 A1

(43)公開日：中華民國 100 (2011) 年 05 月 01 日

(21)申請案號：098135980

(22)申請日：中華民國 98 (2009) 年 10 月 23 日

(51)Int. Cl. : **G06K9/46 (2006.01)** **G06K9/52 (2006.01)**
G06K9/78 (2006.01)

(71)申請人：國立交通大學(中華民國) NATIONAL CHIAO TUNG UNIVERSITY (TW)
新竹市大學路 1001 號

(72)發明人：韓欽銓(TW)；陳映濃(TW)

(74)代理人：林火泉


申請實體審查：有 申請專利範圍項數：18 項 圖式數：10 共 31 頁

(54)名稱

影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法

(57)摘要

本發明揭露一種影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法，先收集不同類組之訓練樣本且決定以點至點、點至線、點至面或點至高維空間最近距離之其中一種方式進行空間轉換；接續，計算此些訓練樣本的主要轉換矩陣；再將所決定的最近距離方式計算組內投影點與組間投影點，並將此些組內投影點與組間投影點所構成之向量依序排列；接續，根據此些向量，計算出組內變異矩陣與組間變異矩陣；然後由組內變異矩陣與組間變異矩陣求得變異轉換矩陣；最後將主要轉換矩陣內積變異轉換矩陣即可求得特徵空間轉換矩陣。因此，本發明係針對特徵空間轉換架構進行改善，提出新的整合型的特徵空間轉換架構，以有效提升人臉辨識效果。



發明專利說明書

(本說明書格式、順序，請勿任意更動，※記號部分請勿填寫)

※申請案號：98135980

G06K 9/46 (2006.01)

※申請日：981023

※IPC 分類：

G06K 9/52 (2006.01)

一、發明名稱：(中文/英文)

G06K 9/18 (2006.01)

影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法

二、中文發明摘要：

本發明揭露一種影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法，先收集不同類組之訓練樣本且決定以點至點、點至線、點至面或點至高維空間最近距離之其中一種方式進行空間轉換；接續，計算此些訓練樣本的主要轉換矩陣；再將所決定的最近距離方式計算組內投影點與組間投影點，並將此些組內投影點與組間投影點所構成之向量依序排列；接續，根據此些向量，計算出組內變異矩陣與組間變異矩陣；然後由組內變異矩陣與組間變異矩陣求得變異轉換矩陣；最後將主要轉換矩陣內積變異轉換矩陣即可求得特徵空間轉換矩陣。因此，本發明係針對特徵空間轉換架構進行改善，提出新的整合型的特徵空間轉換架構，以有效提升人臉辨識效果。

三、英文發明摘要：

四、指定代表圖：

(一)本案指定代表圖為：第 (2) 圖。

(二)本代表圖之元件符號簡單說明：

無。

五、本案若有化學式時，請揭示最能顯示發明特徵的化學式：

六、發明說明：

【發明所屬之技術領域】

本發明係有關影像辨識，尤其是一種影像辨識模型的建立及其應用。

【先前技術】

按，人臉識別係為生物特徵的識別技術，其技術手段可利用統計學方法建構人臉特徵模型，以便待測人臉影像比對，而人臉影像辨識整體技術分為兩個階段：訓練階段與測試階段，在訓練階段使用一套人臉特徵模型，在模型的特徵空間中將不同的人臉影像區別且特徵化，因此在訓練階段中，所使用的人臉特徵模型即影響人臉辨識的精確度。

有鑑於先前技術投入心力來尋找最完美的人臉辨識模型，其中根據 He 等人於 2005 年於 IEEE Trans. On Pattern Analysis and Machine Intelligence, vol. 27, pp. 328-340 之期刊論文中發表一文章「使用拉普拉司臉進行人臉辨識(face recognition using laplacianfaces)」，提出以特徵空間方法建立拉普拉斯矩陣(laplacian Matrix)為基礎的人臉辨識系統，來保留訓練樣本之局部結構，其作法是在臉特徵空間中流型結構的區域性透過區域保存投影方法(locality preserving projection, LPP)在最近相鄰關係圖(nearest-neighbor graph)而保留下來。然而，根據第 1 圖所示，其係為由 He 等人提出方法進行訓練樣本的特徵空間轉換分佈情況，如圖所示，此習知技術仍受到容易外界干擾因素：表情、光線與角度而導致人臉影像區分結果不佳。不過 He 等人提出的方法所產生局部流行結構係比其他先前技術利用歐式結構(euclidean structure)之主成分分析法(PCA)或線性判別分析法(LDA)更有效率。

先前技術中，許多演算法採用分類標籤來進行判別分析法的程序，利

用費雪條件(Fisher criterion)來最佳化組內緊密度和組間可分性，基於區域保存投影方法來計算修改後的組內與組間變異，以保留局部結構，並且，使用正交基鄰近保留判別分析(orthogonal neighborhood preserving discriminant analysis, ONPDA)或邊境費雪分析法(marginal Fisher analysis, MFA)等方法描述樣本之間鄰近關係的相似矩陣。在此列舉三篇具有代表性之論文：1.Cai 等人於 2006 年在同一期刊發表「Orthogonal Laplacianfaces for Face Recognition」延續了拉普拉司矩陣之精神，其不同處也是最重要的地方在於將 Cai 將特徵空間轉換成為正交基(orthogonal base)。2.Yan 在 2007 年於同一期刊發表「Graph embedding and extensions: General framework for dimensionality reduction」該論文亦是延續了拉普拉司的方法，其不同處係在於，加入了類別資訊的概念，並且在計算不同類別資訊時，只考慮最鄰近點的資訊而非所有點。3.由 Yan 等人提出一種圖表嵌入式的普遍架構，其係利用兩張圖，一張為本質圖表(intrinsic graph)，另一張懲罰圖表(penalty graph)，來描述組內點相鄰以及組間邊境點的相鄰關係，因此這些近似方法皆可保留局部組內與組內鄰近之結構。

在人臉辨識的另一階段-測試階段，其係將待測影像轉換進入已建構完成的特徵轉換空間中，與建制特徵轉換空間的訓練樣本進行比對，習知技術中有近似方法係注重距離測量以及比對演算法的設計，其中最近特徵線(nearest feature line, NFL)方法係由 S. Z. Li 與 J. Lu 在 *IEEE Transactions on Pattern Analysis and Machine Intelligence* 論文期刊首次提出，而 S. Z. Li 與 J. Lu 所發表二文分別為「使用最近特徵線方法進行人臉辨識(Face recognition using the nearest feature line method)」以及「影像分類與補償中最近特徵線

方法之成果估算(Performance evaluation of the nearest feature line method in image classification and retrieval)」內文提到特徵線係從兩個特徵點產生且特徵線可線性插入或外推同一類組中每一對特徵點，每個類組具有無限個偽原型(pseudo prototypes)係由線性插入產生，而完成分類工作係由選出的輸入影像與特徵線之間的最短距離，特徵線係線性趨近兩張人臉影像的變化量。

再者，根據 Chien 等人在 *IEEE Transactions on Pattern Analysis and Machine Intelligence* vol. 24, pp. 1644-1649, 2002 中發表的「區分小波和最近特徵分類器(Discriminant waveletfaces and nearest feature classifiers for face recognition)」，其係將最近特徵線分類器(NFL-based classifier)的技術擴展至以最近特徵空間(nearest feature space)的方式來進行人臉影像的測試比對。

而相對於傳統的最相近鄰居分類器(nearest neighbor based classifier, NN-based classifier)，最近特徵線分類器分類效果遠比傳統的點到點的比對方式為佳，然而，最近特徵線分類器在比對時由於要選取組合成直線的樣本配對，因此當樣本量大時，就會需要大量的比對時間，此為其缺點。

除此之外，人臉辨識技術可利用影像本身的特性進行分類器的設計，其技術特徵通常較為簡單，例如色彩資訊，然而此類行特徵受到光線變化等雜訊影像也較大，因此在分類能力上不佔優勢，而在實務上也因此受到限制。

有鑑於此，本發明提出一種影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法，其係將最近特徵線分類器的作法直接融入前段的訓練階段中的拉普拉司矩陣中，以提高影像辨識正確性以及加快辨識速度。

【發明內容】

本發明之主要目的係提出一種影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法，係將最近特徵空間嵌入式的概念融入拉普拉司矩陣中而建立新的特徵空間轉換矩陣，不僅可將訓練樣本在原空間中的拓模資料保留，更可以保存訓練樣本的線性變化關係，並且使得在測試階段可以快速度比對方式，進行辨識人臉影像辨識。

本發明之次一目的係提出一種影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法，本發明所建立的數學模型不侷限於最近特徵線方法來建構，亦相容各種空間的分類器，例如：最近特徵點、最近特徵面與最近高維特徵空間的分類器，以建立更多具有識別度的數學模型，提高人臉辨識的精準度。

本發明之再一目的係提出一種影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法，在訓練階段可選用最近特徵點分類器來進行人臉辨識，以提高辨識效率。

為達到上述之目的本發明所揭示之影像辨識模型之建立方法及利用該影像辨識模型之影像辨識方法，首先，收集不同類組之複數個訓練樣本且決定係以點至特徵子空間最近距離之方式進行空間轉換；接續，以主成分分析法計算此些訓練樣本的主要轉換矩陣，並將訓練樣本投影至降維空間；再以所決定的點至特徵子空間最近距離方式計算所有樣本的組內投影點與組間投影點以及此些投影點所構成之組內向量與組間向量，並將此些向量依序排列；接續，根據此些組內向量與組間向量，計算出組內變異矩陣與組間變異矩陣；由組內變異矩陣與組間變異矩陣求得變異轉換矩陣；

再將主要轉換矩陣內積變異轉換矩陣即可求得特徵空間轉換矩陣。

因此，可在特徵空間轉換矩陣的特徵空間中進行測試影像與訓練樣本之比對，以辨識出該測試影像所屬之類組。

底下藉由具體實施例配合所附的圖式詳加說明，當更容易瞭解本發明之目的、技術內容、特點及其所達成之功效。

【實施方式】

目前常見的人臉辨識方法多著重於特徵空間轉換方法、影像處理以及演算法等三大類，但這些方法時常無法在降維後所保留影像在原空間中的特性，或是容易受到外界因素干擾，例如光影變化，使得分類的效率大打折扣。因此，本發明係在訓練階段以主成分分析法先將影像作前處理，而後以最近特徵空間嵌入式(nearest feature space embedding)而建立一套特徵空間轉換矩陣，亦即，將最近特徵空間特性融入拉普拉司矩陣中，在特徵空間轉換法上進行改善，因此整合了特徵空間轉換與最近特徵空間分類器之技術，以點到線、點到面、或點到高維空間方式來決定特徵空間轉換矩陣。

請參見第 2 圖，如步驟 S10 所示，首先先收集複數個不同個類組的複數張人臉影像，作為建立影像辨識模型的訓練樣本，而且將每個訓練樣本資料正規化為相同大小的視窗影像，以及將每個人臉影像對齊校正。同時，決定 p 值大小， p 值代表特徵子空間的形式，例如 $p=1$ 代表特徵子空間係為點， $p=2$ 代表特徵子空間係為線，依此類推。因此根據 p 值，我們可知特徵轉換空間的策略係以點至點、點至線、點至平面或點至高維空間的最短距離方式，而特徵子空間代表點、線、面或高維空間。

接續，如步驟 S12 所示，決定 K_1 、 K_2 兩值，其係代表在進行費雪條件式(Fisher's Criterion)計算時，各訓練樣本要選擇組內向量個數以及組間向量個數。再進行步驟 S14，以主成分分析法建立在所收集之訓練樣本的主要轉換矩陣 W_{PCA} ，並將訓練樣本投影至降維空間。接著可計算各樣本點在同類組內之投影點以及各樣本點在類組間投影點，如步驟 S16 所示，根據步驟 S10 的 p 值，求得點到點、點到線點到面與點到高維空間的關鍵向量，其中關鍵向量包含組內投影點所構成的組內向量，以及組間投影點所構成的組間向量，並且組內向量以及組間向量依照距離由小而大的方式排列。

如第 2 圖中步驟 S18 所示，從排列有序的組內向量中，選前 K_1 個組內向量， K_1 值已在步驟 S10 決定，並設定對應的兩個權重矩陣 W 以及 M ，以計算出組內變異矩陣(within-class scatter) S_W ，如第 3(a)圖所示，並且同樣從組間向量中，選取前 K_2 個組間向量，並設定對應的兩個權重矩陣 W 以及 M ，以計算出組間變異矩陣(between-class scatter) S_B ，如第 3(b)圖所示。

繼續下一個步驟 S20，係配合利用費雪條件式(Fisher's Criterion)轉換，獲得變異轉換矩陣 W^* 係由該組內變異矩陣 S_B 與該組間變異矩陣 S_W 求得，其關係式為 $W^* = \arg\max_w S_B / S_W$ ，其中選取前數個具最大特徵值的特徵向量來構成變異轉換矩陣。最後，將主要轉換矩陣 W_{PCA} 與變異轉換矩陣 W^* 內積後，獲得特徵空間轉換矩陣 W ，如步驟 S22 所示，其關係式係為 $W = W_{PCA} W^*$ 。

而步驟 S18 可採取另一種方式來進行組內向量與組間向量的篩選，先設定第一特徵臨界值，再選取各類組中小於第一特徵臨界值的組內向量，

並設定對應的兩個權重矩陣 W 以及 M ，計算求得組內變異矩陣 S_W 。以及，同樣設定第二特徵臨界值，選取不同類組中小於第二特徵臨界值的組間向量，並設定對應的兩個權重矩陣 W 以及 M ，求得組間變異矩陣 S_B 。若步驟 S18 係採取本段落之方式進行計算，則無須事先考慮 K_1 與 K_2 的個數，因此可省略步驟 S12，從步驟 S10 直接進行步驟 S14，其餘流程皆不變。

本發明所建立的特徵空間轉換矩陣係為採用最近特徵空間嵌入拉普拉斯矩陣策略，而所建構出的特徵空間轉換矩陣所得到的特徵空間，成為本發明作為影像辨識模型，不僅可保留訓練樣本原有的拓撲資訊，並同時可表現出訓練樣本之間的線性變化以及類組資訊，如第 4 圖所示，係為運用本發明之方法所得之特徵空間的訓練樣本分佈圖，從第 4 圖與第 1 圖比較可知，使用本發明所建立之影像辨識模型將不同類組訓練樣本有效分類，其辨識能力比先前技術佳。

本發明亦提出使用影像辨識模型之影像辨識裝置，如第 5 圖所示，此裝置係由其係由影像擷取器 10 取得一測試影像 12，再利用一影像模擬處理器 14 將此測試影像 12 投影於本發明所建立影像辨識模型 16 中，亦即，特徵空間轉換矩陣之特徵空間中，由於此特徵空間中係根據一套不同類組的訓練樣本 18 而建構，所以影像模擬處理器 14 將利用點對點、點對線、點對面或點對高維空間的最相近距離方式來將測試影像 12 與訓練樣本 18 進行比對，因此計算器 10 計算出測試影像 12 應所屬之類組，最後透過一顯示器 20 輸出測試影像的辨識結果。而若有欲縮短測試階段的時間，亦即人臉辨識的時間，則可將測試影像選用特徵空間中點對點之最相近距離方式與訓練樣本進行比對，即可節省進行人臉辨識的時間。

進一步說明本發明之特徵空間轉換矩陣建置過程，首先在特徵空間中考慮某一特定的訓練樣本點 $\mathbf{y}_i$ ，而點到特徵空間上的距離可定義為 $\|\mathbf{y}_i - f^{(p)}(\mathbf{y}_i)\|$ ，其中 $f^{(p)}$ 是一由 p 個樣本所構成的特徵子空間，例如 $p=2$ 時， $f^{(2)}$ 為線，如第 6 圖所示， $p=3$ 時， $f^{(3)}$ 為面，如第 7 圖所示。而 $f^{(p)}(\mathbf{y}_i)$ 表示 $\mathbf{y}_i$ 在該特徵子空間上的投影點，則對 $\mathbf{y}_i$ 來說總共有 C_p^{N-1} 個配對可以進行投影。而點到特徵子空間上投影所形成的向量及可以用來計算變異矩陣(scatter matrix)，此種方式稱之為 NFS 嵌入(nearest feature space embedding)，接續我們可以建立兩種目標函式如下列式(1)與式(2)所示：

$$F_1 = \sum_i \left[\sum (\mathbf{y}_i - f^{(p)}(\mathbf{y}_i)) w^{(p)}(\mathbf{y}_i) \right]^2 \quad (1)$$

$$F_2 = \sum_i \sum (\mathbf{y}_i - f^{(p)}(\mathbf{y}_i))^2 w^{(p)}(\mathbf{y}_i) \quad (2)$$

其中，上述二式權重值 $w^{(p)}(\mathbf{y}_i)$ 可以用來表示點到特徵子空間上投影點的連結狀況， $w^{(p)}(\mathbf{y}_i)$ 係為 1 或 0，1 表示將投影向量納入計算，0 表示不將投影向量納入計算。而(1)式代表所有的點與其對應的投影點所形成的向量相加以後平方，(2)式則表示所有的點與其相對應的投影點所形成的向量平方後相加。舉例來說， $p=1$ 時，(1)式為局部線性嵌入(locally linear embedding, LLE)的目標函式，而(2)式為拉普拉司矩陣保留投影(laplacian matrix preserving projection, LPP)的目標函數。為了簡化表示，權重值 $w^{(p)}(\mathbf{y}_i)$ 可進一步以 $N \times N^p$ 的矩陣表示，在 $p=2$ 時， $\mathbf{y}_i$ 可以找到 $C_2^{N-1} = (N-1)(N-2)/2$ 個點到線的投影向量，且權重 $\overline{\mathbf{x}_m \mathbf{x}_n}$ 與

$\overline{\mathbf{X}_n \mathbf{X}_m}$ 是不相同的，而 $\overline{\mathbf{X}_m \mathbf{X}_m}$ 、 $\overline{\mathbf{X}_i \mathbf{X}_m}$ 與 $\overline{\mathbf{X}_m \mathbf{X}_i}$ 是不存在。

接續，說明如何以點至特徵子空間建制拉普拉司矩陣的演算法：

1、最近特徵點嵌入(nearest feature point embedding)， $p=1$

在此條件下，則 $f^{(1)}$ 收斂為一個點，如果挑選 K 個最鄰近點，則式(1)

中 F_1 則為標準的 LLE 函數： $\min \sum_i \left(\mathbf{y}_i - \sum_j \mathbf{M}_{i,j} \mathbf{y}_j \right)^2$ ，而由於

LLE 函數與 LPP 函數相等，因此式(1)可表示為 $\mathbf{w}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{w}$ ，而式(2)

中 $w^{(P)}(\mathbf{y}_i)$ 可視為 LPP 的相似度函數，即

$w_j^{(1)}(\mathbf{y}_i) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / t)$ ，而式(2)同樣可以表示成

$\mathbf{w}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{w}$ 。

2、最近特徵線嵌入(nearest feature line embedding)， $p=2$

如第 6 圖所示，以點到線的距離為依據， $\mathbf{y}_i$ 到特徵線 $\overline{\mathbf{y}_m \mathbf{y}_n}$ 的距離可

以 $|\mathbf{y}_i - f_{m,n}^{(2)}(\mathbf{y}_i)|$ 表示，其中投影點 $f_{m,n}^{(2)}(\mathbf{y}_i)$ 可以用 $\mathbf{y}_m$ 及 $\mathbf{y}_n$ 的線性

組合來表示： $f_{m,n}^{(2)}(\mathbf{y}_i) = \mathbf{y}_m + t_{m,n}(\mathbf{y}_n - \mathbf{y}_m)$ ，其中參數

$t_{m,n} = (\mathbf{y}_i - \mathbf{y}_m)^T (\mathbf{y}_m - \mathbf{y}_n) / (\mathbf{y}_m - \mathbf{y}_n)^T (\mathbf{y}_m - \mathbf{y}_n)$ ，而 $\mathbf{y}_i$ 到

$f_{m,n}^{(2)}(\mathbf{y}_i)$ 所形成的向量可以用下列(3)式表示：

$$\begin{aligned} \mathbf{y}_i - f_{m,n}^{(2)}(\mathbf{y}_i) &= \mathbf{y}_i - \mathbf{y}_m + t_{m,n}(\mathbf{y}_m - \mathbf{y}_n) \\ &= \mathbf{y}_i - (1 - t_{m,n})\mathbf{y}_m - t_{m,n}\mathbf{y}_n \\ &= \mathbf{y}_i - t_{n,m}\mathbf{y}_m - t_{m,n}\mathbf{y}_n. \end{aligned} \quad (3)$$

而 $1 - t_{m,n} = t_{n,m}$ ，目標函數 F_1 則可以表示如式(4)所示：

$$\begin{aligned}
& \sum_i \left(\sum_{m \neq n} (\mathbf{y}_i - f_{m,n}^{(2)}(\mathbf{y}_i)) w_{m,n}^{(2)}(\mathbf{y}_i) \right)^2 \\
&= \sum_i \left(\sum_{m \neq n} (\mathbf{y}_i - t_{n,m} \mathbf{y}_m - t_{m,n} \mathbf{y}_n) w_{m,n}^{(2)}(\mathbf{y}_i) \right)^2 \\
&= \sum_i \left(\mathbf{y}_i - \sum_j \mathbf{M}_{i,j} \mathbf{y}_j \right)^2 \\
&= \mathbf{y}^T (\mathbf{I} - \mathbf{M})^T (\mathbf{I} - \mathbf{M}) \mathbf{y} = \mathbf{y}^T (\mathbf{D} - \mathbf{W}) \mathbf{y} \\
&= \mathbf{w}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{w}.
\end{aligned} \tag{4}$$

式(4)中 $\mathbf{W}$ 與 $\mathbf{M}$ 係為：

$$w_{m,n}^{(2)}(\mathbf{y}_i) = \begin{cases} 1 & m \neq n \neq 1, \text{ 若特徵線 } \overline{\mathbf{x}_m \mathbf{x}_n} \text{ 沿著點 } \mathbf{X}_i \text{ 的} \\ & K \text{ 個最近特徵線;} \\ 0 & \text{其餘皆為零} \end{cases} \tag{5}$$

$$\mathbf{M}_{i,n} = \begin{cases} \frac{1}{K} \sum_m t_{m,n} & \text{若 } W_{m,n}^{(2)}(\mathbf{y}_i) = 1, m \neq n \neq 1 \\ 0 & \text{其餘皆為零} \end{cases} \tag{6}$$

其中 $t_{m,n} = (\mathbf{x}_i - \mathbf{x}_m)^T (\mathbf{x}_m - \mathbf{x}_n) / (\mathbf{x}_m - \mathbf{x}_n)^T (\mathbf{x}_m - \mathbf{x}_n)$, $\sum_j \mathbf{M}_{i,j} = \mathbf{1}$,
 $\mathbf{W}_{i,j} = (\mathbf{M} + \mathbf{M}^T - \mathbf{M}^T \mathbf{M})_{i,j}$, 則(1)式可以表示為拉普拉司矩陣的形式。式(2)中, 可以先分解 K 個矩陣, 而每一 $\mathbf{M}_{i,j}(1)$ 表示點 $\mathbf{X}_i$ 與其最鄰近特徵線 $\overline{\mathbf{x}_m \mathbf{x}_n}$, i, m, n 可為 1 至 N 的自然數。兩個非 0 項 $\mathbf{M}_{i,n}(1) = t_{m,n}$, $\mathbf{M}_{i,m}(1) = t_{n,m}$ 為 $\mathbf{M}_{i,j}(1)$ 中的值, 且, 因此式(2)可

以表示成下列式(7)：

$$\begin{aligned}
 & \sum_i \sum_{m \neq n} (\mathbf{y}_i - f_{m,n}^{(2)}(\mathbf{y}_i))^2 w_{m,n}^{(2)}(\mathbf{y}_i) \\
 &= \sum_i \sum_{m \neq n} (\mathbf{y}_i - t_{n,m} \mathbf{y}_m - t_{m,n} \mathbf{y}_n)^2 w_{m,n}^{(2)}(\mathbf{y}_i) \\
 &= \sum_i \left(\mathbf{y}_i - \sum_j \mathbf{M}_{i,j}(1) \mathbf{y}_j \right)^2 + \dots + \sum_i \left(\mathbf{y}_i - \sum_j \mathbf{M}_{i,j}(K) \mathbf{y}_j \right)^2 \\
 &= \mathbf{y}^T (\mathbf{I} - \mathbf{M}(1))^T (\mathbf{I} - \mathbf{M}(1)) \mathbf{y} + \dots + \mathbf{y}^T (\mathbf{I} - \mathbf{M}(K))^T (\mathbf{I} - \mathbf{M}(K)) \mathbf{y} \\
 &= \mathbf{y}^T (\mathbf{D} - \mathbf{W}(1)) \mathbf{y} + \dots + \mathbf{y}^T (\mathbf{D} - \mathbf{W}(K)) \mathbf{y} \\
 &= \mathbf{y}^T (\mathbf{D} - \mathbf{W}) \mathbf{y} = \mathbf{w}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{w}.
 \end{aligned} \tag{7}$$

其中 $\mathbf{M}_{i,n}(k) = t_{m,n}$, $\mathbf{M}_{i,m}(k) = t_{n,m}$, $i \neq m \neq n$,

$\mathbf{W}_{i,j}(k) = (\mathbf{M}(k) + \mathbf{M}(k)^T + \mathbf{M}(k)^T \mathbf{M}(k))_{i,j}$,

$\mathbf{W} = \frac{1}{K} (\mathbf{W}(1) + \mathbf{W}(2) + \dots + \mathbf{W}(K))$, 因此式(2)亦可表示為拉普拉斯矩陣的形式, 因此只需將對應的矩陣 $\mathbf{M}$ 內容的值填入正確的對應值。

3、最近特徵面/高維空間嵌入(nearest feature plane/space embedding), $p=3$

在此條件下, $\mathbf{y}_i - f_{q,m,n}^{(3)}(\mathbf{y}_i)$ 表示點 $\mathbf{y}_i$ 到特徵平面 $E_{q,m,n}$ 上的投影點 $f_{q,m,n}^{(3)}(\mathbf{y}_i)$ 所形成的向量, 其中平面 $E_{q,m,n}$ 由三個特徵點 $\mathbf{y}_q$ 、 $\mathbf{y}_m$ 以及 $\mathbf{y}_n$ 為基底構成的平面, 如第 7 圖所示, 而平面上的投影點 $f_{q,m,n}^{(3)}(\mathbf{y}_i)$ 可以由公式(8)獲得, 其中公式(8)如下所示：

$$f_{q,m,n}^{(3)}(\mathbf{y}_i) = \mathbf{Y}_{q,m,n} (\mathbf{Y}_{q,m,n}^T \mathbf{Y}_{q,m,n})^{-1} \mathbf{Y}_{q,m,n}^T (\mathbf{y}_i - \mathbf{y}_q) + \mathbf{y}_q \tag{8}$$

其中 $\mathbf{Y}_{q,m,n} = [(\mathbf{y}_m - \mathbf{y}_q) \ (\mathbf{y}_n - \mathbf{y}_q)]$ 為一 $d \times 2$ 大小的矩陣, 而已知三個特徵點 $\mathbf{y}_q$ 、 $\mathbf{y}_m$ 以及 $\mathbf{y}_n$, 因此可以得到

$$\left(\mathbf{Y}_{q,m,n}^T \mathbf{Y}_{q,m,n}\right)^{-1} \mathbf{Y}_{q,m,n}^T (\mathbf{y}_i - \mathbf{y}_q) = [t_m \ t_n]^T \quad (9)$$

而皆下來就可以把投影點 $f_{q,m,n}^{(3)}(\mathbf{y}_i)$ 以三個特徵點 $\mathbf{y}_q$ 、 $\mathbf{y}_m$ 以及 $\mathbf{y}_n$ 的線性組合來表示：

$$f_{q,m,n}^{(3)}(\mathbf{y}_i) = t_q \mathbf{y}_q + t_m \mathbf{y}_m + t_n \mathbf{y}_n \quad (10)$$

其中 $t_q + t_m + t_n = 1$ 。與 $p=2$ 的情況相似，點 $\mathbf{y}_i$ 到鄰近 K 個特徵平面的向量加總後可以以 $\mathbf{y}_i - \sum_j \mathbf{M}_{i,j} \mathbf{y}_j$ 表示，而 $\mathbf{M}$ 矩陣中的權重值

即為上述式中的 $[t_q \ t_m \ t_n]^T$ ，而

$$[t_m \ t_n]^T = \left(\mathbf{X}_{q,m,n}^T \mathbf{X}_{q,m,n}\right)^{-1} \mathbf{X}_{q,m,n}^T (\mathbf{x}_i - \mathbf{x}_q), \quad t_q = 1 - t_m - t_n,$$

$\mathbf{X}_{q,m,n} = [(\mathbf{x}_m - \mathbf{x}_q) \ (\mathbf{x}_n - \mathbf{x}_q)]$ 。當 K 已選定而 $\mathbf{M}$ 矩陣中的權重值也給定，式(1)中的 F_1 能以拉普拉司矩陣形式： $\mathbf{w}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{w}$ 表示，同樣地式(1)中的 F_2 亦可以 $\mathbf{w}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{w}$ 表示。

此外，當 $P>3$ 時，特徵點 $\mathbf{y}_i$ 到子空間基底上的投影點可以表示成：

$$f^{(P)}(\mathbf{y}_i) = \mathbf{Y}(\mathbf{Y}^T \mathbf{Y})^{-1} \mathbf{Y}^T (\mathbf{y}_i - \mathbf{y}_1) + \mathbf{y}_1 = \sum_{j=1}^P t_j \mathbf{y}_j \quad (11)$$

其中 $\mathbf{Y} = [\mathbf{y}_2 - \mathbf{y}_1, \mathbf{y}_3 - \mathbf{y}_1, \dots, \mathbf{y}_P - \mathbf{y}_1]^T$ 為 $d \times (P-1)$ 大小的矩陣，並且 $\sum_{j=1}^P t_j = 1$ 。而特徵點 $\mathbf{y}_i$ 與投影點所形成的向量可以表示

成： $\mathbf{y}_i - f^{(P)}(\mathbf{y}_i) = \mathbf{y}_i - \sum_j \mathbf{M}_{i,j} \mathbf{y}_j$ ，因此，最後 F_1 與 F_2 可推導成拉普拉司矩陣的形式。

根據上述拉普拉司矩陣參入最近特徵空間條件後，即可進一步得到衡量區別資訊的變異矩陣，最後可獲得特徵空間轉換矩陣，即可將不同類別

的影像分割開來，如第 4 圖所示，而各類別的樣本還保留了訓練樣本在原空間中的拓樸資訊以及線性變化關係。因此我們只需利用特徵空間轉換矩陣對應的特徵空間，以最近鄰近點方式進行比對即有相當好的辨識能力，可大幅節省習知在進行比對時所需要的時間。

請參見第 8-11 圖，其係為本發明之影像辨識模型所進行的人臉辨識精準度於低維度空間之結果，與四篇習知技術作比較，如圖所示此些習知技術分別為：

● PCA+MFA 代表主成分分析法搭配邊境費雪分析法；PCA+ONPDA 代表主成分分析法搭配正交基鄰近保留判別分析；PCA+LPPface 代表以主成分分析法加上區域保存投影方法；以及 PCA+OLPPface 代表主成分分析法搭配正交基之區域保存投影方法。

● 並且，本發明之影像辨識模型將 p 值設定為 2（以點至線最近距離方式），以及 K_1 值與 K_2 值皆為 10 來建立特徵轉換空間矩陣。其中，第 8-9 圖為以 CMU 資料庫所提供訓練樣本所獲得的結果（第 8 圖為每一類組 6 個訓練樣本、第 9 圖為每一類組 9 個訓練樣本），第 10-11 圖則為 IIS 資料庫所提供訓練樣本所獲得的結果（第 10 圖為每一類組 6 個訓練樣本、第 11 圖為每一類組 7 個訓練樣本）。

根據上述本發明的測試結果，可知本發明之影像辨識模型之建立方法具有優良的辨識度，由於本發明係改變原本使用在人臉辨識之測試階段的最近特徵空間嵌入式的概念，將最近特徵空間嵌入式融入在訓練階段所建構的特徵空間轉換矩陣中，而且本發明可以選擇採用點至不同的特徵子空間（如：點、線、面或高維空間）的方式進行特徵空間轉換的建構，並以拉普

拉司矩陣方式表示之，因此不僅可以將原空間中的拓樸資訊保留，更可進一步將訓練樣本在原空間中的線性變化關係保留，可提升辨識度。而且在測試階段只需利用簡單的點對點分類器來進行待測人臉的辨識，因此，可減少一般在測試階段辨識人臉所花費的時間。

以上所述之實施例僅係為說明本發明之技術思想及特點，其目的在使熟習此項技藝之人士能夠瞭解本發明之內容並據以實施，當不能以之限定本發明之專利範圍，即大凡依本發明所揭示之精神所作之均等變化或修飾，仍應涵蓋在本發明之專利範圍內。

【圖式簡單說明】

第 1 圖為習知技術的訓練樣本的特徵空間轉換分佈示意圖。

第 2 圖為本發明之影像辨識模型之建立方法之步驟流程圖。

第 3(a)圖為組內變異之示意圖。

第 3(b)圖為組間變異之示意圖。

第 4 圖為本發明的訓練樣本的特徵空間轉換分佈示意圖。

第 5 圖為本發明之影像辨識裝置。

第 6 圖為點至 $p=2$ 之特徵子空間之示意圖。

第 7 圖為點至 $p=3$ 之特徵子空間之示意圖。

第 8-11 圖係分別為本發明與先前技術的人臉辨識精準度之成果示意圖。

【主要元件符號說明】

10 影像擷取器	12 測試影像
14 影像模擬處理器	16 影像辨識模型
18 訓練樣本	20 顯示器

七、申請專利範圍：

1. 一種影像辨識模型之建立方法，包括：

- (a)收集複數個類組之複數個訓練樣本，並決定點至特徵子空間最短距離之方式來進行特徵空間轉換；
- (b)建立該等訓練樣本之一主要轉換矩陣，並將該等訓練樣本投影至降維空間；
- (c)根據所決定的該點至該特徵子空間最短距離之方式，計算該等訓練樣本之複數個組內投影點與複數個組間投影點，求得複數個組內向量與複數個組間向量；
- (d)根據該等組內向量與該等組間向量，計算一組內變異矩陣與一組間變異矩陣；
- (e)根據該組內變異矩陣與該組間變異矩陣，求得一變異轉換矩陣；以及
- (f)根據該主要轉換矩陣與該變異轉換矩陣，得到一特徵空間轉換矩陣，以作影像辨識模型使用。

2. 如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該等訓練樣本或該測試影像係為人臉影像。

3. 如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該步驟(c)中根據該點至該特徵子空間之最短距離方式，計算該等訓練樣本在同該類組中之該等組內投影點與在不同該類組中之該等組間投影點，求得該等組內投影點所構成之複數個組內向量與該等組間投影點所構成之複數個組間向量。

4. 如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該步驟(a)

後更包括一步驟：

決定組內向量個數 K_1 與組間向量個數 K_2 。

5. 如申請專利範圍第 4 項所述之影像辨識模型之建立方法，其中該步驟(c)中更包括：

將該等組內向量與該等組間投影向量依照距離由大而小方式排列。

6. 如申請專利範圍第 5 項所述之影像辨識模型之建立方法，其中該步驟(d)中，在以距離由大而小排列之該等組內向量中，選取前 K_1 個該組內向量，並設定對應之至少一權重矩陣，以計算該組內變異矩陣。

7. 如申請專利範圍第 5 項所述之影像辨識模型之建立方法，其中該步驟(d)中，在距離由大而小排列之該等組間向量中，選取前 K_2 個該組間向量，並設定對應之至少一權重矩陣，以計算該組間變異矩陣。

8. 如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該步驟(d)中，選取同類組中向量距離第一特徵臨界值之該等組內向量，並設定對應之至少一權重矩陣，以計算該組內變異矩陣。


9. 如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該步驟(d)中，選取不同類組中向量距離小於第二特徵臨界值之該等組間向量，並設定對應之至少一權重矩陣，以計算組間變異矩陣。

10. 如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該步驟(a)中該特徵子空間係包括點、線、面或高維空間。


11. 如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該步驟(e)係將求得的該組內變異矩陣與該組間變異矩陣進行費雪條件式(Fisher's Criterion)轉換計算該變異轉換矩陣。

- 12.如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該步驟(e)中該變異轉換矩陣 w^* 係由該組內變異矩陣 S_B 與該組間變異矩陣 S_w 求得，其關係式為 $w^* = \arg \max_w S_B / S_w$ 。
- 13.如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該步驟(f)中該特徵空間轉換矩陣係為該主要轉換矩陣內積該變異轉換矩陣。
- 14.如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該主要轉換矩陣係由主成分分析法取得。
- 15.如申請專利範圍第 1 項所述之影像辨識模型之建立方法，其中該影像辨識模型提供至少一測試影像投影，並根據該測試影像距離該訓練樣本的最相近距離來辨識該測試影像所屬之該類組。
- 16.一種使用如申請專利範圍第 1 項之影像辨識模型的影像辨識方法，係將該等訓練樣本與至少一測試影像投影至該影像辨識模型中，以最近距離方式比對該測試影像與該等訓練樣本，以正確辨識該測試影像所屬之該類組。
- 17.如申請專利範圍第 16 項所述之影像辨識方法，其中係係採用點對特徵子空間之最短距離方式來正確辨識該測試影像之該類組。
- 18.如申請專利範圍第 16 項所述之影像辨識方法，其中該特徵子空間係為點、線、面或高維空間。


八、圖式：




第1圖
(先前技術)




第2圖




第3(a)圖




第3(b)圖




第4圖




第5圖




第6圖




第7圖




第8圖



第9圖 維度



維度 第10圖



第11圖