

混合類神經網路應用於影像車號辨識

張財榮

南台科技大學 資訊工程系

trchang@mail.stut.edu.tw

賴建庭

南台科技大學 資訊工程系

m94g0213@webmail.stut.edu.tw

摘要

本文提出完整的影像車牌辨識流程，針對各個部分常見的問題提出改善方法。將車牌辨識方法分為四大部分，分別為前處理、車牌區域定位、字元分割以及字元辨識。其中車牌區域定位是基於模糊理論方法來完成。在字元分割部分，則以連通元件為基礎，提出快速的元件分類法來留下車牌字元，並能夠找出車牌傾斜角度來進行校正。而字元辨識部分，使用自組織映射網路(Self-Organizing Map, SOM)以及倒傳遞類神經網路(Back Propagation, BP)所組成之混合類神經網路架構(Mixture of Experts, ME)來進行辨識工作，此模型是基於委員會機器為概念(Committee Machine)所發展出的架構。其中自組織映射網路扮演了分派器以及開道器(Gating Network)的角色，將輸入字元分派到若干個獨立的子網路，如此可降低每個子網路所需辨識的類別數，專注於屬性相近的樣本辨識學習，進而達到提高辨識率的效果，並且在辨識過程中決定各個子網路的影響權重，由實驗結果發現可以提升百分之一的字元辨識率及百分之五的車牌辨識率。

關鍵詞：車牌辨識、混合類神經網路、模糊理論、自組織映射網路、委員會機器。

1. 前言

近年來國內汽機車使用量日益增加，隨之而來的是龐大的車輛管理問題，常見的有如：公共場所車輛進出管制、道路收費、違規舉發、贓車偵測或是失竊協尋等等。雖然目前已有成熟的感測器技術可應用於解決車輛識別的相關問題（例如RFID），但基於數位元影像處理的車牌辨識系統於解決上述問題上仍有相當大的發揮空間。因為此類系統通常只需要一般的運算設備(PC)搭配取像設備便能運行，同時亦將其可移植到手機、PDA等平台以發揮其高可攜性的優點。目前已有許多研究都致力於車牌辨識系統的辨識率提昇、自動化、即時化、與成本降低等等問題上。本文針對各個部分常見的問題提出具體的改善方法，並提出一種以委員會機器為基礎的架構來提昇辨識率，並採集了180張樣本進行實驗與討論。

2. 系統流程與概觀

本文將車牌辨識系統流程區分為四大部分，分別為前處理、車牌區域定位、字元分割與字元辨識，如圖1所示。其中前處理部分是利用影像處理方法提取影像的某些特徵，以便後續的使用，如邊緣、二值化以及HSI分量等等。車牌定位的部分則是延用陳[2]的理論，利用影像的邊緣、明暗度以及飽和度等特徵分量，針對車牌影像部位的特性來進行模糊歸屬運算，所求得的集合即可代表每個pixels屬於車牌的程度，此外我們再取模糊歸屬集合進行能量計算來找出可能為車牌的候選區域，並透過評分機制來確認車牌的正確所在位置。




圖 1 系統流程圖

而在字元分割部分，我們以連通元件為基礎，一個類似於霍氏轉換(Hough Transform)的投票機制被用以偵測車牌影像的傾斜角度，以便進行傾斜調整。隨後再利用元件的高度、座標等特徵來將元件分組，將成員較多的主流群組留下，去除其它特徵較為分散的非主流群組。此外，為了避免車牌字元因種種因素而遺失，我們必須在這部分的最後加入元件的補償規則。

為了提高字元的辨識率，本文提出一種基於委員會機器概念的辨識器架構[6]。如圖2所示為委員會機器的一種，其中開道器(Gating Network)是為了混合各個專家的決策而設計，由於輸入向量透過開道器影響各個專家的決策權重，而非固定權重，故

稱之為動態架構。我們事先以自組織映射網路(Self-Organizing Map, SOM)[8,9]來訓練出一組拓模層神經權重，利用此組拓模層作為閘道器，此外可用來進行各個專家的辨識類別之分派，如圖 3 所示。

本文分別於第三章到第五章詳細介紹車牌區域定位、字元分割與字元辨識系統的細節。並於第六章說明實驗方法與結果討論，實驗發現相較於單一類神經網路，混合類神經網路模組可以提升 1% 的字元辨識率及 5% 的車牌辨識率。




圖 2 動態式委員會機器架構




圖 3 SOM 用於專家辨識類別分派

3. 車牌區域定位

車牌區域定位的目的是希望從原始影像中搜尋出車牌所在位置。本文延用陳[2]的文中所提出運用三個歸屬函數(Membership Function)來求得三個模糊集合(飽和度歸屬集合 $\tilde{S}$ 、明暗度歸屬集合 $\tilde{I}$ 、邊緣歸屬集合 $\tilde{E}$)，此外我們再取模糊歸屬集合進行能量計算來找出可能為車牌的候選區域，並透過評分機制來確認車牌的正確所在位置。關於模糊歸屬函數、能量計算及候選區域的選取，將在本章中一一介紹。

3.1 飽和度歸屬集合

飽和度(Saturation)代表著色彩的濃淡程度[5]，當某個像素點飽和度高時則視覺上的色彩較為濃厚，反之，飽和度低則表示其色彩較不鮮明，視覺上較偏向黑白。因此，飽和度可以用來決定一個像素值屬於黑白或彩色的程度。借此特性可設計如下的歸屬函數：

$$\mu_{\tilde{S}}(s) = \exp(-as) \quad (\text{式 } 1)$$

上式為一遞減的指數形函數， a 為一常數參數可決定其凹陷程度。由於欲辨識的車牌為黑白形式，此式代表著飽和度越低則隸屬於車牌的程度越高。

3.2 明度歸屬集合

原理和飽和度歸屬集合類似，明度(Intensity)偏高或偏低時，影像在視覺上較趨向黑白；反之，明度值處於中間時，影像具有較明顯的色彩變化，故可利用明度值來設計歸屬函數——明度值愈偏離中間值，則歸屬程度越高。上述的關係可以下式表示：

$$\mu_{\tilde{I}}(i) = 1 - \exp(-a(i - \bar{I})) \quad (\text{式 } 2)$$

另外，由於每張影像的明度值分佈不一，因此固定的中間值較不適於歸屬值的計算，在此採取整張影像的明度平均值 $\bar{I}$ 作為中間值，以達到動態調整的目的。

3.3 邊緣歸屬集合

邊緣是萃取車牌區域的重要依據，因為車牌字元為粗黑字體，底色為白色，所以在車牌區域內將有若干數量的黑白交錯。若某個像素其水平方向的鄰近(左右)範圍內有較多的影像邊緣，則該像素屬於車牌的程度較高。假如與目前像素點 i 距離 d 的像素點是邊緣，則將距離 d 代入高斯函數後加總起來，即產生所謂的 $\mu_{\tilde{E}}$ 歸屬函數，其數學式如下：

$$\mu_{\tilde{E}}(i) = \sum_{d=-L}^L E(i+d) * e^{\frac{-d^2}{2\sigma^2}} \quad (\text{式 } 3)$$

其中 $E(i+d)$ 為一邊緣檢測函數，若像素點 $i+d$ 在邊緣上，則 $E(i+d)=1$ ，否則為 0。 σ^2 為變異數用以設定高斯分佈的區間大小。 L 為搜尋的範圍，可以設為整張影像的長度。但因高斯函數在遠離中心點一段距離後的值幾乎為零，為了減少不必要的計算時間，我們將 L 值設定為正負 50 像素(約為車牌在影像中的大小)。

在系統的實作上，我們發現利用二維的邊緣濾波器(如Prewitt)所得的邊緣影像來進行歸屬集合的運算，所得的歸屬集合在水平邊緣上(如汽車保險桿)將呈現較高的歸屬值，而真正的車牌區域其歸屬值

則相對較低(如圖 4b)，此現象將不利於車牌區域的選取。為解決此問題，我們提出下述方法來得到較佳的邊緣歸屬集合：

1. 求出僅有水平方向相減的邊緣影像以及其所對應的邊緣歸屬集合 $\tilde{E}^1$ 。
2. 再求出利用二維邊緣濾波器所得的邊緣影像以及其所對應的邊緣歸屬集合 $\tilde{E}^2$ 。
3. 利用如下的運算來整合 $\tilde{E}^1$ 和 $\tilde{E}^2$ ，即可得到較佳的邊緣歸屬集合：

$$\tilde{E} = \min(\tilde{E}^1, \tilde{E}^2) \quad (\text{式 4})$$

此法所求出的邊緣歸屬集合大幅的減低了對於水平邊緣的敏感度，使得歸屬值更為精準。缺點是必須付出更多的運算時間。

3.4 能量計算

前面步驟所得的三項歸屬集合：飽和度歸屬集合 $\tilde{S}$ 、明暗度歸屬集合 $\tilde{I}$ 以及邊緣歸屬集合 $\tilde{E}$ 分別有其代表意義，隨後我們將之整合為單項歸屬集合 $\tilde{M}$ ，整合方式為模糊集合的交集運算，即：

$$\mu_{\tilde{M}} = \min(\mu_{\tilde{S}}, \mu_{\tilde{I}}, \mu_{\tilde{E}}) \quad (\text{式 5})$$

整合可得到如圖 4d所示的效果，我們可發現，影像中特性近似車牌的部位以及車牌本身，都會呈現較高的亮度。為了更明確的定出候選區域，我們再以一個二維的移動平均濾波器(moving average filter)對模糊圖 $\tilde{M}$ 進行濾波，得到的值在此稱之為能量，其目的是將原本分佈較分散的區域濾除或減弱，並使集結的區域更加突顯，如圖 4e所示。隨後再以二

值化留下高能量的區塊，每個獨立的區塊即為一個車牌候選區域。

3.5 候選區域的選取

在得到車牌候選區塊後，須給定一評分規則來對每個候選區塊進行評分，以便確認何者才是真正的車牌所在位置。由於被選為候選區塊的區域，都同樣具備較高的條件，因此先前說使用過的特徵如飽和度、明度或邊緣等，對於這些候選區域而言已經不具有區別性，因此不適宜用來作為此處評分的輸入項。我們採取另一特徵—連通元件與標準字體樣版(如圖 4f)的相關性來進行評分。規則是先對候選區域內的灰階影像二元化之後，再取出二元影像內的連通元件(Connective Components)，先行濾除尺寸不可能為車牌字體者，再將留下的元件與標準字體版進行相關性運算：

$$score_m = \sum_i \left[\max_j \frac{(f_i - \bar{f}_i)(g_j - \bar{g}_j)^T}{\sqrt{[(f_i - \bar{f}_i)(g_j - \bar{g}_j)^T]^2}} \right] \quad (\text{式 6})$$

此處 $score_m$ 代表候選子圖 m 的評分， f_i 、 $\bar{f}_i$ 分別代表元件 i 的二元陣列及其平均值； g_j 、 $\bar{g}_j$ 則代表標準字體樣版 j 的二元陣列及其平均值。式 6 意即每一元件與樣版字體中相關性最大者，再行加總即為該候選區域的評分。經過此評分運算後，我們選擇分數最高者為最有可能為車牌的區域。




圖 4 (a) 原始影像灰階圖 (b) 一般的邊緣歸屬集合 (c) 改善後的邊緣歸屬集合 (d) 整合後的模糊集合 (e) 能量集合 (f) 台灣現行車牌標準字體樣版

4. 字元分割

字元分割部分仍是以連通元件為基礎，我們從先前的步驟中取出車牌部位的子影像，在分割出車牌字元之前，我們須先對車牌影像進行一些調整，以得到較有利於辨識的影像，車牌影像的調整包含旋轉校正與雜項去除。其方法將在本章中介紹。

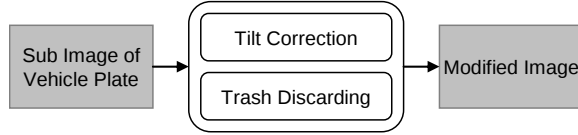


圖 5 車牌影像調整

4.1 旋轉校正

在進行旋轉校正之前須先偵測車牌的傾斜角度。基於霍式轉換的概念，影像上存在越多共線的點可在法角-法線空間上的相同位置上得到越多的累計值[7][14]。在此我們也希望利用共線點的概念來偵測車牌旋轉角度，但為了計算更快速並且更符合車牌辨識的應用，我們僅取每個元件的頂點座標進行計算。在先行排除尺寸不可能為車牌字元的元件後，假設剩餘 n 個元件，考慮每個元件 i 的頂點座標 (x_i, y_i) ，與其它元件的頂點座標 (x_j, y_j) 的連線角度為：

$$\theta_{ji} = \tan^{-1} \frac{(x_j - x_i)}{(y_j - y_i)} \quad \forall i \neq j \quad (\text{式 } 7)$$

以每 10 度為一個區間，將所計算出的連線角度落入的區間進行投票，最後得到投票數最多的區間，對屬於該區間的所有角度取平均值，即為車牌影像的旋轉角度。

4.2 雜項去除

在許多情況下，車牌影像中存在著許多不屬於車牌字元的雜項將會影響辨識結果，在此必須精準地排除雜項元件而留下車牌字元元件。由於我們沒有限制每張車牌影像的縮放倍率以及拍攝角度，每張影像的車牌字體大小、比例不一，因此不可使用絕對的排除規則而須採用影像自身的元件的相對特徵。在此我們以簡易的聚類演算法來將元件分類，在“車牌字元的特徵較為集中，雜訊的特徵較為分散”的假設前提下，我們可取成員最眾多的類別（在此稱主流群集）作為車牌字元群集。此處的聚類演算法的規則如下：

1. 取元件本身高度及其頂點 y 軸座標為特徵值，將所有元件的特徵值正規化到特定範圍內（0~1）。
2. 隨機選入一組特徵值作為初始中心點。

3. 依序選入其他特徵值，並計算該組特徵向量 X_i 與所有類別中心點 C_j 間的歐氏距離 d_{ij} 。
4. 找出與目前元件特徵向量 X_i 距離最近的類別中心點 C_g ，若 d_{gi} 小於距離半徑門檻值 r 則將元件 i 歸類到 c_g 的類別，並重新計算類別中心。類別中心為類別中所有特徵值的平均值；反之若 d_{gi} 大於距離半徑門檻值 r 則以該組特徵值為類別中心增加一個新的類別。
5. 重覆步驟 3 與 4 直到所有元件被歸類完畢。
6. 最後成員最眾多的類別即為主流群集也就是車牌字元群集。

4.3 元件補償

考慮實際上有許多種情況會造成原本屬於車牌字元的元件在上述步驟中被排除，例如車牌字元在二元圖上與深色的車牌外框相連而被排除，或車牌字體中斷裂情形等等。因此在字元分割的最後，我們以一補償規則來尋找被錯誤排除的字元。規則是計算目前被留下的元件的平均長寬，往左右兩邊尋找符合此尺寸的元件，直到元件數量達到預設的數量為止。

5. 辨識系統

委員會機器架構是基於分進合擊(divide and conquer) 的概念，將分類工作分配到數個專家子網路(experts)，最後再整合各專家的意見做最後決策[6]。本研究採用的混合類神經網路架構(Mixture of Experts, ME)，是屬於委員會機器中動態架構(Dynamic Structure)，如圖 2所示，此種架構因為輸入向量將改變閘道器(Gating Network)輸出值，進而影響各個專家的決策權重值，而非固定權重值因而得此名稱。在本研究中設計以自組織映射網路(Self-Organizing Map, SOM)[8,9]來作為決定各個專家決策權重的閘道器，並且利用其拓撲層權重來作專家間的辨識類別分配。在本章中將介紹自組織映射網路的特性，以及混合類神經網路的組態方式。

5.1 自組織映射網路

自組織映射網路的架構如圖 2所示的左半部，包含輸入層與拓撲層，拓撲層與輸入層間具有完整連結(full connection)，自組織映射網路的學習方式是：選取當回合中連結權重與輸入資料點距離最近的拓撲層神經元為優勝神經元，隨後以優勝神經元為中心去更新其周圍神經元的連結權重，更新算式如下：

$$\delta_j = \mu_i \times \eta_{qj}(k) \times [x(k) - w_j(k)] \quad (\text{式 } 8)$$

$$w_j(k+1) = w_j(k) + \delta_j \quad (\text{式 } 9)$$

其中 k 代表第 k 組訓練樣本 μ_k 是為當回合的學習速率， η_{qi} 為一個距離加權，是將該神經元 j 與優勝神經元 g 在拓樸層上的歐式距離，代入一高斯分佈函數而得。經過若干回合的更新之後，使得權重的誤差值(Mean Square Error)小於預先設定的門檻或達到訓練次數即可停止學習。經過學習後的SOM將呈現如下特性：

- 權重值在特徵空間上的分佈會擬合所輸入的資料分佈，且大致上呈等距。
- 權重向量相近的神經元，其在拓樸層上也大致上鄰近。

對於車牌字元辨識的應用來說，特徵空間即是一個字元的所有像素點所組成，假若一個字元大小為 40×20 像素，則特徵維度為 800。我們可將經過訓練後的拓樸層權重值轉換為二維陣列並以灰階形式印出，如圖 6所示。由圖中可見某些權重向量與輸入的標準字體呈高度吻合，而有些則呈現較模糊的狀況。拓樸鄰近的權重值，其彼此間的外觀相似，例如字元 5 與 S、8 與 B、E 與 F 或 C 與 O 等等。




圖 6 拓樸層權重的灰階圖形

5.2 混合類神經網路的組態及運作方式

在前一節已經介紹了自組織映射網路的部份特性，基於這些特性，自組織類神經網路在本研究中具備兩項功用：(a) 混合類神經網路架構中的閘道器，用以決定每個專家輸出值的重要性。(b) 各個專家所負責分類類別的分配器。

在委員會機器的概念下，我們希望每一專家的辨識能力具備其獨特性且彼此間互補。利用SOM的拓樸層及其權重分佈的特性，我們可對學習過後拓樸層權重值進行聚類演算法，將這些拓樸層神經元分為數個群組。每一個分類完的群組對應至一個專家，如圖 2右半部所示。每一個專家所負責的分類類別可直觀的採取與該群組成員相近的類別，例如圖 6所示的深灰色背景與淺灰色背景分別為拓樸層上的兩個群組，其中與深灰色群組較為接近的類

別可能為 2、3、6、8、9、S與J；與淺灰色群組較接近的類別可能為 6、E、F、L與S，我們將這些類別分派給其所屬的專家進行訓練與辨識。然而，實際上運作時的映射情況未必完全如我們所期。一組輸入向量在拓樸層上可找到最相近的神經元，若最相近的神經元所屬群組其下的專家並不具備該輸入類別的辨識能力，此現象我們稱之為映射錯誤(mapping error)，我們同時採取兩個途徑來解決此問題。第一，利用訓練樣本的映射情況作批次的調整；第二，不採取單一個專家的輸出，而採取更多專家的輸出作最後決策。以下歸納出本研究採取的混合類神經網路架構的具體的組態方式，以及辨識時期的運作方式。

■ 組態方式

1. 運行 SOM 的學習演算法，使拓樸層分佈達到一定程度的收斂。
2. 利用聚類演算法(如 K-Means)將拓樸層神經元分為數個群組。
3. 系統維護兩份表單，分別是神經元的群組分配表以及每個群組所負責的類別查詢表，在此稱 classes table。群組分配表在進行聚類演算法後即已固定，而 classes table 的組成則分為初始規劃與批次調整，分別在第 4、5 步驟中說明。
4. 依據待辨識類別與每個群組成員的相似程度，分配每個群組之下的專家所著重的辨識類別，每一個類別可加入多個群組。
5. 準備一批訓練樣本，我們已知這些訓練樣本所屬類別，依序輸入樣本，找出與輸入向量最接近的群組，或按程度前幾名的群組，若發生 mapping error 則將該類別加入該群組的 classes table 中。
6. 針對每個群組所負責的專家，也就是子分類系統，依據 classes table 中所列的類別進行學習，使其對於特定的類別具備高度的辨識率。

■ 運行方式

1. 當欲辨識一組輸入項時，作法如圖 2所示，除了將輸入向量輸入每組專家子網路之外，還須輸入閘道器中，計算每組專家的決策權重。
2. 在此閘道器是計算輸入向量與 SOM 的拓樸層神經元的相關性矩陣，如下式所示，

$$c_i = \max_j \frac{(X - \bar{X})(G_{ji} - \bar{G}_{ji})^T}{\sqrt{[(X - \bar{X})(G_{ji} - \bar{G}_{ji})^T]^2}} \dots (式 10)$$

此處 c_i 代表輸入向量 X 與群組 i 內部所有成員的最高相關性，我們可得到一相關性矩陣 c ：
 $c = [c_0 \ c_1 \ c_2 \ \dots \ c_{N-1}]$ ， N 代表群組數量。

3. 將所得到的 c 矩陣正規化後得到 u ，將 u 代

入下式即得到開道器的輸出：

$$g_k = \exp(u_k) \quad (式 11)$$

4. 在得到各組專家的輸出向量之後，將每組的輸出向量乘上對應的開道器輸出的常數再行加總，即為最後的決策整合。即：

$$Y = \sum_{k=0}^{N-1} y_k g_k \quad (式 12)$$

6. 實驗與討論

本章將車牌辨識流程分為兩個段落進行實驗與探討，第一階段是車牌定位與字元分割部分，第二階段是字元辨識系統的部分。

6.1 車牌定位與字元分割階段

本節將描述第4章之前所提的車牌定位與字元擷取的測試實驗。我們總共收集了 180 張內容中有汽車車牌，影像的大小皆為 640×480 像素，24bit 的全彩影像作為實驗樣本。拍攝影像時並未考慮車牌的縮放倍率與拍攝角度。我們將所以測試樣本輸入所開發的車牌偵測軟體進行偵測，結果在 180 張樣本中，有 7 張未能成功找出車牌區域並分割出字體(成功率 96.1%)，分別有 5 張在車牌定位部分失敗(成功率 97.2%)，2 張則是在字元分割部分未能正確取出車牌字體(成功率 98.8%)。

6.2 字元辨識階段

為了測試本文所提的混合類神經網路架構(如圖 2)對於辨識效能上的提昇作用，我們另外訓練了一組單一倒傳遞類神經網路作為比較之用。我們以圖 4f 所示的標準字體樣版對辨識系統進行訓練，並取前一階段能夠成功定位車牌並擷取字元的樣本共 173 張中的 73 張作為額外訓練組，最後剩餘的 100 張則作為測試組。在此處的訓練組的功用除了訓練類神經網路之外還被用來進行classes table的調整。我們按照5.2節的方法訓練了一組混合類神經網路架構，其輸入維度為 800，開道器部分，也就是SOM的拓模層由 121 個(11×11)拓模層神經元所組成，我們將學習過後的拓模層作K-Means聚類演算法將拓模層神經元分為十個群組，並按照前述方法建立並調整classes table，調整過後的classes table如表 1所示。而每一個群組所負責的子網路則分別由十個倒傳遞類神經網路(Back Propagation, BP)所組成。

在混合類神經網路與單一的倒傳遞類神經網路都經過輸入同樣一組訓練樣本進行訓練，且以同樣另一組樣本測試後，得到的測試結果如表 2所示。

表 1 Classes Table

Experts	Classes
1	4 A V 1 M
2	6 8 B C D E G L O Q U 9 R H
3	5 8 9 B E F J P R S 6 O D Q
4	2 3 8 9 H J P R S 6 B Q O D U
5	1 3 7 I T V Y R W X Z E
6	3 4 A F H K P R V X B E M N Y 7
7	N U W J
8	H K M N R U 8 W P
9	2 3 I T Z 7
10	6 8 B E F K L R M 5 U P

表 2 測試結果

	Back Propagation	Mixture of Experts
車牌整體成功率	91.0% (91/100)	96.0% (96/100)
字元辨識成功率	98.5% (591/600)	99.3% (596/600)

由於每張車牌有六個字元，只要有一個字元錯誤則判定為整張車牌錯誤，因此使得車牌整體成功率較低。若由車牌整體的辨識成功率來看，單獨的倒傳遞類神經網路與委員會機器具有 5% 的差距。

表 3 中所列出的參考文獻中都實作了類似於本研究所提的車號辨識系統，我們取其提供的數據以及所採用的辨識器系統進行比較。其中Stage 1 代表車牌定位部分的效能，Stage 2 代表字元辨識部分的效能，而*則代表該論文並未探討車牌傾斜失真的部分，或是採取限制的拍攝方式。

表 3 參考文獻數據比較

Ref.	Stage 1.	Stage 2.	Classifier
[2]	97.9%	95.6%	SOM
[3]	N.A.	91.0%	Template
[1]	96.5%	89.1%	Probability Neural Network
*[11]	75.4%	98.5%	Multi-Layer Perceptron
*[10]	N.A.	95.0%	Multi-Layer Perceptron
*[4]	N.A.	94.0%	Support Vector Machine
this	96.1%	96.0%	Committee Machine

7. 結論

這篇文章中提出完整的影像車號辨識流程，並針對辨識各個部分所常見的問題提出改善方法，由實驗結果來看，本文所採取的車牌定位方法以及字元分割方法，對於車牌影像的各種變異或失真情況具有良好的容忍能力。而在辨識系統部分，採用了委員會機器概念中的混合類神經網路架構，並設計利用自組織映射網路作為混合類神經網路架構中的開道器，並用以分配各組專家所著重的辨識類別，使得每組專家具備其獨性，由實驗結果看來，此種設計在影像車號辨識上有著顯著的成效提昇。

參考文獻

- [1] Anagnostopoulos, C.N.E., I.E., Loumos, V., and Kayafas E., "A License Plate-Recognition Algorithm for Intelligent Transportation System Applications," **IEEE Trans. on Intelligent Transportation Systems**, Vol. 7, pp 377-392, 2006.
- [2] Chang, S.L., Chen, L.S., Chung, Y.C., and Chen, S.W., "Automatic license plate recognition," **IEEE Trans. on Intelligent Transportation Systems**, Vol. 5, pp. 42-53, 2004.
- [3] Comelli, P., Ferragina, P., Granieri, M.N., and Stabile, F., "Optical recognition of motor vehicle license plates," **IEEE Trans. on Vehicular Technology**, Vol. 44, pp.790-799, 1995.
- [4] Ge, G., Xu, J. and Wang, M., "On the Study of Image Characters Location, Segmentation and Pattern Recognition using LS-SVM," **WCICA 2006 on Intelligent Control and Automation**, Vol. 2, pp. 9650-9654.
- [5] Gonzalez, R. C. and Woods, R. E., **Digital Image Processing(2nd)**, Prentice Hall, 2002.
- [6] Haykin, S., **Neural Networks: A Comprehensive Foundation**, Prentice Hall, 1998.
- [7] He, M.G., Harvey, A.L., and Vinay, T., "Hough Transform In Car Number Plate Skew Detection," **Int. symposium on Signal Processing and Its Applications**, Volume 2, pp.593-596, 1996.
- [8] Hsu, C.C., "Generalizing self-organizing map for categorical data," **IEEE trans. on Neural Networks**, vol. 17, no. 2, pp.294-304, 2005.
- [9] Kohonen T., "The self-organizing map," **Proc. of IEEE**, vol. 78, no. 9, pp.1464-1480, sep. 1990.
- [10] Koval, V., Turchenko, V. and Kochan, V., A. Sachenko, G. Markowsky, "Smart. License Plate Recognition System Based on Image Processing Using Neural Network," **Proc. IEEE Int. Workshop on Intelligent Data Acquisition and Advanced Computing Systems**, pp. 123-127, 2003.
- [11] Nijhuis, J.A.G., Ter Brugge, M.H., Helmholt, K.A., Pluim, J.P.W., Spaanenburg, L. and R.S Venema, "Car license plate recognition with neural networks and fuzzy logic," **Proc. of IEEE Int. Conf. Neural Networks**, Vol. 5, pp. 2232-2236, 1995.
- [12] Otsu, N., "A Threshold Selection Method from Gray-Level Histograms," **IEEE Trans. on System, Man, and, Cyber-netics**, Vol. SMC-9, pp. 62-66, 1979.
- [13] Tang, H.M., "Face recognition committee machine," **Proc. Int. Conf. Multimedia and Expo 2003**, vol. 3, pp. III - 425-8, Jul. 2003.
- [14] Zhang, Y. and Zhang, C., "A new algorithm for character segmentation of license plate," **Proc. IEEE Intelligent Vehicles Symposium 2003**, pp. 106-109, Jun. 2003.