行政院國家科學委員會專題研究計畫　期中進度報告

總計畫(1/3)

計畫類別：整合型計畫
計畫編號：NSC92-2213-E-002-081-
執行期間：92 年 08 月 01 日至 93 年 07 月 31 日
執行單位：國立臺灣大學資訊工程學系暨研究所

計畫主持人：洪一平
共同主持人：陳祝嵩，陳文雄，石勝文，王新民
計畫參與人員：蔡昌明、陳嘉平、葉士良、張文彥

報告類型：精簡報告
報告附件：國際合作計畫研究心得報告
處理方式：本計畫可公開查詢

中　華　民　國 93 年 5 月 31 日

行政院國家科學委員會補助專題研究計畫期中精簡報告

結合音訊與視訊之多模組身分確認之研究－總計畫(1/3)

計畫類別：□個別型計畫　　■整合型計畫

計畫編號：NSC -92-2213-E-002-081

執行期間：92 年 8 月 1 日至 93 年 7 月 31 日

計畫主持人：洪一平

共同主持人：王新民、陳祝嵩、陳文雄、石勝文

本成果報告包括以下應繳交之附件：

□ 赴國外出差或研習心得報告一份

□ 赴大陸地區出差或研習心得報告一份

□ 出席國際學術會議心得報告及發表之論文各一份

■國際合作研究計畫研究報告書一份

執行單位：國立台灣大學資訊工程學系暨研究所
中央研究院資訊科學研究所
國立暨南國際大學電機工程系
國立暨南國際大學資訊工程系

中　華　民　國　93 年 5 月 30 日

行政院國家科學委員會專題研究計畫期中精簡報告

結合音訊與視訊之多模式身份確認之研究 — 總計畫(1/3)

Research on Audio- and Video-Based Multi-Modal Biometric Person Authentication

計畫編號：NSC -92-2213-E-002-081
執行期限：92 年 8 月 1 日至 93 年 7 月 31 日
主持人：洪一平
共同主持人：王新民、陳祝嵩、陳文雄、石勝文
計畫參與人員：蔡昌明、陳嘉平、葉士良、張文彥等

一、 中文摘要

此整合型計畫的主要目的在於研究如何整合各種不同的生物特徵以進行身份確認。其中，子計畫二著重於人臉辨識；子計畫三探討如何將人臉表情及唇形追蹤之資訊應用於身份確認；子計畫四與子計畫五分別研究如何利用靜態與動態的虹膜資訊進行身分確認。在此一年度的總計畫中，主要在於針對多重分類器的技術進行相關的研究與探討，以奠定未來兩年各子計畫成果的整合基礎。傳統的多重分類器技術大多是以線性的方式來直接結合這些分類器的輸出結果，但在此一計畫的研究中，我們探討了「後分類法」的觀念，可以對多重分類器的輸出結果以非線性的方式結合。實驗結果證實我們所提出的方法可以提高分類的正確率。

關鍵詞：多重分類器、後分類法、身份確認、生物認證。

Abstract

The goal of this project is to study how to integrate different methods of person identity verification based on various biometric features. Sub-project 1 focuses on face recognition. Subjects 2 focuses on facial expression and lip tracking for person identification. The static and dynamic iris recognitions are respectively studied in sub-projects 4 and 5. In the main project, we focus on the topic of multiple classifier system (MCS) in the first year. In the past, linear combination was widely used in MCS. In this project, we study the post-classification (or meta-classification) scheme for improving the MCS combination. It can combine multiple classifiers in a nonlinear manner. According to our experimental results, the developed method can improve the performance of MCS.

Keywords: Multiple classifier system, meta-classification, post-classification scheme, person identity verification, biometric authentication.

二、 緣由與目的

近幾年來，隨著科技的進步，如何以使用者本身所具備的生物特徵來進行身份確認已成為熱門而重要的研究領域。此一研究課題甚至被美國麻省理工學院列為改變世界的十大最具潛力的科技之一。

在過去的許多研究中，針對不同的單一生物特徵都有許多的技術及方法被提出。然而人類的認知其實是同時結合多種資訊與特徵來輔助決策。因此，如何有效地結合多種生物特徵來進行身份確認是本計畫所要討論的重點。

在本計畫中，我們主要針對如何結合多種生物特徵的技術作一基礎的理論研究與探討。我們採用了多重分類器的觀念，並對

其做一個整體的討論。此外，我們也探討了後分類法 (post- or meta- classification scheme) 的觀念，可應用於多重分類器上，進而提高分類的效能與正確率。

此外，為了瞭解各種不同生物特徵應用於身份確認的個別效能及所需之技術，在各子計畫中也對各種不同的生物特徵技術做了相關的研究。配合上述的多重分類器技術，我們未來兩年將可結合多種生物特徵來從事身份確認的研究，並期望此一研究可以有所突破，進一步提高身份確認的正確率。

三、 研究方法與結果

在本節中，我們首先將描述總計畫之成果。接著，將概述各子計畫之執行成效。雖然「子計畫一：利用音訊進行身份確認之研究」並未於本年度獲得通過，然提案人王新民教授仍為本總計畫之共同主持人，且仍繼續與本計畫配合進行相關之研究。因此，未來兩年我們仍然會設法整合王教授的研究成果，以期達到結合音訊與視訊的身份確認目標。

總計畫

在總計畫部分，我們將對多重分類器的觀念做一探討，並介紹我們所提出之方法與實驗的結果。

(1)、多重分類器介紹

多重分類器的主要觀念是想結合多個簡單的、較弱的成員分類器，透過整合這些成員分類器的輸出結果來得到一個優於成員分類器的輸出，進而改善分類的效能。在這一技術中，主要有兩個部分需要設計，一為成員分類器的建立；另一為成員分類器的結合。

在此，我們將多重分類器的整合方法分為兩大類：分類器層次整合(classifier-level integration)、學習器層次整合(learner-level integration)。

(a)、分類器層次之整合

在分類器層次整合方面，首先得先建立多個成員分類器。這些分類器的建立可以是使用不同生物特徵為來源(例如：人臉、聲音、表情、虹膜等)。其可以是相同種類的分類器但有不同的參數，也可以是將訓練資料的特徵分成多類所個別訓練出來的分類器。給定一個測試資料，這些分類器將先個別作判斷，然後再針對這些個別的判斷結果做整合。常用的整合方法有下列三種：(1)多數投票法 —給定一個測試資料，每個成員分類器會將自己的一票投給某一類別，最後再找出票數最高的類別作為最後的輸出；(2)權重平均法 — 即是將每個成員分類器所決定之票數乘上所屬的權重，而其權重的取得可以是靜態的指定或是由動態的學習中獲得，最後得到最多權重票數之類別即為最後的輸出結果；(3)以名次為基準的方式 — 給定一個測試資料，每個分類器對每一個類別都給一個名次，最後再將所有類別之名次加總起來，得到分數最低的即是最後的輸出結果。此外，也有學者使用後分類(meta-classification)的技術做對各成員分類器的結果再進行分類處理以得到較佳的結果。

(b)、學習器層次之整合

在學習器的整合方面，可以使用boost的方法。在此我們以AdaBoost的技術來做一說明，也以此技術為基礎做相關的延伸與研究發展。

在AdaBoost [3][9]的技術中，是以各成員分類器所具備的權重來做結合，也就是說，給定一組成員分類器$\{h_1, h_2, \ldots, h_T \mid h_i : R^d \rightarrow \{1, -1\}\}$，透過下式的關係，對每一輸入資料$\mathbf{x}$，我們可以得到其應所屬的類別：

$$f(\mathbf{x}) = \sum_{t=1}^{T} a_t h_t(\mathbf{x})，$$

其中a_t為一組非負的權重係數，而f即為一多重分類器。而這些成員分類器及其權重可由boosting的過程中獲得。

AdaBoost處理的過程，主要是給定一個弱分類學習器(weak learner)及一組有權重的訓練資料，$S \equiv \{(\mathbf{x}_1,y_1), \ldots, (\mathbf{x}_N,y_N) \mid \mathbf{x}_i \in R^d, y_i \in \{1,-1\}, i=1, \ldots, N\}$來產生出多個分類器。在開始時，所有訓練資料的權重都是一樣的；但在經過分類學習後，我們將調高被分錯的訓練資料之權重（假設訓練錯誤小於百分之五十），再以此調整後之資料重新訓練出一個新的學習器。如此一直反覆執行，我們就可產生一組多重分類器，而各成員分類器對資料有不同的分類能力。每個成員分類器的權重關係a_t也可以在這過程中求得。基本上，Adaboost的程序即是要對訓練資料找到f使得下式有最小值

$$\Sigma_n \boldsymbol{exp}\{-y_n\, f(\mathbf{x}_n)\}。$$

其詳細之演算法步驟如下所述：

Adaboost演算法：

步驟 1：給定訓練資料$S = \{(\mathbf{x}_1,y_1), \ldots, (\mathbf{x}_N,y_N)\}$。

步驟 2：初始化每一個資料的權重為$w_n^{(1)} = 1/N$, 其中$n = 1, \ldots, N$。

步驟3：在每一次的遞迴 $t = 1, \ldots, T$ 做以下步驟

步驟3.1：使用弱分類學習器對有權重的訓練資料$\{S, w^{(t)}\}$來得到一適當的成員分類器$h_t: R^d \to \{1, -1\}$。

步驟 3.2：計算h_t的權重訓練誤差 $\varepsilon_t = \sum_{n=1}^{N} w_n^{(t)} I\left(y_n \neq h_t(\mathbf{x}_n)\right)$，其中若敘述statement是對的，則$I$(statement)=1；反之，則$I$(statement)=0。

步驟3.3：若$\varepsilon_t = 0$ 或$\varepsilon_t > 1/2$，則設定$T = t-1$ 然後跳至***步驟4***。

步驟3.4：令 $a_t = \frac{1}{2}\log\frac{1-\varepsilon_t}{\varepsilon_t}$。

步驟 3.5：更新權重值 $w_n^{(t+1)} = \frac{1}{Z_t} w_n^{(t)} \exp\{(-a_t y_n h_t(\mathbf{x}_n))\}$，其中$\boldsymbol{Z_t}$為正規化(normalization)之常數，可使得 $\sum_{n=1}^{N} w_n^{(t+1)} = 1$。

步驟 4：輸出多重分類器 $f_T(\mathbf{x}) = \sum_{t=1}^{T} a_t h_t(\mathbf{x})$。

在上述的方法中是使用單一的弱分類學習器的 Adaboost 作法，然而在本計畫中，我們同時擁有多種的生物特徵(例如：人臉、表情、虹膜等)，該如何將這些不同種類的資訊整合起來在目前研究上仍有待解決。在這裡，我們規劃以交替的方式依序輪流對不同的生物特徵做學習，並得到適用於不同生物特徵的成員分類器，再依此多重分類器進行分類判斷。因此，若是當我們有多個不同種類的特徵(或不同種類的模組)時，此時依其順序則有 $n!$ 種組合方式來產生 Adaboost 的多重分類器。

(2)、後分類法

在此節中，我們將探討利用後分類法的觀念來改進上述AdaBoost的方法。所謂的後分類法就是將多重分類器處理完之結果視為另一種輸入資料，再以一個分類器做一次分類。也就是說，給定一個維度為d的輸入資料向量$\mathbf{x}$可以透過T個多重分類器(例如：AdaBoost技術)將該資料由R^d對映至R^T，即

$\underline{x} = \Omega(x) = [a_1h_1(x)\ a_2h_2(x)\ \ldots\ a_Th_T(x)]^t$。

我們就可將原本的分類問題S轉換成一個新分類問題$\underline{S} = \{(\underline{\mathbf{x}}_1,y_1), \ldots, (\underline{\mathbf{x}}_N,y_N)\}$，而此一問題則可再由另一個分類器$F$: $R^T \to \{1,-1\}$來處理。

從後分類法的觀點來看，我們發現原始的AdaBoost 多重分類器以及其各成員分類器都可以線性的後分類器來表示。也就是說，這些多重分類器與成員分類器的觀念都是後分類法的一種特例。我們將此觀念以下面兩個特性來說明：

特性一：對各成員分類器h_j ($j = 1, \ldots, T$)，可由一個分界線為$I^t_j\ \underline{\mathbf{x}} = 0$ 的後分類器來

表示，其中I_j為在第j個元素值為 1，其餘皆為 0 的T×1 向量。

特性二：對AdaBoost的多重分類器f，可由一個分界線為$\boldsymbol{1}^t \underline{\mathbf{x}} = 0$的後分類器來表示，其中$\boldsymbol{1} = [1\ 1\ \ldots\ 1]^t$為$T$×1 向量。

圖一為上述觀念在T＝2 之示意圖。因此，此一多重分類器及其成員分類器都是屬於包含所有線性分類器的集合$\boldsymbol{\Gamma} = \{G: R^T \rightarrow \{1,-1\} \mid G(\underline{\mathbf{a}}^t \underline{\mathbf{x}} + b),\ \underline{\mathbf{a}} \in R^T \text{ and } b \in R\}$。而線性分類器即為一具備線性與非線性分類能力之通用分類器的特例。而線性與非線性分類器是指分類邊界(classification boundary)而言，若一分類邊界可以用一直線來表示則稱此分類器為線性分類器；若一分類邊界可以用一曲線來表示時則為非線性分類器(如圖二所示)。一般而言，非線性分類器可以較精準地得到分類結果。故在我們的實作中，後分類器F是採用支持向量機(support vector machine, SVM)為基礎，以結合AdaBoost技術發展了一套非線性Boosting之方法。

在目前的分類方法中，SVM 是一廣為使用且有很好效能的技術，且利用 Cover 所提出的「將資料投影至高維空間時，較容易以線性的方式對資料作分類」之觀念，使得 SVM 具備了線性與非線性的分類能力。而在 Keerthi 和 Lin 的論文中更證明了：當在 SVM 中採用 radial basis kernel 時，線性的 SVM 可以被非線性的 SVM 所涵蓋。因此在我們的方法中，我們即採用了 AdaBoost+ nonlinear SVM 的技術，而此後分類法所得之效能將可比只單純使用 AdaBoost 要好。其演算法如下所示：

非線性Boost演算法：

步驟 0：給定訓練資料$S = \{(x_1,y_1), \ldots, (x_N,y_N)\}$，遞迴次數$T$，線性SVM之參數$\tau_l = \{C_1, C_2, \ldots\}$與radial-basis之非線性 SVM 參數 $\tau_{nl} = \{(C_1,\gamma_1), (C_2, \gamma_2), \ldots\}$。令$\tau = \tau_l \cup \tau_{nl}$且$e^* = 0$。

步驟 1：利用AdaBoost來找出成員分類器$h_1, h_2, \ldots, h_T$與權重$a_1, a_2, \ldots, a_T$。假設$\Omega(\mathbf{x}) = [a_1h_1(\mathbf{x})\ a_2h_2(\mathbf{x})\ \ldots\ a_Th_T(\mathbf{x})]^t$，則$\underline{S} = \{(\Omega(\mathbf{x}_1),y_1), \ldots, (\Omega(\mathbf{x}_N),y_N)\}$。

步驟 2：對SVM之參數$\tau_i \in \tau$，i=1, 2, …

步驟 2.1：對$\underline{S}$做訓練，並以交叉確認(cross validation, CV)之方式計算其誤差值e。

步驟 2.2：若$e < e^*$，則設$e^* = e$、$\tau^* = \tau_i$。

步驟 3：設定SVM之參數為τ^*，並輸出訓練後之分類器。

(3)、實驗結果

在實驗中，我們從 UCI machine learning repository 與 Delve assessment datasets 中選用了七個測試資料(benchmark)來比較 Adaboost 與我們提出方法之效能。在這些資料中，對於其訓練資料量小於 600 時，我們採用 5-fold CV 來評估其正確率；而若訓練資料量大於 600 筆時，則以 10-fold CV 來評估。而在目前的實驗中都是以同一種類的資料來進行。

(a)、學習器層次之整合

為了觀察所提出之技術與只使用 Adaboost 多重分類器在不同方法上之效能，我們在 AdaBoost 的弱分類學習器部分，分別採用了兩種不同的方法來實驗：RBF nets (radial basis function networks)與 SVM。

在第一組實驗中，先以 RBF nets 作為 AdaBoost 的弱分類學習器，並設定遞迴次數 T=200，因此在 AdaBoost 中會產生 200 個 RBF nets 分類器。為了方便起見，我們將此原始的 AdaBoost 多重分類器縮寫為 RBF+AdaBoost，而將加了 nonlinear SVM 後分類器的多重分類器縮寫為 RBF+AdaBoost+SVM。此兩種方法之平均正確率和標準差如(表一)所示。

而在第二組實驗中，則是以 SVM 為 AdaBoost 的弱分類學習器，遞迴次數 T=50。在這組實驗中，我們分別比較了

只以一個 nonlinear SVM 分類器(SVM)、以 AdaBoost 多重分類器(SVM+AdaBoost)以及加入後分類法的多重分類器(SVM+AdaBoost+SVM)等方法，其平均之正確率與標準差如(表二)所示。

由上述的兩個實驗中，我們可以發現所提出的後分類法觀念的確可提高資料的分類正確率。

(b)、分類器層次之整合
除了以上的學習器層次的整合實驗外，我們也對分類器層次的整合作了一些實驗與測試。

在我們的初步研究中，我們曾嘗試結合 RBF nets 與 QDC(quadratic discriminant classification) 、 FLDA(Fisher Linear Discriminant Analysis)與 Kernel FLDA 等方法來建構多重分類器，並再配合 nonlinear SVM 的後分類器對各種資料做實驗。在我們初步的實驗中也發現此一方法可以提升分類的正確率(結果如表三與表四所示)。

子計畫二

人臉辨識應用於身份確認是重要且具挑戰性的研究課題，因此在此子計畫中，我們對此做了相關的研究開發。在本年度子計畫中，我們主要研發了三個模組：樣本蒐集、人臉偵測與身份確認。有了這些模組，我們就可以將其整合為一全自動的人臉辨識系統。

在樣本蒐集中，我們開發了一自動的人臉多角度樣本蒐集系統，透過機率的描述並利用最短路徑問題的方法來求解，可以自動地框取出影像序列中的人臉區域，並且可概略地知道人臉的粗略位置。而在人臉偵測上，我們採用了串接式分類器(a cascade of boosted classifiers)的觀念來完成此一部分。最後，我們以Kernel Linear Discriminant Analysis（Kernel LDA）演算法為基礎，將資料映射至高維空間中處理，而發展出一套具高準確率的身份確認系統。

子計畫三

在此子計畫中，我們著重於探討結合人臉表情與唇形動態資訊對於身份確認系統之研究。在目前的方法中，我們將系統分成了系統設定與系統使用兩個階段。在系統設定階段中，使用者被要求先做出特定的臉部表情，並記錄一段影片。接著，利用主成分分析法(PCA)對此影片找到一參考用的固有子空間。而在系統使用階段中，當使用者做出與先前系統設定階段相同的表情時，我們就可以使用相互子空間法(mutual subspace method)計算出此表情所形成之子空間與固有子空間之夾角。當此夾角小於一特定之門檻值時，即可通過身份的確認。另外，為了使時間軸的資訊也可加入參考，我們也嘗試採用光流(optical flow)技術來做運動估測，以期能找出序列影像時間之前後關連性。

子計畫四

在醫學界中，虹膜是一個被公認為具有獨特性的生物特徵。因此，在此子計畫中，我們欲利用虹膜的獨特性來進行身份確認的研究。利用虹膜進行身份確認的系統可分成四大模組：影像擷取模組、前處理模組、特徵萃取模組與型樣識別模組。

在本年度的研究中，我們先著手於虹膜影像的擷取部分。我們對目前文獻上的作法作了整理與參考，並且將先前我們所發展的第一代虹膜擷取設備做一改良，採用了紅外線濾鏡、微距鏡及環型偏光鏡等設備，因此可擷取到較佳的瞳孔與虹膜比例之影像。

子計畫五

在此子計畫中，我們結合視線簽名與動態虹膜資訊來進行身份確認的研究。在本年度中，我們完成下列幾項研究工作：(1)使用近紅外光所取得之影像來處理虹膜之

定位以及特徵之萃取。(2)利用立體追蹤系統來估測未戴眼鏡使用者的視線資訊。(3)採用 Gabor filter 來開發虹膜辨識技術。(4)發展以多張不同角度攝得之影像作虹膜辨識之方法。(5)開發 PTZ 攝影機之校正技術並以此來作為虹膜取像系統。

四、 未來的整合規劃

在目前的多重分類器實驗中，我們都是以同一種類的資料或生物特徵來進行方法效能之評估。且在實驗中，我們所提出之方法都有不錯的表現。在下一年度的整合規劃中，我們將開始整合各種不同種類的生物特徵資料，且依分類器層次整合與學習器層次整合兩大方向來進行，並比較此兩者之間的優劣。

在分類器層次的整合上，我們將對不同的生物特徵採用適當的分類器來進行身份確認，然後再嘗試使用各種線性與非線性的後處理方法來整合，並比較之。

而在學習器層次的整合上，我們將以各種不同的執行順序，在每一次的遞迴中使用不同的生物特徵來產生成員分類器，甚至採用隨機選取的方式來選擇每次遞迴中所欲著重的生物特徵，並比較這些不同選擇方法的結果優劣。同時，也將依各種不同生物特徵之本身獨特性以及可信度來輔助權重的調整，加入人類認知的觀念，將可信度高的或獨特性強的生物特徵的成員分類器提高其權重比，以使身份確認系統的判斷結果可以更貼近人類的真實認知與判斷。

最後，我們也將比較我們所提出之結合 Adaboost 與非線性後分類法(post-classification)與使用多成分類器的 meta-classification 方法之效能增益。

五、 計畫成果自評

此計畫乃為期三年的整合型計畫。在第一年度的計畫中，各子計畫均已分別利用靜態與動態的人臉與虹膜等生物特徵進行身份確認技術之研發。同時，總計畫也對多重分類器之效能做了相當深入的研究與改進之探討。我們期望此一有關多重分類器之基礎理論研究可以對未來在做多模式的生物特徵結合時有所裨益。藉由多模式的生物特徵結合，此一整合型計畫將可進一步提高身份確認之正確率，進而落實系統於實際應用與相關產業。

六、 參考文獻

[1] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*, Cambridge University Press, UK, 2000.

[2] R. P. W. Duin, "The Combining Classifier: To Train or Not to Train," *Proceedings of ICPR'2002*, Quebec, Canada, 2002.

[3] Y. Freund and R. E. Schapire, "A Decision-theoretic Generalization of On-line Learning and An Application to Boosting," *Journal of Computer and System Sciences*, 55(1), pp. 119-139, 1997.

[4] G. D. Guo and H. J. Zhang. "Boosting for Fast Face Recognition," *Proceedings of IEEE ICCV Workshop on Recognition, Analysis, and Tracking of Faces and Gestures in Real-Time Systems* (RATFG-RTS 2001), 2001.

[5] S. S. Keerthi and C. J. Lin, "Asymptotic Behavior of Support Vector Machine with Gaussian Kernel," *Neural Computation*, Vol. 15, pp. 1667-1689, 2003.

[6] S.Z. Li, Z.Q. Zhang and Harry Shum et al., "FloatBoost Learning for Classification," *Proceedings of the 16-th Annual Conference on Neural Information Processing Systems NIPS 2002*, Vancouver, Canada, 2002.

[7] G. Rätsch, T. Onoda and K. –R. Müller, "Soft Margins for AdaBoost," *Machine Learning* , Vol. 42, pp. 287-320, 2001.

[8] G. Rätsch, S. Mika, B. Schölkopf and K. –R. Müller, "Constructing Boosting Algorithms for SVMs: An Application to One-Class Classification," *IEEE Transactions on Pattern Analysis and Pattern Analysis*, Vol. 24, pp. 1184-1197, 2002.

[9] R. Schapire, "The Boosting Approach to Machine Learning, An Overview," *Proceedings of MSRI Workshop on Nonlinear Estimation and Classification*, 2002.

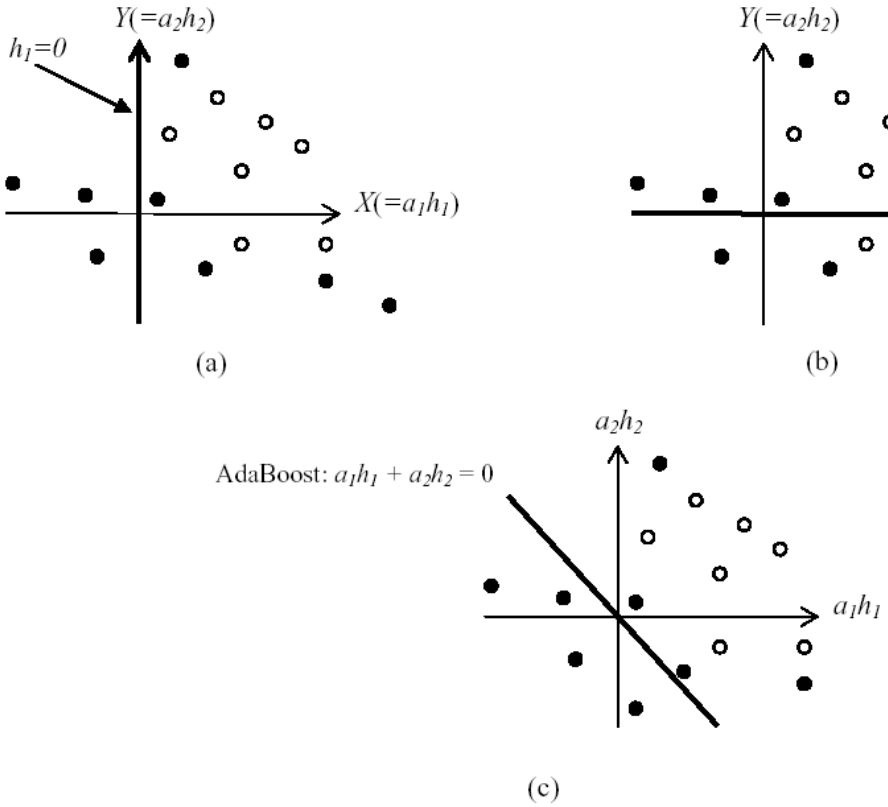

圖一、 AdaBoost之成員分類器和多重分類器與後分類器觀念之示意圖(T=2)。(a)弱分類器h_1可由一分界線為Y軸之後分類器來表示。(b)弱分類器h_2可由一分界線為X軸之後分類器來表示。(c)AdaBoost多重分類器可由一過原點且斜率為−1 之後分類器來表示。

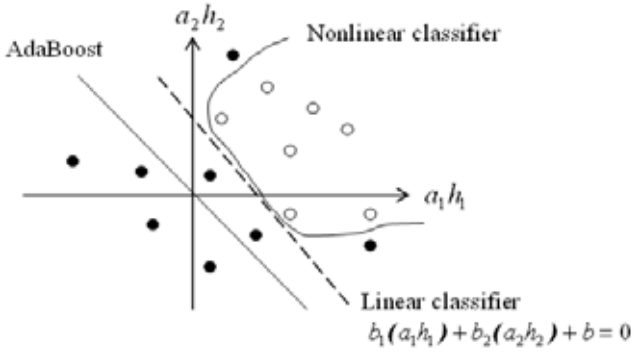

圖二、 線性與非線性分類器之分類邊界示意圖

表一、 學習器層次--以 RBF 為弱分類學習器之多重分類器 CV 正確率比較(%)

	AdaBoost (RBF+AdaBoost)	Nonlinear Boost (RBF+AdaBoost+SVM)
bupa	71.01 ± 5.423	74.20 ± 4.037
diabetis	74.74 ± 4.596	77.11 ± 1.785
ionosphere	84.86 ± 4.585	86.29 ± 4.199
sonar	91.71 ± 3.699	91.22 ± 4.253
splice	91.67 ± 1.254	92.43 ± 1.129
titanic	79.09 ± 4.166	79.18 ± 3.742
wdbc	95.22 ± 1.481	96.11 ± 1.200

表二、 學習器層次--以 SVM 為弱分類學習器之多重分類器 CV 正確率比較(%)

	SVM	AdaBoost (SVM+AdaBoost)	Nonlinear Boost (SVM+AdaBoost+SVM)
bupa	63.77 ± 3.55	63.77 ± 3.55	64.93 ± 3.14
diabetis	77.76 ± 3.80	77.89 ± 3.91	78.68 ± 3.15
ionosphere	92.88 ± 3.19	94.29 ± 2.02	96.00 ± 1.86
sonar	86.83 ± 9.38	86.83 ± 9.38	90.73 ± 4.36
splice	89.81 ± 1.48	91.61 ± 1.05	91.89 ± 0.82
titanic	79.05 ± 3.27	79.05 ± 3.27	79.05 ± 3.27
wdbc	94.16 ± 1.94	94.16 ± 1.94	95.58 ± 1.40

表三、 分類器層次--結合 RBF nets 與 QDC 之多重分類器正確率比較(%)

	RBF	QDC	RBF+QDC+SVM
bupa	73.38	59.12	73.53
diabetis	77.37	73.55	78.55
wdbc	96.79	94.46	96.96
splice	92.48	89.34	92.86
titanic	76.55	76.18	78.32

表四、 分類器層次--結合 FLDA 與 Kernel FLDA 之多重分類器正確率比較(%)

	FLDA	Kernel FLDA	FLDA+Kernel FLDA+SVM
AT&T	99.25	99.0	99.5
Yale	98.2	98.8	99.4