

行政院原子能委員會  
委託研究計畫研究報告

核能級控制器線上診斷機制研究

**Study on Online Diagnosis Mechanism for Nuclear-level Controllers**

計畫編號：1012001INER011

受委託機關(構)：中原大學

計畫主持人：劉益宏

聯絡電話：03-2654306

E-mail address：lyh@cycu.edu.tw

核研所聯絡人員：陳昌國

報告日期：101年12月5日

## 目 錄

目 錄 .....	I
中文摘要 .....	1
ABSTRACT.....	2
壹、計畫緣起與目的 .....	3
貳、研究方法與過程 .....	5
一、支持向量機 .....	5
二、支持向量描述 .....	11
參、主要發現與結論 .....	16
肆、參考文獻 .....	17

## 中文摘要

對於錯誤診斷而言，錯誤(異常)偵測是一個關鍵的前處理，其通常以一個二元分類的方式(正常與異常)來解決。儘管這個策略容易實踐，但會遭遇兩個關鍵的問題：由於大尺寸訓練資料集所導致的高計算複雜度、以及不平衡訓練集所導致的偏差分類精度。為了避免這些關鍵的問題，本論文提出了一個以單類別學習為基礎之新型錯誤偵測器：「保角核支持向量資料描述委員會」。此委員會由數個不同的保角核支持向量資料描述委員所構成，而每一個委員由不同的正常資料來訓練。所提出的「保角核支持向量資料描述委員會」可以改善支持向量資料描述的「擴充能力」，因此能夠明顯改善錯誤偵測的精度。本研究報告將有助於未來核能控制器之安全設計。

## **Abstract**

Fault detection is a crucial pre-stage for fault diagnosis, and often treated as a binary (normal and abnormal) classification problem. While this strategy is simple to implement, it suffers from high computational complexity and biased classification accuracy due to large-scale and imbalanced training set, respectively. To avoid these problems, we propose a one-class learning-based fault detector. The proposed fault detector improves generalization ability of the regular one-class classifier, the one-class SVM, thus enhancing the fault-detection accuracy.

## 壹、計畫緣起與目的

錯誤診斷通常都以一個二元(雙類別)分類的方式來處理，亦即正常與異常的分類。因此，過去常用的錯誤診斷器皆以二元分類器為主，像是支持向量機(support vector machine, SVM)以及類神經網路(neural networks)。然而，在設計錯誤診斷器時，常會面臨一個關鍵的問題，就是異常資料不足。當異常資料取得不易時，用來訓練錯誤診斷器的訓練資料將會很少，造成不具代表性的問題，基於不具代表性的訓練資料所訓練出來的二元分類器，在線上執行錯誤診斷時就會發生極大的誤差。因此，基於二元(雙類別)分類的錯誤診斷器可靠度下降，進而無法使用。

在本計畫為解決此關鍵問題，採用不同於以往基於二元分類的方式來進行錯誤診斷。本計畫採取的策略是單類別分類模式。

單類別分類器在過去幾年來已逐漸被重視，其主要用來解決傳統二元分類問題中單一類別訓練資料無法取得、或是取樣不足的問題。因此，單類別分類可應用至新穎偵測及離群偵測等問題。單類別分類器在訓練時，只需要單一類別的資料就可訓練分類器。近年來，已有幾種單類別分類器被提出，包括下列：

1. 單類別神經網路
2. 單類別支持向量機
3. 支持向量描述
4. 高斯混合模型
5. 核主成分分析

其中單類別支持向量機與支持向量描述皆為核方法，當此兩種方法中的核函數採用輻射基底函數時，這兩種方法的解是一樣的。近年來，單類別支持向量機已廣泛使用在各種不同的新穎偵測應用當中，並皆已得到不錯的結果。此外，高斯混合模型是一種基於資料密度所發展的機率模型，其可以輸出測試資料屬於目標類別的歸屬機率，使用者只要訂出機率門檻值，即可以判別該測試資料是否屬於目標類別。核主成分分析原來是用來當作特徵抽取及圖形壓縮的演算法，其為常用的主成分分析演算法的非線性版本。近年來，其被發現亦可當作單類別分類器。核主成分分析先將測試資料映射至高維的特徵空間當中，

在計算其重建錯誤值，此錯誤值若越大，代表其屬於目標類別的機率就越小。

在本計畫中，我們利用單類別分類器-支持向量描述設計一個錯誤診斷器，並與傳統的二元分類器支持向量機做比較。

## 貳、研究方法與過程

### 一、支持向量機

支持向量機是由 Vapnik 所發展的一種學習理論，屬於監督式學習理論的一種，並且主要是被發展用來進行資料分類、圖形識別之用，其基本想法是利用含兩個類別的訓練資料找出一個分離平面，該平面距離兩個類別中最近資料點的距離愈大，則對於未知的測試集合能夠產生愈小的分類錯誤率，故具有較好的擴充能力。以下我們將先依次介紹在支持向量機演算法中運用到的最佳化理論、最佳分離平面與如何建構最佳分離平面，其中最佳化理論包括初始最佳化問題(Primal Optimization Problem)、泛用拉哥朗君方程式、拉哥朗君對偶問題(Lagrangian Dual Problem)、肯塔克定理(Kuhn-Tucker Theory)。

#### ● 最佳化理論

已知  $f(w), g_i(w), i = 1, \dots, k$  與  $h_j(w), j = 1, \dots, m$  等函數定義於  $\Omega \subseteq \mathbb{R}^n$ ，則初始最佳化問題可寫成

$$\begin{aligned} \text{Minimize} \quad & f(w) & w \in \Omega \\ \text{Subject to} \quad & g_i(w) \leq 0 & i = 1, \dots, k \\ & h_j(w) = 0 & j = 1, \dots, m \end{aligned} \tag{1}$$

其中， $f(w)$  為目標函數(objective function)， $g_i(w)$  為不等式限制條件，而  $h_j(w)$  為等式限制條件。所有滿足(1)式之  $w$  所形成的集合稱為解空間(feasible region)，而最佳解  $w^*$  為全域最小，若且唯若，滿足  $f(w^*) \leq f(w)$ 。

Lagrangian 函數常被用來求目標函數的最佳解，其定義為目標函數加上

Lagrange 乘子(Lagrange multiplier)與限制條件的乘績，若初始最佳化問題為(1)

式則 Lagrangian 函數為(2)式

$$L(w, \alpha, \beta) = f(w) + \sum_{i=1}^k \alpha_i g_i(w) + \sum_{j=1}^m \beta_j h_j(w) \quad (2)$$

其中， $\alpha_i$  與  $\beta_j$  為 Lagrange 乘子。

初始最佳化問題可能因限制條件的原因而不易求解，但其對偶形式通常較容易求解，而且不易受到初始變數(primal variables)的限制，Lagrangian 對偶問題

$$\begin{aligned} \text{Maximize} \quad & \theta(\alpha, \beta) = \inf_w L(w, \alpha, \beta) \\ \text{Subject to} \quad & \alpha > 0 \end{aligned} \quad (3)$$

其中， $L(w, \alpha, \beta)$ 代表初始最佳化問題之 Lagrangian 函數。將初始最佳化問題轉換為其對偶形式需分成兩個步驟，首先求得原問題之 Lagrangian 函數，再令其對初始變數的導數為零，將所得之結果帶回原 Lagrangian 函數，便可以得到 Lagrangian 對偶問題。若初始最佳化問題為(3-44)式，其中  $f(w)$ 、 $g_i(w)$ 、 $h_j(w)$  皆為凸面函數(convex function)，則  $w^*$  為最佳解的充分且必要的條件是  $\alpha^*$ 、 $\beta^*$  的存在，而  $\alpha^*$ 、 $\beta^*$  滿足(4)式

$$\begin{aligned} \frac{\partial}{\partial w} L(w^*, \alpha^*, \beta^*) &= 0 \\ \frac{\partial}{\partial \beta} L(w^*, \alpha^*, \beta^*) &= 0 \\ \alpha_i^* g_i(w^*) &= 0 \quad i=1, \dots, k \\ g_i(w^*) &\leq 0 \quad i=1, \dots, k \\ \alpha_i^* &\geq 0 \quad i=1, \dots, k \end{aligned} \quad (4)$$



其中， $\alpha_i^* g_i(w^*) = 0$  又稱為肯塔克補充條件 (kuhn-Tucker complementarity condition)，以下簡稱 KT 條件式。其意函為 Lagrange 乘子與所對應的限制條件的乘積為零，當 Lagrange 乘子為零時，其對應的限制條件不為零；當限制條件為零時，Lagrange 乘子不為零。

SVM 演算法主要是利用訓練資料集合找出最佳的分離超平面。給定一個訓練資料集合  $\chi = \{(x_1, y_1), \dots, (x_l, y_l) : x_i \in \mathbb{R}^n, y_i \in \{-1, +1\}\}$ ， $i = 1, 2, \dots, l$ ，其中， $y_i$  為  $x_i$  之類別標記，若一分離超平面為  $\langle x, w \rangle + b = 0$  且滿足(5)式，則稱資料集合  $\chi$  具有可分離性。本論文中使用的內積(inner product)為點積(dot product)，即  $\langle x, x \rangle = x^T x$ 。

$$\begin{aligned} \langle x_i, w \rangle + b &> 0 & y_i &= +1 \\ \langle x_i, w \rangle + b &< 0 & y_i &= -1 \end{aligned} \quad (5)$$

其中， $w$  為權重向量， $b$  為偏移量。

考慮分類超平面  $\langle x, w \rangle + b = 0$  及訓練資料集合  $\chi = \{(x_i, y_i)\}$ ， $i = 1, 2, \dots, l$ ，則邊界限度  $\gamma_i(w, b)$  定義為(6)式，而最小邊界限度  $\gamma_x(w, b)$  定義為(7)式。

$$\gamma_i(w, b) = y_i (\langle x_i, w \rangle + b) \quad (6)$$

$$\gamma_x(w, b) = \min_{x_i \in \chi} \gamma_i(w, b)$$

$$\chi = \{x_1, x_2, \dots, x_l\} \quad (7)$$

假設權重向量  $w^*$  與偏移量  $b^*$  滿足(5)式，且將訓練集合  $\chi$  的最小邊界限度最大化，則由  $w^*$  與  $b^*$  所構成的分離超平面具有最大的邊界限度，稱為最佳分離超

平面，其定義如(8)式。最佳分離超平面除了具有最大邊界程度外，對於任一訓練資料集合而言，最佳分離超平面是唯一的。

$$(w^*, b^*) = \arg \max_{w, b} \gamma_\chi(w, b) \quad (8)$$

- 建構最佳分離超平面

最佳分離超平面依照不同的訓練資料會有不同的建構方式，本節將介紹當訓練資料為線性可分離、線性不可分離、非線性不可分離時，如何建構最佳分離超平面，其中，若訓練資料具有可分離性，可利用剛性邊界程度(Hard Margin)方式求解；反之若訓練資料中兩個類別的資料互相重疊，則須利用柔性邊界程度(Soft Margin)方式求解。

#### A. 線性可分離情形

當訓練資料是線性可分離的情形時，我們可使用剛性邊界程度的方式建構最佳分離平面。若一最佳化問題如(9)式：

$$\begin{aligned} & \text{Maximize} && \gamma_x(w, b) \\ & \text{Subject to} && \gamma_x(w, b) > 0, \end{aligned} \quad (9)$$

$$\chi = \{(x_1, y_1), \dots, (x_l, y_l), x_i \in \mathbb{R}^n, y_i \in \{+1, -1\}, i = 1, \dots, l\}$$

由於距離最佳分離平面最近的訓練資料點滿足(10)式

$$\begin{aligned} \langle x_i, w \rangle + b &= +1 && y_i = +1 \\ \langle x_i, w \rangle + b &= -1 && y_i = -1 \end{aligned} \quad (10)$$

因此其邊界限度  $\gamma(w^*, b^*)$  等於  $1/\|w\|$ ，故(9)式中的最大化問題等同於(11)式之最小化問題

$$\begin{aligned} \text{Minimize} \quad & \frac{1}{2}\|w\|^2 \\ \text{Subject to} \quad & \langle x_i, w \rangle + b \geq +1 \quad y_i = +1 \\ & \langle x_i, w \rangle + b \leq -1 \quad y_i = -1 \end{aligned} \quad (11)$$

接著我們運用 Lagrangian 理論來求此問題之最佳解，可以改為(12)式

$$y_i(\langle x_i, w \rangle + b) - 1 \geq 0 \quad i = 1, \dots, l. \quad (12)$$

故此問題之 Lagrangian 函數為(13)式

$$L_p(w, b, \alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^l \alpha_i [y_i(\langle x_i, w \rangle + b) - 1] \quad (13)$$

為了求出此問題之 Lagrangian 對偶問題，將(13)式分別對初始最佳化問題中之變數  $w$ 、 $b$  做偏微分並令其結果為零，可得(14)式

$$w = \sum_{i=1}^l \alpha_i y_i x_i \quad (14)$$

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (15)$$

將此二式帶回並整理後可得 Lagrangian 對偶問題，如(16)式所示，

$$L_D(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle \quad (16)$$

故此最佳化問題就可以轉為對偶形式，如(17)式

$$\text{Maximize} \quad L_D(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i^T x_j$$

$$\begin{aligned} \text{Subject to } \quad & \sum_{i=1}^l \alpha_i y_i = 0 & (17) \\ & \alpha_i \geq 0 \quad i = 1, \dots, l. \end{aligned}$$

此對偶形式為一個二次函數，我們只要解得 Lagrangian 對偶問題中的變數  $\alpha_i^*$ ，就可以求得最佳分離超平面中的權重向量，如(18)式

$$w^* = \sum_{i=1}^l \alpha_i^* y_i x_i \quad (18)$$

而此問題之 KT 條件式為(19)式

$$\alpha_i^* [y_i (\langle x_i, w^* \rangle + b^*) - 1] = 0 \quad i = 1, \dots, l. \quad (19)$$

若資料點其 Lagrangian 乘子比大於零，故(19)式可簡化成(20)式

$$y_i (\langle x_i, w^* \rangle + b^*) - 1 = 0 \quad (20)$$

這些資料點稱為支持向量，可以用來求此最佳化分離超平面的權重向量  $w^*$  與偏移量  $b^*$ ，如(21)式所示

$$\begin{aligned} w^* &= \sum_{i=1}^{N_S} \alpha_i^* y_i x_i^{SV} \\ b^* &= \frac{1}{N_S} \sum_{i=1}^{N_S} \left( \frac{1}{y_i} - \langle x_i^{SV}, w^* \rangle \right) \end{aligned} \quad (21)$$

其中，有上標 SV 的  $x_i$  代表其為支持向量， $N_S$  代表支持向量的個數。最後，對於測試資料  $x$  而言，可用求得之最佳分離超平面對其進行分類，其決策函數為(22)式

$$f(x) = \text{sign} \left( \sum_{i=1}^{N_S} \alpha_i^* y_i \langle x_i^{SV}, x \rangle + b^* \right) \quad (22)$$

## 二、支持向量描述

當一個包含個資料的資料集合(目標類別資料集合)  $\{x_i, i = 1, \dots, N\}$  需要被描述，支持向量描述試著去找到能包含所有(或是多數)資料且擁有最小體積的超球體，但是，如果要包含少數較偏離的訓練資料，這個超球體將會變大且不能將資料表示的很精準，所以，我們允許一些較偏離的資料在這個超球體之外，於是，引入鬆弛變數  $\xi_i$ 。

### 線性支持向量資料描述

為了描述一個中心為  $a$ ，半徑為  $R$  的超球體，我們試著最小化半徑

$$F(R, a, \xi_i) = R^2 + C \sum_{i=1}^N \xi_i \quad (23)$$

其中， $F$  是先前問題， $C$  是資料的錯誤權重值(會影響超球體的體積或是目標類別被捨棄的個數)， $\xi_i$  是落在超球體表面外的資料到超球體表面之距離。而最小化(23)式的限制條件為(24)式：

$$\begin{aligned} \|x_i - a\|^2 &\leq R^2 + \xi_i \\ \xi_i &\geq 0 \quad i = 1, \dots, N \end{aligned} \quad (24)$$

為了解決上述的拘束型最佳化問題，於是建構 Lagrangian( $L$ )：

$$L(R, a, \xi_i, \alpha_i, \beta_i) = R^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \alpha_i (R^2 + \xi_i - \|x_i - a\|^2) - \sum_{i=1}^N \beta_i \xi_i \quad (25)$$

$$\frac{\partial L}{\partial R} = 0 \Rightarrow \sum_{i=1}^N \alpha_i = 1 \quad (26)$$

$$\frac{\partial L}{\partial a} = 0 \Rightarrow a = \sum_{i=1}^N \alpha_i x_i \quad (27)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \Rightarrow C - \alpha_i - \beta_i = 0 \quad (28)$$

於是，先前問題的對偶問題為最大化(29)式：

$$L = \sum_{i=1}^N \alpha_i (x_i \cdot x_i) - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j (x_i \cdot x_j) \quad (29)$$

限制條件如下

$$\begin{aligned} \sum_{i=1}^N \alpha_i &= 1 \\ 0 \leq \alpha_i &\leq C \quad i = 1, \dots, N \end{aligned} \quad (30)$$

我們可以發現，超球體的中心  $a$  是資料點的線性組合，而擁有非零的  $\alpha$  值的資料點稱為支持向量，半徑  $R$  由符合  $0 < \alpha_i < C$  的資料點求得。對於目標類別的訓練資料而言，當  $\alpha_i = 0$  時，資料點落在超球體邊界之內，判定接受；當  $0 < \alpha_i < C$  時，資料點落在超球體邊界上，判定接受； $\alpha_i = C$  時，資料點落於超球體邊界之外，為不被接受的資料點，稱做被捨棄的目標類別資料。

決定一個新的測試資料  $z$  是否在超球體中，是去計算它與超球體中心  $a$  的距離，當它與  $a$  的距離小於超球體半徑  $R$ ，即  $(z-a)^T(z-a) \leq R^2$ ，則  $z$  被判為落在超球體內。

### 非線性支持向量資料描述

當原始資料在輸入空間的分佈不為球狀時(即使一些離群值已經忽略)，我們無法由此方法找到適合且嚴謹的資料描述，於是引入核心函數  $K$ ，兩資料向量在特徵空間的內積  $(x_i \cdot x_j)$  可以被  $K(x_i, x_j)$  所取代，即  $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ ，於是先前問題的限制條件變為(31)式：

$$\begin{aligned} \|\Phi(x_i) - a\|^2 &\leq R^2 + \xi_i \\ \xi_i &\geq 0 \quad i = 1, \dots, N \end{aligned} \quad (31)$$

接著建構 Lagrangian

$$L(R, a, \xi_i, \alpha_i, \beta_i) = R^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \alpha_i (R^2 + \xi_i - \|\Phi(x_i) - a\|^2) - \sum_{i=1}^N \beta_i \xi_i \quad (32)$$

相同地，將(32)式對變數做偏微分並令其為零：

$$\frac{\partial L}{\partial R} = 0 \Rightarrow \sum_{i=1}^N \alpha_i = 1 \quad (33)$$

$$\frac{\partial L}{\partial a} = 0 \Rightarrow a = \sum_{i=1}^N \alpha_i \Phi(x_i) \quad (34)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \Rightarrow C - \alpha_i - \beta_i = 0 \quad (35)$$

於是，原非線性問題的對偶問題為最大化(36)式：

$$L = \sum_{i=1}^N \alpha_i K(x_i \cdot x_i) - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(x_i \cdot x_j) \quad (36)$$

限制條件為(37)式：

$$\begin{aligned} \sum_{i=1}^N \alpha_i &= 1 \\ 0 \leq \alpha_i &\leq C \quad i = 1, \dots, N \end{aligned} \quad (37)$$

由於不同的核心函數  $K$  會在原輸入空間得到不同的描述邊界，所以問題在於找到最適合的核心函數。接下來討論兩種核心函數：多項式核心函數與幅射基底函數。

- 核函數

多項式核函數為(38)式：

$$k(x_i, x_j) = (x_i \cdot x_j + 1)^d \quad (38)$$

其中，自由變數為多項式核函數的次方項。由提高  $d$  值，可將資料由原輸入空

間映射至高維度的特徵空間，例如，一個 2 維向量  $(x_1, x_2)$  可以被 ( $d = 2$  時) 多項式核心函數映射至  $(x_1, x_2, x_1x_2, x_1^2, x_2^2)$  特徵空間。但是，這個核心函數通常不能夠得到理想的資料描述，使用不同的值會得到不同的資料描述，當  $d$  值越大時，資料描述的空間會過於稀疏，且當輸入空間中的資料必須有更多被這個資料描述接受時，描述的結果在原輸入的二維空間中將變成一個更大而稀疏的超球體，這樣無法達到理想的結果。為了抑制超球體在更大的空間中的增長，下面介紹更合適的核函數。

輻射基底函數核函數為(4-28)式：

$$K_G(x_i, x_j) = \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (39)$$

於是，(39)式變成(40)式：

$$L = 1 - \sum_{i=1}^N \alpha_i^2 - \sum_{i \neq j} \alpha_i \alpha_j K_G(x_i, x_j) \quad (40)$$

於是，一個新的測試資料  $z$  可以被接受的情況為

$$1 + C_x - 2 \sum_{i=1}^N \alpha_i K_G(z, x_i) \leq R^2 \quad (41)$$

其中， $C_x = \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K_G(x_i, x_j)$ ，其中  $C_x$  只跟支持向量與  $\alpha_i$  有關。

我們可以導出(41)式的兩種極端解，一種是當  $\sigma$  極小時的解，一種是當  $\sigma$  極大時的解。當  $\sigma$  極小時， $K_G(x_i, x_j) \cong 0, i \neq j$  則  $L = 1 - \sum_{i=1}^N \alpha_i^2$ ，當  $\alpha_i = 1/N$  時可以被最大化，此時  $L = 1 - 1/N$ ，所有的  $x_i$  皆為支持向量，且  $x_i$  與球心的距離為  $1 - 1/N$ ，且近似 Parzen density estimation 方法。當某一  $\alpha_i = 1$ ，而其它所有  $\alpha_i = 0$  時可以被最大化，此時所有與球心的距離為 0。但是，這個無限大的球體無法



得到，因為實際的  $\alpha$  值不足以大到使得所有  $(i, j)$  組合皆得到相同的  $K_G(x_i, x_j)$  值。基於上述的分析，加上限制條件  $\sum_{i=1}^N \alpha_i = 1$  與  $0 \leq \alpha_i \leq C$ ，必須挑選符合  $1/N \leq C \leq 1$  的  $C$  值。

### 參、主要發現與結論

為了驗證單類別分類器之錯誤診斷器性能，本計畫利用擴展 MIT 人臉資料集合來進行實驗。此資料集包含了一個訓練資料集、及一個測試資料集。訓練資料集有 489410 筆資料，其中 17497 為人臉資料、471913 為非人臉資料；測試資料集有 471 筆人臉資料及 23574 筆非人臉資料。每一筆資料皆為 361 維的向量。我們比較支持向量機及支持向量描述的結果，如表一所示，其中 N 為人臉訓練資料數目、M 為非人臉訓練資料數目。

表一 支持向量機與支持向量描述之錯誤率比較 (%)

	N=1000, M=1000	N=1000, M=2000
支持向量機	19.4	14.2
支持向量描述	13.8	13.4

由結果可知，支持向量描述的錯誤率皆比支持向量機小，而且當非人臉訓練資料數目越少時，支持向量描述表現更好，這主要是因為支持向量機需要兩個類別的訓練資料，而當非人臉訓練資料數目越少時，非人臉的類別愈不具代表性，因此，支持向量機的錯誤率就愈高。相反的，支持向量描述的錯誤率較不受非人臉訓練資料數目的影響，原因在於其訓練實僅需要人臉訓練資料，因此，不論非人臉訓練資料是否具有代表性，支持向量描述的性能皆不受影響，進而維持一定的水平。

本實驗結果顯示，相較於傳統的二元分類錯誤診斷器，本計畫提出的單類別分類錯誤診斷方式可達到較佳的結果。此外，因為單類別分類在訓練時，不需要異常情形的資料，因此，單類別分類錯誤診斷方式不但可以達到較高的診斷率，也可以大幅縮短事前在資料收集的時間，進而縮短整個離線的訓練時間。

本計畫初步探討了單類別分類器在錯誤診斷的應用，並證實了其可行性。未來，將進一步比較支持向量描述與其他單類別分類器在錯誤診斷的性能，包括了如前所述的單類別神經網路、單類別支持向量機、高斯混合模型、及核主成分分析等。

## 肆、參考文獻

1. V. Venkatasubramanian, R. Rengaswamy, K. Yin, and S. N. Kavuri, "A review of process fault detection and diagnosis Part I: quantitative model-based methods," *Computers and Chemical Engineering*, vol. 27, pp. 293-311, 2003.
2. I. Hwang, "A survey of fault detection, isolation, and reconfiguration methods," *IEEE Transactions on Control Systems Technology*, vol. 18, pp. 636-653, 2010.
3. Simon Haykin, *Neural Networks: A Comprehensive Foundation*, Second Edition, Prentice-Hall, 1999.
4. C. W. Hsu and C. J. Lin, "A comparison of methods for multiclass support vector machines," *IEEE Transactions on Neural Networks*. Vol. 13, No. 2, pp. 415-425, 2002.
5. Tax and Duin, "Data domain description using support vectors," in *proceedings of European Symposium on Artificial Neural Networks*, Bruges (Belgium), 21-23 April 1999, D-Facto public., ISBN 2-600049-9-X, pp. 251-256.