

# 融合影像及數值資訊於多目標追蹤系統

黃聖強 吳承翰  
國立彰化師範大學 國立彰化師範大學  
電機工程系 電機工程系  
m97622005@ mail.ncue.edu.tw m97622020@ mail.ncue.edu.tw

蘇進東 鍾翼能  
大葉大學 國立彰化師範大學  
電機工程系 電機工程系  
disdong9616@ ynhchung@  
yahoo.com.tw cc.ncue.edu.tw

## 摘要

在多目標追蹤(Multiple-Target Tracking, MTT)系統中,資料相關結合技術為判定雷達量測訊號與既存目標關係的重要關鍵。本文提出運用競爭式類神經網路(Competitive Hopfield Neural Network, CHNN)資料相關結合技術,追蹤多個變速度的目標;擷取其特殊的運算架構,有效改善傳統神經網路於資料相關結合時,產生不合理的解。並應用影像處理技術,將獲得的影像經影像處理程序,取得其中的特徵數值資訊,提供至追蹤系統,加強其追蹤目標的強度,使得量測訊號與目標能有更好的匹配。經模擬結果顯示,本文提出的方法能有效的解決在複雜的環境中資料相關結合技術的問題。

**關鍵字:** 影像及數值資訊、競爭式類神經網路、資料相關結合技術、變速度追蹤

## Abstract

The data association technique which will determine the correlation between measurements and existing targets plays an important role in Multiple-Target Tracking (MTT) systems. In this paper, we apply a data association technique based on Competitive Hopfield Neural Network (CHNN) for multiple-maneuvering target tracking. The basic concept of this approach is extracting its particular operation structure that reforms tradition Neural Network occasional irrational solutions efficiently. In order to enhance the tracking performance, we design one image processing flow diagram to obtain numerical information to tracking system. The computer simulation results indicate that the proposed approach can solve the data association problems efficiently under complex conditions.

**Keywords:** Image processing, Data association, Competitive Hopfield Neural Network

## 1. 簡介

隨著航空科技的發達,雷達追蹤系統不論是應用於軍事或是民用,都已是現今社會不可或缺的重要技術。在複雜的多目標追蹤(Multiple-Targets Tracking, MTT)環境中,如何有效的掌握目標的真實軌跡,是追蹤系統(Tracking System)效能好壞的重要依據,其中以資料相關結合技術(Data Association Technique)與變速度(Maneuvering)的檢測最為關鍵。感測器接收到量測資訊,時常夾帶許多雜訊,造成追蹤系統錯誤的判斷,所以要如何排除雜訊的干擾及正確判斷感測器接收之量測訊號與既存目標軌跡的關係為本研究之重點。另一方面,由於雷達無法直接量測目標的加速度,目標突然的加速,造成追蹤系統在運算上的誤差,若系統參數即時不加以修正,誤差會逐漸擴大,最後導致追蹤失敗。因此,變速度(Maneuvering)檢測技術[1-2]也是雷達追蹤中重要的一個環節。

過去學者針對資料相關結合技術提出許多的演算法,如應用於高度雜訊的環境的JPDA(Joint-Probabilistic Data Association)[3-4]理論; One-Step Conditional Maximum Likelihood 理論[5-6];具有學習能力及最佳化運算之運算能力的 Hopfield Neural Network[7-8];其將權重值輸入每個神經元,神經元會更新使能量函數收斂,能量函數收斂最後的狀態可得資料結合的結果。然而,此法困難在於目標數與限制因素權重值的決定,導致不正確的資料結合。而後,學者提出運用競爭性類神經網路 Competitive Hopfield Neural

Network(CHNN)[9-10]，解決權重值於網路的負擔。基於上述，本研究運用 CHNN 資料相關結合技術融合影像數值資訊演算法於追蹤系統，並以適應性追蹤架構輔助，達到最佳的追蹤效果並同時解決資料相關結合及目標變速時的問題。

## 2. 動態系統模型

根據追蹤位置，在移動目標中可由卡門濾波器之理論定義出狀態變數方程式如下：

$$X(k+1) = F(k)X(k) + G(k)U(k) + W(k) \quad (1)$$

$$Z(k) = H(k)X(k) + V(k) \quad (2)$$

其中

$X(k)$ ：系統狀態向量(State Vector)

$Z(k)$ ：系統量測向量(Measurement Vector)

$F(k)$ ：系統轉移矩陣(State Transition Matrix)

$G(k)$ ：輸入控制矩陣(Control Matrix)

$U(k)$ ：變速度控制因子(Control Factor)

$H(k)$ ：量測矩陣(Measurement Matrix)

$W(k)$ ：系統輸入狀態雜訊(State Noise)

$V(k)$ ：系統輸出量測雜訊(Measurement Noise)

$X(k)$ ，代表時間  $k$  時，系統的狀態向量。 $W(k)$ 、 $V(k)$  為期望值零平均高斯分佈的白雜訊 (Zero mean, Gaussian white noise)，分別有變異數矩陣 (Covariance matrix)， $Q(k)$  和  $R(k)$ ，兩雜訊間互相獨立。

其中  $W(k)$  之變異數矩陣 (Covariance matrix)  $Q(k)$  可表示為：

$$E[W(i)W^T(j)] = \begin{cases} Q_i(k), & i = j \\ 0, & i \neq j \end{cases} \quad (3)$$

其中  $V(k)$  之變異數矩陣 (Covariance matrix)  $R(k)$  可表示為：

$$E[V(i)V^T(j)] = \begin{cases} R_j(k), & i = j \\ 0, & i \neq j \end{cases} \quad (4)$$

目標的初始狀態假設為高斯分佈平均向量  $\hat{X}(0|0)$  及共變異數矩陣  $P(0|0)$ 。在真實的情況中，可由感測器提供大量接近目標的量測訊號以確定任何目標的軌跡估測值，其要正確地計算符合目標之封閉空間的量測訊號是相當不容易的。因此，在資料相關結合技術中，如何在多目標追蹤及結合量測向量  $Z(k)$  至已存在的動態追蹤模型，值得好好探討。為解決此問題，本文應用卡門濾波器遞迴運算的特性，方程式推導如下：

$$\hat{X}(k|k) = \hat{X}(k|k-1) + K(k) \left[ Z(k) - h \left( \hat{X}(k|k-1) \right) \right] \quad (5)$$

$$\hat{X}(k+1|k) = F(k) \hat{X}(k|k) \quad (6)$$

$$K(k) = P(k|k-1) H(k)^T S(k)^{-1} \quad (7)$$

$$S(k) = H(k) P(k|k-1) H(k)^T + R(k) \quad (8)$$

$$P(k|k) = P(k|k-1) - K(k) H(k) P(k|k-1) \quad (9)$$

$$P(k+1|k) = F(k) P(k|k) F(k)^T + G(k) Q(k) G(k)^T \quad (10)$$


所以，當新的量測訊號  $Z(k)$  被接收時，透過先前預估  $\hat{X}(k-1|k-1)$  及其變異數矩陣的資料，可預估下一步的狀態，因此新的狀態  $\hat{X}(k|k)$  與變異數矩陣  $P(k|k)$  便獲得更新。

## 3. 影像處理

將獲得的原始影像藉由影像處理技術進行前處理，擷取其特徵的數值資訊加以分析應用，處理流程如圖一所示。一張 RGB 彩色影像 (Color Image) 是一個色彩像素 (Color Pixels) 的  $M \times N \times 3$  的陣列，其中每一個色彩像素含有紅、綠、藍成分之三合一的點，對應到彩色影像，也就是說一張 RGB 的影像可視為三張灰

階影像的堆疊。將原始影像進行灰階轉換，可將影像的資料量減少為原來的三分之一，提升運算的效率。對影像上的每個像素及其鄰域像素與一個對應的係數相乘的總和為影像上該像素新的響應，若鄰域為  $m \times n$ ，則需要  $m \times n$  個係數，將其對應係數排列為陣列，我們稱之為遮罩(Mask)、濾波器(Filter)或窗(Window)等，圖二為低通濾波器之範例。遮罩的大小為  $(2n+1) \times (2n+1)$ ， $n$  為正整數，使用濾波器可淡化影像中的雜訊，使影像較為平滑，但會造成邊緣或線條特性模糊。影像分割運用臨界值法，因其具有直覺上的特性及實現的便利性。欲從影像中分割出其中物體，則可設定一臨界值  $T$ ，即可達到此目的。定義影像中每一像素  $f(x, y) \geq T$ ，稱之為物體點(Object Point)，反之稱為背景點(Background Point)，表示為(11)[12]。影像分割的結果如圖三。

$$g(x, y) = \begin{cases} 1, & f(x, y) \geq T \\ 0, & f(x, y) < T \end{cases} \quad (11)$$



圖一 影像處理流程

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

圖二 3\*3 低通濾波器遮罩



圖三 臨界值法獲得之影像

影像辨識部分運用樣板比對(Template Matching)，以一個樣板影像與比對影像，計算出兩者圖案的交互相關性係數(Cross-Correlation Coefficient)，其計算公式如(12)[11]所示。樣板比對法對影像中每個像素逐一做比對；比對影像或物件，因旋轉、縮放或平移，會影響匹配度的精確性，因此，需將比對影像進行座標轉換的處理後再加以比對，才能得到高度的匹配。

$$R_{TS} = \frac{\sum_{i=0}^{K-1} (T_i - m_T)(S_i - m_S)}{\sqrt{\sum_{i=0}^{K-1} (T_i - m_T)^2} \sqrt{\sum_{i=0}^{K-1} (S_i - m_S)^2}} \quad (12)$$

其中

$R_{TS}$ =交互相關性係數(Cross-Correlation Coefficient)

$T_i$ ：樣板影像第  $i$  點

$S_i$ ：比對影像第  $i$  點

$m_T$ ：樣板影像像素平均值


$m_S$ ：比對影像像素平均值

#### 4. 資料結合技術

資料結合技術在多目標追蹤環境中是判斷感測器接收量測資訊與既存目標之軌跡關係的核心技術，然而感測器時常因複雜的外在環境及雜訊的干擾，含其它的量測訊號，造成錯誤的資料結合。本文提出的 CHNN 資料相關結合技術能有效提升系統判斷量測訊號與既存目標的準確性，如下所述：

首先定義 Hopfield Neural Network，其為二維的二值神經網路。假設網路由  $n * m$  相互連結的神經元組成， $V_{x,i}$  為神經元  $(x,i)$  的狀態， $T_{x,y,j}$  為連結神經元  $(y,j)$  與神經元  $(x,i)$  間之權

重值(Weights)，如圖四所示。



圖四 網路架構中，預估目標與量測訊號示意圖

在網路中，從神經元 \$(y, j)\$ 輸入至神經元 \$(x, i)\$ 的權重為 \$T\_{x,i;y,j}\$、\$V\_{y,j}\$ 及輸入偏權值 \$I\_{x,i}\$，如圖四所示，神經元 \$(x, i)\$ 之方程式為

$$U_{x,i} = \sum_{j=1}^m T_{x,i;y,j} V_{y,j} + I_{x,i} \quad (13)$$

其中，\$V\_{x,j}\$ 狀態為

$$V_{x,j} = \frac{1}{2} (\text{sign}(U_{x,i}) + 1) \quad (14)$$

提供非同步的網路更新，二維的 Hopfield Neural Network 的 Lyapunov function[] 穩定度為

$$E = - \sum_{x=1}^n \sum_{y=1}^n \sum_{i=1}^m \sum_{j=1}^m T_{x,i;y,j} V_{x,i} V_{y,j} - 2 \sum_{x=1}^n \sum_{i=1}^m I_{x,i} V_{x,i} \quad (15)$$

每次的更新，使函數值降低，而更新的次數直到函數收斂至穩定。


假設 \$V\_{x,j}\$ 為 \$x\$-th 雷達量測值和 \$i\$-th 目標之狀態結合，其中“1”和“0”表示結合與未結合，所以可定義能量函數 \$E\$ 為

$$E = A \sum_{x=1}^n \sum_{i=1}^m d_{x,i} V_{x,i} + B \sum_{x=1}^n \sum_{y=1}^n \sum_{i=1}^m \sum_{j=1}^m V_{x,i} V_{y,j} \delta_{x,i} + C \sum_{i=1}^m \left( \sum_{x=1}^n V_{x,i} - 1 \right) + D \sum_{x=1}^n \sum_{i=1}^m F_{x,i} V_{x,i} \quad (16)$$

其中，\$\delta\_{x,i}\$ 為 Kronecker delta function。

(16) 式中，第一項表示已結合的雷達目標與量測訊號的距離總和，\$d\_{x,i}\$ 表示 \$x\$-th 量測值和 \$i\$-th 目標間的距離。需考慮若沒有量測訊號落入 Gate 時，則先前的目標資訊應被當作輸入下個目標的參考資訊。為完成此目的，讓 \$m\$ 個目

標被包含在量測訊號裡，假設有 \$m\$ 個目標，則新獲得的量測訊號為 \$n - m\$ 個，且 \$m\$ 個目標排列於 \$n - m\$ 個量測訊號前，如圖五所示。



圖五 目標與量測訊號排列示意圖

$$d_{x,i} = \begin{cases} [\tau^T(k) S(k)^{-1} \tau(k)]^{1/2} & \text{if } x \neq i \text{ and } x > m \\ \infty & \text{if } x \neq i \text{ and } 1 \leq x \leq m \\ \lambda & \text{if } x = i \end{cases} \quad (17)$$

由(17)式定義 \$d\_{x,i}\$，\$d\_{x,i}\$ 為 Mahalanobis Distance，可由量測訊號的創新量及共變異數矩陣計算獲得。當 \$x=i\$ 時，則 \$d\_{x,i} = \lambda\$，\$\lambda\$ 為 Gate 的半徑，因此量測訊號落入 Gate 時，量測訊號中將有一個被選擇，但若沒有量測訊號落入 Gate，目標將選擇自己當量測訊號。當 \$x \neq i\$ 且 \$1 \leq x \leq m\$，為不讓目標選擇其它目標為量測訊號，故定義 \$d\_{x,i} = \infty\$。其中創新量 (Innovation) \$\tau(k) = Z(k) - H(k) \hat{X}(k|k-1)\$，\$S(k)\$ 為創新量 (\$\tau(k)\$) 之共變異數矩陣 (Covariance Matrix)。

(16) 式中第二項為每一個量測訊號只能與一個目標做結合。第三項為每一個目標物只能擁有一個已結合之量測值。第四項中，\$F\_{x,i}\$ 為影像相關係數。指每一個已結合的量測值，則有一影像數值資訊補償。參數 \$A\$、\$B\$、\$C\$、\$D\$ 在能量函數是相當重要的，卻也難以決定適當的值，且相當依賴目標數、目標與量測訊號的距離。因此，若設定不適當，最終導致傳統的 Hopfield Neural Network 不合理的結果[8]。為降低其於整個網路的負擔及簡化計算過程，將使用 Winner-take-all 競爭式更新函數為

$$V_{x,i} = \begin{cases} 1, & \text{if } U_{x,i} = \max \{U_{1,i} \cdots U_{n,i}\} \\ 0, & \text{otherwise} \end{cases} \quad (18)$$

依此更新法則，將強制每一個目標與一個量測訊號做結合，所以(16)式中的第三項將被自動消除。其簡化後方程式如下

$$E = \sum_{x=1}^n \sum_{i=1}^m (A d_{x,i} + D F_{x,i}) V_{x,i} + B \sum_{x=1}^n \sum_{y=1}^n \sum_{i=1}^m \sum_{j=1}^m V_{x,i} V_{y,j} \delta_{x,y} \quad (19)$$

比較(15)式與(19)式，可發現

$$I_{x,i} = \frac{A d_{x,i} + D F_{x,i}}{-2} \quad (20)$$

$$T_{x,i,y,j} = -B \delta_{x,y} \quad (21)$$

將(20)式與(21)式代入(13)式，其結果為

$$U_{x,i} = -\sum_{j=1}^m B V_{x,j} - \frac{A d_{x,i} + D F_{x,i}}{2} \quad (22)$$

經以上之推導，此網路的能量函數不斷循環運算至收斂穩定，最終可得一組最佳量測訊號之組合，提供感測器估測之參考值，以進行下一階段之運算。

## 5. 變速度追蹤

雷達追蹤系統無法量測目標的加速度，當目標突然加速，會造成系統運算上的誤差，若即時不加以修正系統參數，誤差會逐漸擴大，造成追蹤失敗，所以變速度的檢測及加速度預估的演算法是必要的。變速度檢測利用目標的統計創新量，建立一個變速度偵測法則，判斷目標物是否有作變速度運動，若有作變速度運動時，可利用適應性程序修正卡門濾波器的參數，定義如下：

$$|\tau_i(k)| \leq \left| D \sqrt{S_{ii}(k)} \right|, \quad \text{for all } i \quad (23)$$

其中下標  $i$  指創新量  $\tau_i(k)$  第  $i$  個元素， $D$  為高斯機率密度函數的相關常數，可由高斯分佈查表可得。偵測機率為 0.682 時， $D=1$ ；偵測機率為 0.954 時， $D=2$ ；偵測機率為 0.998 時，

$D=3$ ； $S_{ii}(k)$  表示共變異數矩陣(Covariance Matrix)中第  $i$  行、第  $i$  列之對角元素。若(23)式中  $|\tau_i(k)| > \left| D \sqrt{S_{ii}(k)} \right|$ ，判定目標發生變速度，則利用下式修正之：

$$\tau^2(k) \{a_i(k) \delta_{ii}(k) + R_{ii}(k)\}^{-1} = D^2 \quad (24)$$

$a_i(k)$  可由上式推導得到

$$a_i(k) = \frac{[\tau_i(k)/D]^2 - R_{ii}(k)}{\delta_{ii}(k)} \quad (25)$$

為了使目標追蹤能維持正常，且減少追蹤誤差，預測誤差之變異數矩陣  $P(k|k-1)$  必需修正為  $[a_{\max}(k) * P(k|k-1)]$ ，這  $a_{\max}(k)$  為  $a_i(k)$  中之最大值。

運用此方法，對於目標突然的變速度，卡門增益會適時修正，使追蹤濾波器能有較快的反應速度。因此，可獲得較佳的追蹤效果。

## 6. 模擬結果

為了驗證本文提出演算法能有效改善追蹤的誤差及提高追蹤的準確度，故以 MATLAB 軟體模擬追蹤單目標及多目標並分析其結果。量測雜訊以隨機亂數產生器模擬高斯白雜訊(Gaussian White Noise)；系統位置雜訊標準差為 20m，量測位置雜訊標準差為 200m。常數  $A$ 、 $B$ 、 $D$  設定為： $A=1$ ， $B=L+1$ ， $L$  為 Gate 的半徑， $D=100$ 。程式執行 100 次 Monte Carlo runs。並以三種演算法比較其模擬追蹤結果，三種演算法分別如下：

演算法一：本文提出的方法。

演算法二：CHNN 與適應性程序。

演算法三：卡門濾波器與適應性程序。

單目標追蹤：

表一、表二為單目標初始位置和變速度區間設定。模擬結果之目標軌跡圖如圖六至八所示。表三為各種演算法結果比較。

雙目標追蹤：

表四、表五為雙目標初始位置和變速度區間設定。模擬結果之目標軌跡圖如圖九至十一所示。表六為各種演算法結果比較。


由模擬結果可以證實，本文提出的方法加入影像處理獲得的數值資訊補償追蹤系統，在位置誤差有明顯的改善，也獲得較佳的追蹤結果。

表一 單目標追蹤的初始位置

	$x(m)$	$\dot{x}(m/s)$	$y(m)$	$\dot{y}(m/s)$
Target	1000	200	9000	250

表二 單目標追蹤變速度區間設定

step	25-45step		60-80step		others	
加速度	$a(x)$ ( $m/s^2$ )	$a(y)$ ( $m/s^2$ )	$a(x)$ ( $m/s^2$ )	$a(y)$ ( $m/s^2$ )	$a(x)$ ( $m/s^2$ )	$a(y)$ ( $m/s^2$ )
Target	30	-30	-30	30	0	0



圖八 演算法三的單目標追蹤軌跡

表三 單目標追蹤結果比較


	位置誤差 (m,rms)	速度誤差 (m/s,rms)
演算法一	98.0313	27.2882
演算法二	122.9065	23.7867
演算法三	150.1198	37.7331

表四 雙目標追蹤的初始位置


	$x(m)$	$\dot{x}(m/s)$	$y(m)$	$\dot{y}(m/s)$
Target1	1000	200	9000	-250
Target2	1000	200	5000	250

表五 雙目標追蹤變速度區間設定


step	25-45step		60-80step		others	
加速度	$a(x)$ ( $m/s^2$ )	$a(y)$ ( $m/s^2$ )	$a(x)$ ( $m/s^2$ )	$a(y)$ ( $m/s^2$ )	$a(x)$ ( $m/s^2$ )	$a(y)$ ( $m/s^2$ )
Target1	30	-30	-30	30	0	0
Target2	30	30	-30	-30	0	0



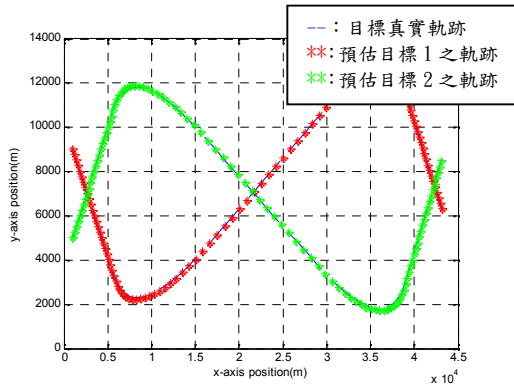
圖六 演算法一的單目標追蹤軌跡




圖七 演算法二的單目標追蹤軌跡



圖九 演算法一的雙目標追蹤軌跡



圖十 演算法二的雙目標追蹤軌跡



圖十一 演算法三的雙目標追蹤軌跡

表六 雙目標追蹤結果比較

		位置誤差 (m,rms)	速度誤差 (m/s,rms)
演算法一	Target1	95.2948	25.9338
	Target2	93.2181	25.9644
演算法二	Target1	119.9430	24.9031
	Target2	118.0023	25.1190
演算法三	Target1	155.8445	32.7016
	Target2	157.0553	32.5849

## 7. 結論

本文提出融合影像及數值資訊於多目標追蹤系統，此演算法的優點為在雷達量測訊號和目標軌跡間能夠選擇最佳關聯性，並融合影像數值資訊加強資料庫追蹤的強度。基於模擬結果，本文提出的演算法性能表現較佳，且在多目標的環境中能有效的降低追蹤的誤差，完成目標變速度時之追蹤，驗證本文所推導之追蹤理論能有效適用於多變速目標環境下的追蹤。

## 參考文獻

- [1] Hongda Chen, Chang, K,C, "Novel Nonlinear Filtering & Prediction Method for Maneuvering Target Tracking," *IEEE Transactions on Aerospace and Electronic Systems*, Volume 45, Issue 1, pp.237 – 249, 2009.
- [2] Punithakumar, K, Kirubarajan, T, Sinha, A, "Multiple-model probability hypothesis density filter for tracking maneuvering targets," *IEEE Transactions on Aerospace and Electronic Systems*, Volume 44, Issue 1, pp.87 – 98, 2008.
- [3] Y. Bar-Shalom and T.E. Fortmann, "Tracking and Data Association," Academic Press, 1989.
- [4] Sumedh Puranik and Jitendra K. Tugnait, "Tracking of Multiple Maneuvering Targets using Multiscan JPDA and IMM Filtering," *IEEE Transactions on Aerospace and Electronic Systems*, Vol. 43, No. 1, pp. 23-35, 2007.
- [5] Yi-Nung Chung, Pao-Hua Chou, Hsin-Ta Chen, and Feng-Pin Chou, "A Dynamic Multiple Sensor for Radar Maneuvering Target Tracking Problems", *Journal of Information Science and Engineering*, Vol. 23, No. 6, pp. 1833-1847, 2007.
- [6] 陳沛琨,胡國昌,鍾翼能, "利用適應性多模預估器作目標變速度追蹤," *國防科技學術研討會*, pp.455-460, 2008.
- [7] Chin, L, "Application of Neural Networks in target tracking data fusion," *IEEE Transactions on Aerospace and Electronic Systems*, 30, 281-287, 1994.
- [8] Zhou, B, and Bose, N, K, "A Comprehensive Analysis of Neural Solution to the Multitarget Tracking data association problem," *IEEE Transactions on Aerospace and Electronic Systems*, pp.260-263, 1993.

- [9] Yi-Nung Chung, Pao-Hua Chou, and Maw-Rong Yang, and Hsin-Ta Chen, "Multiple-Target Tracking with Competitive Hopfield Neural Network-based Data Association", *IEEE Trans. Aerosp. Electron. Syst.* Vol. 43, No. 3, pp. 1180-1188, 2007.
- [10] Chung, P, C, Tsai, C, T, Chen, E, L, and Sun, Y, N, "Polygonal Approximation Using A Competitive Hopfield Neural Network ," *Pattern Recognition*, **27**, 11, pp.1505-1512, 1994.
- [11] 陳沛琨, "應用多感測器資料融合技術於影像分析及目標追蹤之研究," **國立彰化師範大學, 電機工程學系, 碩士論文**, 2009.
- [12] 廖紹綱譯, 數位影像處理, **東華書局**, 2005.