

## 發展自成長類神經網路嵌入式低成本 MEMS INS/GPS 整合式 定位定向演算法

### The Development of Self-Growing Neural Network Embedded POS Determination Scheme for MEMS IMU/GPS Integrated Systems

張秀雯<sup>1</sup>                      江凱偉<sup>2</sup>  
Hsiu-Wen Chang              Kai-Wei Chiang

#### 摘要

數位式移動測繪系統是一種整合數位影像與直接定位定向的技術。利用多張動態數位影像直接定位定向以直接計算該影像於拍攝時間點其影像製造平台的空間軌跡之時變位置與時變姿態參數。現今最通用之技術為使用全球定位系統作為位置感測的主要元件同時使用慣性導航系統作為姿態感測的主要元件。並使用卡曼濾波器作為即時性 INS/GPS 整合系統的最佳預估工具。該演算法可提供具有高計算效率及可預估狀態的連續過程。而後處理模式的 RTS 又具有能使用整條軌跡資料去估計軌跡的優點，如今商業化的移動式測繪系統即是使用 RTS 後向平滑演算法來提供高精度的位置與姿態解以運行直接定位定向之解算程序。本研究開發與分析整合微機電系統之慣性量測元件與 GPS 接收機，所提出的架構運用自成長式類神經網路之階層式最大關聯神經網路 (CCN) 以克服傳統技術 KF 所存在之限制。使用 CCN 於 INS/GPS 整合位置與姿態系統 POS 較多層前饋式網路 (MFNN) 更具有彈性位相關係並可從新軌跡所獲得之知識自行成長神經元已吸納新資訊及提供較穩定的誤差補償等之優點，將對此領域之自動化控制之研究相當有幫助。

**關鍵字：**慣性導航系統、全球衛星定位系統、移動式測繪車、自成長類神經網路。

#### Abstract

The technique that integrates digital imaging with direct-georeferencing is known as a DMMS (Digital Mobile Mapping System). This is a new alternative to directly decide the time-variable position and orientation parameters for orienting the images in space, trajectory and attitude of the imaging platform by using different images. The most common technologies used for this purpose today are using GPS as a major position sensor, while the INS is the major orientation sensor. KF has been considered as the optimal estimation tool for real-time INS/GPS. Post-mission processing, compared to real-time filtering, has the advantage that data of the whole mission can be used to estimate the trajectory. Most of the commercial mobile mapping systems use an optimal smoothing algorithms to provide accurate positioning and developing an

---

<sup>1</sup> 國立成功大學測量及空間資訊學系 碩士生，seawing1984@gmail.com  
<sup>2</sup> 國立成功大學測量及空間資訊學系 助理教授

alternative data fusion scheme that integrates the outputs of a low cost orientation for direct geo-referencing. This study exploits and analyzes the idea of MEMS IMU and GPS receivers. The proposed scheme is implemented using a constructive neural network CCN to overcome the limitations of conventional techniques that are based on the KF. The CCN applied in this research has the advantage of having a flexible topology, growing neurons from new data sets in different trajectory and stable outputs if compared to the recently utilized MFNN for INS/GPS integrated POS. These attractive factors can make the proposed schemes have more automatically characteristic.

**Keyword: INS, GPS, Integration, Mobile Mapping Systems, Self-grow Neural networks.**

## 一、前言

配備了諸如慣性導航系統(Inertial Navigation System, INS)及全球導航衛星系統(Global Navigation Satellite System, GNSS)等具備互補特性的定位系統之整合式導航系統能夠提供較單一的系統更優異的無縫導航及定位特性。然而，未來的 GNSS 在市區、地下道、隧道、森林等地區仍然會受到訊號遮蔽的效應所影響。一般而言，訊號遮蔽的效應可區分為完全遮蔽導致無法鎖定 4 顆衛星及部分遮蔽所導致的觀測量品質不佳等二種，如圖 1 所示。圖中黃點為 GPS 的零散動態定位軌跡而紅線為 INS/GPS 整合系統連續定位軌跡。

相較之下，INS 具有高採樣頻率及短時間內高精度之特性，所以可以被使用來解決 GNSS 所遭遇諸如訊號遮蔽、低採樣頻率、週波脫落、易被干擾等限

制。相對的，INS 在獨自運作的模式下期定位誤差約略與時間的平方成正比 (Chiang,2004)。而整合式定位及導航系統能夠克服單一系統之缺點且提供更穩定的導航及定位成果，故目前不管在軍用或民用的整合系統發展皆趨向於使用 INS 及 GNSS。主要的優勢在於此二系統具有互補之特徵；GNSS 在無訊號遮蔽的環境下可以提供穩定的定位及導航資訊。故它可用來減低 INS 因積分加速度計及角速度之系統誤差所造成隨時間累積的定位誤差。對於高動態運動的物體而言，GNSS 無法提供足夠的採樣頻率來追蹤載體的運動。另外 INS 可以提供 GNSS 所無法提供的姿態參數 (El-Sheimy, 2002)。圖 2 所示為 INS、GNSS 及整合式系統相關特性之示意圖。圖中綠點及紅線分別為 GNSS 及 INS/GNSS 整合系統的動態軌跡。



圖 1、GNSS 訊號遮蔽的效應(Chiang, 2004)

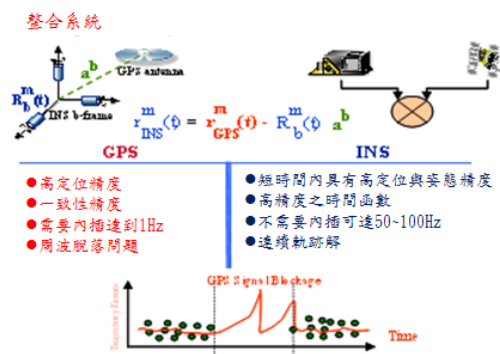


圖 2、INS、GPS 及整合式系統相關特性之示意圖(Chiang, 2004)

數位式移動測繪系統 (Digital Mobil Mapping System, DMMS) 被廣泛應用於地理資訊系統 (GIS) 以及 3D 城市模擬等領用上獲取空間資訊的有效工具。這項技術的基本理念為利用多台相機拍攝多張同一物體從不同距離與角度之影像，利用立體像對重組該物體於相機拍攝空間中之三維座標。直接定位定向技術及為該過程中用以計算每張影像重組所需之時變位置與姿態參數 (El-Sheimy, 1996)。有別於以往利用傳統地面控制點來間接定位定向影像於拍攝空間位置，這項技術已實現直接重組影像平台之軌跡與姿態 (Park and Gao, 2008)。DMMS 之發展起因於傳統測量技術常耗費大量人力與資金，甚至是時效性低而無法滿足日益擴大的需求量。故商業化之 DMMS 利用戰術等級以上之 IMU 結合 GPS 以獲取維持系統的可靠度與精度。雖然該項技術可克服多項傳統測量技術之缺點，唯其普及化仍因高精度之 IMU 所具有之高昂價格與獲取法規限制而無法提升，導致這項技術之普及化仍無法達到預期。圖 3 所示為加拿大卡加利大學所研發之商業化 DMMS：VISAT。

KF 已被廣泛認可為做為 INS/GPS 整合系統的最佳化標準估計工具。然而，已有多數研究者指出這項技術的限制 (Gelb, 1974; Brown and Hwang, 1992; Vanicek and Omerbasic, 1999)。INS/GPS 整合用的 KF 最主要之不便性為其必需先定義出每個感測器誤差的隨機模型 (Brown and Hwang, 1992)，更甚者，GPS 與 INS 資料的協變方先驗資

訊以及各感測系統的統計屬性值皆須準確的知道 (Vanicek and Omerbasic, 1999)，加上 GPS/INS 整合應用的過程與觀測模型為非線性，其擴展式卡曼濾波器 (EKF) 假設狀態變數之行為皆符和高斯隨機變數 (GRV)，當然 EKF 也可在非線性動態系統及非高斯分布下運作，但在太過嚴重之非線性高動態系統下，EKF 將可能出問題 (Shin, 2005)。

另一方面，人工類神經網路 (Artificial Neural Network, ANN) 技術已被用於發展替代 INS/GPS 整合架構的新方式以解決 KF 的限制問題與改進汽車導航系統在 GPS 訊號中斷下的位置精度 (Chiang, 2004)。然而，Chiang (2004) 在文章中指出未來發展 GPS/INS 整合架構時這應著重在人工智慧如 ANN 與 KF 的結合，因這樣的整合方式將具有人工智慧的優點，即可在實際狀況下估測所有導航狀態變數。在 Goodall et al. (2005) 的研究也指出 ANN-KF 的混合架構有能力善用 ANN 技術的優點成功的在車子進入 GPS 信號中斷後有效估計所有導航狀態解及成功提升位置之精度。然而這領域的研究並未有效剔除人工類神經網路所具有的缺點，如隱藏層及神經元數目如何決定、訓練時的收斂問題與時間等等。對於 MFNN 這一型的類神經網路，這些未知數是由人工試誤法來調整得到最佳解，可知此一過程將耗費不少人力。故本研究致力發展與研究自成長式類神經網路在此應用領用之可行性與表現，此種類神經網路相較於 MFNN 可有效減低訓練之時間與避免不必要之訓練過程。




圖 3、陸基 MMS 之實例(El-Sheimy, 2004)

## 二、問題闡述

一般 GPS/INS 整合系統利用 KF 估算之參數解無法達到的 MMS 之精度要求,造成此種狀況之因可大略分為:(1)所使用的 INS 系統穩定度不夠高,容易在無 GPS 輔助下使估算解迅速發散;(2)MMS 估算解無法單純由 GPS 提供高精度之姿態解,故遭受訊號失鎖之環境將無法使 MMS 運作正常。由此可知,低價位及低精度之 MEMS IMU 勢必無法僅靠 KF 演算法達到 MMS 之運作所需之精度。為了解決能使用低成本 IMU 整合 GPS 之架構能提供高精度之位置與姿態解,使用後處理最佳化演算法可作為解決方案之一。後處理的優點為可利用全部的資料去估測軌跡,當僅有部分軌跡點是不可能用濾波器估測軌跡,直到取得最後一個點(Gelb, 1974)。當濾波器開始啟用於第一步後,最佳化平滑器如 RTS 後向平滑器即可被使用,這是利用了過濾後的結果與其協變方當作第

一次的估計值,而這個初步估計將利用額外的資料而非濾波過程的資料進行改進。最佳化平滑器的改進由資料的型態決定之,其表現是相當可觀的,大部分的直接定位技術應用需具備較高精度的平台,尤其在姿態角方面(El-Sheimy, 1996)。車載測繪系統在最佳化平滑器之後處理模式中可達到高精度的位置與姿態的需求,而實際上大部份的商業化車載測繪系統即以最佳化平滑器演算法以提供精確的位置與姿態解已供直接定位定向演算法使用(Shin, 2005)。而另一方面之研究如(Chiang, 2004)提出 ANN-KF 的混合架構有能力善用 ANN5 之優點已改進載體進入 GPS 信號中斷時,有效估計導航狀態解及改善位置精度。近來被用於 MMS 的商化 INS/GPS 整合系統皆使用戰術等級以上的 IMU 以提供精確的位置與姿態導航參數(POS)解,此法為改進硬體設備之道,然而這樣的改善受限於高等級(導航級)IMU 在多數國家製造

後具有法律規範限制了其取得過程與使用範圍；而以低價位之 MEMS 整合 POS 解的 INS/GPS 系統需透過其他演算法已改進系統穩定性與精度等級，本研究即以此方向做為改進之道，此法相較於前述硬體解決方式其可有效降低成本並解決取得管道限制等問題，一般 MMS 應用低價位之 MEMS INS/GPS 系統無法僅以傳統演算法克服該系統之不穩定性與導航解發散等問題。前人研究 (Chiang, 2004) 指出，ANN 與最佳化平滑器之混合架構可成功應用於直接定位定向之低價位 MEMS IMU 整合 GPS 系統，用以獲取較高精度之 POS 解，然而該 ANN 仍需大量人工介入，故本研究之目標為：(1) 發展較自動化之 ANN 嵌入式 RTS 平滑器於 INS/GPS 整合系統。(2) 驗證本文所提出 CCN 演算法可使 MEMS INS/GPS 整合系統精度提升。(3) 與先前的 ANN-KF 混合式架構比較成果。

### 三、從卡曼濾波器到最佳化平滑器

為了最佳化估計導航解，INS 的導航方程式解需整合 GPS 的位置與速度解，而 EKF 即為這整合最常用到的技術。地方框架下之簡單導航方程式可參考 (El-Sheimy, 2002)：

$$\begin{bmatrix} \dot{\mathbf{r}} \\ \dot{\mathbf{v}} \\ \dot{\mathbf{R}}_b^l \end{bmatrix} = \begin{bmatrix} D^{-1}\mathbf{v}^l \\ R_b^l f^b - (2\Omega_{ie}^l + \Omega_{el}^l)\mathbf{v}^l + \mathbf{g}^l \\ R_b^l (\Omega_b^b - \Omega_{il}^b) \end{bmatrix} \quad (1)$$

$\mathbf{r}^l$  在地方框架下之位置向量 [  $\phi$  (緯度 0),  $\lambda$  (經度),  $h$  (高程) ]。

$\mathbf{v}^l$  在地方框架下之速度向量 [  $e$ ,  $n$ ,  $u$  ]。

$R_b^l$  IMU 固體座標系至地方座標系之

座標變換矩陣。

$\mathbf{g}^l$  在地方框架下之重力向量。

$\Omega_{ib}^b, \Omega_{il}^b$  與角速度  $w_{ib}^b, w_{il}^b$  相應之反對稱矩陣

$D^{-1}$  為 3\*3 維度矩陣，除對角線由使用者緯度與精度組成元素外，其他皆為零。

由 El-Sheimy (2002) 進一步指出上述的微分方程式之解與數值操作讓 INS 的導航方程式演算法本身極少具優質解，原因在於慣性測量偏差與固定步長所造成之積分誤差會使 POS 參數快速發散。故導航計算軟體必須具有解決這些誤差來改正 POS 參數之能力 (Chiang et al., 2003)。計算導航參數 (位置、速度與姿態) 的 KF 裡，其動態誤差模型可透過線性化之 INS 導航方程式與捨去次要項的線性模型。該模型的型式請參考 (Bar-Itzhack and Berman, 1988)：

$$\delta \dot{\mathbf{x}} = D^{-1} \delta \mathbf{v}^l \quad \delta \dot{\mathbf{A}} = E \delta \mathbf{v}^l + R_b^l \delta \boldsymbol{\omega}^b$$

$$\delta \dot{\mathbf{x}} = -(2\Omega_{ie}^l + \Omega_{el}^l) \times \delta \mathbf{v}^l - \delta R_b^l f^b + R_b^l \delta f^b + \delta \mathbf{g}^l$$

$$\delta f^b = b_a + \text{diag}(f^b) s_a$$

$$\delta \boldsymbol{\omega}^b = b_g + \text{diag}(\boldsymbol{\omega}^b) s_g \quad (2)$$

$\delta \mathbf{r}^l$  在地方框架下之位置狀態誤差向量。

$\delta \mathbf{v}^l$  在地方框架下之速度狀態誤差向量。

$\delta \mathbf{A}^l$  在地方框架下之姿態狀態誤差向量。

$\delta \mathbf{g}^l$  在地方框架下之計算過後重力誤差向量。

$\delta f^b$  與  $\delta \boldsymbol{\omega}^b$  在物體框架下之加速規偏差與陀螺儀飄移向量。

$S_a$  與  $S_g$  在物體框架下之加速規與陀螺儀尺度因子。

$E$  由載體之緯度與地球曲率半徑所組成之 3\*3 非零矩陣。

KF 方程式可分割為兩個部份：預測與更新。時間預測方程式負責將 (k-1) 時刻狀態向前傳遞至時刻 (k)，觀測更

新方程式利用新的觀測值供先驗狀態估計值取得最佳化後驗狀態估計值，預測方程式與觀測更新方程式請參考 (Shin and El-Sheimy, 2005)。KF 利用更新估計的方式減低觀測更新方程式內的 INS 的誤差，而不論 GPS 是否具

有觀測值，KF 皆可即時產生預測誤差狀態向量，但在此狀況下 KF 方程式需要系統相關統計資料以使之趨於穩定，也就是無法被事前肯定 (Shin and El-Sheimy, 2005)。整個 KF 之過程如圖 4。

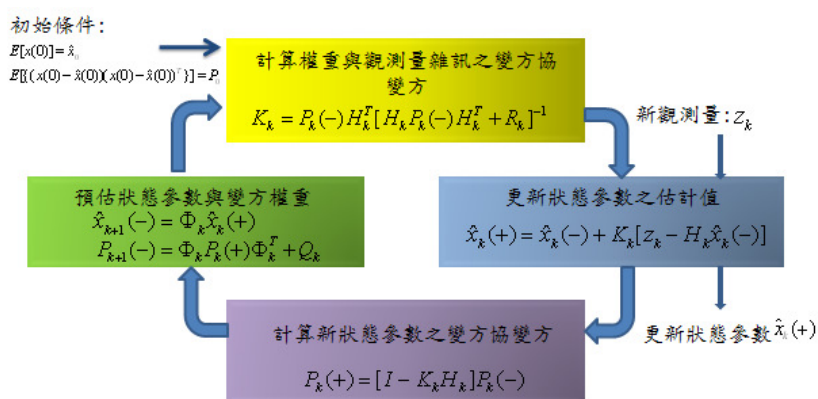


圖 4、KF 流程

由於平滑器需要用到所有的 KF 估算解以及必須在 KF 後運作，準確的平滑解即需要準確的 KF 估算解才能獲取 (Gelb, 1974)。KF 利用時刻  $k$  以前可用觀測值來更新時刻  $k$  ( $\hat{x}_k$ ) 最佳化估計，不同於最佳化後向平滑器利用了時刻  $k$  值前後的全部觀測資料來解算最佳化後之平滑估值。平滑估值可被視為前向與後向估計的組合，前者利用  $k$  時刻之前 KF 提供的所有觀測值，而後者利用全部或部分  $k$  時刻後的觀測值，由於觀測值陸續更新加入，一般後向平滑解之精度就算不是更高也絕不會低於濾波後的解 (Brown and Hwang, 1992)。平滑後獲取至濾波階段，所有平滑演算法與濾波解相關，故精確的濾波需要精確的平滑化 (Gelb, 1974)，根據 (Gelb, 1974)，有三種後向平滑演算法：固定間距平滑、固定點平滑、固定旗幟平滑，本文僅討論固定間距平滑；其他兩

種平滑法請見 (Gelb, 1974) 和 (Brown and Hwang, 1992)。本研究使用具有被認為最簡單與容易之 RTS 平滑器；RTS 由前掃與後掃兩部分完成，前掃意指一般 KF 預估過程與更新狀態解及相應之協變方矩陣，如圖 5a 所示。後掃部分則由最後時間點為起點並以初始條件  $\hat{x}_{N,N}^s = \hat{x}_{N,N}$  與  $P_{N,N}^s = P_{N,N}$  向後進行平滑解的計算：

$$\hat{x}_{k,N}^s = \hat{x}_{k,k} + A_k (\hat{x}_{k+1,N}^s - \hat{x}_{k+1,k}) \quad (3)$$

$$A_k = P_{k,k} \Phi_{k+1,k}^T P_{k+1,k}^{-1} \quad (4)$$

$\hat{x}_{k,N}^s$  狀態向量之平滑估計解。

$A_k$  平滑器之增益矩陣，其中  $k=N-1, N-2 \dots 0$ 。

而協變方矩陣之計算如下 (Gelb, 1974)：

$$P_{k,N}^s = P_{k,k} + A_k (P_{k+1,N}^s - P_{k+1,k}) A_k^T \quad (5)$$

DGPS 觀測值在時間區間  $N$  中可全部

被利用以計算 KF 估算解，在固定間隔平滑法中，最初與最後的觀測值皆固定，圖 5b 有介於 0 至 N 的時刻 k 皆要求已知最佳平滑估值，明顯此演算法僅適用於後處理 (Shin and El-Sheimy, 2005)。根據文獻，後處理模式可有效移除部分誤差，但在本研究之應用，其殘餘誤差還不足以使用在 MMS 上，故 ANN-RTS 平滑器將在本研究中扮演移除剩餘誤差的角色。




圖 5、固定區間後向平滑器示意圖

#### 四、人工類神經網路

ANN 在本研究中主要用來學習以補償 KF 與 RTS 平滑器所殘餘下的誤差，以提高 KF 與 RTS 之姿態及位置解的精度。該架構可依據載體平台之運動特性以學習狀態參數之導航感測器誤差行為，KF 導航解之殘餘誤差可用為相當複雜之非線性函數近似之，由於該複雜性並非一般函數可模擬，而 ANN 具有對複雜問題及函數做有效學習模擬之特性，因此將會是一個值得嘗試使用的工具，又以具自成長性特徵的 ANN 為主要研究目標，自成長型類神經網路 CCN 比固定型多層前饋類神經網路 MFNN 更具自動化與簡易之操作特性。

ANN 之基本概念源自人類的腦部運作，與廣泛之數位電腦計算具有很大的

差異，該基礎模擬人腦具有接受子、中心運作區與反應子。一般來說該模型可分為三個主要部分：(1) 權重鏈結  $\langle w_{i,j}, W_{j,k} \rangle$ ；(2) 用以統合被加權過之輸入訊號  $\phi_i$  以及外部偏差子  $b_k$  之加法器；(c) 用以限制神經元輸出訊號以及最終反應訊號大小之活化函數。這些基本要件可見圖 6 所示，而整個類神經網路之數學函數可寫為：

$$\hat{y}_i(t) = \hat{f}(\phi, \theta) = AF_i \left[ \sum_{j=1}^{n_h} W_{j,k} \phi_j \left( \sum_{l=1}^{n_o} w_{i,j} \phi_l + w_{j,0} \right) + W_{k,o} \right] \quad (6)$$

其中  $\theta$  為包含如權重及偏差等之參數向量，一般偏差子會被設為 1。




圖 6、固定區間後向平滑器示意圖

決定權重值時必須給予一組適當的範本來指導輸出訊號該對應怎樣的輸入訊號，而整個改變權重的調整過程稱之為監督式學習，是一種常見的 ANN 學習過程。如圖 7 描述，可見 ANN 依據輸入訊號將權重值調整直到該組權重能夠模擬出最近似目標值之輸出函數，一般改變權重的學習法為倒傳遞誤差學習演算法，但因該演算法耗時且需要多次人為調整參數，故本研究沿用文獻 (Lin, 2008) 所提供之 MFNN，該 ANN 使用更複雜之 LM 演算法，該學習因子與隱藏層數目等等皆以人工試誤法逐步調整出最佳值。




圖 7、監督式學習演算法近似數學函數之示意圖

自成長式類神經網路之種類可在文獻(Alpaydin, 1991)找到，由文獻中可知最著名的一種即為階乘式最大相關類神經網路(Cascade-Correlation neural Network)。CCN 由 1990 Scott E. Fahlman(Fahlman and Lebiere, 1990)等人所發展出來，主要的兩個關鍵想法為：(1)具階乘式位相關係；(2)用獨特學習演算法作自動學習與插入新隱藏神經元。CCN 由最簡單的架構開始成長，該架構僅有輸入層與輸出層，見圖 8。根據 Fahlman 之文章，用以學習之演算法可為牛頓法或 Quickprop 等二階型演算法，本研究採用 Quickprop 以簡化計算過程與加快學習速度。整個 CCN 成長的過程可分為三個階段：(1)僅具輸入與輸出層之最簡單架構，每條連線即代表相應權重，用以傳遞輸入訊號並以 Quickprop 調整兩層之間之權重以設法達到與目標訊號相似之輸出值，如圖 8；(2)當權重停止更新但未能達到所設誤差門檻時，將自動產生一組候選神經元並暫時與輸入層及已存在之隱藏神經元鏈結，此階段僅改變輸入層至該候選元之間的權重而不改變該層至輸出層之間的權重，如圖 9 所示僅有紫色權

重部分調整。改變權重的目標為使相關係數(C)達到最大(此相關係數代表該神經元(V)與輸出神經元之殘餘誤差(E)所具有之相關指數)：

$$C = \sum_o \left| \sum_p (V_p - \bar{V})(E_{p,o} - \bar{E}_o) \right| \quad (7)$$

其中 o 代表輸出神經元、p 為輸入訊號、 $E_{p,o}$  代表第 p 個輸入訊號至第 o 輸出神經元所造成之誤差、 $\bar{V}$  和  $\bar{E}_o$  為 V 與  $E_o$  之平均值。本研究以 Quickprop 進行該權重調整以最大化相關係數 C：

$$\delta_p = \sum_o \sigma_o (E_{p,o} - \bar{E}_o) \phi_p \quad (8)$$

$$\frac{\partial C}{\partial w_i} = \sum_p \delta_p I_{i,p} \quad (9)$$

其中  $\sigma_o$  代表候選神經元輸出值與輸出層神經元輸出值之正反號， $\phi_p$  代表輸入訊號 p 對應該候選神經元之輸入  $I_{i,p}$  所產生之微分值。由方程式 (6) 和 (7) 可調整權重至每個候選神經元相應相關係數皆不再增大。具有最大相關係數之候選神經元將正式插入成為新的隱藏層神經元，如圖 10。(3) 接著剛調整過的權重會被凍結，改為介於隱藏層與輸出層之間的權重開始調整。值得一提的事，剛被插入的隱藏神經元如同新的輸入向量，請見圖 10。整個類神經網路會一直自動加入隱藏神經元直到該網路可產生與目標向量近似之訊號，整個過程相較於 MFNN 可有效解決猜測位相關係之步驟(如隱藏神經元個數、隱藏神經元層數)，達到自動化的目標。



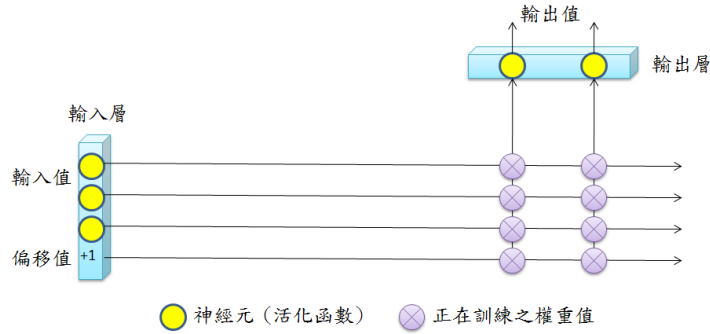


圖 8、CCN 起始位相

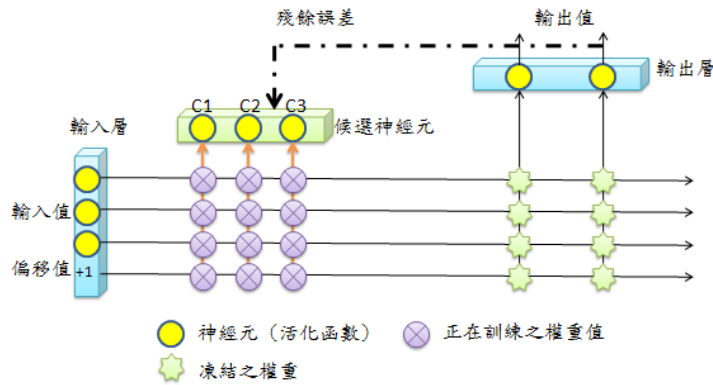


圖 9、插入候選神經元之 CCN

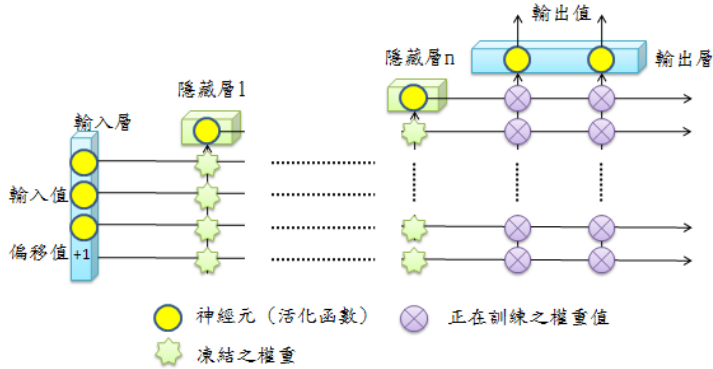


圖 10、插入多層隱藏神經元之 CCN

### 五、系統架構

本研究使用傳統演算 KF 與 RTS 以提供最佳導航參數(包含位置、速度與姿態)，並使用具有 21 個狀態向量之 EKF，如下所式：

$$[\delta p_{b3} \quad \delta v_{b3} \quad \delta A_{b3} \quad b_{a,b3} \quad b_{g,b3} \quad s_{a,b3} \quad s_{g,b3}]^T$$

架構如圖 11，KF 與 RTS 估算 21 狀態向量後將在即時模式或後處理模式下補償這些狀態向量，該狀態向量包含了感測器偏差 ( $b_{a,1x3}$  與  $b_{g,1x3}$ ) 與尺度因子 ( $S_{a,1x3}$  與  $S_{g,1x3}$ )，這些估計值會被回饋至 INS 導

航方程運算以校正 IMU 之觀測值。由於本研究著重在位置與姿態之導航解，故不將感測器誤差包含至 ANN 之輸入訊號已簡化計算流程並提高計算速度。

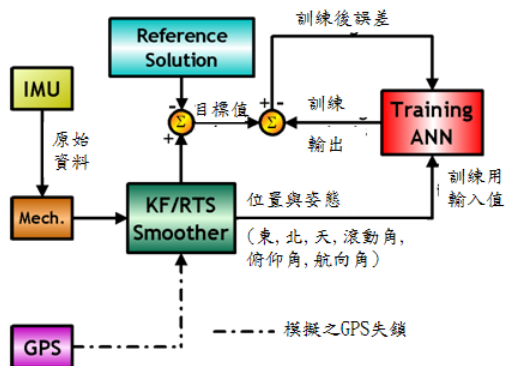


圖 11、ANN 學習架構

由具高精度系統所提供之 KF 與 RTS 平滑器解之 POS 參數將被用於 ANN 當作目標值。整個學習目標是讓 ANN 能學到 GPS 失鎖下所產生的誤差行為特徵，故

本研究使用高精度與高可靠度之 IMU 當作參考系統，其系統提供在無任何 GPS 失鎖下之 RTS 後處理模式平滑後之導航解。

最佳化位相之 ANN 代表其架構能以最適切之隱藏神經元顆數與隱藏層數目對未知模型提供最近似之模擬。然 MFNN 因無法自行找出最適切之架構參數，需要人工試誤法等方式決定這些參數 (Haykin, 1999)；相反的，CCN 能自行決定這些參數，可省去多餘之人工調整工程。本研究所使用之 MFNN 僅為了做對照組使用，故延用前人之研究 (Lin, 2008) 所發展之 ANN 位相，該位相具有一層隱藏層及 60 至 65 之隱藏神經元數。圖 12 整理本研究所使用之兩大 ANN 彼此之間的差別。

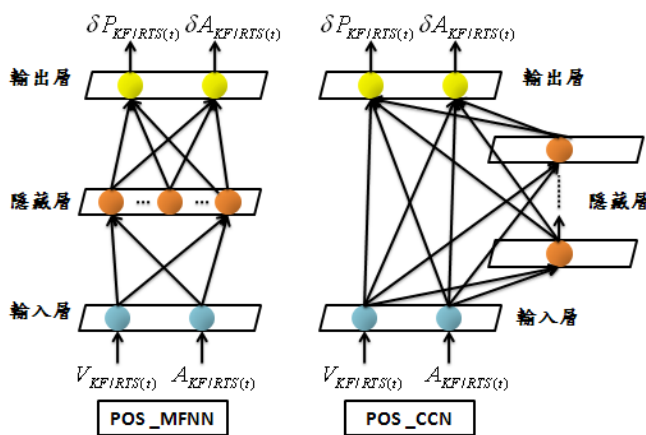


圖 12、MFNN 與 CCN 位相差異

如圖 13 所示，訓練完成之 ANN 補償架構會被嵌入密閉型鬆偶合式 INS/GPS 整合架構，INS 接收原始觀測量後利用 21 狀態參數之 INS 導航方程式再透過 KF 與 RTS 平滑器解算 POS 導航解，同時 POS 導航解會被送至 ANN

以預估或改正導航解。即由 ANN 預估 KF 與 RTS 解算完之導航解所具有的殘餘誤差。當 ANN 已提前訓練完成時，因不需要再有重複計算之權重調整，其運作能力應可用於即時觀測模式。

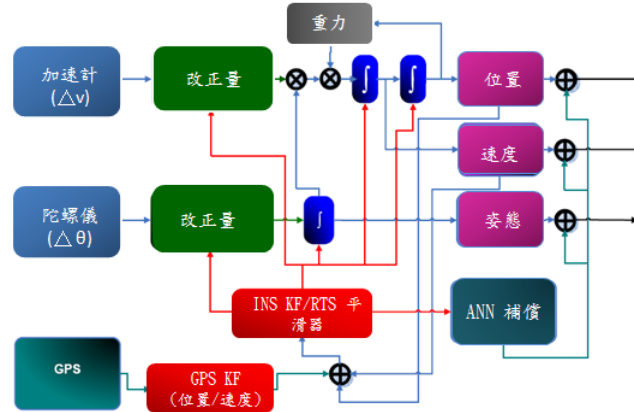


圖 13、ANN 嵌入式 KF 與 RTS 平滑器運作

## 六. 成果分析

本研究為了檢驗所提出之方案效能，實驗數據來自三個不同場地的汽車軌跡，使用具有 Litton LN200 (1 deg/hr) 戰術級 IMU，BEI MotionPak II (MEMS) 低價位 IMU 以及 NovAtel OEM-4 接收

器。其中 LN200 的整合系統作為參考軌跡，而以 MotionPak II 整合系統所提供的觀測值與導航解來驗證方案效能。圖 14 為實驗場地軌跡及系統配置圖。

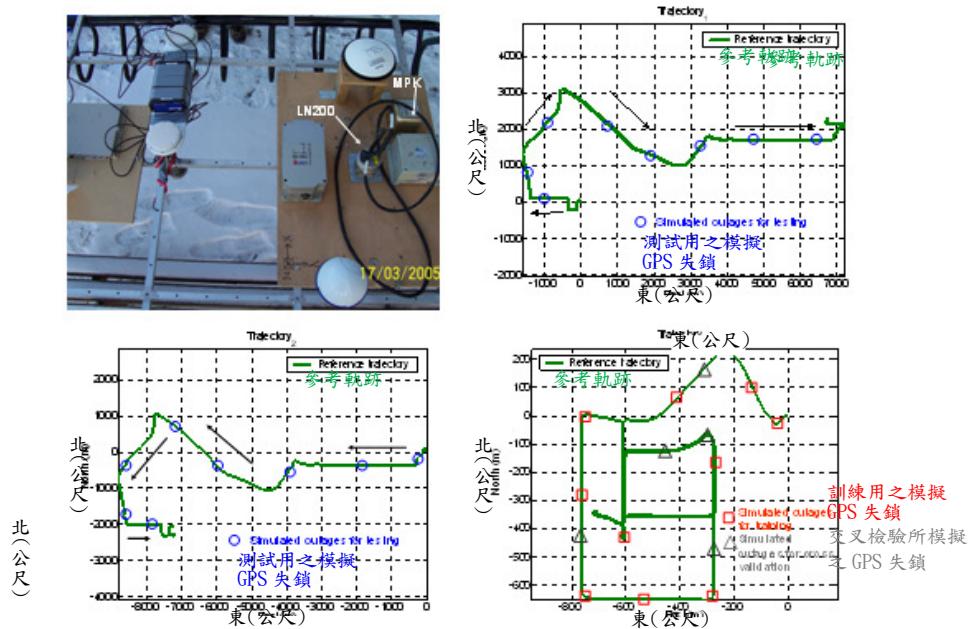


圖 14、實驗軌跡與系統配置

本實驗以 GrafNav™ 7.0 軟體解算 GPS 觀測資料，在 DGPS 模式下可達十公分等級之精度，而 LN200/DGPS 所生之參考軌跡由二十一個狀態值組成 EKF 與

RTS 後向平滑，其 EKF 與平滑器參數已調整至最有效估算之導航精度。以正方框標誌的 30 秒 GPS 中斷時間是來自第三個實驗軌跡之資料所模擬，使用圖 13

之 ANN 嵌入式 KF 與 RTS 平滑器操作並比對參考軌跡模擬之 KF 與 RTS 平滑化輸出結果，所產生的誤差即為 KF 與 RTS 誤差行為，再用以訓練 ANN 使其達到需求輸出，而五個模擬中斷之三角形標誌則用已進行交叉檢測類神經網路的一般化過程不至於過度訓練（詳見 Alpaydin, 1991）。

## 七、訓練架構

ANN 必須具有能力確實地學習誤差的行為特徵，該行為特徵包含載體動態變化的影響以及 INS 感測器誤差所造成的 KF 與 RTS 平滑器誤差，因此在學習過程必須先確實該架構已有效具有該

能力。除此之外，本實驗提出之架構尚需經過獨立之其他軌跡資料已檢驗該 ANN 是否具有一般化之特徵，也就是可通用至在學習過程中未出現的軌跡資料群，這部分之檢驗過程將在下一段分析數據。表 1 中標示原始值之欄位代表原始 KF 與 RTS 平滑器所提供之 POS 導航解與參考軌跡解之誤差；補償後殘餘誤差代表由本實驗架構 ANN-KF 及 ANN-RTS 補償 KF 與 RTS 導航解誤差後再與參考軌跡比較計算之誤差。由表 1 可見此 CCN 架構可有效學習如 MFNN 所模擬之 GPS 訊號失鎖環境下之目標行為特徵並達到平均 90 百分比之相似度。

表 1、訓練成果總表

訓練方法 六輸入	POS	RMS 值 (度)			進步值 (%)	
		原始值	CCN 補償後 殘餘誤差	MFNN 補償後 殘餘誤差	CCN 與 KF(RTS) 相比	MFNN 與 KF(RTS) 相比
Tj-3 (KF + CCNs) (KF+MFNNs)	滾動角	0.9193	0.0488	0.0375	95	96
	俯仰角	0.5733	0.0399	0.0343	93	94
	航向角	6.4335	0.9213	0.4959	86	92
	北	1.0806	0.3188	0.2733	70	75
	東	1.7810	0.3421	0.2149	81	88
	高程	0.3651	0.0773	0.0678	79	81
Tj-3 (RTS+CCNs) (RTS+MFNNs)	滾動角	0.9289	0.0314	0.0230	97(97)	98(97)
	俯仰角	0.5862	0.0199	0.0190	97(97)	97(97)
	航向角	2.7762	0.5667	0.4838	80(91)	83(92)
	北	0.2331	0.0420	0.0395	82(96)	83(96)
	東	0.2165	0.0387	0.0470	82(98)	78(97)
	高程	0.1032	0.0360	0.0335	65(90)	68(91)

## 八、檢驗架構

依據訓練完之架構成果，其已學習軌跡三所模擬之動態特性，包含直線段、轉彎、加速度與減速度過程。圖 15 與圖 16 分別為該訓練架構使用在軌跡一與二之姿態補償結果，三條線分別代表使用 KF 後依舊殘留的誤

差、使用 KF 與 CCN 或 MFNN 後補償所剩下的誤差。可以看出在俯仰角與滾動角上兩類神經網路架構皆可消除因參考系統與測試系統擺放位置不同所引起之系統性偏移，以及部份由慣性感測元件本身所造成之系統震

盪誤差。至於航向角之表現並不如俯仰角與滾動角好，導致該現象之結果應為訓練軌跡之航向角測試軌跡相對於訓練軌跡環境變化大，故可發現 MFNN 訓練架構仍有過度補償之現象，而 CCN 相較之下避免了過大的補償。本實驗根據不同的輸入資訊對測試結果做比較，發現越多的資訊不一定帶來越好的結果，尤其在 MFNN 訓練架構，故本實驗之結果為四項輸入訊息(時間、俯仰角、滾動角、航向

角)補償之姿態誤差結果做為分析。表 2 整理圖 15 至 18 之綜合結果，由圖可發現 MFNN 容易出現過度補償之現象，造成不必要之放大過程，這些來源可為訓練軌跡與測試軌跡之輸入訊息特徵差異較大或者 MFNN 訓練過久造成。相較之下，CCN 具有克服這些問題之特性，不管在位置與姿態之 KF 與 RTS 補償模式，可發現過度補償之結果皆未發生在 CCN 架構下。

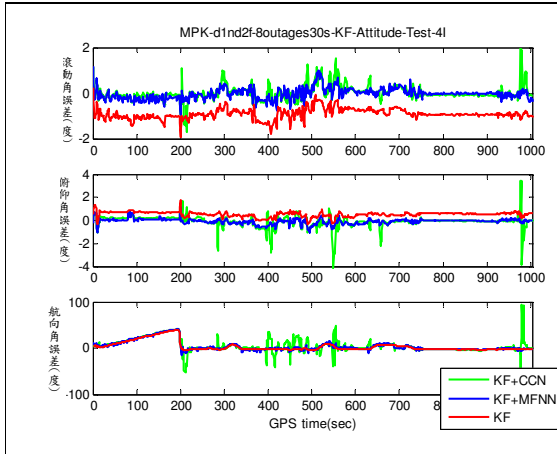


圖 15、ANN-KF 姿態測試結果(軌跡 1)

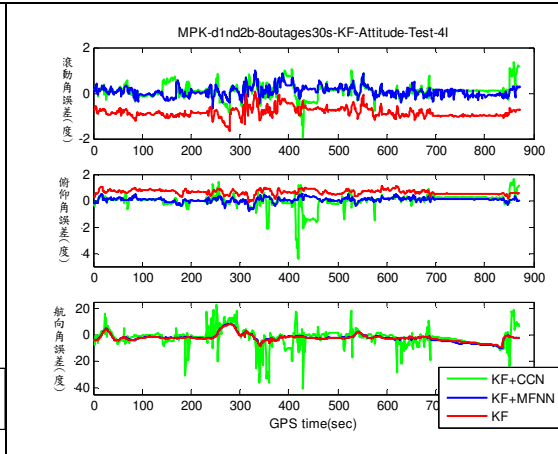


圖 16、ANN-KF 姿態測試結果(軌跡 2)

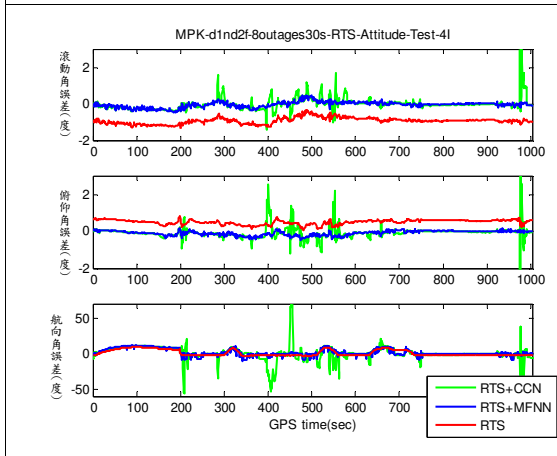


圖 17、ANN-RTS 姿態測試結果(軌跡 1)




圖 18、ANN-RTS 姿態測試結果(軌跡 2)

僅由軌跡三資料作為訓練樣本之類神經網路在預測未知軌跡資料形態之軌跡一與軌跡二時，容易發生補償過小

或者偏大的現象。這也很可能是因為所模擬的 GPS 失鎖環境樣本個數不足以囊括各種知識給予類神經網路，故適當增

加模擬個數是一個解決的辦法。在位置部分，為了減少 ANN-KF 預測方向錯誤的反增大現象，本研究將軌跡三訓練資料群之 GPS 失鎖環境增加以擴大成功機率。值得注意的現象是 CCN-KF 在學習過程中達到平均 85%、90%以及 93%之相似度，比起 MFNN-KF 的平均值 90%、91%以及 90%之值稍微偏低，但在測試預測過程中卻可以提供較好的結果。圖 19 到 22 中的結果僅繪出 GPS 失鎖時段之

補償結果，與姿態之全程線段較不一樣，這是因為當 GPS 訊號回復後可即時提供精準的位置導航解，可使圖中的紅色線段回到零點附近並維持高精度之位置解，故剪取類神經網路補償 GPS 失鎖時段之結果作為分析。這個方式可減少運算、避免類神經網路吸收多餘的知識也可避免影響無 GPS 訊號失鎖環境時的導航解。

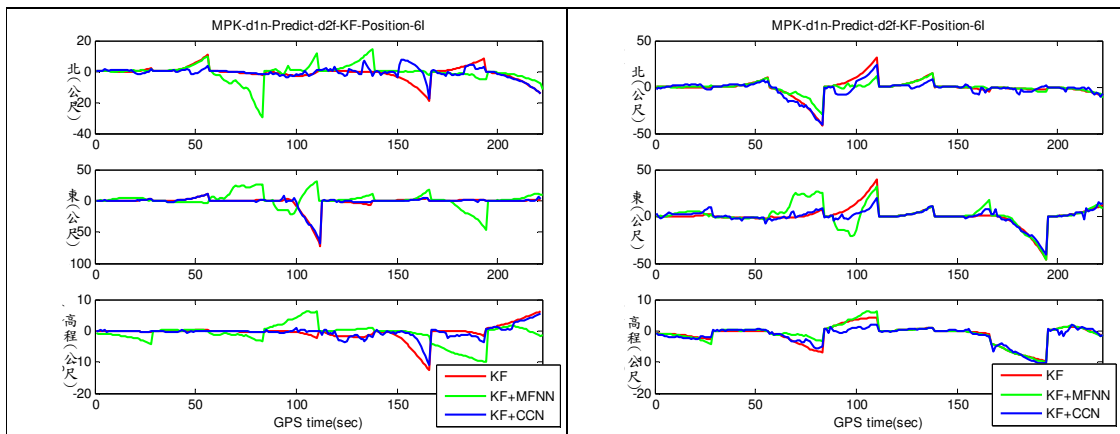


圖 19、ANN-KF 位置測試結果(軌跡 1)

圖 20、ANN-KF 位置測試結果(軌跡 2)

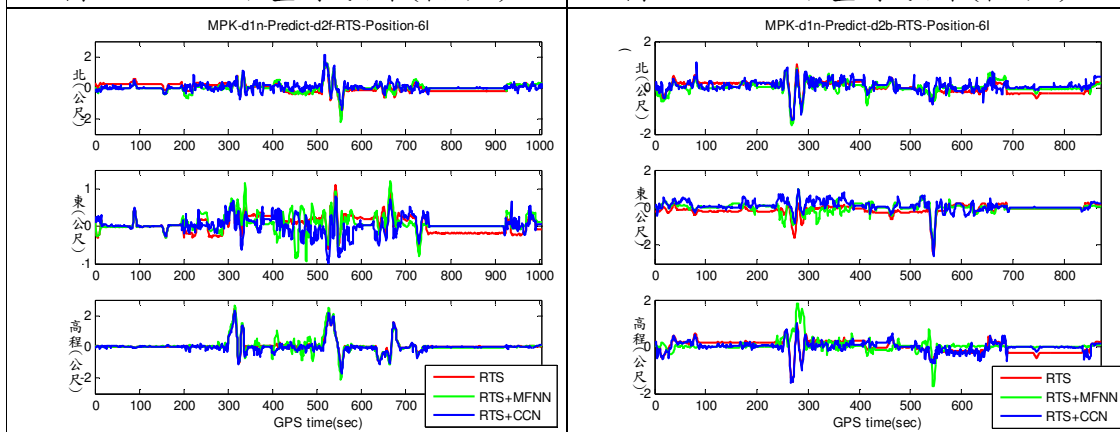


圖 21、ANN-RTS 位置測試結果(軌跡 1)

圖 22、ANN-RTS 位置測試結果(軌跡 2)

由上述之圖可歸納出 CCN-KF 之架構正確預測方向之機率比 MFNN-KF 架構來的高。然而，從圖 19 至 20 可發現仍存在預測情況不好之現象。本實驗之輸

入訊號所做之預處理為速度除以向量  $[20, 20, 1]$ 、姿態除以向量  $[10, 10, 200]$ 。然而，從處理過之輸入訊號大小可察覺造成類神經網路預測

情況較不好之現象有可能存在於軌跡一與軌跡三之間的輸入訊號特性大不相同。此情況較明顯之狀況及為航向角之結果，訓練軌跡之航向角變化比測試軌跡大上許多，而高程變化則小上許多，剛好可從圖上發現測試軌跡航向角有偏大補償之現象；高程部分有偏小之現象。表 2 整理圖 19 至 22 之結果，ANN-RTS 可有效提升比 KF 姿態參數達平均 80%、75% 以及 14%；位置參數平均達 76% 左右。另一方面，ANN-RTS 可有效提升比 RTS 之俯仰角、滾動角平均 79%、77% 之精度提升。

本研究所提出之 ANN-RTS 架構可有效提升使用 MFNN 低價位低精度之 KF 以及 RTS 所提供之導航解精度，導航解中以姿態方面之提升較位置參數明顯。因此，對於一套使用低精度低成本之 MEMS 系統作為整合 GPS/INS 系統之應用來說，本研究之架構可將該系統級之 KF 與 RTS 所提供之導航可有效提升至戰術等級系統之精度。圖 23 描述使用 ANN-RTS 對於補償 KF 以及 RTS 導航解所產生之相對補償誤差示意圖。

表 2、測試成果總表

測試方法 四輸入	POS	RMS 值 (度)			進步值 (%)	
		原始值	殘餘誤差 CCN	殘餘誤差 MFNN	CCN 與 KF(RTS) 相比	MFNN 與 KF(RTS) 相比
Tj-1 (KF + CCNs) (KF+MFNNs)	滾動角	0.9432	0.2388	0.3205	75	66
	俯仰角	0.5614	0.2385	0.5094	58	9
	航向角	10.9320	11.5690	14.8860	-6	-36
	北	4.4081	3.4422	4.5573	22	-3
	東	10.5150	9.9911	7.7041	5	27
	高程	2.5148	1.9186	2.6232	24	-4
Tj-2 (KF+CCNs) (KF+MFNNs)	滾動角	0.9436	0.1646	0.3329	83	65
	俯仰角	0.5174	0.1543	0.4019	70	22
	航向角	4.1803	5.1983	4.3370	-24	-4
	北	9.0268	8.6431	5.7135	4	37
	東	9.9548	7.8694	11.7520	21	-18
	高程	3.3027	3.1350	3.2281	5	2
Tj-1 (RTS+CCNs) (RTS+MFNNs)	滾動角	0.8692	0.2311	0.3502	75(73)	63(62)
	俯仰角	0.6675	0.1875	0.5415	67(72)	4(40)
	航向角	3.5811	3.7488	7.2621	66(-5)	34(-205)
	北	0.3235	0.2820	0.3048	80(13)	79(6)
	東	0.2311	0.2226	0.2551	86(4)	84(-10)
	高程	0.4149	0.4077	0.4855	70(2)	65(-17)
Tj-2 (RTS +CCNs) (RTS+MFNNs)	滾動角	0.8698	0.1360	0.3738	86(84)	57(57)
	俯仰角	0.6631	0.1183	0.4157	77(82)	38(37)
	航向角	2.7187	4.9899	9.4589	-19(-84)	-164(-248)
	北	0.2719	0.2670	0.2569	89(2)	89(6)
	東	0.3080	0.3027	0.2720	67(2)	71(12)
	高程	0.2686	0.2514	0.2837	66(6)	61(-6)

根據上述之表格與圖示顯示初步實驗結果可歸納出如表 3 之人工類神經網路優缺點比較。歸納本研究所提及對自成長神經網路 CCN 與固定式類神經網路 MFNN 之各項要點作分析比較。




圖 23、ANN-RTS 對殘餘誤差之影響

表 3、CCN 與 MFNN 之優缺點總表

類神經網路	優點	缺點
前饋式類神經網路 (MFNN)	<ul style="list-style-type: none"> <li>● 容易達到與訓練樣本具高相似度之輸出訊號。</li> <li>● 位相架構較 CCN 來的線性化，故學習如航向角這類相較平滑之目標值以 MFNN 較易達到完成門檻值。</li> </ul>	<ul style="list-style-type: none"> <li>● 須浪費時間再搜索最適合的隱藏神經元數目與隱藏神經元層數。</li> <li>● 當隱藏層神經元多的時候，其訓練過程會變冗長而耗時。</li> <li>● 使用較多輸入資訊時較不易反映出好的學習狀況</li> <li>● 容易形成發生過度學習。</li> <li>● 受「遺忘記憶問題」嚴重。</li> </ul>
階乘式最大相關類神經網路 (CCN)	<ul style="list-style-type: none"> <li>● 從簡單架構開始擴大，增快學習過程。</li> <li>● 階乘式架構使輸出具較複雜之非線性化，對較複雜之曲線有較好之表現</li> <li>● 自動成長內部位相，無須猜測。</li> <li>● 對較多之輸入訊號較具有有效吸收知識之能力。</li> <li>● 再成長之能力適用於新環境。</li> </ul>	<ul style="list-style-type: none"> <li>● 可用凍結依些權重之方式避免記憶遺忘，但不是完全避免</li> <li>● 對輸入訊號較敏感，輸入訊號之前處理必須妥善縮放平移。</li> </ul>



## 九、討論與未來期望

本研究發展自成長神經網路 CCN 嵌入式 POS 演算法來達到比傳統 RTS 候處理模式還要好的估計解，使用的方式為結合 CCN 與 RTS 進行後處理。根據初步的研究結果，CCN 可有效提升不僅位置同時姿態等的導航參數精度，並且具有克服 MFNN 人工介入之缺點。使用的方法為將 CCN 先行做適當訓練以習得實驗軌跡之 KF 與 RTS 平滑器具有的誤差特性，再用完成訓練之架構驗證其他測試資料群。

CCN 在本研究中可達到與 MFNN 同樣的效果，也就是能使 POS 參數精度提升。這個架構主要的優點是從最少的神經元開始學習吸收知識，不足吸收知識之情況再自行生長神經元，因該類神經元以階乘式排列方式使輸出訊息具有高非線性之特徵，在模擬姿態類型之複雜曲線比 MFNN 來的容易。

應用 CCN-RTS 架構在低價位 MEMS 之 IMU 下，即可使 KF 所推估的姿態值達到高精度。換句話說，此架構將大幅提升 MEMS 系統內由 KF 與 RTS 平滑器推估之 POS 參數誤差，尤其在姿態參數上。因此本演算法在低價位 MEMS 級 IMU 用於車載測繪系統上為相當有效之工具，具有促進未來使用低價位中等級 MMS 系統的發展。而該 MMS 系統可有效收集現實世界中載體所拍攝之目標物坐標，例如門牌、道路分界、建物位置等等。配合相關影像處理與目標物類別分析，即可使測量作業自動化並達到降低人工成本與節省時間之改進。

## 致謝

本研究承國科會研究計畫 (NSC NSC 95-2221-E-006 -335 -MY2) 部份經費資助下得以完成，特此感謝。

## 參考文獻

1. Alpaydin, E., 1991, *GAL, Neural Networks that grow when they learn and shrink when they forget*, International Computer Science Institute, TR 91-032.
2. Bar-Itzhack, I.Y. and Berman, N., 1988, *Control Theoretic Approach to Inertial Navigation System*, AIAA Journal of Guidance, Control & Dynamics, Vol. 11, pp. 237-245.
3. Brown R.G. and Hwang P.Y.C., 1992, *Introduction to random signals*, John Wiley and Sons, New York, 1992.
4. Chiang, K. W. Noureldin, A. and El-Sheimy, N., 2003, *A New Weight Updating Method for INS/GPS Integration Architectures Based on Neural Networks*, Measurement Science and Technology Vol.15, No.10, pp. 2053-2061
5. Chiang, K.W., 2004, *INS/GPS Integration Using Neural Networks for Land Vehicular Navigation Applications*, PhD Thesis, Department of Geomatics Engineering, the University of Calgary, Calgary, Canada, UCGE Report 20209
6. El-Sheimy, N., 1996, *The Development of VISAT - A Mobile Survey System for GIS Applications*, Ph.D. thesis, UCGE Report No. 20101, Department of Geomatics Engineering, the University of Calgary.
7. El-Sheimy, N., 2002, *Introduction to Inertial Navigation*, ENGO 699.71 lecture

- notes, Geomatics department, University of Calgary.
8. Gelb, A., 1974, *Applied Optimal Estimation*, The Analytic Science Corporation.
  9. Shin, E.H. and El-Sheimy, N., 2005, *Navigation Filter Design for Pipeline Pigging*, Journal of Navigation (2005), 58: 283-295 Cambridge University Press.
  10. Fahlman, S.E. and Lebiere, C., 1990, *The cascade learning Architecture*, In D.S. Touretzky (Ed.), *Advances in Neural Information Processing System 2*, Denver, CO, Morgan Kaufmann Publishers, pp.198-209.
  11. Haykin, S., 1999, *Neural Networks: A Comprehensive Foundation*, 2nd Edition, Prentice-Hall, New Jersey
  12. Shin, E.H., 2005, *Estimation Techniques for Low-Cost Inertial Navigation*, Ph.D. thesis, UCGE Report 20219, Department of Geomatics Engineering, The University of Calgary.
  13. Vanicek, P. and Omerbasic, M., 1999, *Does a navigation algorithm have to use Kalman filter?*, Canadian Aeronautics and Space Journal, Vol. 45, No. 3, September, 1999.
  14. Lin, C.Y., 2008, *The Development of Hybrid INS/GPS integration Schemes Using Artificial Neural Network*, Master's thesis, Department of Geomatics, National Cheng Kung University.
  15. Park, M. and Gao, Y., 2008, *Error and Performance Analysis of MEMS-based Inertial Sensors with a Low-cost GPS Receiver*, Sensors, 8, pp.2240-2261.