

GPS 監測站高程變化之多因子估測模式— 以北港 GPS 衛星追蹤站為例

Multi-variable Estimation of Height Variations at Pei-Kang GPS Permanent Station

陳鴻智¹ 洪本善² 張嘉強³

H. Z. Chen P. S. Hung C.C. Chang

摘要

臺灣西南地區，因養殖漁業、工廠大量抽取地下水，使該地區地層產生下陷致生潛在危機。由於高程變化或許為自然界各種力量與因素，諸如時間、流量、水位、地下水等綜合結果，本研究收集該追蹤站附近之水文資料：計有北港溪流量及其水位，和地下水水位等觀測近 11 年（1995 年至 2005 年）期間資料，針對長（一年）週期資料，以類神經網路及線性迴歸兩種方法探討影響因子(如時間、流量、水位、地下水水位)對高程變化之推估。測試結果顯示，高程變化多因子估測模式之誤差 RMS 值平均為 $\pm 1\text{cm}$ ；影響高程變化的主要項目仍為時間因子，其次為地下水水位。為進一步了解因子間共同對高程變化估測情形，本研究將時間因子為基礎再加入上述因子，進行估測，測試結果顯示，以時間因子並加入上述三個因子的估測模式之誤差 RMS 值平均亦達到 $\pm 1\text{cm}$ 級，顯示高程變化是受自然界各種力量與因素混合影響。

關鍵詞：GPS 高程、神經網路、線性迴歸分析。

Abstract

Due to the heavy withdrawal of underground water for cultivating fishery and industrial factories, the land subsidence occurred in southwestern Taiwan has resulted in environmental hazard and potential risk. Since the land subsidence is possibly related to various natural factors, such as time, stream flow rate, ground water elevation or underground water level, etc., which were collected for around 11 years (from 1996 to 2005) near PKGM, this paper also investigates the factor identification based on the height predictions using a multi-variant type of regression model and artificial neural network model. It was found that the prediction models can present a RMS ± 1 cm level of height prediction error. Moreover, the most dominating influence factor was tested to be the variable of time. The factor of time plus stream flow rate, ground water elevation and underground water level can also present a RMS ± 1 cm level of height variation in a significant land subsidence area. It showed that the land subsidence is related to various natural factors.

Key word: GPS Height, Neural Network, Linear Regression.

1 內政部國土測會中心測量員、逢甲大學土木及水利工程研究所博士候選人

2 逢甲大學建設學院土地管理學系系主任

3 清雲科技大學應用空間資訊系教授

一、前言

濁水河流域下游沖積扇的臺灣西南地區，地層下陷是一個長期為人們所關心的問題((Liu, et al., 2001; Liu, et al., 2004)，咸認為地層下陷是與雲嘉地區大量抽取地下水有關，這種在軟地層上長期抽取地下水後，業導致每年下陷量達公分級(Chang, 2000)。由於人口增長及養殖需要，抽取地下水的情形近年來尚無有效的減緩，地層下陷區域有逐漸往內陸擴展並對公共建築造成潛在的影響(Chang, 2006)。

要關注地層下陷造成的災害，監測與了解地層下陷的大地測量技術與方法便顯得重要了(Bitelli, et al., 2000)。事實上，高精度空間大地測量監測技術，尤其是全球定位系統(GPS)已經遠遠凌駕傳統地面測量技術(Herring, 1999)。GPS 監測站持續不斷的觀測作業，已可得到相當高精度的 GPS 成果(Bock, et al., 1997)。上述成果公分級的精度，基本上足供諸如地層運動或地層下陷研究應用。

鑑於此，有必要建立一運用 GPS 監測資料的預測技術以推估未來地層下陷，俾供防災等安全方面參考。

二、研究地區及資料

由於高程變化或許為自然界各種力量與因素，諸如時間、流量、水位、地下水等綜合結果，本研究試以位於雲嘉地區之內政部北港衛星 GPS 追蹤站(位置如圖 1 所示)作高程變化推估，同時收集該追蹤站附近之水文資料：計有北港溪流量及其水位，和地下水水位等資料，以類神經網路及線性迴歸兩種方法探討多因子對高程變化之推估，由於神經網路需要較多的資料才能建模的特性，以一年期模式對未來 GPS 測點之高程進行估測。




圖 1、內政部北港衛星追蹤站位置圖

本研究收集了該追蹤站觀測近 11 年 (1995 年至 2005 年) 期間之每週 GPS 高程監測成果，資料總計有 533 筆，其高程成果之變化趨勢，呈現穩定下降的趨勢，每年約下降 4 公分，如圖 2 所示。




圖 2 、1995 年至 2005 年之 PKGM 每週高程觀測值

由於高程變化或許為自然界各種力量與因素，諸如時間、流量、水位、地下水等綜合結果，本研究亦收集了距離追蹤站附近約 2 公里處之北港 2(PEIKANG2)，位置如圖 3 所示，(經濟部水文水資源資料管理供應系統，2007)同時段觀測之水文資料：計有北港溪水位及其流量，和地下水水位等觀測資料，上述三資料分別如圖 4、圖 5 和圖 6 所示。

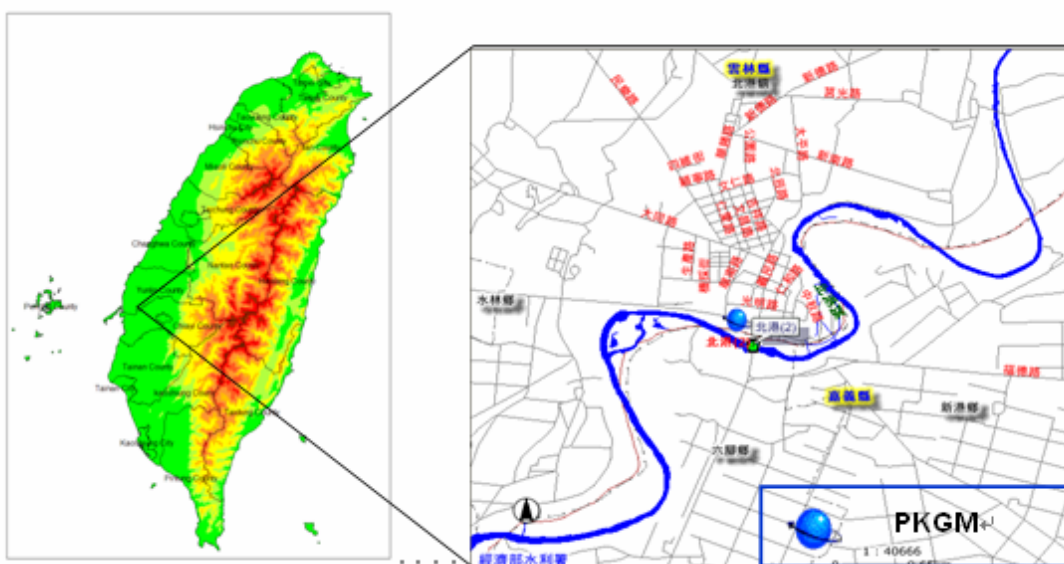


圖 3 、PEIKANG2 位置圖




圖 4 、1995 年至 2005 年之 PEIKANG2 每週水位觀測值




圖 5、1995 年至 2005 年之 PEIKANG2 每週流量觀測值




圖 6、1995 年至 2005 年之 PEIKANG2 每週地下水位觀測值

三、研究方法

本研究採用神經網路法與迴歸分析法來探討多因子 GPS 監測站高程變化推估方式。以下將分別介紹其基本原理。

3.1 倒傳遞神經網路模型

神經網路 (Artificial Neural Networks, ANN) 係模仿人類思維模式所歸納出的學習演算法則，經由學習的過程，達到自動化預測與辨識的能力 (Hu et al. 2004; Stopar et al. 2006)。神經網路中之神經網路是由大量稱為神經元或節點的簡單信息處理元件組成。每個處理元件 X_1, X_2, \dots, X_n 間的路徑稱為連結，且各自連結一個加權值 $W_{1j}, W_{2j}, \dots, W_{nj}$ (Hagan et al., 1996; Haykin, 1999; Kumar, 2006)；輸出值 Y_j 是將輸入值的加權乘積和經轉換函數 f 轉換，其表示如下式所示：

$$Y_j = f\left(\sum_{i=1}^n W_{ij} X_i - b_j\right) \quad (1)$$

式中 W_{ij} 是層間節點 i 和 j 間的連接權， b_j 是節點 j 的門檻值。

多層節點模型與誤差反向傳播 (Error Back Propagation, BP) 算法是目前一種比較成熟而又應用最廣泛的神經網路模型和算法，它把一組樣本的輸入輸出問題轉化為一個非線性優化問題，可由大量數據找出規律。神經網路擬合序列的優點為：

1. 具有模仿多種函數的能力，包括非線性函數、分段函數等。
2. 傳統的數據序列辨識方法必須事先假設數據間存在某種類型的函數關係，而神經網路則係利用數據變量自身屬性建立相關的函數關係，它不需要預先假設基本的參數分布。

3.可以避免系統數據辨識方法在序列累加時因正負抵消而產生失真。

本研究採用倒傳遞神經網路，該網路由輸入層、隱含層和輸出層構成。整個訓練過程由正向和反向傳播過程組成，如圖 7。

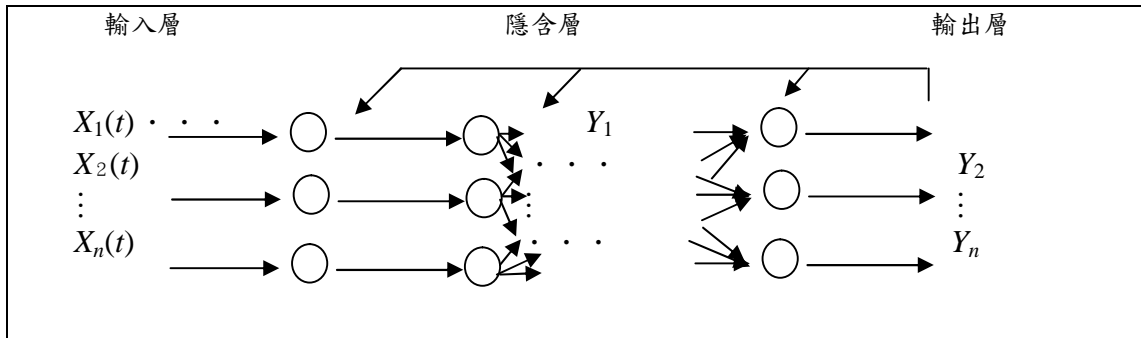


圖 7、三層 BP 網路模式

倒傳遞神經網路的學習法則，主要是針對網路學習誤差函數與網路連結加權值，進行網路學習誤差的最小化與權值不斷調整的過程。其學習算法可列整如下：

- 1.讀入經預處理的訓練樣本集 $\{Y_j^0\}$ 與目標集 $\{T_j\}$ ；
- 2.用隨機數初始化 W_{ji}^0 和 b_j^0 ；
- 3.計算各層節點的輸出：

$$Y_j^n = f(\sum W_{ji}^n Y_j^{n-1} - b_j^n) \quad (2)$$

式中 Y_j^n 第 n 層節點 j 的輸出， Y_j^{n-1} 同時為第 $n-1$ 層節點 j 的輸出，同時為第 n 層節點 j 的輸入； W_{ji}^n 為連接第 $n-1$ 層節點 i 與第 n 層節點 j 之間的權重值； b_j^n 為第 n 層節點 j 的偏置值。

- 4.誤差函數 E 計算誤差：

$$E_j = \left(\frac{1}{2}\right) \sum_{j=1}^p (T_j^n - Y_j^n)^2 \quad (3)$$

係網路輸出值 Y_j^n 與訓練範例目標值 T_j^n 之間的差異值。

採用快速下降梯度演算法，對(3)式求導後可得網路權重值修正量 ΔW_{ji}^n 如下：

$$\Delta W_{ji}^n = -\eta \frac{\frac{\partial E}{\partial W_{ji}^n}}{\frac{\partial E}{\partial W_{ji}^{n-1}} - \frac{\partial E}{\partial W_{ji}^n}} \Delta W_{ji}^{n-1} = \alpha_{ji}^n \Delta W_{ji}^{n-1} \quad (4)$$

(4)中

$$\alpha_{ji}^n = -\eta \frac{\frac{\partial E}{\partial W_{ji}^n}}{\frac{\partial E}{\partial W_{ji}^{n-1}} - \frac{\partial E}{\partial W_{ji}^n}} \quad (5)$$

(5)中

η 為網路學習速度，對 α_{ji}^n 而言最大允許值為 1.75(Fahlman,1998)

- 5.由步驟 4 所得的權重值改正值，修正網路中的權重值：

$$W_{ji}^{k+1} = W_{ji}^k + \Delta W_{ji}^k \quad (6)$$

- 6.重複步驟 3 到步驟 5，直到整體誤差低於所定的門檻值時，便停止運算。

3.2 線性迴歸分析

迴歸(regression)方程可對自變量 $x_{1i}, x_{2i}, \dots, x_{ni}$ 的一組特定值去預測因變量 y 可能

的值，其是迴歸分析當中應用最廣的一種應用。本文相關之資料推估則是採用一次線性迴歸方程

$$y_i = b_0 + b_1x_{1i} + b_2x_{2i} + \dots + b_nx_{ni}, \quad i = 1, 2, \dots, n \quad (7)$$

式中， b_0 為常數，為迴歸線與 y 軸相交值， b_1, \dots, b_n 為迴歸係數； $x_{1i}, x_{2i}, \dots, x_{ni}$ 為時間、流量、水位、地下水水位等變量， y_i 為高程值。

四、資料處理與成果分析

本研究使用之神經網路係 Alyuda 公司研發的 Alyuda NeuroIntelligence Ver2.1 軟體 (Alyuda Research Inc, 2003)，該軟體以隨機取樣方式決定訓練樣本、測試樣本與驗證樣本 (如圖 8)，另經程式計算後可自動算出最佳之隱含層數 (如圖 9)。

TRN	VLD	TST	IGN	(N) Column #1	(N) Column #2	(N) Column #3	(N) Column #4	(N) Column #5
TRN	1995.288462	43.182	10.86143	-16.61	1.544286			
TRN	1995.307692	43.177	14.57429	-17.4	1.517143			
TRN	1995.326923	43.152	14.79	-18.21	1.511429			
TRN	1995.346154	43.156	83.71429	-18.11286	1.527143			
VLD	1995.365385	43.164	22.67429	-17.61429	1.651428			
TRN	1995.384615	43.167	17.34	-17.21428	1.704286			
TRN	1995.403846	43.172	21.41857	-17.77286	1.69			
VLD	1995.423077	43.164	18.12857	-17.60428	3.46			
TRN	1995.442308	43.163	184.7229	-16.60857	2.862857			
VLD	1995.461538	43.163	20.48143	-16.18714	2.041429			
TST	1995.480769	43.157	22.87572	-16.51	2.035714			
TRN	1995.5	43.16	20.50143	-16.26429	2.021429			
TRN	1995.519231	43.163	17.43143	-16.18143	2.057143			
TRN	1995.538462	43.158	126.2343	-16.80143	2.077143			
TRN	1995.557692	43.167	23.21857	-16.26571	2.544286			
VLD	1995.576923	43.163	21.91286	-15.54857	2.982857			

圖 8、神經網路之訓練、測試與驗證樣本

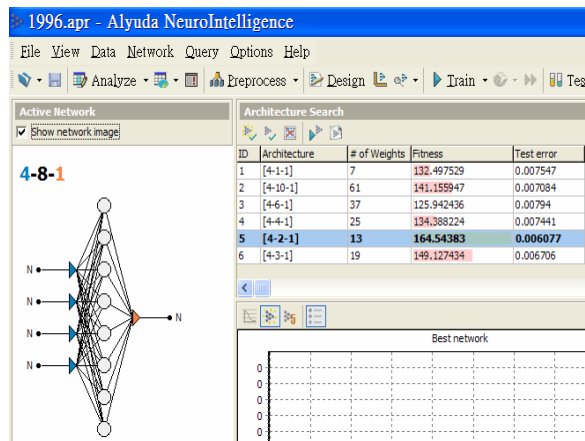


圖 9、神經網路之隱含層數

訓練時所用的函數與各項參數的選定，其所使用的訓練演算法計 7 種 (如圖 10)，而本研究所用之函數與各項參數均為程式內定選用函數與參數值，其中訓練函數採 Quick Propagation 函數，訓練函數參數係數為 1.75，學習速率為 0.1。經選定訓練函數與各項參數後，測試網路結果可示如圖 11。

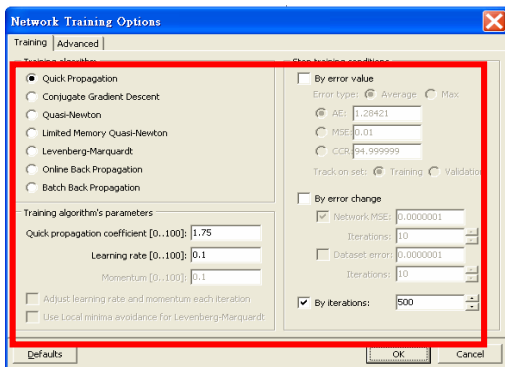


圖 10、神經網路之函數與參數選定




圖 11 神經網路之測試網路

在進行高程值之預測計算時，由各分析模式在成果比對時間點(一年取 12-13 個值，分別為每四週取一筆)上，所預測之高程值，在與實際觀測之高程值比較後，其估測誤差之 RMS (root mean square)即可用來評估各分析模式之運用效能。

4.1 單因子模式

為了解研究區影響高程變化的主要因子，本階段將時間、流量、水位、地下水水位項目各別地以神經網路法與迴歸分析法計算預測之高程值，在與實際觀測之高程值比較後，其估測誤差之 RMS (root mean square)即可用來評估各分析模式之運用效能。

神經網路法估測誤差之 RMS 平均值介於 $\pm 1.1\text{cm}$ 至 $\pm 2.8\text{cm}$ 間，標準差介於 0.4cm 至 1.5cm 間；線性迴歸分析法估測誤差之 RMS 平均值介於 $\pm 1.4\text{cm}$ 至 $\pm 2.7\text{cm}$ 間，標準差介於 0.9cm 至 1.6cm 間，詳如表 1 所示。由表中可知，影響高程變化的主要項目仍為時間因子，其次為地下水水位。單因子推估模式估測高程誤差之 RMS 變化如圖 12 所示。

表 1、單因子推估模式估測高程誤差之 RMS

成果比對 時間點	神經網路法(cm)				線性迴歸分析法(cm)			
	(a)	(b)	(c)	(d)	(a)	(b)	(c)	(d)
1996	0.9	2.0	1.8	1.9	1.0	1.9	2.0	2.0
1997	0.8	1.7	2.7	1.9	0.7	1.8	2.6	1.8
1998	1.0	1.4	1.4	1.2	1.1	1.3	1.3	1.2
1999	0.8	2.2	2.7	2.1	0.8	2.3	2.8	2.1
2000	1.0	2.8	3.1	2.6	0.9	2.5	3.1	2.8
2001	0.8	1.2	2.1	1.4	0.9	1.1	2.2	1.2
2002	2.2	5.6	6.4	4.5	3.8	6.5	6.4	5.3
2003	1.2	2.6	2.9	2.3	1.7	2.5	2.5	2.1
2004	1.3	2.0	2.8	1.9	1.8	2.5	2.7	2.4
2005	1.0	1.1	1.2	1.1	1.0	1.1	1.1	1.2
平均	1.1	2.3	2.8	2.1	1.4	2.4	2.7	2.2
標準差	0.4	1.3	1.5	1.0	0.9	1.6	1.5	1.2

註:(a):時間; (b):流量; (c):水位 (d): 地下水水位




圖 12、單因子推估模式估測高程誤差之 RMS

4.2 多因子模式

從單因子分析知影響高程變化的主要項目為時間因子，本階段於是將時間因子為基礎再將流量、水位、地下水水位項目加入，作兩兩估測，並同時將前述四個因子項目一起加入作分析探討。

神經網路法估測誤差之 RMS 平均值介於 $\pm 1.1\text{cm}$ 至 $\pm 1.4\text{cm}$ 間，標準差介於 0.4cm 至 0.8cm 間；線性迴歸分析法估測誤差之 RMS 平均值介於 $\pm 1.1\text{cm}$ 至 $\pm 1.4\text{cm}$ 間，標準差介於 0.5cm 至 0.9cm 間，詳如表 2 所示。測試結果顯示，以時間同時加入上述三個因

子的估測模式之誤差 RMS 值平均亦達到 $\pm 1\text{cm}$ 級，顯示高程變化是受自然界各種力量與因素混合影響。多因子推估模式估測高程誤差之 RMS 如圖 13 所示。

表 2、多因子推估模式估測高程誤差之 RMS

成果比對 時間點	神經網路法(cm)				線性迴歸分析法(cm)			
	{(a),(b),(c), (d)}	{(a),(b)}	{(a),(c)}	{(a),(d)}	{(a),(b),(c), (d)}	{(a),(b)}	{(a),(c)}	{(a),(d)}
1996	1.0	0.8	1.9	0.9	0.7	1.0	1.0	0.8
1997	0.8	0.9	0.8	0.9	0.7	0.8	0.7	0.8
1998	1.2	1.3	1.0	1.1	1.1	1.1	1.1	1.1
1999	1.1	0.8	1.1	0.9	0.9	0.9	0.9	0.9
2000	1.1	0.7	3.2	1.0	1.0	0.9	0.9	1.0
2001	0.9	0.5	0.8	0.5	0.7	0.8	0.8	0.8
2002	2.2	2.3	2.5	2.4	2.3	3.8	3.1	2.5
2003	1.3	1.1	1.3	1.3	1.4	1.6	1.5	1.5
2004	1.0	1.5	1.3	1.1	1.2	1.7	1.8	1.1
2005	0.6	1.0	0.8	0.6	0.6	1.0	1.0	0.6
平均	1.1	1.1	1.4	1.1	1.1	1.4	1.3	1.1
標準差	0.4	0.5	0.8	0.5	0.5	0.9	0.7	0.5

註:(a):時間; (b):流量; (c):水位 (d): 地下水水位

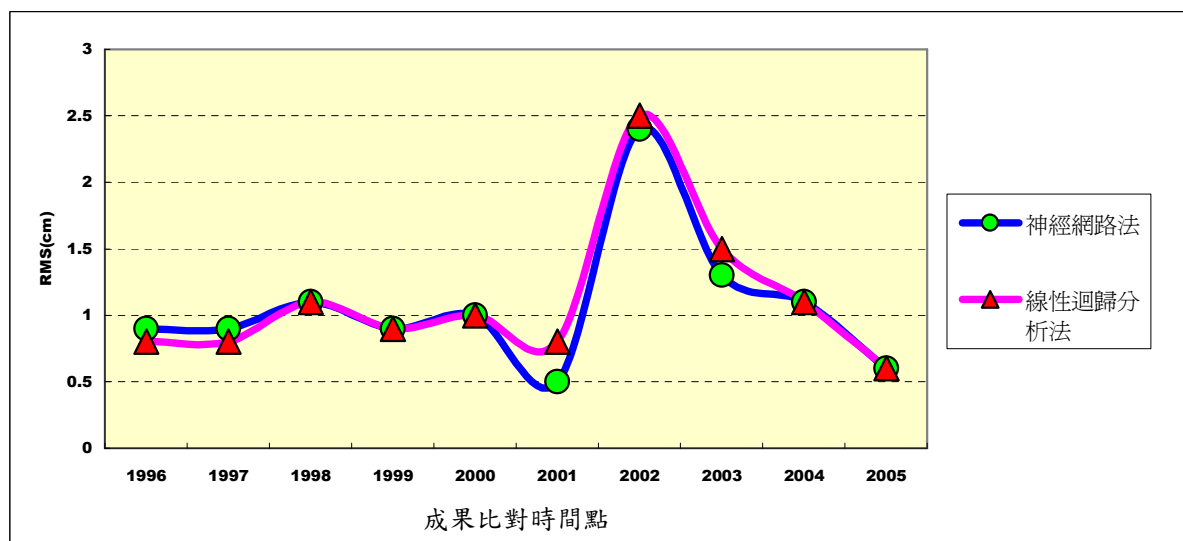


圖 13、多因子推估模式估測高程誤差之 RMS

五、結論與建議

針對本研究之測試結果，可以進一步加以探討說明如下：

1. GPS 測點之高程變化推估模式，採單因子方式，依據研究的過程瞭解，影響高程變化的主要項目仍為時間因子，其次為地下水水位。無論就上述兩因子而言，採用神經網路法（估測誤差 RMS 平均值分別為 $\pm 1.1\text{cm}$ 及 $\pm 2.1\text{cm}$ ）略優於線性迴歸分析方法（估測誤差 RMS 平均值分別為 $\pm 1.4\text{cm}$ 及 $\pm 2.2\text{cm}$ ）。

2. 為進一步了解高程變化或許為自然界各種力量與因素，諸如時間、流量、水位、地下水等綜合結果，依據研究的過程瞭解，以時間同時加入上述三個因子的估測模式

之誤差 RMS 值平均亦達到 $\pm 1\text{cm}$ 級，顯示高程變化是受自然界各種力量與因素混合影響。

3.本研究探討之 GPS 高程估測模式，發現影響高程變化的主要項目為時間因子，似可進一步探討除去時間波動影響後，看看有無微小影響因子，並續以人工智慧之方式發掘出其關連以更精準的預測高程之變化。

參考文獻

- 經濟部水文水資源資料管理供應系統，2007，<http://gweb.wra.gov.tw/wrweb/index.htm>.
- Alyuda Research Inc., 2003. Alyuda NeuroIntelligence Ver. 2.1 Help, Alyuda Research Inc.
- Bitelli, G., F. Bonsignore and M. Unguendoli, 2000. Leveling and GPS Networks to Monitor Ground Subsidence in the Southern Po Valley, *Journal of Geodynamics* 30, pp. 355-369.
- Bock, Y., S. Wdowinski, P. Fang, J. Zhang, S. Williams, H. Johnson, J. Behr, J. Genrich, J. Dean, M. van Domselaar, D. Agnew, F. Wyatt, K. Stark, B. Oral, K. Hudnut, R. King, T. Herring, S. Dinardo, W. Young, D. Jackson and W. Gurtner, 1997. Southern California Permanent GPS Geodetic Array: Continuous Measurements of Regional Crustal Deformation, *Journal of Geophysical Research* 102(B8), pp. 18013-18033.
- Chang, C. C., 2000. Estimation of Local Subsidence Using GPS and Leveling Data, *Surveying and Land Information System* 60(2), pp. 85-94.
- Chang, C. C. and T. N. Wang, 2006. GPS Monitoring of Land Subsidence Associated with Seasonal Underground Water Decline: Case Analysis for a Section of Taiwan High Speed Rail, *Surveying and Land Information Science*, 66(1), pp. 45-54.
- Fahlman, S.E., 1998. Faster-learning variations on back propagation: A empirical study, in *Proc. 1998 Connectionist Models Summer School*(San Mateo, CA, D. Touretzky, G. Hinton, and T. Sejnowski (eds.), Morgan Kaufmann, pp. 38-51.
- Hagan, M. T. H. B. Demuth and M. Beale, 1996. *Neural Network Design*, PWS Publishing Company.
- Haykin, S., 1999. *Neural Network*, PWS Publishing Company.
- Herring, T. A., 1999. Geodetic Applications of GPS, *Proceeding of the IEEE*, 87(1), pp. 92-110.
- Hu, W., Y. Sha and S. Kuang, 2004. New Method for Transforming Global Positioning System Height into Normal Height Based on Neural Network, *Journal of Surveying Engineering*, 130(1), pp. 36-39.
- Huang, Y. P. and C. H. Huang, 1997. Real-valued Genetic Algorithms for Fuzzy Grey Prediction System, *Fuzzy Sets and Systems*, 87(3), pp. 265-276.
- Kumar, S., 2006. *Neural Network*, McGraw-Hill.
- Liu, C. H., Y. W. Pan, J. J. Liao, C. T. Huang and S. Ouyang, 2004. Characterization of Land Subsidence in the Choshui Reiver Alluvial Fan, Taiwan, *Environmental Geology* 45, pp. 1154-1166.
- Liu, C. W., W. S. Lin, C. Shang and S. H. Liu, 2001. The Effect of Clay Dehydration on Land Subsidence in the Yun-Lin Coastal Area, Taiwan, *Environmental Geology* 40(4-5), pp. 518-527.
- Sato, H. P., K. Abe and O. Ootaki, 2003. GPS-measured Land Subsidence in Ojiya City, Niigata Prefecture, Japan, *Engineering Geology* 67, pp. 379-390.
- Stopar, A., M. Kuhar and G. Turk, 2006. GPS-derived Geoid Using Artificial Neural Network and Least Squares Collocation, *Survey Review* 38, pp. 513-524.