

倒傳遞類神經網路在長時期潮汐預報之應用

蔡清標¹

教授¹

國立中興大學土木系^{1,2,3}

李宗霖²

博士後研究²

謝榮哲³

研究生³

中央氣象局海象測報中心⁴

李汴軍⁴

主任⁴

摘要

本文係藉由倒傳遞類神經網路結合調和方程式，建立可以預報長時期潮汐變化的模式。一般的潮汐預報，往往需要使用長達 1 年以上的實際觀測資料，以頻譜分析方法，求得主要分潮，再代入調和分析或數值模式來預測潮汐水位。然而，本文的預報模式可在有限的資料中，學習過去的潮汐變化特性，進而推算主要分潮，並預測潮汐序列的變化。本文研究結果顯示，使用 2 個月的實測資料，就能順利地推算出主要分潮，而以半個月的觀測資料作為類神經網路的學習，即可相當準確地預測半日潮、全日潮及混合潮等不同潮汐形態，在未來一年內的潮位變化。

Artificial Neural Network in Long-Term Tidal-Level Forecasting

Ching-Piao Tsai¹ Tsong-Lin Lee² Rong-Jer Shieh³ Beng-Chun Lee⁴

Professor¹

Postdoctoral Researcher²

Graduate student³

Director⁴

Department of Civil Engineering, National Chung-Hsing University^{1,2,3} Marine Meteorology Center, Central Weather Bureau⁴

ABSTRACT

Accurate forecasting for tidal-level variation is of great importance for construction installations or human activities in maritime areas. This paper reports an application of the artificial neural network associated with the harmonic equation to forecast the long-term tide level. The tidal level could be predicted conventionally by the harmonic analysis based on the least square method. Good resolution in the conventional methods demands a sufficiently long records to ascertain the parameters of the major constituents. Alternatively, the present model can determine the harmonic parameters using a short-term observed tidal records based on a learning process. Field data of three types of tides, referred as the diurnal, semidiurnal and mixed types, are used to test the performance of the present model. The results show that the major constituents can be obtained only using a two-months measured data. The results also present that one-year tidal level forecasting can be satisfactorily achieved using a half-month length of observed data.

施及人類休閒活動等將可提供極大的俾益。

一、前言

隨著工商業的進步，人口密度的增加，陸地上空間的使用已日益飽和，因此，為了持續經濟活動所需之建設及擴展空間的需求，海岸的開發與利用已蔚為趨勢。然而，在海岸開發與休閒活動時，如海洋工程的施工、船隻行駛、沿海漁業及親水活動等均與海象有關，其中以潮汐和人類的活動關係最為直接與密切。故若能提供長期的潮汐預報，及由短期實測資料建立長期預測模式，對海洋工程的設計、海上作業、海岸防災措

潮汐的形成，主要是由月球與太陽對地球引力不同所引起之週期性海水面升降現象。而在往昔潮汐預報的研究中，Darwin[1]針對開放海域的前題下，提出平衡潮理論(Equilibrium Tide Theory)，定性地描述潮汐現象，但因近岸海底地形非常錯綜複雜，以致平衡潮理論常無法直接用來預測潮汐。Doodson[2]提出調和分析法(Harmonic Analysis)來預測潮汐，文中係以最小二乘法求出各分潮的振幅及相位角，即所謂的調和常數，再代入調和方程式中預測潮汐，因此法簡

便，故至今仍廣泛地被應用。依其理論，任何一地之潮位 Y 可表示成下式

$$Y(t) = A_0 + \sum_{i=0}^N A_i \cdot \cos(\omega_i t) + \sum_{i=0}^N B_i \cdot \sin(\omega_i t) \quad (1)$$

式中 $Y(t)$ 代表某時刻之潮位， A_0 為平均海水位， A_i 及 B_i 為某分潮之振幅分量， ω_i 表某分潮運行之角速度及 N 為分潮個數。

當某測站有長期的潮汐水位記錄(如 369 天以上)，可先藉頻譜分析法(Spectral Analysis)決定出主導當地海域潮汐的分潮個數 N ，另式中之 A_0 、 A_i 及 B_i 則可由最小二乘法求解之。Yen et al.[3] 提出以卡門濾波法(Kalman Filter Method)推求潮汐模式之最佳調和參數，此法雖可以較短時期之潮位即可達到高精度的預測要求，但該模式仍得引用已知之主要分潮。Tsai & Lee[4] 則應用倒傳遞類神經網路(back-propagation neural network, BPN)作即時(real time)的潮汐預報，預測結果相當精確，但美中不足的是該模式無法提供長時期的預測。

隨著科學的進步，人類對神經生理學、心理學，及非線性最优化的問題上已有進一步之瞭解，故以模擬人自身思考演算方式的類神經網路(artificial neural network, ANN)因而產生，其除了在人工智能方面的發展，並且被廣泛的應用於自然現象的預測上。類神經網路的發展，係從 McCulloch 及 Pitts[5]建立類神經網路數學模型開始，其中經歷了由 Minsky[6]提出類神經網路不能解決非線性問題的挫折期，直至 Rumelhart[7]建立完整的倒傳遞類神經網路後，才使得類神經網路逐漸被廣泛重視，並運用於應用科學上。

本研究則以應用倒傳遞類神經網路，結合調和方程式，建立可以預報長期的潮汐水位模式，模式中包括主要分潮的決定。

二、倒傳遞類神經網路

倒傳遞類神經網路(BPN)是屬於多層前授式網路，採用監督式的訓練方法，其網路架構主要包含一輸入層，隱藏層(可以是一層或多層)及一輸出層，如圖 1 所示。

倒傳遞類神經網路的演算過程分為學習過程 (learning process) 及回憶過程 (recalling process)。其中學習過程包含兩個階段：順向傳遞(forward pass)與逆向傳遞(backward pass)。

順向傳遞是從輸入層開始，一層一層向前傳遞並由非線性轉換函數計算各層處理單元的輸出

值，以此類推，直至網路的最後一層。

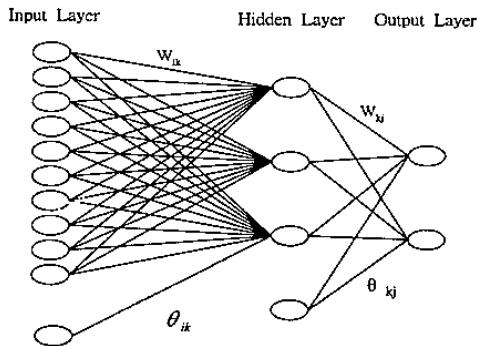


圖 1 類神經網路結構圖

逆向傳遞則是由輸出層向後傳遞，這一階段在於計算誤差及更新連接權重，其方法是將前層的誤差值向後傳遞(error back-propagation)，並以此為依據修改連接權重，接著計算該層的誤差，再將其往後傳遞，直到輸入層。

此學習過程通常以一次一個訓練範例的方式進行，直到學習完所有的訓練範例，且達到網路收斂為止。至於回憶過程則是網路依學習過程中所學習到之連接權值，以輸入向量輸入，推估輸出向量的過程，亦可稱為預測過程(forecasting process)。

此外由於 BPN 演算過程中加入隱藏層的影響，導致計算上易落入區域極小值而產生收斂緩慢的缺點，故為加速網路收斂速度並避免收斂過程中的震盪現象，通常會引入慣性項 α (momentum factor) 及學習因子 η (learning factor)來改善。

三、實例操作

本研究使用三年(1996~1998)的逐日逐時之潮位記錄進行實例操作，實例資料係由中央氣象局和港灣技術研究所提供，測站包含基隆港、台中港及高雄港，其測站位置，如圖 2 所示。高雄港屬於全日潮(diurnal tide)型態，即每日僅有一次高潮和一次低潮；台中港為半日潮(semidiurnal tide)，也就是每日有兩次高潮和兩次低潮；至於基隆港潮汐現象則不單純為半日潮或全日潮，故為混合潮(mixed tide)。

本文以下列兩種統計指標評估網路效能，分別定義如下：

1. 均方根誤差(normalized root mean squared error, RMS)

$$\text{RMS} = \sqrt{\frac{\sum (y_k - \hat{y}_k)^2}{\sum y_k^2}} \quad (2)$$

2. 相關係數(correlation coefficient, C.C.)

$$CC = \frac{\sum_{k=1}^n (y_k - \bar{y}_k)(\hat{y}_k - \bar{\hat{y}}_k)}{\sqrt{\sum_{k=1}^n (y_k - \bar{y}_k)^2} \sum_{k=1}^n (\hat{y}_k - \bar{\hat{y}}_k)^2} \quad (3)$$

式中 n 為範例數， y_k 為第 k 個範例的觀測值， \hat{y}_k 為第 k 個範例的預測值， \bar{y}_k 為觀測值之平均 ($\bar{y}_k = \frac{1}{n} \sum_{k=1}^n y_k$) 及 $\bar{\hat{y}}_k$ 為預測值之平均 ($\bar{\hat{y}}_k = \frac{1}{n} \sum_{k=1}^n \hat{y}_k$)。



圖 2 基隆、台中及高雄潮位站位置圖

由於本文使用於神經網路之轉換函數係採用雙彎曲函數(Sigmoid function : $f(x) = 1/(1+e^{-x})$)，其函數值域介於 0 至 1 之間，因此需將訓練對與測試對的資料正規化處理。正規化方程式為

$$x_{\text{new}} = \left[D_{\min} + \frac{x_{\text{old}} - x_{\min}}{x_{\max} - x_{\min}} \times (D_{\max} - D_{\min}) \right] \quad (4)$$

其中， D_{\min} 與 D_{\max} 代表線性映射之範圍， x_{\max} 和 x_{\min} 為序列中之極大值與極小值， x_{old} 及 x_{new} 則表示為轉換前與轉換後之序列值。

3-1 主要分潮之決定

傳統的主要分潮決定方式，往往需要至少一年次以上之潮位資料(Reid[8])，再以頻譜分析法求得。本文則嘗試利用類神經網路中所對應的權重值關係來判別，權重值愈大，將表示其對應的分潮所佔的成份愈重。為能表現出輸入層與權重之間的關係，使用的倒傳遞類神經網路為無隱藏層。網路的配置中，輸入層置入常用的 69 個天文潮所對應的 $\cos(\omega_i t)$ 及 $\sin(\omega_i t)$ ，而於輸出層放置潮汐水位 $Y(t)$ ，同時分別以 1 個月及 2 個月的潮位資料做為網路學習範例，求取權重與分潮之間的相互關係。以台中港為例，其 1 個月及 2 個月的學習結果則分別如於圖 3 及圖 4 所示。

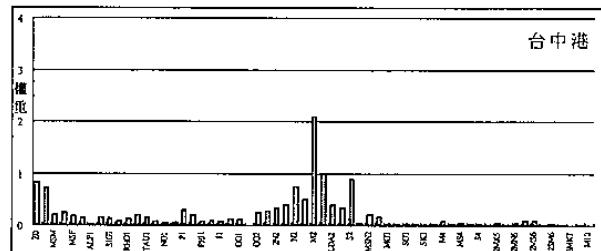


圖 3 以一個月潮汐資料推求主要分潮之結果

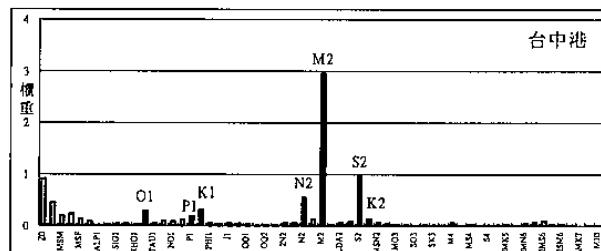


圖 4 以二個月潮汐資料推求主要分潮之結果

由圖 3 結果顯示，以 1 個月的潮位資料只能大略看出此地潮位主要是受全日分潮或半日分潮的影響，而無法彰顯主要分潮，但在圖 4 中 2 個月的潮汐資料學習結果下，即可清楚地看出大約有 5~7 個峰值，分潮大小分別為 $M2$ 、 $S2$ 、 $N2$ 、 $K1$ 、 $O1$ 、 $P1$ 、 $K2$ 等七個，此與劉[9]以兩年之潮汐資料，由頻譜分析之結果相同(如圖 5)。而基隆港及高雄港所分析的分潮，則如表 1 所示。

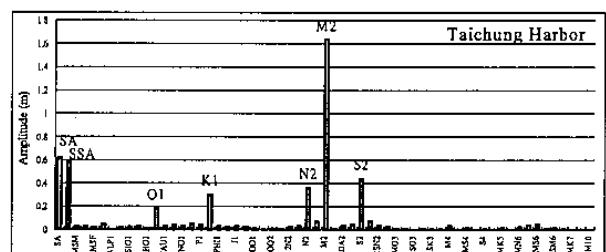


圖 5 以兩年之潮汐資料，由頻譜分析主要分潮之結果

表 1 類神經分析求得之前 7 個分潮

港口	所選取之分潮及對應的權重值
基隆港	$M2$ $K1$ $O1$ $P1$ $S2$ $N2$ $NO1$ (1.35) (0.91) (0.69) (0.41) (0.40) (0.37) (0.21)
台中港	$M2$ $S2$ $N2$ $K1$ $O1$ $P1$ $K2$ (2.94) (0.96) (0.55) (0.32) (0.28) (0.26) (0.14)
高雄港	$M2$ $K1$ $O1$ $S2$ $N2$ $P1$ $CHI1$ (1.55) (1.23) (1.20) (0.54) (0.52) (0.28) (0.26)

一般而言，主要分潮數目的選取將會影響潮汐預報的精度。基此，本文針對輸入不同的分潮數目，對網路預測之效能影響進行分析及討論。表 2 為高雄港的結果為例，表中顯示當輸入分潮為 5 個時，其均方誤差僅為 0.1091，但輸入 6 個分潮，誤差增大為 0.1595，可見 P1 分潮並不能改善預測結果，因此，選取 M2、K1、O1、S2、N2 等 5 個分潮作為高雄港之主要分潮。另各港口分析結果，亦詳列於表 3。

表 2 主要分潮數對預測結果之影響

港口	輸入之分潮名稱	分潮數	RMS
高雄港	M2、K1、O1、S2	4	0.1139
	M2、K1、O1、S2、N2	5	0.1091
	M2、K1、O1、S2、N2、P1	6	0.1595
	M2、K1、O1、S2、N2、P1、CHI1	7	0.1480

表 3 各港口使用之主要分潮

港口	主要分潮名稱	分潮個數
基隆港	M2、K1、O1、P1、S2	5
台中港	M2、S2、N2、K1、O1	5
高雄港	M2、K1、O1、S2、N2	5

3-2 潮汐預報之網路架構

本文潮汐預報模式的網路架構，係於輸入層輸入 $2N$ 個變數(N 為主要分潮數)，各分潮並對應 $\cos(\omega_i t)$ 及 $\sin(\omega_i t)$ ，而在輸出層所輸出的變數只有 1 個，即為所要預測的潮汐水位 $Y(t)$ ，其網路架構如圖 6 所示。

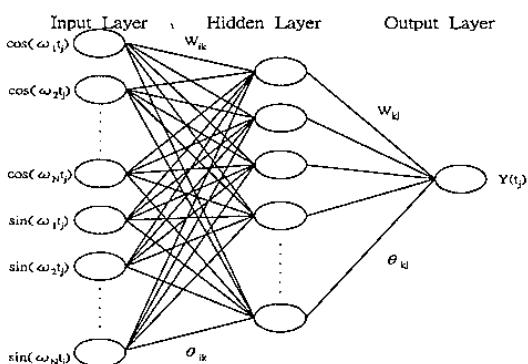


圖 6 預測潮汐各參數之網路架構

一般影響網路效能的因子主要有隱藏層之層數、學習因子 η 、慣性因子 α 及訓練疊代次數(training iterations)等參數。同時由於類神經網路為一非線性化過程，且網路參數間會互相影響，

因此如何調整各參數，架構一最佳模式誠屬不易。本文經過不斷的嘗試，各港口網路參數最佳化之結果，如表 5 所示。

表 5 各港口選用之網路參數

港口	隱藏層層數	η	α	訓練次數
基隆港	1	0.1	0.8	1000
台中港	1	0.01	0.8	1000
高雄港	1	0.01	0.5	1000

由表中發現，一年長期預測的誤差值會隨訓練範例數增加而減少。由整體結果，以 15 天為最佳，其相關係數大多在 0.9 以上，預測誤差亦小於 0.1 以下。然而，當訓練範例數增加至一個月時，其預測誤差則有些微增加，此可能因學習範例增加使網路過於複雜，導致發生過度學習(overlearning)之效果。

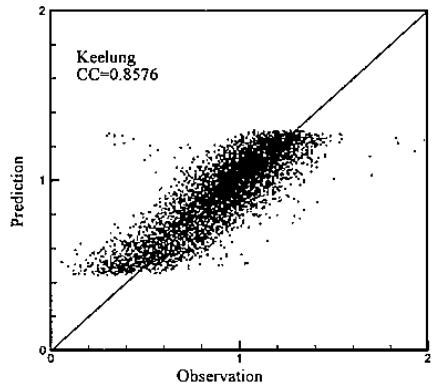
3-3 結果與分析

本文以上述最佳之類神經網路架構為基礎，將各不同範例數做學習，並預測各港口 1 年潮汐水位的變化；而各港口之預測結果則以誤差指標 RMS 及 CC 表示，列於表 6。

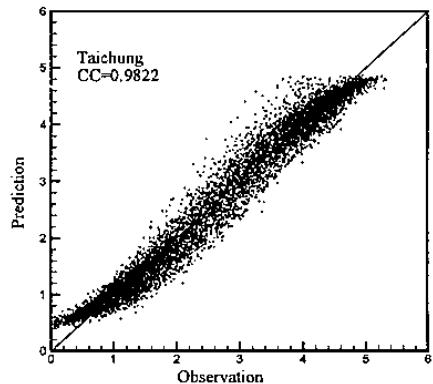
表 6 各港口預測一年潮汐水位結果之比較

港口	訓練組	RMS	CC
基隆港	1 day (13/4/1996)	0.2117	0.6499
	7 days (13~19/4/1996)	0.2032	0.6932
	15 days (13~27/4/1996)	0.1234	0.8931
	30 days (13/4~12/5/1996)	0.1237	0.8947
台中港	1 day (12/4/1996)	0.3815	0.5136
	7 days (12~8/4/1996)	0.2133	0.8775
	15 days (12~26/4/1996)	0.0844	0.9822
	30 days (12/4~11/5/1996)	0.1835	0.9309
高雄港	1 day (2/10/1997)	0.2486	0.4127
	7 days (2~8/10/1997)	0.1583	0.8202
	15 days (2~16/10/1997)	0.1091	0.9127
	30 days (2/10~1/11/1997)	0.1107	0.9111

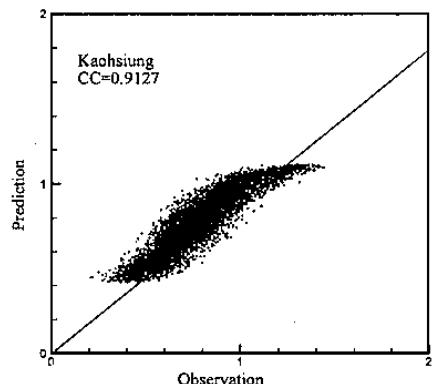
圖 7 為各港口以 15 天預測 1 年潮汐的散佈圖，圖中顯示，以半日潮為主的台中港(b)，預測相關程度很高，而以混合潮和全日潮為主的基隆港(a)及高雄港(c)，預測相關性明顯較低，可見潮型分佈愈單純，預測更理想。



(a)基隆港



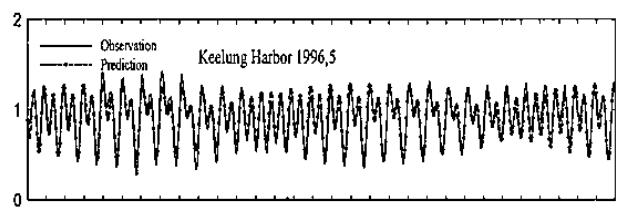
(b)台中港



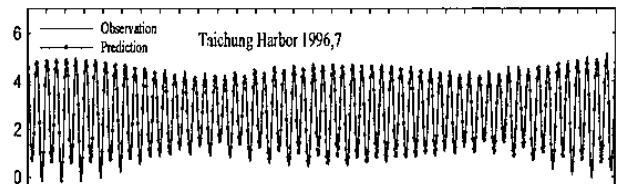
(c)高雄港

圖 7 (a)基隆港、(b)台中港及(c)高雄港預測潮汐之散佈圖

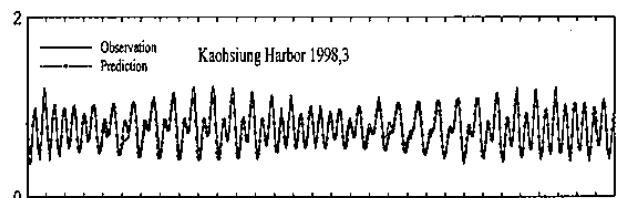
圖 8 為基隆港、台中港及高雄港的 1 年的潮位預測時序圖(文中僅列出部分時間)。圖中顯示，以半日潮為主之台中港(b)因其潮位主要只受半日分潮 M2 的影響，故其潮位變化也比較單純，預測結果最好。而基隆港(a)及高雄港(c)，因受全日分潮 K1、O1 及半日分潮 M2 影響，所以潮位變化也較複雜，預測結果較台中港差，但整體而言，其 RMS 誤差值均在合理的範圍內。



(a)基隆港



(b)台中港



(c)高雄港

圖 8 為(a)基隆港、(b)台中港及(c)高雄港的 1 年的潮位預測時序圖

五、結論

近年來，由於海岸的開發與利用逐漸增加，如海洋工程的施工、船隻行駛、沿海漁業及親水活動等等。然而這些海岸開發規劃則與海象有關，其中以潮汐和人類的活動關係最為直接與密切。所以對海洋工程的設計、海上作業、海岸防災措施及人類休閒等活動的規劃，若能提供長期的潮汐預報，及由短期實測資料建立長期預測模式，將可提供相當大的幫助。本文以倒傳遞類神經網路結合調和方程式，所建立可以預報長時期潮汐變化的模式，除可利用在有限的資料中，學習過去的潮汐變化特性而推算主要分潮外，並僅需以半個月的觀測資料作為類神經網路的學習，即可相當準確地預測半日潮、全日潮及混合潮等不同潮汐形態，在未來一年內的潮位變化。

誌謝

本研究承蒙行政院國家科學委員會之補助 (NSC89-2611-E-005-001)，另承港灣技術研究中心提供台中港與中央氣象局海象測報中心提供基隆港和高雄港之實測潮汐資料，謹誌謝忱。

參考文獻

1. Darwin, G. H. (1892) "On an apparatus for facilitating the reduction of tidal observations," *Proc. Roy. Soc.* (London), Ser. A 52, 345-376.
2. Doodson, A. T. (1957) "The analysis and predictions of tides in shallow water," *Int. Hydrogr. Rev., Monaco.*, 33, 85-126.
3. Yen, P. H., C. D. Jan, Y. P. Lee and H. F. Lee (1996) "Application of Kalman filter to short-term tide level prediction," *J. of Wtrwy, Port, Coast. and Oc. Engrg.*, ASCE, 122(5), 226-231.
4. Tsai, C. P. and Lee, T. L. (1999) "Back-Propagation Neural Network in Tidal-Level Forecasting," *Journal of Waterway, Port, Coastal, and Ocean Engineering.*, Vol. 125, No. 4, pp. 188-195.
5. McCulloch, W. S. and Pitts., W. H. (1976) "A logical Calculus of the Ideas Imminent in Nervous Activity," *Bull. Math. Biophysics*, Vol. 5, pp. 115-123, 1943.Box, G.E.P. and Jenkins, G., Time Series Analysis forecasting and Control, Holden-Day Inc.
6. Minsky, M. and Papert,S.(1969) *Perceptrons*, MIT press., Cambridge, Mass.
7. Rumelhart, D. E., G. E. Hinton and R. J. Williams (1986) "Learning representations by back-propagating errors," *Nature*, 323, 533-536.
8. Reid, R. O. (1990). "Tide and stprm surges." In *Handbook of Coastal and Ocean Engineering*, ed. J.B. Herbich., Vol 1, 534-590.
9. 劉文俊、吳文耀(1996)「台灣海域潮汐特性之初步分析」，中央氣象局研究發展專題。

