

嘉南藥理科技大學補助教師專題研究計畫成果報告

生活污水回收再利用技術與管理：

以類神經網路模式預測生活污水處理廠處理效能

計畫類別：☐個別型計畫 ☒整合型計畫

計畫編號：CNEM9302

執行期間：93 年 1 月 1 日至 93 年 12 月 31 日

總計畫主持人：廖志祥

子計畫主持人：廖志祥

執行單位：嘉南藥理科技大學環境資源管理系

中 華 民 國 九 十 四 年 二 月 二 十 八 日

嘉南藥理科技大學補助教師專題研究計畫成果報告

運用類神經網路預測廢水廠處理效能

計畫編號：CNEM93-02

執行期限：93 年 1 月 1 日至 93 年 12 月 31 日

主持人：廖志祥 嘉南藥理科技大學環境資源管理系

中文摘要

本研究主要是利用類神經網路(Neural Networks)多輸入多輸出系統的能力，運用於生活污水廢水處理廠的放流水質預測模擬。根據實廠的實際操作參數和進流水質，以含有隱藏層的倒傳遞網路(Back-Propagation neural networks)做批次式運算，預測實際的放流水質。本研究建構 5 種含不同變數的模式，進行類神經網路的訓練和預測的比較，研究結果顯示，資料先經正規化處理有助於模式的預測效能並能辨識是否含有不良變數，當含有不良的變數時，正規化後模式的預測效能將會降低。本研究建構的 5 種模式中，其中預測 BOD 和 COD 的精度達到 82%和 88%的模式為最佳的放流水質預測模式，當測得廢水廠當天進流水質時，運用本研究所建構最佳之模式，能迅速的運算而預測當天的放流水質，幫助現場操作人員即時調整操作參數，以使放流的水質能合乎排放標準。

關鍵詞：類神經網路、廢水處理廠、倒傳遞網路。

一、研究目的

一般廢水廠在環保署的規定下，必須定期監測水質資料以確保合乎水質的標準，但是定期花

費成本所監測的數據只提供環保署檢查，如果能運用一種方法再加以利用這些定期產生的數據，將此數據轉變成有用的資訊，以達到善用這些數據的目的。研究建立這種資訊的處理模式可以幫助廢水廠預測各種問題的產生，並且能提供問題的因應對策。

現今有許多模式可以用來處理數據，例如：模糊理論、類神經網路(Neural Networks)、數學模型分析、經驗統計建構法等[1]，類神經網路屬於多輸入多輸出系統並且具有過濾能力，適合應用在廢水廠處理效能的預測。

本研究的目標為將 Montréal Wastewater treatment plant 實廠所得的監測水質數據，以能運用在非線性系統上之倒傳遞類神經網路(Back-Propagation neural networks, BPN)模式為架構[2]，進行經此廢水廠操作過後所放流的水質預測。根據文獻得到類神經網路可以幫助預測擾亂的環境並將放流變動減到最小[3]，所以建立此模式可以幫助廢水廠操作人員因應水質變化而能即時修正操作參數，使得廢水廠能得到最佳的處理，並得到經最佳處理的放流水質。

二、研究方法

1、研究對象

研究的對象為位於加拿大蒙特羅的 Montréal Wastewater treatment plant，此廢水廠為生活污水處理廠，由此廢水廠取得 2001-2002 年之完整水質資料。監測的水質資料包括進流的流量(Flow)、進流的溫度(Temp)、進流的生化需氧量(BODin)、進流的化學需氧量(CODin)、進流的總固體量(TSin)、進流的總磷含量(TPin)，經廢水廠處理後放流的水質資料包括放流的 BODout、CODout、TSout、TPout。進流水質資料有經由南北收集系統而得的 2 種水質資料和混合後的平均水質資料，Fig. 1 為廢水廠的處理程序，由 Fig. 1 可看出經由南北收集系統而來的原水混合後再開始處理，所以取混合後的平均水質資料當網路輸入變數。




Fig. 1 廢水廠處理程序

2、類神經網路

類神經網路(artificial neural network)是模仿生物神經網路的資訊處理系統，以及使用經驗模式(Empirical Model)的一種工具，其包括軟體與硬體的計算系統，使用大量的相連人工神經元(neuron)來模仿生物神經網路的能力。

經驗模式是對研究程序機構一無所知的情況下，將程序視作「黑盒子(Black Box)」，僅僅憑藉程序的輸入與輸出數據，透過數學技巧來決定程序的模式。此數學技巧指的是迴歸分析(Regression Analysis)，即對所取得的數據作曲線擬合(Curve Fitting)[4]。

人工神經元是生物神經元的簡單模擬，從外界環境或其他人工神經元取得資料，並以數學運算輸出其結果到外界環境或其他人工神經元。

3、倒傳遞類神經網路

倒傳遞類神經網路屬於監督式學習網路模式，是根據期望目標值與模式輸出值比較後，進而調整權重值與偏權值的一種模式。圖2是表示倒傳遞網路的架構和演算法的例子，輸入神經元2個，隱藏層1層，隱藏層神經元4個，輸出神經元3個，隱藏層轉移函數使用正切雙彎曲轉移函數(tansig)，輸出層轉移函數使用線性轉移函數(purelin)，其中的演算法會以方程式(1)和方程式(2)解釋。倒傳遞演算法是一種梯度下降(Gradient Descent)演算法，網路權重值是沿著性能函數負的梯度方向移動，使模式輸出值與期望輸出值的差距趨近於0，若有差距，將誤差反向傳遞到各層神經元的權重值與偏權值，藉由權重值和偏權值的改變，使模式輸出值與期望輸出值趨於一致。




Fig. 2 倒傳遞網路結構[4]

Fig. 2 的倒傳遞網路結構所列的演算法列於方程式(1)和方程式(2)：

$$a_1 = \text{tansig}(IW_{1,1}p_1 + b_1) \quad (1)$$

$$a_2 = \text{purelin}(LW_{2,1}a_1 + b_2) \quad (2)$$

其中， p_1 = 輸入； a_1 = 隱藏層輸出； a_2 = 輸出層輸出； IW = 隱藏層權重值； LW = 輸出層權重值； b_1 = 隱藏層偏權值； b_2 = 輸出層偏權值； tansig 和 purelin = 轉移函數。

倒傳遞演算法對於多層網路，其每一層的輸出將成為下一層的輸入，如方程式(3)：

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \quad m = 0, 2, \dots, M-1 \quad (3)$$

其中， M = 網路中層數目； a = 網路輸出； W = 權重值； f = 轉移函數。

轉移函數(Transfer Function)是模仿生物神經元模型的非線性處理機能，是從其它處理單元輸入的輸入加權值之加權乘積和，轉換成處理單元輸出的數學公式。Fig. 3 為 tansig 函數，Fig. 4 為

purelin函數，介紹如下：

tansig 產生介於-1 至 1 之間的輸出，適合應用在輸入層和隱藏層。




Fig. 3 Tansig 轉移函數[4]

purelin 產生任意值的輸出，適合應用在輸出層。




Fig. 4 Purelin 轉移函數[4]

4、資料前處理

正規化處理：將複雜的網路輸入和目標尺度化，使得具零均值和標準差為 1，以減少由於變數範圍小的數據在網路中被忽略，例如：TP 的數據都在個位數以下，而 COD 的數據幾乎都百位數，所以在網路訓練時容易被忽略，正規化方式列於方程式(4)：

$$\text{Normalized Data} = \frac{In - \text{Min}}{\text{Max} - \text{Min}} \quad (4)$$

其中，Normalized Data = 正規化後數值; In = 原始數值; Max = 原始數值中最大值; Min = 原始數值中最小值。

反正規化處理：正規化後經類神經網路訓練後所得之輸出值必須再經過反正規化才能得到真正的輸出值，反正規化方式列於方程式(5)：

$$\text{Renormalized Data} = \frac{\text{Out} - O_{\text{Min}}}{O_{\text{Max}} - O_{\text{Min}}} (\text{Max} - \text{Min}) + \text{Min} \quad (5)$$

其中，Renormalized Data = 反正規化後數值; Out = 網路輸出值; O_{Max} = 網路輸出值中的最大值; O_{Min} = 網路輸出值中的最小值。

5、建立模式

本研究使用的硬體 CPU 為 AMD Athlon XP 1600+，軟體使用 Matlab 5 + Neural networks toolbox。模式建立是以倒傳遞類神經網路模式為架構，建立五種使用不同變數的模式。訓練方式是以整年度數據做批次式訓練和預測，由廢水廠所得的 2001 年數據做訓練，2002 年所得之數據做預測，其預測方式是以當天進流水質預測當天的放流水質。輸入層和隱藏層的轉移函數使用 tansig，輸出層轉移函數使用 purelin。根據文獻證明單一隱藏層的網路以可近似任何的連續函數[5]，隱藏層若已有足夠的神經元，對於任何函數而言，單一隱藏層就足夠[6]。為了避免網路過於複雜與造成掉落局部最小值[7]，而導致無法收斂，所以本研究皆採用一層隱藏層進行運算。建立的五種模式如下：

BPN1

Fig. 5 為 BPN1 架構示意圖，輸入層使用 BODin、CODin、TSin、TPin、Temp、Flow 六變數，輸出層使用 BODout、CODout、TSout、TPout 四變數。




Fig. 5 BPN1 架構示意圖

BPN2

Fig. 6 為 BPN2 架構示意圖，將主要進流和放流 BOD、COD、TS、TP 四項水質分開建立成四種網路架構。主要功能是以最少的變數來進行，以減少變數之間的影響。




Fig. 6 BPN2 架構示意圖

BPN3

以 BPN1 架構為主，去除變數 TS。輸入層為 BODIn、CODIn、TPin、Flow、Temp，輸出層為 BODout、CODout、TPout。

BPN4

以 BPN3 架構為主，去除變數 TP。輸入層為 BODIn、CODIn、Flow、Temp，輸出層為 BODout 和 CODout。

BPN5

以 BPN4 架構為主，去除變數 Temp。輸入層為 BODIn、CODIn、Flow，輸出層為 BODout 和 CODout。

6、效能預測評鑑指標

評鑑倒傳遞類神經網路(BPN)模式預測效能是以相對誤差(RE；方程式(6))、相關係數(R；方程式(7))、平均絕對值誤差率(MAPE；方程式(8))和均方誤差(RMSE；方程式(9))來評估網路預測效能[8]。RE 為預測值與實際值誤差的比率，愈接近 0 代表誤差率愈小，正值代表預測值過大，負值代表預測值過小。R 值是判斷實際值和預測值相關性的指標，愈接近 1 為愈具有相關性。MAPE 愈低代表預測值和實際值的平均誤差率愈小，RMSE 愈低代表預測值和實際值的平均差距愈小。MAPE 和 RMSE 愈接近 0，代表模式的預測精度愈高。

$$RE = \frac{E - M}{M} \times 100\% \quad (6)$$

其中，M = 實際值；E = 預測值。

$$R = \frac{\left(\sum_{t=1}^N M \times E \right) - N \times \bar{M} \times \bar{E}}{(N-1)\sigma_M \times \sigma_E} \quad (7)$$

其中， $\bar{M}$ = 實際值的平均值； σ_M = 實際值的

標準差； $\bar{E}$ = 預測值的平均值

σ_E = 預測值的標準差；N = 樣本數。

$$MAPE = \left(\frac{1}{N} \sum_{t=1}^N \frac{|M - E|}{M} \right) \times 100\% \quad (8)$$

模式精度 = 1-MAPE。

$$RMSE = \sqrt{\sum_{t=1}^N (M - E)^2 / N} \quad (9)$$

三、結果與討論

1、正規化的效果

研究初期建立 BPN1 與 BPN2，Fig. 7 與 Fig. 8 為 BPN1 與 BPN2 的 BOD 相對誤差圖，圖中 X 軸為時間(天)，Y 軸為相對誤差，平均誤差(Mean Error)的功能是為了判斷預測的相對誤差有無常態分佈，由 Fig. 8 可看出相對誤差分佈比 Fig. 7 的來得大，由此可得 BPN1 經正規化後反而相對誤差比未正規化還大。Table 1. 為 BPN1 與 BPN2 有無正規化之 R 值，Table 2. 為 BPN1 與 BPN2 有無正規化之 MAPE，Table 3. 為 BPN1 與 BPN2 有無正規化之 RMSE。由 Table 1.、Table 2. 和 Table 3. 發現 BPN1 經正規化處理後，反而 R 值、MAPE 和 RMSE 變得較差。在 BPN1 方面，判斷可能是 BPN1 含有不良的變數，而導致經正規化後網路預測效果變差。而在 BPN2 方面，經正規化處理之後，有增加網路效能的效果產生。由 Table 1. 得到相關性最差為 TS，所以再建立針對 TS 的 BPN3、BPN4 和 BPN5 來確定。




Fig. 7 BPN1 未經正規化預測 BOD 相對誤差圖




Fig. 8 BPN1 經正規化後預測 BOD 相對誤差圖

Table 1. BPN1 與 BPN2 的 R 值

類神經網路模式		BOD	COD	TS	TP
BP N1	未正規化	0.69	0.72	0.43	0.58
	正規化	0.66	0.65	0.20	0.45
BP N2	未正規化	0.73	0.69	0.03	0.68
	正規化	0.75	0.78	0.35	0.66

Table 2. BPN1 與 BPN2 的 MAPE

類神經網路模式		BOD(%)	COD(%)	TS(%)	TP(%)
BP N1	未正規化	19.13	12.55	15.77	15.19

	正規化	25.76	17.11	28.07	23.35
BP N2	未正規化	17.94	13.26	23.08	16.88
	正規化	17.18	11.08	19.47	16.45

Table 3. BPN1 與 BPN2 的 RMSE

類神經網路模式		BOD	COD	TS	TP
BPN1	未正規化	9.88	20.31	4.29	0.11
	正規化	13.53	26.98	7.57	0.14
BPN2	未正規化	9.21	20.8	6.39	0.10
	正規化	8.94	17.94	5.26	0.10

2、類神經網路變數的選擇

變數的選擇對於類神經網路影響很大，不良的變數會降低類神經網路的預測效能，所以選擇正確的變數是很重要的。BPN3、BPN4 和 BPN5 正規化後的預測效果皆比未正規化的預測效果佳，所以將五組模式正規化後分析結果的 BOD 和 COD 之 MAPE 和 RMSE，整理為 Table 4。從 Table 4. 可得到，缺少 TS 變數的 BPN3、BPN4 和 BPN5 的正規化後 MAPE 和 RMSE 皆比 BPN1 正規化後的 MAPE 和 RMSE 低，並且 MAPE 和 RMSE 皆接近，可由此證明變數 TS 是降低網路預測效能的原因。

Table 4. 經正規化後 MAPE 和 RMSE 表

類神經網路模式	MAPE		RMSE	
	BOD(%)	COD(%)	BOD	COD
BPN1	25.76	17.11	13.53	26.98
BPN2	17.18	11.08	8.94	17.94
BPN3	17.33	11.57	8.8	17.4

BPN4	17.04	12.31	9.21	19.01
BPN5	17.53	11.82	9.49	17.8

3、網路模式的預測結果比較

以 Table 4. 評估，整體看來最佳預測效能的模式是 BPN2，BPN2 模式的預測效果優於其它模式，但缺點是每個輸出變數都要建立獨立的網路，而稍差於 BPN2 模式的 BPN3 模式，其 MAPE 和 RMSE 都與 BPN2 非常接近，其輸出變數較多，故判定 BPN3 模式為最佳預測效能的模式。BPN3 模式使用的變數為輸入層為 BODin、CODin、TPin、Flow、Temp，輸出層為 BODout、CODout、TPout，隱藏層有 100 個神經元。Fig. 9 為 BPN3 經正規化後預測 BOD 相對誤差圖。




Fig. 9 BPN3 經正規化後預測 BOD 相對誤差圖

四、結論

- 1、以上述結果得知，在資料代入不含不良變數的類神經網路模式訓練之前，先進行資料正規化對於模式的預測效果是有幫助的，但在含有不良變數的模式中，資料正規化會明顯地降低模式的預測效能。
- 2、類神經網路裡，輸入和輸出的變數對於網路的效能有很大的影響，所以應慎選具有相關性的網路變數並排除不良的變數。
- 3、本研究結果顯示，輸出變數少的模式，其預測

效能稍優於輸出變數多的模式，在預測效能差距很小的情況下，選擇擁有較多輸出變數的模式較佳。本研究最佳的模式，其 BOD 和 COD 的預測精度約 82 和 88%，能有效地幫助廢水廠預測水質並加以改善。

參考文獻

1. 張智星，MATLAB 程式設計與應用，清蔚科技股份有限公司，初版，新竹(2000)。
2. Michael Häck and Manfred Khöne, "Estimation of wastewater process parameters using neural networks," Water Science & Technology, vol.33, No.1, pp.101-115(1996).
3. C.A. Gontarski, P.R. Rodrigues, M. Mori, L.F. Prenem, "Simulation of an industrial wastewater treatment plant using artificial neural networks," Computers and Chemical Engineering, vol.24, pp.1719-1723(2000).
4. 羅華強，類神經網路-MATLAB 的應用，清蔚科技股份有限公司，初版，新竹(2001)。
5. Funahashi, K., "On the approximate realization of continuous mappings by neural networks," Neural Networks, vol.2, pp.183-192(1989).
6. Cybenko G., "Approximations By Superpositions of a Sigmoidal Function," Mathematics of Control, Signals and Systems, vol.2, pp.303-314(1989).
7. Mohamed F.Hamoda, Ibrahim A.Al-Ghusain, and Ahmed H.Hassan, "Intergrated wastewater treatment plant performance evaluation using artificial neural networks," Water Science & Technology, vol.40, No.7, pp.55-65(1999).
8. 林惠玲、陳正倉，應用統計學，雙葉書廊有限公司，初版，台北(1999)。