

神經回路網을 利用한 水稻 蒸發散量豫測

—백프로파게이션과 카운터프로파게이션 알고리즘의 適用—

Estimating Evapotranspiration of Rice Crop Using Neural Networks

—Application of Back-propagation and Counter-propagation Algorithm—

李 南 鎬* · 鄭 夏 禹**
Lee, Nam Ho · Chung, Ha Woo

Summary

This paper is to evaluate the applicability of neural networks to the estimation of evapotranspiration. Two neural networks were developed to forecast daily evapotranspiration of the rice crop with back-propagation and counter-propagation algorithm. The neural network trained by back-propagation algorithm with delta learning rule is a three-layer network with input, hidden, and output layers. The other network with counter-propagation algorithm is a four-layer network with input, normalizing, competitive, and output layers. Training neural networks was conducted using daily actual evapotranspiration of rice crop and daily climatic data such as mean temperature, sunshine hours, solar radiation, relative humidity, and pan evaporation. During the training, neural network parameters were calibrated. The trained networks were applied to a set of field data not used in the training. The created response of the back-propagation network was in good agreement with desired values and showed better performances than the counter-propagation network did. Evaluating the neural network performance indicates that the back-propagation neural network may be applied to the estimation of evapotranspiration of the rice crop. This study does not provide with a conclusive statement as to the ability of a neural network to evapotranspiration estimating. More detailed study is required for better understanding and evaluating the behavior of neural networks.

* 安城產業大學校

** 서울大學校 農業生命科學大學

키워드 : 神經回路網, 蒸發散量, 백프로파게이션,
카운터프로파게이션, 델타學習規則,

媒介變數

I. 緒論

蒸發散量에 대한 正確한 知識은 물管理시스템의 計劃 및 運營에 重要하다. 특히 農業에 있어서 作物生產을 위한 물 供給計劃의 樹立 및 물management操作을 위한 實時間 意思決定에 蒸發散量 資料가 필요하다는 폭넓은 理解를 갖고 있다. 蒸發散量의 算定은 蒸發現像과 관련된 物理的 法則과 質量과 에너지 保存에 基礎를 두고 日別 氣象資料를 使用한다. 蒸發散量 算定을 위한 많은 方法들이 開發되었는데 어떤 方法들은 相對的으로 간단하고 적은 資料를 必要로 하는 반면에 다른 方法들은 複雜하고 많은 資料를 必要로 하고 있다. 蒸發散量 算定方法에 使用되는 많은 變數들은 서로 複雜하게 連結되어 있다. 이와같은 複雜性은 數學的으로 表現하기가 어려운 問題를 解決하는데 많은 成果를 보이고 있는 神經回路網 技法의 導入을 可能하게 한다. 神經回路網은 問題를 數學的으로 表現해서 解를 구하기 보다는 學習을 通해서 問題의 解決을 試圖하고 있다.

人工知能과 規則基盤 컴퓨터는 不確實性과 애매모호한 情報를 處理하는데 그 限界性을 露出하고 있는 反面 神經回路網은 패턴認識 및 分類, 映像認識, 豫報, 로보트制御, 最適化 등과 같은 많은 分野에서 그 可能性을 보이고 있다.^{5,6,7,11)} 이는 神經回路網이 並列處理, 學習 및 노이즈에 강한 計算機能을 갖고 있기 때문이다. 神經回路網適用에 關心이 높아지고 있는 다른 理由에는 하드웨어와 소프트웨어의 改善에 있다. 1943년 McCulloch와 Pitts에 의해 提案된 神經回路網 模型은 1957년 Rosenblatt의 perceptron의 등장을 誘導하였으나 그후 沈滯期를 겪다가 1980년대에 Kohonen, Hopfield, Rumelhart등에 의해 다시 活性化 되었다.^{15,18)}

神經回路網을 豫測을 위해 利用한 예를 살펴 보면, 姜等¹⁴⁾은 洪水期의 日流出量 豫測을 위하여 5개의 神經回路網模型을 開發하여 實際

流域에 適用하여 그 適用性을 分析하였는데, 對象資料의 自己相關函數와 交叉相關函數를 구하여 統計學的 分析을 통해 模型의 入力, 出力 패턴을 決定하였다. French 등²⁾은 3개 層으로 構成된 神經回路網模型을 開發하여 降雨強度의 時間的・空間的 變化를 豫測하고 그 結果를 分析하였고 2개의 他 豫測方法과를 比較한 바 있다. 孫等¹⁶⁾은 綜合的 培養液管理의 基礎가 되는 培養液의 電氣傳導度를 豫測하기 위하여 9개의 이온 濃度를 入力資料로 하고 電氣傳導度를 出力으로 하는 백프로파게이션 多層 神經回路網을 開發하여 그 適用性을 검토하였다. Klimasaukas 등⁵⁾은 週末의 株式價格의 變化를 豫測하기 위해 백프로파게이션 神經回路網을 開發하고 18주 移動平均法과 比較하였다. 開發된 神經回路網의 中間層에 傳達函數로 싸인函數와 시그모이드(sigmoid)函數를 同時에 使用하여 상당히 좋은 結果를 얻은 것으로 報告하고 있다. 李等¹⁹⁾은 日最高 오존濃度를 豫測하기 위해 風速, 雲量, 日射量, 相對濕度등의 氣象資料와 大氣중의 二酸化窒素, 一酸化炭素, 亞黃酸가스, 總炭化水素등의 汚染濃度를 基礎資料로 하고 誤差 백프로파게이션 學習알고리즘을 利用한 神經回路網model을 開發하였으며 이豫測結果를 重回路統計模型에 의한豫測結果와를 比較한 바 있다.

本 研究의 目的是 水稻의 蒸發散量 算定을 위한 神經回路網의 適用性을 檢討하기 위하여 日別 氣象資料를 利用하여 日蒸發散量을 算定하기 위해 백프로파게이션 알고리즘과 카운터 프로파게이션 알고리즘을 使用하는 神經回路網들을 開發하고 이들을 試驗地域에 適用하여 結果를 比較하고 그 適用可能性에 대해 論議하는 데 있다.

II. 神經回路網의 基本理論

1. 神經回路網

人間의 頭腦에 대한 研究는 過去부터 계속되어 오고 있는데 이는 思考, 記憶, 問題解決과 같은 強力한 機能을 갖고 있는 計算機具의 一種이기 때문이다. 이것은 컴퓨터를 利用해서 頭腦의 機能들을 模型化하려는 試圖들을 誘導하였고 그 結果 人工神經回路網이 生成되었다.

뉴론(neuron)은 生物學的 神經組織 특히 腦의 細胞單位이다. 뉴론의 基本的인 機能은 情報의 受容, 演算處理, 出力의 電送이다. 各 뉴론은 수상돌기(dendrites)라 불리는 入力過程을 통해 다른 많은 뉴론들로부터 信號를 받고組合하는 단순한 마이크로프로세싱 單位이다. 수상돌기로 부터의 信號는 뉴론간의 連結部分인 시냅스(synapses)를 통해 뉴론에 傳達한다. 人工神經回路網에서 生物學的 뉴론에 해당되는 單位를 處理要素(processing element)라 한다. 處理要素의 機能을 表示한 模式圖는 Fig. 1과 같다. 處理要素는 많은 入力經路를 갖고 있다. 이와 같은 入力經路의 欽들은 加重值인 連結強度가 합해진 후 합해지고, 합해진 入力값은 傳達函數(transfer function)에 의해 修正된 후 出力된다. 處理要素들은 여러 層을 構成하게 되는데, 하나의 神經回路網은 入力, 中間, 出力

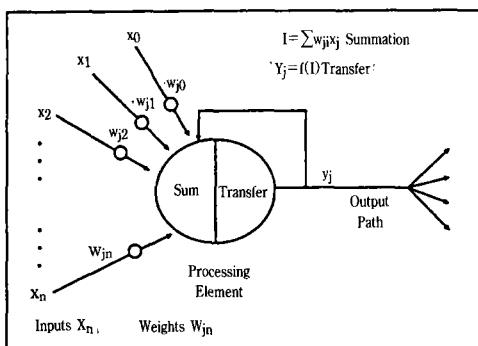


Fig. 1. Schematic diagram of functions of a processing element

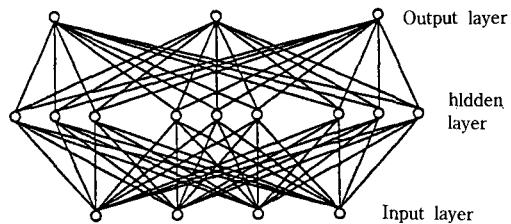


Fig. 2. Structure of a typical neural network

層으로 構成된다. 各 層은 隣接한 層과 서로 連結된다. Fig. 2는 간단한 神經回路網의 一例를 보이고 있다.

2. 神經回路網의 學習 알고리즘

人間의 頭腦를 模倣한 人工神經網의 學習에는 指導學習(supervised learning)과 自律學習(un-supervised learning)이 있다. 指導學習이란 人間이 미리 訓練할 欲을 神經回路網에 提示해주고 그 目標에 到達할 때까지 回路網의 連結強度를 調整해 나가는 것이다. 自律學習은 自己 스스로의 組織化를 통하여 特徵들을 抽出하여 學習하는 方式으로 人間의 頭腦活動과 類似性을 보인다. 本 研究에서는 指導學習을 利用한 백프로파게이션 技法과 自己組織化 學習을 利用한 카운터 프로파게이션 技法을 學習 알고리즘으로 使用하였다.

가. 백프로파게이션(back-propagation)

이 알고리즘은 最近에 單純性 때문에 多層神經回路網의 가장 效率的인 學習方法으로 浮刻되고 있다. 이를 利用한 神經回路網은 Fig. 2와 같은 構造를 갖고 있다. 入力層의 各 處理要素에 入力패턴을 주면 이 信號는 變換되어 中間層에 傳達되어 出力層에서 信號를 出力시킨다. 이때 出力된 欽과 期待 欽을 比較한 후 誤差를 減少시키도록 連結強度를 調節하고 다시 下位層으로 逆傳播하여 다시 連結強度를 調節한다. 逆傳播 알고리즘에서 하나의 處理要素는 入力資料를 式(1)과 같은 方法으로 傳達한다.

$$O_j = f(\sum(W_{ji} \cdot O_i)) \quad \dots \dots \dots \quad (1)$$

여기서, O_j 는 j 번째 處理要素의 出力値이고, W_{ji} 는 j 번째 處理要素의 連結强度이고, f 는 傳達函數이다. 逆傳播 알고리즘의 傳達函數는 微分可能한函數이면 使用될 수 있는데 代表的인函數로는 段階函數(hard limiter), 臨界論理(threshold logic) 및 시그모이드 등이 있다. 傳統的으로 式(2)와 같이 定義되는 시그모이드函數가 使用되는데 Fig. 3과 같이 圖示된다.

$$f(x) = \frac{1}{1+e^{-xG}} \quad \dots \dots \dots \quad (2)$$

여기서, x 는 入力資料이고 G 는 傳達函數의 기울기를 調整하는데 使用되는 媒介變數인 學習利得(gain)이다. 利得値은 0과 1 사이에 存在한다. 本 알고리즘은 神經回路網의 結果와 期待値과의 誤差를 計算한다. 그리고 이 誤差의 程度에 따라 連結强度를 調整한다. 여기서 學習規則은 最少自乘平均法이라 불리는 デルタ規則을 使用한다. 이 デルタ規則은 神經回路網의 出力値과 期待値의 誤差의 제곱을 最少化한다. 이 誤差(E)는 式(3)과 같다.

$$E = \frac{1}{2} \sum_n (D_n - O_n)^2 \quad \dots \dots \dots \quad (3)$$

여기서, D_n 는 期待出力値이고 O_n 는 神經回路網의 出力値이다. 傳達函數의 微分에 의해 變換된 이 誤差는 下位層으로 逆傳達되고 이 誤差는 下位層의 誤差項으로 된다. 誤差의 逆

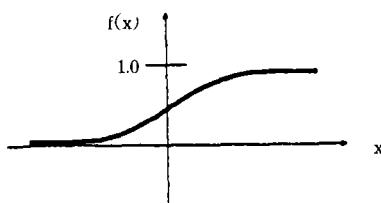


Fig. 3. Sigmoid transfer function

傳播過程은 第1層에 到達 될때까지 계속된다. 連結强度의 修正方程式은 다음과 같다.

$$\begin{aligned} W'_{ji} &= W_{ji} + \alpha \cdot E \cdot x_{ji} + \beta \cdot \Delta W \\ \Delta W &= W'_{ji} - W_{ji} \end{aligned} \quad \dots \dots \dots \quad (4)$$

여기서, W'_{ji} 는 學習規則에 의해 修正된 後의 連結强度이고, α 는 學習率, β 는 連結强度의 變化를 平滑하게 하는데 使用되는 모멘텀項이다. 이 學習規則의 短點은 地域最少値에 빠질 危險이 있는데 이를 克服하기 위하여 學習率과 모멘텀項을 調節하도록 提案되고 있다.

나. 카운터프로파게이션(counter-propagation)

이 알고리즘은 Kohonen의 競爭層과 Grossberg層의 서로 다른 形態의 層을 結合하여 使用한다. 이를 利用한 神經回路網은 Fig. 4와 같은 構造를 갖고 있는데 패턴매칭, 패턴分類, 統計的인 分析 및 データ壓縮 등에 有用한 模型으로 알려져 있다. 이 回路網의 長點은 各層마다 相異한 學習알고리즘을 使用함으로서 다른 回路網에 비해 相對的으로 적은 時間에 學習을 할 수 있다는 點이다.

入力層의 各 處理要素에 入力패턴을 주면 이 값들을 우선 式(5)에 의해 值으로 定規化 한다. 여기서 x' 는 定規化된 入力資料이다.

$$x'_i = \frac{x_i}{(\sum_n x_n^2)^{1/2}} \quad \dots \dots \dots \quad (5)$$

競爭層에서는 Kohonen의 學習規則(learning rule)에 의해 入力ベク터와 連結强度ベク터 사이의 코사인 角을 計算하여 가장 작은 角을 가진 處理要素가 勝利하게 되고 이 勝者만이 出力(winner take all)을 낼 수 있으며 그 이웃들의 連結强度를 調整하게 된다. 連結强度의 調整은 다음 式으로 한다.

$$W'_{ji} = W_{ji} + \alpha \cdot (x_{ji} - W_{ji}) \quad \dots \dots \dots \quad (6)$$

여기서 α 는 0에서 1 사이의 實數値을 갖는 學習率이다.

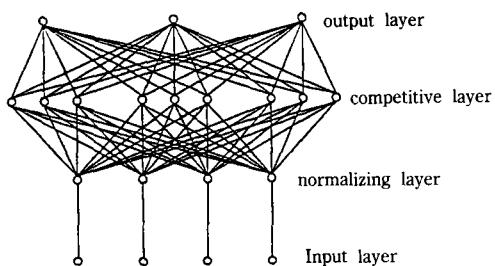


Fig. 4. Structure of a counter-propagation network

III. 神經回路網의 適用

1. 水文資料

日蒸發散量 算定을 위한 神經回路網의 適用性을 評價하기 위해서, 水源地方의 水文資料가 蒐集되었다. 平均氣溫, 日照時間, 輻射量, 相對濕度, 計器蒸發量과 같은 日氣象資料가 神經回路網의 入力變數로 使用되었다. 水稻의 蒸發散量은 서울大學校 農科大學 試驗農場에서 實測된 것을 利用하였는데, 1983~1984年에 測定된 研究에 使用되었다. 日蒸發散量은 Marriotte 시스템²⁰⁾을 利用한 라이시메타를 利用하여 1日 1回 測定되었다. 水稻品種은 中生種인 상풍이었다.

2. 神經回路網의 學習

神經回路網의 學習이란目標에 到達하기 위해 神經回路網에게 一連의 例題들을 認識시키는 것이다. 本研究에서는 回路網의 學習을 위해서 1983년 灌溉期間의 圃場資料와 日氣象資料를 使用하였다. 따라서 入力層의 處理要素의 數는 5개이고 出力層의 處理要素의 數는 1개인데 出力變數는 水稻의 日蒸發散量이다.

가. 백프로파게이션 神經回路網(BPN)

水稻 蒸發散量의 豫測을 위한 BPN은 中間層의 갯수와 中間層을構成하는 處理要素의 갯수에 의해 豫測精度가 變化하며 또한 學習回數에 의해 影響을 받는다. 그리고 BPN의 行動을

좌우하는 重要的 媒介變數에는 모멘텀項, 學習利得 및 學習率 등이 있다. Lee⁸⁾는 이들 影響因子와 媒介變數들의 變化에 따른 神經回路網의 行動을 分析한 바 있는데, 影響因子인 中間層의 갯수가 1개, 中間層의 處理要素가 9개 일때 가장 좋은 豫測結果를 보이고 있다. 또한 媒介變數의 銳敏度 分析結果에 따르면 學習率과 學習利得은 그 痘이 增加할 수록 豫測結果가 좋았으며 모멘텀項은 0.6에서 가장 좋은 結果를 보였다. 이 結果를 利用해서 本研究에서는 Fig. 5와 같은 神經回路網을 使用하였다. 이 때 學習率은 0.9, 學習利得은 1.0, 學習回數는 20,000으로 하였다.

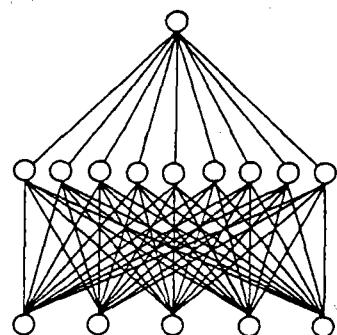


Fig. 5. A proposed back-propagation neural network

나. 카운터프로파게이션 神經回路網(CPN)

水稻 蒸發散量의 豫測을 위한 CPN은 基本 CPN을 利用하여 Fig. 6에서 보는 것과 같이 5개의 處理要素를 갖는 入力層, 處理要素 6개인 入力벡터의 定規化를 위한 中間層, 處理要素 6개의 Kohnen 競爭層으로構成하였다. CPN의 重要的 媒介變數는 學習率인데 銳敏度 分析結果 1.0일때 가장 좋은 豫測結果를 나타내고 있어 이를 採擇하였다. 이 때 學習回數는 20,000으로 하였다.

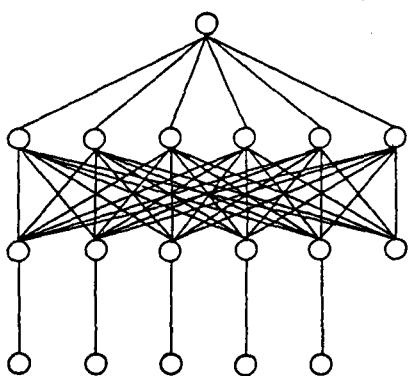


Fig. 6. A proposed counter-propagation neural network

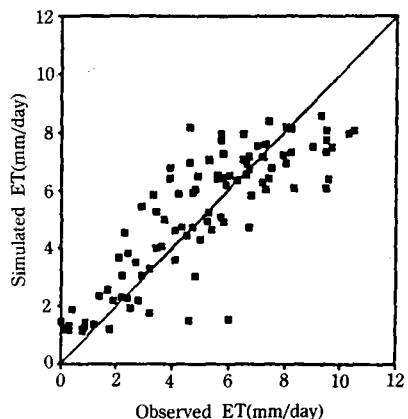


Fig. 7. Observed and estimated evapotranspirations by BPN(1984)

3. 神經回路網의 學習 및 適用

選定된 神經回路網의 適用性 檢討를 위해, 1984 年度의 日氣象 資料와 實測 蒸發散量 資料를 利用해 神經回路網들을 學習하고 이를 利用해서 1985年과 1986年的 灌溉期間의 日蒸發散量을 豫測하였다. 豫測期間은 1985年 移秧后 110日間, 1986年은 105日間이었다. 神經回路網의 豫測誤差分析를 위해서 豫測蒸發散量과 實測値의 相關係數와 RMS 誤差를 計算하였다. 計算된 結果는 Table 1에 整理되어 있다. 1984 年의 資料를 利用하여 神經回路網을 學習한 結果 BPN은 1.015, CPN은 1.127의 BMS 誤差를 相關係數는 각각 0.846, 0.806을 나타내고 있어 BPN이 CPN에 비해 약간 좋은 學習結果를 보이고 있다. Fig. 7과 Fig. 8에는 BPN과 CPN에 의한 豫測値과 實測値을 X-Y 그라프상에 圖示하였다. BPN의 結果는 1:1 直線을 中心으로

Table-1. Comparison of observed and simulated evapotranspiration

Class	Year	BPN		CPN	
		R	RMS E.	R	RMS E.
Learn	1984	0.846	1.015	0.806	1.127
	1985	0.769	1.231	0.685	1.444
Recall	1986	0.638	1.351	0.534	1.435

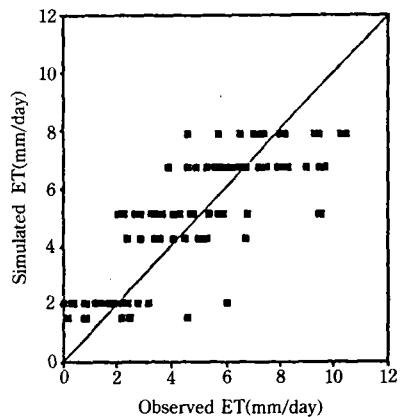


Fig. 8. Observed and estimated evapotranspirations by CPN(1984)

고루 分布되어 있으나 CPN의 結果는 6개의 值을 利用하여 入力패턴을 再現하고 있다.

學習된 神經回路網을 利用해서 1985年과 1986 年의 蒸發散量을 豫測한 結果는 BPN이 각각 1.231, 1.351의 RMS 誤差를, CPN이 1.444, 1.435의 RMS 誤差를 보이고 있어 BPN이 相對的으로 CPN보다 약간 改善된 豫測結果를 보이고 있다. Fig. 9와 Fig. 10은 각각 BPN과 CPN에 의해 豫測된 蒸發散量과 實測蒸發散量의 日別 變化를 圖示하고 있다. BPN의 경우는 部分的으로는 2mm/day 以上의 誤差를 보이고

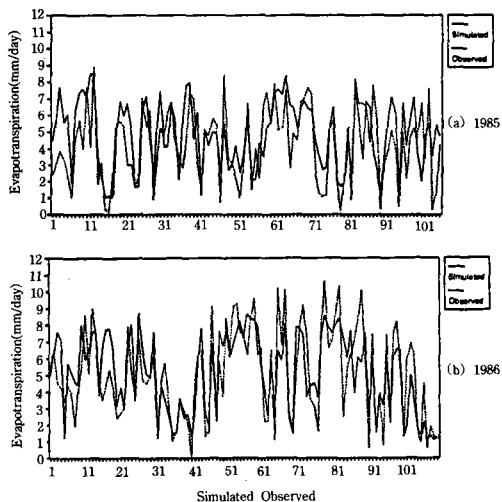


Fig. 9. Observed and estimated evapotranspirations by BPN(1985–1986)

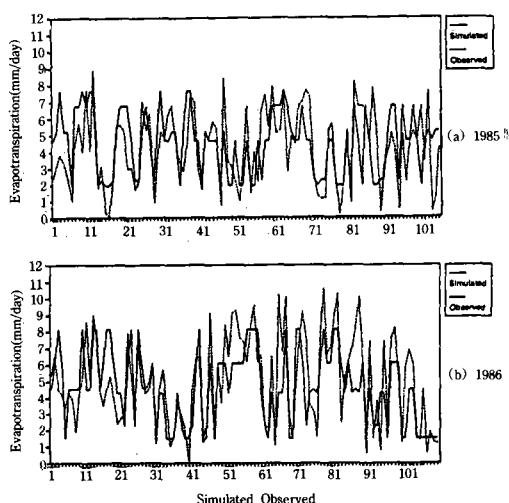


Fig. 10. Observed and estimated evapotranspirations by CPN(1985–1986)

있으나, 大體的으로 豫測값은 實測값에 상당히接近하는 것으로 나타나 있어 入力패턴을 어느 정도 잘 認識하는 것으로 보이나 CPN의 경우는 相對的으로 豫測精度가 낮은 것으로 나타났다. 이것은 CPN이 좋은 豫測結果를 갖기 위해서는 回路網의 規模가 커야하나¹⁵⁾ 本研究의 경우는

입力變數가 5개로 限定되어 있어 回路網의 規模가 작기 때문인 것으로 생각된다.

IV. 結論

水稻의 日蒸發散量豫測을 위한 神經回路網의 適用可能性與否를 檢討하기 위해 백프로파게이션과 카운터프로파게이션 알고리즘을 利用한 神經回路網들이 構成되고 이들의 學習 및 適用을 위해 實測 蒸發散量資料를 利用하였다. 學習된 神經回路網은 適用性 檢討를 위해 學習에 使用되지 않는 資料를 利用하여 日蒸發散量을豫測하였고 그 結果는 實測값과 比較되었다.豫測값은 比較的 實測값에 接近하는 것으로 나타났다. 이 研究 結果에 의하면 神經回路網이豫測 分野에 있어 一次的인 適用可能性을 보였다고 생각된다. 그러나 本研究는 神經回路網의 蒸發散量豫測能力의 最終的 結論을 내리기에는 不充分하다고 생각된다. 神經回路網의 舉動을 보다 잘 理解하고 評價하기 위한 研究가要求된다.

參 考 文 獻

1. Cun, Y., 1988, A Theoretical Framework for Back-Propagation, Proceedings of the 1988 Connectionist Models Summer School, Carnegie Mellon Univ. : 21-28.
2. French, M. N., W. F. Krajewski, and R. R. Cuykendall, 1992, Rainfall forecasting in space and time using a neural network, J. of Hydrology, 173 : 1-31.
3. Jensen, E., 1973, Consumptive Use of Water and Irrigation Water Requirements, ASCE, N. Y.
4. Khanna, T., 1990, Foundations of Neural Networks. Addison-Wesley Publishing Co.
5. Klimasauskas, C., J. Guiver and G. Pelton, 1989, Neural Computing, Neuralware, Inc.

6. Kosko, B., 1992, Neural Network and Fuzzy Systems, Prentice-Hall International Ed.
7. Kung, S. Y., 1993, Digital Neural Networks. Prentice Hall, International, Inc.
8. Lee, Nam H., 1993, Application of Neural Networks for Estimating Evapotranspiration, Proc. of International Conference for Agr. Machinery and Processing Eng., Seoul : 1273-1281.
9. McClelland, J. L. and D. E. Rumelhart, 1988, Explorations in Parallel Distributed Processing, A Bradford Book.
10. Moldovan, D. I., 1986, Modern Parrallel Procssing, Dept. of Elec. Eng. Systems, University of South California.
11. Nelson, M. M., and W. T. Illingworth, 1991, A Practical Guide to Neural Nets, Addison-Wesley Publishing Commpany, Inc.
12. Rumelhart, D. and J. McClelland, 1986, PDP Models and General Issues in Cognitive Science, Chap. 4 in Parallel Distributed Processing. Exploration in the Microstructures of Cognition, Vol. 1. : Foundations. The MIT Press.
13. Rumelhart, D., G. E. Hinton and R. J. Williams, 1986, Learning Internal Representation by Error Propagation, Chap. 8 in Parallel Distributed Processing, Explorations in the Microstructures of Cognition, Vol. 1. : Foundations, The MIT Press.
14. 강관원, 박찬영, 김주환, 1992, 패턴認識 方法을 適用한 河川 流出의 非線形 豫測, 韓國水文學會誌, 25(3) : 105-113.
15. 金大洙, 1992, 神經網 理論斗 適用, 하이테크 情報.
16. 孫禎灝, 金文基, 南相運, 1993, 養液栽培를 위한 培養液 管理 支援시스템의 開發(II), 神經回路網에 의한 電氣傳導度의 推定, 生物生產施設環境, 2(1) : 162-168.
17. 손채봉, 강창우, 서춘원, 김은수, 1993, 改善된 Counter Propagation Network, 第3回人工知能, 神經網 및 퍼지시스템 綜合學術大會 論文集 : 323-326.
18. 李光魯, 신옥근, 金大洙, 1992, 神經網의 主要 모델, 技術動向 및 研究開發 問題分析, 週刊技術動向, 韓國電子通信研究所, 92-04 : 18-43
19. 이상점, 김용국, 이종호, 1993, 神經回路網을 利用한 오존濃度의 豫測에 관한 研究, 第3回人工知能, 신경網 및 퍼지시스템 綜合學術大會 論文集 : 155-158.
20. 鄭夏禹 外, 1983-1984, 蒸發散量 算定方法의 研究, 서울大 農業開發研究所.