

신경회로망을 이용한 저수지 유입량의 실시간 예측모형 연구

A Study on Real-time Forecasting of Reservoir Inflow Based on Artificial Neural Network

고 원 준* · 조 원 철**

1. 서 론

최근들어 한정된 수자원의 효율적인 운영관리에 대한 관심이 높아지고 있으며, 특히 우리나라의 경우 연강우의 2/3이상이 홍수기인 6월~9월에 편중됨으로 해마다 홍수에 의해 큰 피해를 입는 반면, 시간이 갈수록 물부족 현상은 심화되고 있다. 따라서 수자원의 확보 및 효율적이고 체계적인 수자원의 관리가 요구되며 다목적댐의 건설 및 기존 시설의 효율적인 운영관리가 절실히 필요하다. 다목적댐의 최적운명을 위해서는 치수와 이수를 동시에 고려하여 홍수조절을 해야하며 이를 위해서는 댐저수지로의 정확한 유입량 예측이 실시간으로 이루어져야 한다. 본 연구에서는 이러한 다목적댐의 최적운명을 위해 강우에 의한 저수지로의 유입량을 신경망 이론을 적용하여 예측하고자 한다.

신경망 이론은 병렬다중결선의 계층구조이며, 각 입력변수간에 상호종속적인 경우에도 상관관계를 형성하여 학습에 의한 가중치를 결정하므로 불확실한 강우-유출과정을 모형화하는데 유리하다. 신경망 이론은 인간의 두뇌와 비슷한 방법으로 자료안에 내재되어진 패턴을 인식하도록 하는 것으로 1949년 Hebb에 의해 신경세포간의 연결강도를 조정하는 학습규칙이 제안되었으며 Runmelhart 등(1986)은 다층신경망에 대한 학습방법으로 오차역전파 알고리즘(Error Back Propagation Algorithm)을 제안하였다. 그후로 신경망 이론을 이용하여 강우-유출과정을 모형화하는 많은 연구가 이루어졌다.

본 연구에서는 시변성이 큰 소양강댐 유역의 시유입량 실시간 예측모형의 개발을 위해 신경망 이론을 적용하였으며 학습방법으로 오차역전파 알고리즘과 1990년 Fahlman과 Lebiere 의해 개발된 Cascade-Correlation 알고리즘을 사용하여 1시간, 3시간, 6시간까지 선행유입량을 예측하여 두가지 학습알고리즘의 특성 및 예측의 정확도를 비교·분석하였다.

2. 신경망 이론

다양한 신경망 모형들중 수공학 분야에서 자주 이용되는 것은 3층 신경망 모형이며, 이 모형은 외부입력을 받아들이는 입력층, 처리된 결과를 출력하는 출력층, 그리고 입력층과 출력층을 연결하는 은닉층으로 구성되어 있다. 각 층에서 입력과 출력간의 상관관계는 처리소자(node)간의 연결강도(weight)에 의존한다.

본 연구에서 적용한 신경망 모형은 오차역전파 알고리즘과 Cascade-Correlation 알고리즘을 적용한 3층 신경망 모형이다.

1) 오차 역전파 알고리즘

오차 역전파 알고리즘은 다층신경망을 학습시키기 위한 알고리즘으로 현재 가장 널리 응용되고 있다. 오차 역전파 알고리즘은 신경망의 입력패턴에 따라 각 처리소자의 입력값과 전달함수(transfer function)를 이용하여 출력값을 산출하는 순방향처리(feedforward)와 목표값과 계산값과의 차이를 역으로 진행시키면서 오

* 연세대학교 대학원 토목공학과 석사과정

** 연세대학교 토목공학과 교수

차가 최소가 되도록 층과 층 사이의 연결강도를 조절하는 역방향처리(feedback)로 이루어진다. 본 연구에서 사용된 전달함수는 Sigmoid 함수이고 다음과 같이 정의된다.

$$f(x) = \frac{1}{1 + \exp(-\lambda x)} \quad (1)$$

여기서, x 는 입력값이고, λ 는 이득(gain)으로 출력값의 분포를 결정하는 비례상수이다.

입력층의 입력값은 연결강도에 의해 가중되어 은닉층으로 전달되고, 각 은닉층 처리소자의 출력값들은 전달함수에 의해 비선형적으로 변환되어 가중 연결에 의해 출력층으로 전달되게 된다. 이러한 과정을 통한 출력층에서의 최종적인 출력은 다음과 같이 정의된다.

$$O_{pk} = f\left(\sum_k W_{kj} f\left(\sum_i V_{ji} X_{pi} + \theta_j\right) + \theta_k\right) \quad (2)$$

여기서, X_{pi} 는 입력층의 입력값, V_{ji} 는 입력층과 은닉층 사이의 연결강도, W_{kj} 는 은닉층과 출력층 사이의 연결강도, θ_j 는 은닉층의 bias, 그리고 θ_k 는 출력층의 bias이다.

출력층의 출력값 O_{pk} 와 목표값 Y_{pk} 와의 오차를 계산하여 연결강도 조정량 ΔW_{kj} 를 구하며 Delta rule에 의해 출력층과 은닉층 사이의 연결강도를 조절하게 된다.

$$\Delta W_{kj}(t+1) = \eta \delta_{pk} H_{pj} + \alpha \Delta W_{kj}(t) \quad (3)$$

여기서 t 는 학습단계, H_{pj} 는 은닉층에서의 출력값, η 는 학습율, 그리고 α 는 Momentum상수이다.

위의 식(3)에서 출력층에서의 δ_{pk} 는 다음과 같다.

$$\delta_{pk} = (Y_{pk} - O_{pk}) f'(net_{pk}) = (Y_{pk} - O_{pk}) O_{pk} (1 - O_{pk}) \quad (4)$$

은닉층과 입력층 사이의 연결강도를 조정하기 위해서는 은닉층의 목표출력값을 알아야 하므로 일반화 Delta rule을 사용하여 다음과 같이 은닉층과 입력층 사이의 연결강도를 조절하게 된다.

$$\Delta V_{ji}(t+1) = \eta \delta_{pj} X_{pi} + \alpha \Delta V_{ji}(t) \quad (5)$$

여기서 은닉층에서의 δ_{pj} 는 다음과 같이 계산된다.

$$\delta_{pj} = f'(net_{pj}) \sum_k \delta_{pk} W_{kj} = H_{pj} (1 - H_{pj}) \sum_k \delta_{pk} W_{kj} \quad (6)$$

그림 1은 오차역전파 알고리즘으로 각층의 연결강도를 조정하는 과정을 나타낸 것이며 다층신경망의 연결강도가 최적값이 될 때까지 순방향처리와 역방향처리를 반복적으로 수행한다.




그림 1. 오차역전파 알고리즘의 학습진행과정

2) Cascade-Correlation 알고리즘

신경망의 학습알고리즘으로 많이 사용되는 오차역전파 알고리즘의 가장 큰 한계점은 신경망의 구조가 처음부터 결정된 상태에서 학습이 이루어진다는 점이다. 다시 말해 사용자가 적용하기 위한 분야에 대해 적절한 신경망구조를 trial & error 방식으로 찾아야 한다. 따라서 본 연구에서는 오차역전파 알고리즘의 한계를 극복하기 위해 학습이 진행되는 동안 적절한 신경망 구조를 자동으로 설정하는 Cascade-Correlation 알고리즘을 사용하였다(Fahlman과 Lebiere, 1990). 다음은 Cascade-Correlation 알고리즘의 학습과정을 서술한 것이며 그림 2와 같이 도시하였다.

1. 입력력 패턴을 구성하는 각각의 처리소자를 서로 연결하고 은닉층 없이 입력층과 출력층만으로 신경망을 구성한다(그림 2(a))
2. 신경망의 오차가 최소화될 때까지 Delta Rule에 의해 출력층으로 향하는 연결강도를 조정한다.
3. 오차가 적정 수준이하로 감소하지 않으면 여러개의 잠정 은닉층 처리소자를 설정하여 각각에 대해 은닉층 처리소자의 출력값과 기존 신경망의 잔차의 상관성이 최대가 될 때까지 연결강도를 조정하며, 여러개의 잠정 은닉층 처리소자는 서로간에 독립적이다(그림 2(b)).

잔차와 은닉층 처리소자 출력값 사이의 상관성은 다음과 같이 나타낼 수 있다.

$$C = \sum_p |Cov[E_R, V_p]| \tag{7}$$

$$\approx \sum_p \left| \frac{1}{P} \sum_p (E_{Rp} - \bar{E}_R)(V_p - \bar{V}) \right| = \sum_p \left| \frac{1}{P} \sum_p (E_{Rp} - \bar{E}_R) V_p \right|$$

여기서, E_{Rp} 는 패턴별 잔차값, V_p 는 패턴별 잠정 은닉층 처리소자의 출력값, \bar{E}_R 는 E_{Rp} 의 평균값, 그리고 \bar{V} 는 V_p 의 평균값이다.

또한 상관성 C 를 최대화하기 위한 연결강도의 조정량은 최급강하법에 의해 식(8)과 같이 나타낼 수 있으며 식(9)에 의해 입력층과 잠정 은닉층 사이의 연결강도를 조정한다.

$$\frac{\partial C}{\partial W_{ci}} = \frac{1}{P} \sum_p \sum_o \sigma_o (E_{Rp} - \bar{E}_R) f'(\sum_j W_{cj}^i X_{pj}) X_{pi} \tag{8}$$

$$\Delta W_{ci}^j(t+1) = \eta \frac{\partial C}{\partial W_{ci}^j} + \alpha \Delta W_{ci}^j(t) \tag{9}$$

여기서, W_{ci}^j 는 입력층과 j 번째 잠정 은닉층 사이의 연결강도이고 σ_o 는 $Cov[E_R, V]$ 의 부호를 나타낸다.

4. 더 이상 상관성이 증가하지 않으면 여러개의 잠정 은닉층 처리소자들 중에서 가장 상관성이 큰 처리소자를 신경망의 은닉층 처리소자로 설정하고 연결강도를 고정한 후, 새로 추가된 은닉층 처리소자와 출력층을 연결한다(그림 2(c)).

5. 2번으로 돌아가 이 과정을 반복하며 오차가 적정수준이하로 내려가거나 은닉층 처리소자가 한계 개수에 도달하면 학습을 중지한다(그림 2(d)).




그림 2. Cascade-Correlation 알고리즘 학습진행과정

3. 유입량 예측모형 적용 및 결과

본 연구에서는 소양강댐으로의 시유입량을 실시간 예측하기 위한 신경망 모형으로 다음과 같은 형태의 모형을 사용하였으며 입력값에 강우량과 유입량을 동시에 고려하여 침투유출량의 발생과 강우 지속기간이 끝난 후에도 홍수유입량의 예측이 용이하게 하였다.

$$\hat{Q}(t + \text{lead}) = f(Q(t), Q(t-1), \dots, Q(t-n_q); \bar{R}(t), \bar{R}(t-1), \dots, \bar{R}(t-n_r)) \quad (10)$$

여기서, 좌변은 예측시간(lead)후의 예측된 홍수유입량이고 우변은 지체시간 n_q 까지의 유입량과 지체시간 n_r 까지의 유역 평균강우량이다.


소양강댐 유역의 대표적 홍수사상중 84년부터 90년 사이의 4개의 홍수사상(84. 8.30~9. 5, 90. 6.20~23, 90. 7.17~19, 90. 9. 9~13)을 학습자료로 하여 95년 8월 22~28일의 홍수사상을 모의하여 실제 예측능력을 검증하였다.

오차역전파 알고리즘의 특성을 알아보기 위해 예측시간별로 모형을 구성하고 은닉층 처리소자의 수를 10개, 15개, 20개로 변화시켜 모의해본 결과, 다음과 같은 모형이 가장 양호한 것으로 나타났다.


M1 - 8 - 20, M3 - 10 - 10, M6 - 14 - 10

여기서, 첫 번째 항은 예측시간이고, 둘째항은 입력값의 개수, 세 번째항은 은닉층 처리소자의 개수이다.

오차역전파 알고리즘을 적용한 신경망 모형의 경우 은닉층 처리소자의 개수에 따라 학습율이 변화하며 은닉층 처리소자의 개수가 증가함에 따라 학습율이 증가하지는 않았다. 오차역전파 알고리즘과 Cascade-Correlation 알고리즘의 차이를 알아보기 위해 동일한 입력력 변수에 대해 은닉층 처리소자의 개수를 늘려가며 오차의 거동을 비교하였다.



(a) 오차역전파 알고리즘



(b) Cascade-Correlation 알고리즘

그림 3. 모형별 은닉층 처리소자 개수의 변화에 따른 오차의 변화

그림 3과 같이 오차역전파 알고리즘을 적용한 경우 은닉층 처리소자의 개수에 따라 각각 다른 학습율을 보이고 있으며 Cascade-Correlation 알고리즘을 적용한 경우 은닉층 처리소자의 개수가 늘수록 오차는 감소하고 학습율은 증가하는 것을 알 수 있다. 또한 예측시간이 늘어날수록 학습을 시키기 위한 입·출력 변수간의 상관성의 감소로 학습율이 떨어지는 것을 알 수 있다. 따라서 오차역전파 알고리즘을 적용하여 최적의 신경망 구조를 찾기 위해선 여러번의 모의를 반복하여야 하나 Cascade-Correlation 알고리즘을 적용한 경우 원하는 오차범위내에서 최적의 신경망 구조를 자동으로 설정할 수 있다.

예측시간별 모형에 Cascade-Correlation 알고리즘을 적용한 결과와 오차역전파 알고리즘을 적용한 결과를 비교하였으며 표 1과 그림 4에 제시하였다.

표 1. 오차역전과 알고리즘과 Cascade-Correlation 알고리즘을 적용한 모형의 예측 결과

구	분	Correlation coefficient	Determination coefficient	RMSE	MAPE	TSE	침투량 차이(%)
1시간 예측	C1 - 8 - 58	0.970	0.920	439.65	28.53	-2.79	3.12
	M1 - 8 - 20	0.948	0.895	506.91	25.33	-5.91	3.97
3시간 예측	C1 - 10 - 67	0.942	0.876	550.38	30.08	-3.17	10.47
	M3 - 10 - 10	0.931	0.841	622.17	26.22	-1.85	18.92
6시간 예측	C6 - 14 - 189	0.857	0.664	905.09	34.26	7.34	-0.48
	M6 - 14 - 10	0.877	0.424	1185.00	36.21	-4.28	34.89


4. 결 론

본 연구에서는 신경망 이론을 이용하여 저수지로의 홍수유입량을 예측하는 모형을 개발하는데 신경망 모형의 학습방법으로 오차역전과 학습알고리즘과 Cascade-Correlation 학습알고리즘을 적용하였으며 95년 8월의 홍수를 6시간까지 선행 예측하여 다음과 같은 결론을 얻었다.


- 1) 하천유역의 복잡한 물리적 요인 때문에 수학적 모형의 적용이 어려운 강우 - 유출시스템을 신경망에 의한 입·출력패턴의 학습기법을 이용하여 모형화 할 수 있었다.
- 2) 신경망 모형을 학습시키기 위해 오차역전과 알고리즘과 Cascade-Correlation 알고리즘을 적용하였으며, 오차역전과 알고리즘은 모형별 최적의 신경망 구조를 설정하기 위해 여러차례 구조를 변화시키며 찾아야 하나 Cascade-Correlation 알고리즘은 최적의 신경망 구조를 자동으로 설정함을 알 수 있었다.
- 3) 오차역전과 알고리즘과 Cascade-Correlation 알고리즘을 적용한 신경망 모형으로 1시간, 3시간의 홍수유입량을 선행 예측한 결과 Cascade-Correlation 알고리즘과 오차역전과 알고리즘이 모두 양호한 결과를 얻었으나 Cascade-Correlation 알고리즘을 적용한 모형이 보다 정확한 결과를 보여주었다.
- 4) 6시간의 홍수유입량을 선행 예측한 결과 오차역전과 알고리즘을 적용한 신경망 모형은 침투유량을 과다예측하였으나, Cascade-Correlation 알고리즘을 적용한 신경망 모형은 비교적 양호하게 침투유량을 예측하였다.

5. 참고문헌


- 김주환 (1992). "패턴인식방법을 적용한 하천 유출의 비선형 예측." 한국수문학회지.25(3). pp. 105~113.
- Hebb, D. O.(1949). The organization of behavior: A neuropsychological theory. Wiley, New York.
- Hsu, K. L., Gupta, H. V., and Soroosh, S. (1995). "Artificial neural network modeling of the rainfall-runoff process." Water Resources Research, 31(10), pp. 2517~2530.
- Fahlman, S. E. and Lebiere, C. (1990). "The Cascade-Correlation Learning Architecture."CMU-CS-90-100
- French, M. N., Krajewski, W. F., and Cuykendall, R. R. (1992). "Rainfall forecasting in space and time using a neural network." Journal of Hydrology, 137, pp. 1~31
- Karunanithi, N., Grenney, W. J., Whitley D. and Bovee, K. (1995). "Neural networks for river flow prediction." Journal of Computing in Civil Engineering, 8(2), pp. 201~220.
- Runmelhart, D. E., Hinton, G. E., and Cuykendall, R. R. (1986). "Learning representations by back propagation errors." Nature(London), 323, pp. 533~536.
- Thirumalaiah, K. and Deo, M. C. (1998). "River stage forecasting using artificial neural networks." Journal of Hydrologic Engineering, 3(1), pp. 26~32.



(a) 1시간 유입량 예측 모형의 결과



(b) 3시간 유입량 예측 모형의 결과



(c) 6시간 유입량 예측 모형의 결과

그림 4. 오차역전파 알고리즘과 Cascade-Correlation 알고리즘을 적용한 모형의 예측 결과