

수자원의 이용계획을 위한 장기유출모형의 개발에 관한 연구 A Study on Development of Long-Term Runoff Model for Water Resources Planning and Management

조현경^{1*}

Hyeon-Kyeong Cho^{1*}

<Abstract>

Long-term runoff model can be used to establish the effective plan of water resources allocation and the determination of the storage capacity of reservoir. So this study aims at the development of monthly runoff model using artificial neural network technique. For this, it was selected multi-layer neural network(MLN) and radial basis function neural network(RFN) model. In this study, it was applied model to analysis monthly runoff process at the Wi stream basin in Nakdong river which is representative experimental river basin of IHP. For this, multi-layer neural network model tried to construct input 3, hidden 7, and output 1 for each number of layer. As the result of analysis of monthly runoff process using models connected with artificial neural network technique, it showed that these models were effective in the simulation of monthly runoff.

Keywords : Long-term runoff model, Artificial neural network

1. 서론

최근 급격한 인구의 증가와 산업의 발전으로 인하여 물의 수요는 날로 증가하고 있으며, 지구온난화의 영향으로 범지구적으로 기후의 이상현상이 날로 심해지고 있다. 따라서 이에 대비한 이수과 치수정책은 전 세계적으로 각 정부당국의 수자원 이용계획에 있어서 매우 중요한 정책으로 수행되고 있다.

특히 용수의 효율적인 공급과 운영계획을 뜻하는 이수정책을 수립하기 위해서는 일유출량, 월유출량 및 연유출량과 같은 장기 유출량 자료에 대한 광범위한 분석과 정확한 예측에 관

한 연구가 선행되어야 한다.

이러한 장기유출량의 추정은 우리나라 수자원계획 전반에 영향을 미치는 저수지 등의 규모와 이에 따른 용수공급량을 결정하는데 사실상 가장 중요한 요소이다.

국내에서 장기유출량을 추정하는 방법으로는 과거에는 일본인 토목기사였던 가지야마가 우리나라 전국 하천자료를 이용하여 유도한 가지야마 공식이 대표적으로 사용되어 왔다. 그러나 이 공식은 개발된 이후 유역의 지형특성과 강우, 유출 등의 수문특성에 있어서 많은 변화가 있었기 때문에 타 방법을 개발하여 이용하려는 연구가 계속되어왔으며, 현재는 비교 방법으로

^{1*}교신저자, 정회원, 영남이공대학교, 토목과, 교수, 工博,
E-mail: chohk@ync.ac.kr

^{1*}Corresponding Author, Prof., Dept. of Civil Engineering,
Yeungnam College of Science & Technology, Ph.D.

만 이용되고 있다.

지금까지 장기유출량 산정에 관련된 연구 성과를 살펴보면, 박상우와 전병호(1995)¹⁾는 계절형 ARIMA 모형을 이용하여 월유출량 모형의 적용성에 대해 연구하였고, 안상진과 이재경(2000)²⁾은 ARIMA 모형을 이용하여 계절별 월유출량을 모의한 바 있다. 또한 박정규(2009)³⁾는 SWAT 모형을 금강유역의 일유출량을 추정하는 데 적용한 바 있고, 윤선권 등(2009)⁴⁾은 장기유출모의를 위한 수문시계열 예측모형의 적용성을 평가한 바가 있다. 그리고 이은형 등(2011)⁵⁾은 SWAT-CUP 모형을 이용하여 대청호 유역의 장기유출량 보정 및 검증에 대해 연구한 바 있으며, 노선희 등(2013)⁶⁾은 온실가스에 의한 기후변화 시나리오를 고려한 금강유역의 미래 용수공급의 변화를 전망하는 연구에서 ArcSWAT 모형을 이용하여 장기유출량을 산정한 바 있다.

그러나 최근에 장기유출량을 산정하기 위한 모형들은 대상유역에 대한 정밀한 지형정보를 필요로 하는 부담이 있었다. 따라서 본 연구는 이러한 모형들의 단점을 극복하기 위하여 최근 공학분야에서 많이 이용되고 있는 신경망 이론을 이용하여 장기유출모형을 구축하고 이수기에 하천의 장기유출량을 산정하여 용수이용계획 수립 등의 업무를 수행할 수 있는 방법을 제시하는데 그 목적을 두었다.

2. 모형의 기본이론

2.1 인공신경망기법의 개요

인간의 두뇌는 본체인 세포체 부분과 수상돌기 부분 그리고 축색부분으로 구성된 수많은 뉴런(Neuron)을 가지고 있는데, 이 뉴런이 기억과 학습 등의 정신활동을 담당하고 있다.

특히 인간두뇌에서 이루어지는 학습과정을 수학적으로 모형화한 것을 인공신경망이라 한다. 이러한 인공신경망은 공학적인 문제들을 처리할 때 기존의 방법이 순차적이고 논리적으로 수행되는 것에 비해 학습을 통해 다수의 유니

트(Unit)들에게 서로 영향을 주고 받으며 동시에 병렬처리를 수행한다는 특징을 가지고 있다.

이러한 인공신경망은 크게 다층(Multi-Layer) 신경망, 방사형 기본함수(Radial Basis Function) 및 코헨 네트워크(Cohen Network) 등이 있는데, 본 연구에서는 다층 신경망(MLN)과 방사형 기본함수 신경망(RFN)을 장기유출량 산정모형의 구축에 적용하였다.

먼저, 다층 신경망에 대해 살펴보면 일반적으로 인공적인 뉴런의 모형인 유닛은 다른 여러 개의 유닛과 연결되어 전체적인 인공신경망을 형성하게 된다. 이때 유닛들은 연결강도에 의해 결합되어 있으며, 연결강도는 한 처리소자가 다른 처리소자에 끼칠 수 있는 영향력의 크기를 나타낸다고 볼 수 있다. 따라서 학습과정에서 처리소자들은 여러 다른 처리소자들과 각각의 영향력에 따라 크기가 다른 연결강도로 연결된다. 이때 전달되는 연결값을 변형시켜 다른 처리소자에 입력될 활성화값(Activation Value)을 만드는데, 이는 전달함수에 의해 수행된다. 이때 전달함수로는 선형함수(Linear Function), 계단함수(Step Function) 및 시그모이드 함수(Sigmoid Function) 등이 주로 이용되는데, 본 연구에서는 뉴런의 출력이 아날로그 형태로 나타나는 장점이 있는 시그모이드 함수를 사용하였다. Fig. 1과 식(1)은 본 연구에서 이용된 시그모이드 함수를 나타낸 것이다.




Fig. 1. Transfer functions(Sigmoid).

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

앞에서 설명한 인공신경망 모형은 다음과 같

은 식(2)~(5)와 같이 나타낼 수 있다.

$$X = (x_1, x_2, \dots, x_n) \tag{2}$$

$$S = (s_1, s_2, \dots, s_n) \tag{3}$$

$$NET = x_1s_1 + x_2s_2 + \dots + x_ns_n \tag{4}$$

$$z = f(\sum x_i s_i - h) \tag{5}$$

여기서, x_i 는 각각의 입력치, s_i 는 각각의 연결강도, z 는 출력치, h 는 임계치이다.

다음으로 방사형 기본함수 신경망은 다층 신경망이 입력노드로부터 전달되는 신호들을 선형 결합하는데 비하여 중심신호와 거리 역비례하는 강도로 변환하는 등 신호를 처리하는 방식에서 차이가 있다. 방사형 기본함수 신경망에 관련된 식은 다음 식(6)~(7)과 같이 나타낼 수 있다

$$F = \exp\left(-\frac{1}{2\sigma^2}(x_1 - \mu_1)^2 + \dots + (x_n - \mu_n)^2\right) \tag{6}$$

$$N = w_1F_1 + \dots + w_JF_J \tag{7}$$

여기서, μ_1, \dots, μ_n 은 각 신호의 중심값, F_1, \dots, F_J 는 은닉 뉴런들의 활성화 정도, J 는 은닉 뉴런의 수이다.

2.2 오차역전파 방법

오차역전파 방법은 Rumelhart 등(1986)⁷⁾이 제시한 학습(Learning) 방법인데, 다중인식자를 학습시키기 위한 알고리즘으로 현재 가장 많이 사용되는 방법이다. 이는 인공신경망이 정보와 지식을 습득하는 방법으로 실제값과 출력값 사이의 오차를 줄이도록 반복 실행하여 연결강도를 조정하는 것이다.

오차역전파 방법은 다층 신경망의 가중치들에 대하여 다음 식(8)과 같은 오차함수에서

$$E_p(s) = \frac{1}{2} \sum_k (t_{pk} - O_{pk})^2 \tag{8}$$

오차의 합을 반복적으로 최소화하는 것에 목적을 두고 있다.

이때 오차함수를 최소화 하기 위한 방법으로 써 예측치와 실측치간의 제곱오차로 표현되는

목적함수의 기울기를 구하여 매개변수의 사이에서 탐색이동과정을 반복함으로써 최적매개변수를 구하는 방법인 경사법(Gradient Method)을 이용한다. 이 오차함수가 최소값을 가지는 모든 연결가중치의 값을 구하는 것이 학습과정이 되는 것이다.

3. 적용 및 분석

3.1 분석유역 및 분석자료

본 연구의 대상유역은 우리나라의 대표시험유역 중 하나인 낙동강의 위천유역이다. 위천유역내에는 자기 강우관측소 11개소와 자기 수위관측소 6개소가 있으며, 1982년부터 2006년까지 수문관측이 실시되어 수문자료가 비교적 풍부한 유역이다. 위천유역의 하천수계 구성은 Fig. 2와 같으며, 대상 관측소는 유역출구점인 무성지점을 비롯한 전 수위관측소를 선정하여 적용하였다.

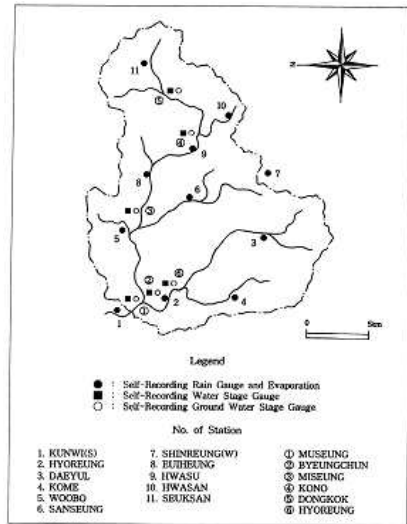


Fig. 2. Study River Basin(Wi-Stream).

그리고 분석에 사용된 수문자료는 2002년부터 2005년까지의 월강우량, 월유출량 및 월증발량 자료이고, 국제수문개발계획(IHP) 보고서⁸⁾ 등을 이용하여 분석에 필요한 자료를 수집하였다. 이 때 11개 지점의 강우량은 Thiessen법을 이용하여 유역평균 강우량으로 변환하여 사용

하였다. 다음 Fig. 3은 6개 지점 중 무성, 동곡 및 효령 지점에서 수집한 수문자료를 나타낸 것이다.

여기서, 인공신경망기법에 의한 모형수행을 위한 학습 자료는 2002년부터 2004년까지의 3개년에 걸친 월강우량, 월유량 및 월증발량 자료를 이용하였으며, 학습에 사용되지 않은 2005년 자료는 본 모형에 대한 적용성을 검증하기 위한 모의자료로 사용하였다. 이때 반복횟수는 500회에서 5,000회 정도까지 변화시켜 가면서 최적치를 구하였다.

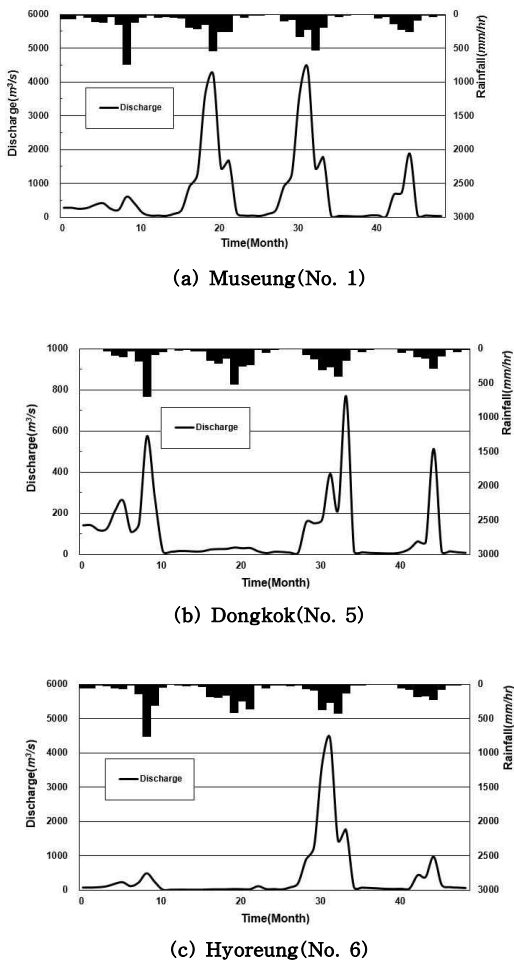


Fig. 3. Study data.

3.2. 인공신경망 모형의 구성

월유출량을 모의하기 위한 인공신경망 모형은 다음 Fig. 4와 같이 다층신경망 구조인데, 입

력층(Input Layer), 은닉층(Hidden Layer) 및 출력층(Output Layer)으로 구성되어 있다. 각 층은 일종의 여과기능을 하는데 신경망의 입력 신호를 받아 처리하여 출력패턴을 발생시킨다. 이때 불완전한 입력신호가 들어와도 이전에 학습된 입력신호와 유사하다고 판단되면 신경망이 인식하고 있는 출력패턴을 발생시켜 출력값을 생성시킬 수 있다.




Fig. 4. Structures of neural networks.

월 유출량을 모의하기 위한 신경망 모형의 입력층, 은닉층 및 출력층의 구조는 다음 Table 1과 같다. 이 때 은닉층에 대하여 Hertz 등 (1991)의 연구에 따라 입력층이 n 이라면 $2n + 1$ 로 하였다.

Table 1. Numbers of layer

Layer		
Input	Hidden	Output
3	7	1

3.3 모형의 학습 결과

진절에서 구성된 인공신경망 모형을 적용하기 위하여 위천유역의 6개 수위표 지점을 대상으로 2002년부터 2004년까지의 월강우량, 월유출량 및 월증발량 자료를 이용하여 각 방법별로 학습을 수행하였으며, 계산치와 관측치를 비교하여 도시한 결과 Fig. 5~6과 같이 나타났다. 여기서는 대표적으로 유역출구점인 무성지점에 대해서만 나타내었다.




Fig. 5. Comparisons of Computed and Observed Discharge(MLN model).

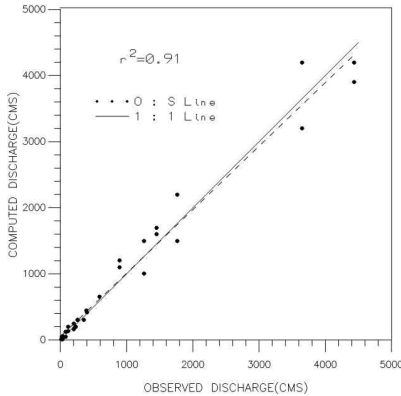


Fig. 6. Comparisons of Computed and Observed Discharge(RFN model).

분석 결과 2개 모형 모두 계산치와 관측치가 매우 근접한 결과를 나타내어 월유출량의 상관성이 높음을 알 수 있었으며, 특히 다층 신경망 모형이 방사형 기본함수 신경망모형보다 좀 더 우수한 결과를 얻는 것으로 나타났다.

3.4 모형의 적용 결과

본 연구에서는 월유출량을 산정하기 위하여 다층 신경망과 방사형 기본함수 신경망모형을 이용하여 위천유역의 6개 수위표지점에 대하여 2005년 자료에 적용하였으며, 그 결과 다음 Fig. 7~12와 같이 산정되었다.

다층 신경망과 방사형 기본함수 신경망모형을 적용하여 산정된 월유출수문곡선을 비교해 볼 때 대체로 실측수문곡선에 접근하여 그 형상을 잘 나타내고 있다.

특히 다층 신경망모형을 이용하여 계산한 수문곡선이 방사형 기본함수 신경망모형의 경우보다 수문곡선의 첨두치나 형상을 비교해 볼 때 비교적 관측 수문곡선과 잘 일치함을 알 수 있었다. 다층 신경망모형은 실측치와 비슷한 결과를 얻었으나 방사형 기본함수 신경망모형은 모든 지점에서 다른 두 개의 값에 비해 첨두치 부분(하계)에서 과대하게 산정되는 것으로 나타내는 특징을 공통적으로 보였다.




Fig. 7. Comparisons of Computed and Observed Discharge(No. 1).




Fig. 8. Comparisons of Computed and Observed Discharge(No. 2).

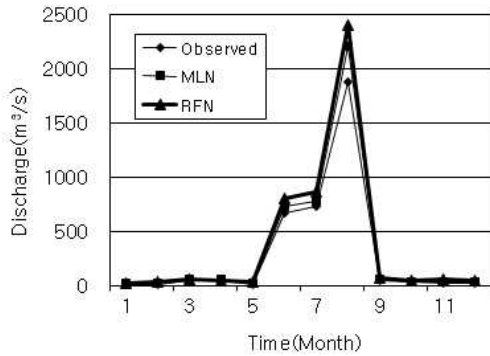


Fig. 9. Comparisons of Computed and Observed Discharge(No. 3).




Fig. 10. Comparisons of Computed and Observed Discharge(No. 4).




Fig. 11. Comparisons of Computed and Observed Discharge(No. 5).




Fig. 12. Comparisons of Computed and Observed Discharge(No. 6).

3.5 모형의 적합성 검증

본 연구에서 월유출량을 산정하기 위한 다층 신경망과 방사형 기본함수 신경망모형에 대한 적합성 검증은 산정된 월유출량 수문곡선과 관측된 실측수문곡선을 비교 검토함으로써 수행되었다.

검정기준은 모형의 효율도(Model Efficient, ME), 절대오차의 평균(Mean Square Error, MSE), 상대오차의 평균을 나타내는 Bias 및 최적오차의 백분률(Volume Error, VER) 등을 계산하여 수문곡선의 형상을 검토하였다.

Table 2. Results of the statistical test for each model

Station	Model	ME	MSE (CMS)	Bias (CMS)	VER (%)
No. 1	MLN	0.96	101.76	10355	-9.80
	RFN	0.94	129.31	16721	-18.50
No. 2	MLN	0.95	95.50	9119	-1.69
	RFN	0.89	141.58	20044	-7.66
No. 3	MLN	0.97	98.26	9654	-15.03
	RFN	0.91	163.34	26681	-27.67
No. 4	MLN	0.96	40.49	1639	-26.01
	RFN	0.91	59.96	3595	-39.34
No. 5	MLN	0.94	32.71	1070	-25.91
	RFN	0.91	42.26	1785	-36.24
No. 6	MLN	0.94	66.64	4441	-19.65
	RFN	0.93	70.56	4978	-21.81

결과의 적합성을 판정하기 위하여 검정을 실시한 결과 Table 2와 같이 나타났다. 먼저, ME를 살펴보면 다층 신경망모형은 0.94~0.97, 방사형 기본함수 신경망모형은 0.89~0.94를 나타내었다. MSE는 다층 신경망모형은 32.71~101.76 CMS, 방사형 기본함수 신경망모형은 42.26~163.34 CMS를 나타내었다. Bias는 다층 신경망모형은 1070~10355 CMS, 방사형 기본함수 신경망모형은 1785~26681 CMS를 나타내었다. VER는 다층 신경망모형은 -26.01~-1.69%, 방사형 기본함수 신경망 모형은 -39.34~-7.66%를 나타내었다.

이와 같이 Fig. 7~12 및 Table 2의 결과를 비교해 볼 때 다층 신경망과 방사형 기본함수 신경망모형 중에서 다층 신경망모형에 의한 월 유출량 수문곡선이 실측 수문곡선과 비교해 볼 때 매우 비슷한 것으로 나타났다.

5. 결 론

본 연구에서는 각종 산업전반에 널리 사용되는 공학이론인 인공신경망 기법을 하천유역의 장기유출량을 산정하기 위한 모형을 개발하기 위하여 적용하였으며, 이를 비교적 많은 수문 자료를 보유하고 있는 낙동강의 위천 유역에 적용하여 그 적용성을 확인하였고, 그 과정에서 다음과 같은 결론을 얻었다.

1) 본 연구에서 하천유역에서 월유출량을 산정하기 위한 인공신경망 방법으로 다층 신경망(MLN)과 방사형 기본함수 신경망(RFN) 모형을 제시하였다.

2) 본 연구의 주 방법인 다층 신경망(MLN) 모형은 입력층의 수 3, 은닉층 7, 출력층 1개로 구성하고 2002년부터 2004년까지의 자료를 가지고 오차역전파 방법에 의해 학습을 수행하였다.

3) 2002년부터 2004년까지의 수문자료를 이용하여 학습한 결과를 계산치와 실측치의 도시적인 비교와 통계적인 검정을 통해 볼 때, 본 모형은 월유출량 실측치에 대해 매우 상관성이 있는 결과를 얻은 것으로 나타났다.

4) 학습한 결과를 이용하여 2005년 자료에 적

용한 결과를 가지고 다층 신경망과 방사형 기본함수 신경망모형을 비교해 볼 때 다층 신경망모형이 월유출량 수문곡선의 형상과 통계치로 볼 때 좀더 실측치에 가까운 결과를 얻었다.

이상과 같이 용수의 효율적인 공급과 운영계획을 위하여 제시한 인공신경망 모형을 적용하여 분석한 결과 그 효용성을 확인할 수 있었으며, 학습자료를 더 축적한다면 더욱 신뢰성 높은 결과를 얻을 수 있을 것으로 보인다. 특히 본 연구에서는 하천유역에서의 적용성만 평가하였지만 앞으로 댐유역에 적용한다면 더욱 실용성있는 연구가 될 것이라고 판단된다.

이 논문은 2011학년도 영남이공대학교 연구조성비 지원에 의한 것임.

참 고 문 헌

- 1) 박상우, 전병호, 월유출량계열의 확장 예측을 위한 추계학적 다중 입력력모형, 한국수자원학회논문집, 28, 1, pp.81-89, (1995)
- 2) 안상진, 이재경, 추계학적 모의발생기법을 이용한 월 유출예측, 한국수자원학회논문집, 33, 2, pp.159-167, (2000)
- 3) 박정규, 금강유역의 일 유출량 해석을 위한 SWAT 모델 적용, 환경관리학회지, 15, 1, pp.29-36, (2009)
- 4) 윤선권, 안재현, 김종석, 문영일, 장기유출 모의를 위한 수문시계열 예측모형의 적용성평가, 한국수자원학회논문집, 42, 10, pp. 809-824, (2009)
- 5) 이은형, 서동일, SWAT-CUP을 이용한 대청호 유역 장기 유출 유량 보정 및 검증, 한국수자원학회논문집, 44, 9, pp.711-720, (2011)
- 6) 노선희, 정관수, 박진혁, 류경식, RCP 기후변화 시나리오를 고려한 금강유역의 미래 용수공급 변화전망, 한국수자원학회논문집, 46, 5, pp.505-517, (2013)
- 7) Rumelhart, D.E., Hinton, G.E, and Williams, R.J., Learning International Representation by Error Propagation, in Parallel Distributed

Processing, 1, pp.318-362, (1986)

- 8) 국제수문개발계획(IHP) 보고서, 건설교통
부, (2002-2005)

(접수:2013.07.23, 수정:2013.08.16, 게재 확정:2013.08.23)