

인공신경망 Downscaling모형에 있어서 최적신경망구조 선택기법

Optimal Network Selection Method for Artificial Neural Network Downscaling Method

강부식*, 류승엽**, 문수진***

Boosik Kang, Seungyeop Ryu, Sujin Moon

요 지

CGCM3.1 SRES B1 시나리오의 2D 변수들을 입력값으로 인공신경망 모형을 이용한 스케일 상세화기법으로 강부식(2009)은 소양강댐 유역의 월 누적강수 경향분석을 실시하였다. 원시 GCM 시나리오를 스케일 상세화 시키기 위한 기법의 하나로 인공신경망 모형을 사용할 수 있는데, 이 경우 GCM에서 모의되는 강수플럭스, 해면기압, 지표면 근처에서의 일 평균온도, 지표면 근처에서의 일평균온도, 지표면으로부터 발생하는 잠열플럭스 등과 같은 22개의 변수를 잠재적인 예측인자로 사용하여 신경망을 구성하게 된다. 입력변수세트의 구성은 인공신경망의 계산 효율을 좌우하는 중요한 요소라 할 수 있다.

본 연구에서는 변수의 물리적 특성을 고려하여 순차적인 변수선택을 통한 신경망 입력변수 세트를 구성하고 입력세트 간의 학습성과 비교를 통하여, 최적 입력변수 선정 및 신경망의 학습효과를 높일 수 있는 방법에 대해 연구하였다. 물리적 상관성이 높다고 판단되는 GCM_Prec, huss, ps를 입력변수로 하여 순차적인 케이스를 학습해본 결과 huss와 ps를 입력변수로 하는 케이스에 대해서 적은 오차와 높은 상관성을 보였다, 또한, 신경망의 학습 효과를 높이기 위해 홍수기와 비홍수기로 구분하여 학습한 결과 홍수기와 비홍수기로 구분하여 신경망을 구성하였을 경우가 향상된 모의값을 나타내었다. 기후변화모의자료는 CCCma(Canadian Center for Climate Modeling and Analysis)에서 제공되는 CGCM3.1/T63 20C3M 시나리오를 사용하였으며, 관측값으로는 AWS에서 제공된 일 누적강수를 사용하였다. 인공신경망의 학습기간은 1997년부터 2000년이며, 검증기간은 2001년부터 2004년으로 구성하였다.

핵심용어 : 인공신경망(Artificial Neural Network), GCM, 민감도 분석

1. 서론

기후변화의 요인은 대기와 다른 기후시스템과의 상호작용인 내부변동성(internal variability)의 형태와 강제력(forcing)의 변화로 인한 기후계변동으로 들 수 있다. IPCC(2007) 보고서에 의하면 기후계의 변동으로 인하여 지구의 평균 지표기온은 1906년부터 2005년까지 약 0.74℃ 상승하였으며, 강수의 경우 온도와 기상조건에 크게 영향을 받으며 온도가 1℃ 상승할 때 대기의 수분 보유력은 약 7% 증가한다고 설명하고 있다. 따라서 온도의 변화는 수증기의 증가를 가져올 것이며, 강수의 발생빈도가 더 높아질 것이다. 이러한 지역규모의 기후변화영향에 대한 연구수행을 위해 수학적 방정식을 이용하여 대기과정을 설명하는 대기대순환모형(GCMs; General Circulation Models)이 사용되고 있다(Tripathi, 2006). 최근 대기대순환 모형이 가지고 있는 저해상도의 모의값을 스케일상세화를 통해 대상유역에서의 월누적강우량의 장기적인 변화추세를 예측하는데 인공신경망 기법이 사용되고 있으며, Valverde Ramirez(2005)는 장기적 강우예측에 있어서 좋은 보정기법이 될 수 있다고 설명하였다. 다양한 대기변수들의 비선형 조합으로 생성되는 신경망의 경우

* 정회원 · 단국대학교 토목환경공학과 부교수 · E-mail : bskang123@naver.com
** 정회원 · 단국대학교 토목환경공학과 석사과정 · E-mail : ryuseungyeop@dankook.ac.kr
*** 정회원 · 단국대학교 토목환경공학과 박사과정 · E-mail : moonsujin@dankook.ac.kr

물리적인 상관성이 낮은 대기변수들의 입력변수에 포함될 경우 학습효과가 저하되는 경향이 있다. 이에, 본 연구에서는 물리적 특성을 고려하여 순차적인 변수선택을 통한 신경망 입력변수 세트를 구성하고 입력세트 간의 학습성과 비교를 통하여, 최적 입력변수 선정 및 신경망의 학습효과를 높일 수 있는 방법에 대해 연구하였다.

2. 연구방법

2.1 인공신경망




그림 1. 다층신경망의 구조

인공신경망은 인간의 두뇌를 구성하고 있는 뉴런의 복잡한 인식과정을 도입하여 수학적 모형으로 일반화시키기 위하여 개발된 병렬정보처리시스템이다. 인공신경망과 같은 비선형모형은 비선형관계들을 표현할 때 전형적인 선형방법들보다 뛰어나다(Cannon, 2007). 신경망의 계층구조에 따라 입력층과 출력층만 존재하는 단층신경망과 입력층, 하나이상의 중간층(은닉층), 출력층이 존재하는 다층신경망으로 구분되는데, 일반적으로 많이 쓰이는 다층신경망의 구조를 사용하였으며, 다층신경망의 구조는 그림1과 같다. 본 연구에 쓰인 역전파알고리즘은 미분 가능한 활성화함수를 사용하여 경사하강법을 통하여 오차함수의 최소값을 찾아 가중치의 크기를 결정하는 방법이며 (Rojas, 1996) 인공신경망의 학습방법중 하나로 일반적으로 많이 사용되어오고 있다.

2.2 대상유역과 데이터 구성

본 연구의 대상유역으로는 낙동강을 선정하였으며, 낙동강 소유역(2001-2012)을 상류로 구분하였다. 낙동강 상류 유역에서의 신경망 구성에 사용된 예측 변수는 한국기상청에서 제공하는 AWS의 일평균강우량과 CCCma에서 제공하는 CGCM3.1/T63 20C3M 일자료를 사용하였으며, 1997년 1월 1일부터 2000 12월 31일까지를 학습기간으로 구성하였다. 모의된 신경망의 검증을 위해서 CGCM3.1/T63 SRES B1 시나리오를 사용하였다.

2.3 입력변수 선정

신경망을 구성하는데 있어 상관성이 낮은 입력변수들을 사용하게 되면 학습효과가 저하되는 경우가 발생한다. 강부식(2009)은 다양한 대기 변수들의 조합으로 인공신경망의 구조를 결정하였는데, 다양한 대기변수들이 신경망을 구성하는데 얼마나 영향을 미치는지 파악하기 위한 과정으로

표 1. 입력변수 선정

	GCM_Prec	huss	ps
Case 1	○	○	×
Case 2	○	×	○
Case 3	○	○	○
Case 4	×	○	○
Case 5	×	○	○

※Case 5는 홍수기와 비홍수기로 구분하여 신경망을 모의함.

물리적인 상관성이 크다고 판단되는 변수만을 선정하여 본 연구를 진행하였다. 순차적인 변수들의 조합으로 신경망을 구성하기 위해서 물리적 상관성이 크다고 판단되는 GCM_Prec(가강수량), huss(증발산), ps(대기압)을 입력변수로 선정하여 Case별로 입력세트를 구분하였다. 이에 더해, 계절성 강우특성이 강한 한반도에서의 강우예측을 위한, 신경망 구성의 학습효과 향상을 위해서 홍수기와 비홍수기로 나눈 학습케이스를 추가하였다.

3. 연구결과

3.1 신경망 학습

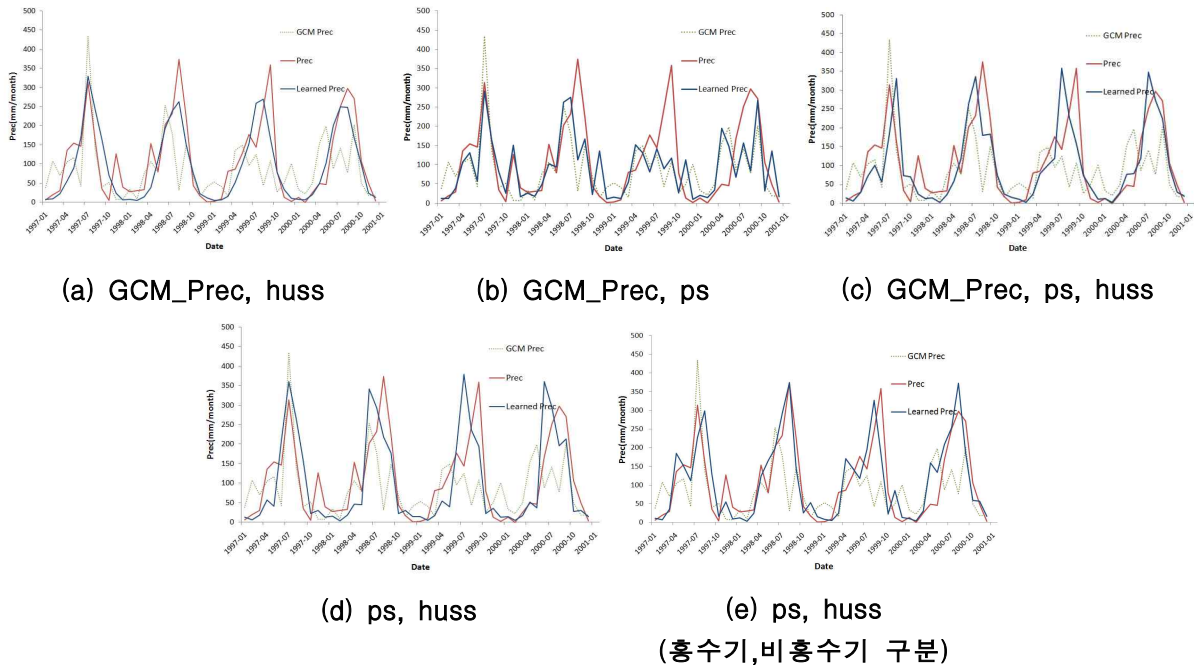


그림 2. 입력변수에 따른 월 누적강수의 학습성과 (낙동강 상류)

물리적인 상관성이 크다고 판단되는 변수들을 이용하여 학습케이스별 신경망을 1997년부터 2000년까지의 AWS 관측값을 목표값으로 설정하고 역전파 알고리즘을 이용하여 학습을 실시하였다. Case 1에서 1998년도의 경우 관측값과 모의값과의 연간 강우량의 차이가 289.5mm/yr로 큰 오

차를 보이며, Case 2의 경우 1999년도의 관측값과 모의값의 연간 강우량의 차이가 381mm/yr로 큰 오차를 보여 신경망의 학습이 제대로 이루어지지 않았음을 보여주고 있다. 5가지의 학습 케이스 중 GCM_Prec가 입력변수중 하나로 선정되어 신경망이 학습된 경우, 신경망의 학습이 저하되는 양상을 보이고 있다. 이론적으로 가장 물리적인 상관성이 크다고 판단되는 변수이지만, 한반도의 지역적 특성과는 상관성이 떨어진다는 것을 알 수 있다. huss가 입력변수로 선정된 경우 신경망의 구성에 있어서 높은 상관성을 보여주었는데, huss가 한반도의 계절성 강우특성과 높은 상관성을 가지고 있다고 판단된다. 신경망의 학습이 잘 이루어졌다고 판단되는 Case 4의 변수들을 이용하여 홍수기와 비홍수기로 구분하여 신경망을 구성한 Case 5의 결과, 관측값과 모의값의 연간 강우량 차이가 1998년에 9.9mm/yr, 1999년에 28.1mm/yr로 향상된 학습 결과를 나타내었다.

3.2 신경망 검증

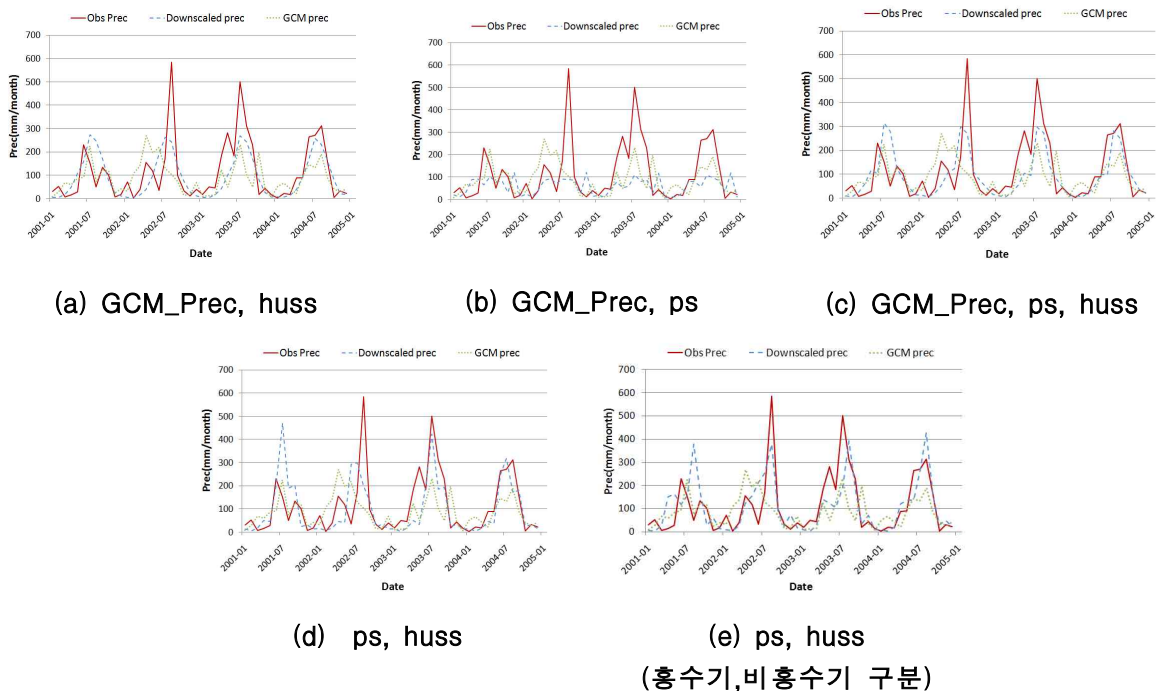


그림 3. 입력변수에 따른 월 누적강수의 검증결과 (낙동강 상류)

CGCM3.1/T63 20C3M의 2D변수들 중 물리적 특성이 상관성이 크다고 판단되는 변수들을 이용하여 목표값과의 학습을 통해 인공신경망의 각 층사이의 가중치가 결정된 신경망 구조를 CGCM3.1/T63 SRES B1(프로젝트 시나리오)를 이용하여 2001년부터 2004년 12월 31년까지의 월 누적강수량을 보정 후, 관측데이터를 이용하여 검증하였다. 검증하기 위한 방법으로는 평균오차(MERR)와 상관계수(CORR)를 이용하였으며, MERR은 0값에 가까울수록 오차가 적고, CORR은 1값에 가까울수록 관측값에 일치함을 나타낸다. 스케일상세화를 통해 얻은 결과값과 대상구역에서 관측된 월 누적강우를 검정한 결과가 그림3과 표2에 나타나있다. Case 4의 경우 Case1~Case3에 비해서 MERR값이 낮은 결과를 보이고 있다. Case 4의 경우 Case1~Case3에 비해서 MERR값이 낮은 결과를 보이고, CORR값은 다른 학습케이스와 근사한 결과를 보임을 알 수 있다. 또한,

Case4와 같은 입력변수를 이용하여 홍수기와 비홍수기를 구분하여 모의한 Case 5의 경우 더욱 향상된 검증 결과를 나타내고 있다.

표 2. 학습케이스에 따른 평균오차와 상관계수

	MERR	CORR
Case 1	0.60	0.718
Case 2	1.66	0.416
Case 3	0.60	0.702
Case 4	0.45	0.639
Case 5	0.02	0.658

4. 결론

본 연구에서는 물리적 상관성이 높다고 판단되는 CGCM3.1/T63 20C3M의 2D변수들을 이용하여 신경망의 학습효과를 높일 수 있는 방법에 대해 연구하였다. GCM_Prec, huss, ps만을 입력변수로 구성하여 순차적인 신경망의 학습 및 검증을 해본 결과, huss와 ps만을 입력변수로 하여 신경망을 구성한 Case 4의 경우가 MERR = 0.45, CORR = 0.639로 가장 높은 검증결과를 보여주었다. Case 4에 대해 홍수기와 비홍수기로 구분하여 신경망을 구성(Case 5)해본 결과, 신경망을 모의하는데 있어서 홍수기와 비홍수기를 구분하여 학습시킬 경우, MERR = 0.43, CORR = 0.658 로 향상된 결과를 얻을 수 있었다. 본 연구를 통하여 물리적 상관성이 큰 입력변수만으로 신경망을 구성하여 강우예측을 하여도 충분히 신뢰성 있는 예측값을 얻을 수 있음을 알 수 있었고, 홍수기와 비홍수기로 구분하여 신경망을 구성하는 것이 향상된 강우모의값을 얻을 수 있음을 알 수 있었다.

참고 문헌

1. 강부식, 이봉기(2009) 인공신경망모형을 이용한 대규모 대기모형모의결과의 담유역스케일에서의 지역화기법, 한국수자원학회학술발표회논문집, 한국수자원학회, pp.179-183
2. 김맹기(2005) 한반도 기후변화 시나리오를 위한 통계적 규모축소법의 적용성, 한국기상학회지, 한국기상학회, 제41권, 제2-1호, pp. 217-227.
3. Cannon, A.J., Whitfield, P.H.(2002) Downscaling recent streamflow conditions in British Columbia, Canada using ensemble neural network models, Journal of Hydrology, Vol. 259, issues 1-4, pp.136-151.
4. IPCC, 2007: Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate, Solomon, S., Qin, D., Martin, M., Marquis, M., Averyt, K., Tignor, Melinda M.B., Miller, H.L. and Chen, Z., Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, pp.252-262.
5. Rojas, R.(1996) Neural Netwroks, Springer-Verlag, Berlin
6. Tripathi, S., Srinivas, V.V. and Nanjundiah, R.S.(2006) Downscaling of Precipitation for climate change scenarios: A support vector machine approach, Journal of Hydrology, Vol. 330, Issues 3-4, pp.621-640.