

다변량 신경망 모형을 이용한 대청댐 유입량 산정에 관한 연구

A Study of Predictive method of Daechung Dam Inflow Using Multivariate Neural Network Model

강권수*, 염경택**, 허준행***

Kwon-Su Kang, Kyung-Taek Yum, Jun-Haeng Heo

요 지

수자원시스템의 설계, 계획, 운영에 있어 핵심적인 수문변수의 미래거동에 대한 보다 나은 추정치가 필요하다. 예를 들어, 수력발전, 레크리에이션 이용과 하류지역의 오염회석과 같은 다중 목적 기능을 유지하기 위하여 다목적댐을 운영할 때에, 다가오는 미래시간에 대한 계획된 유량의 예측이 요구된다. 예측의 목적은 미래에 발생할 정확한 예상치를 제공하는 것이다(Keith W. Hipel, 1994). 본 연구의 주요 목적은 금강수계인 대청댐에서 다변량 신경망 모형을 이용한 유입량 예측을 수행해 보는데 있다. 신경망 모형인 MLP, PCA, RBF모형 등을 이용하여 대청댐의 수문자료인 강우량, 유입량, 기온, 습도 등의 자료를 이용하여 최적의 모형을 탐색해 보고자 시도하였으며, 이 중 New classification모형과 New Function Approximation Network모형이 타 모형보다 좋은 결과를 보여 주고 있음을 알 수 있었다.

핵심용어 : Multivariate Neural Network Model, MLP, PCA, RBF

1. 서 론

다목적댐의 주요 수문인자는 강우량, 유입량, 방류량, 저수위 등으로 구성된다. 댐유역강우량은 유역의 Thissen망을 구성하여 우량관측소와 소유역 면적을 고려한 가중치를 고려하여 계산하는 것이 일반적이다. 방류량은 다목적댐에 따라 상·하류 취수량, 발전방류량, 여수로방류량, river outlet방류량 등으로 구성되어진다. 유입량은 저수위차에 따른 용량계산, 계측된 방류량과의 용량 차이를 계산하여 구한다. 유입량 예측의 과학적이고 체계적인 방법으로 대두되는 것은 추계학적 방법과 인공신경망 방법이 있다. 본 연구에서는 대청댐에 대하여 수문기상 관측자료로 활용되고 있는 강우량, 유입량, 습도, 기온 등을 고려하여 유입량 예측을 수행하여 보고자 한다.

본 연구의 목적은 금강수계 다목적댐인 대청댐의 월유입량 예측에 대하여 다양한 신경망계열의 모형들을 비교 분석하여 보다 더 정확한 방법을 알아 보고자 하는데 있다.

2. 금강수계 다목적댐인 대청댐 적용

2.1 대상유역과 적용기간

* 정희원 · 한국수자원공사 충청지역본부 대청댐관리단 차장 · E-mail : kgs2770@kwater.or.kr

** 정희원 · 한국수자원공사 수자원사업본부장 · E-mail : yumkt@kwater.or.kr

*** 정희원 · 연세대학교 토목공학과 교수 · E-mail : jheo@yonsei.ac.kr

본 연구의 대상구역으로는 금강수계 다목적댐의 하나인 대청댐이며 시계열 자료는 댐의 월자료에 해당하는 강수량, 유입량, 최고기온, 평균기온, 최소기온, 습도, 증발량의 자료를 기반으로 하였으며, 적용기간(1981 ~ 2009년)의 자료를 이용하여 2010년 1월부터 12월까지 12개월 동안의 월 유입량을 예측할 수 있도록 모형을 구성하였다. 수문자료 해석의 기본이 되는 약 30년간의 자료를 이용하여 분석을 실시하였다. 그림 1은 대청댐의 수문기상자료를 보여주고 있다.

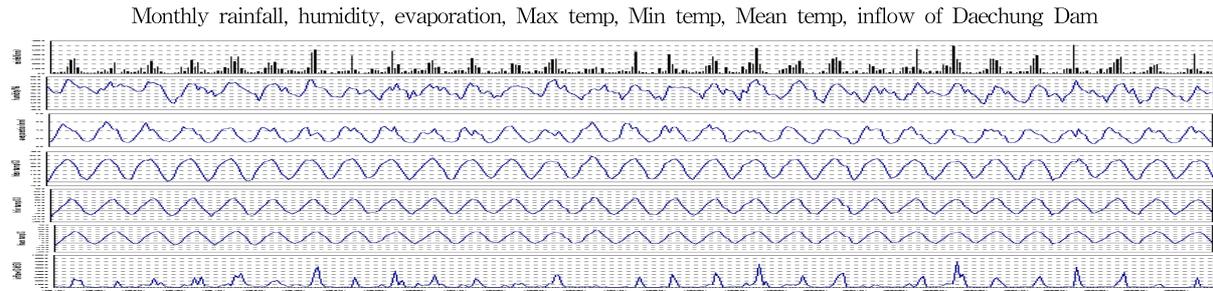


그림 1. 대청댐의 수문기상 관측자료(1981 ~ 2009)

2.2 적용방법

2.2.1 Multilayer perceptrons (MLPs)

Multi-layer perceptron(MLPs)은 정적인 역전파를 가지고 훈련된 전형적인 층으로 구성된 feedforward networks이다. 이들 네트워크는 정적인 패턴분류를 요구하는 무수한 적용을 가지고 있는 것으로 발견된다. 이들의 주요 장점은 사용하기가 쉽고, 그들이 어떤 입력/출력 지도를 잘 근사시킬 수 있다는 것이다.

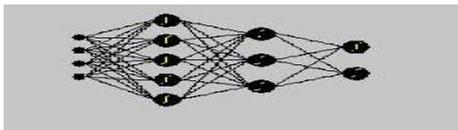


그림 2. Multilayer perceptrons (MLPs)

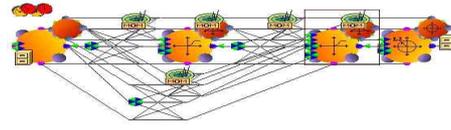


그림 3. Generalized feedforward networks

2.2.2 Generalized feedforward networks

Generalized feedforward networks는 연결이 하나 또는 여러개의 층으로 점프하는 MLP의 일반화를 말한다. 이론에 있어서, MLP는 일반화된 feedforward network를 풀수 있는 어떤 문제든 해결이 가능하다.

2.2.3 Radial basis function (RBF) networks

Radial basis function (RBF) networks는 과정 요소(PE)의 하나의 숨겨진 층을 포함하는 일반적인 비선형 하이브리드 네트워크이다. 이 층은 MLP에 의하여 사용되는 표준 sigmoidal 함수보다는 gaussian 전이함수를 사용한다. gaussian의 중심과 폭은 비감독된 학습규칙에 의하여 정하여지며, 감독된 학습은 출력층에 적용된다. 이들 네트워크는 MLP보다 훨씬 빠르게 학습하는 경향이 있다.

2.2.4 Principal component analysis networks (PCAs)

Principal component analysis networks (PCAs)는 같은 형태의 비감독된 그리고 감독된 학습을 결합한다. PCA는 입력으로부터 일련의 상관되지 않은 특징, 주요 성분을 발견하는 비감독된 선형 과정이다. MLP는 이들 성분으로부터 비선형 분류를 수행하기 위하여 감독된다.

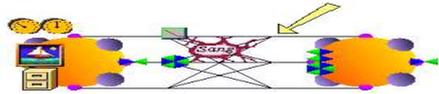


그림 4. Principal component analysis networks (PCAs)

2.2.5 Self-organizing feature maps (SOFMs)

Self-organizing feature maps (SOFMs)은 임의 차원의 입력을 지형학적 제약조건에 영향을 미치는 1차원 또는 2차원상의 이산형 지도로 변형시킨다. 이 네트워크의 주요한 장점은 self-organizing과정을 사용하여 대표적인 특징으로 입력공간을 줄여 SOFM에 의하여 생산되는 클러스터링이다.

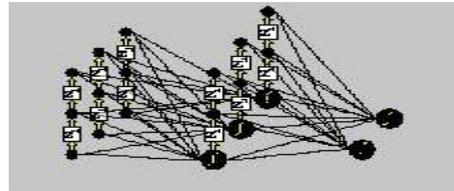
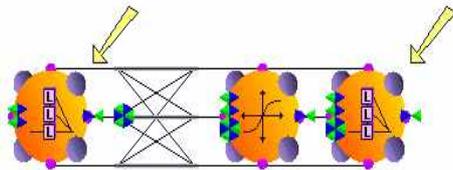


그림 7. Self-organizing feature maps (SOFMs) 그림 8. Time lagged recurrent networks (TLRNs)

2.2.6 Time lagged recurrent networks (TLRN)

Time lagged recurrent networks (TLRN)는 짧은 기간 메모리 구조를 가진 확장된 MLP이다. 대부분 실제 자료는 그것의 시간 구조에 있어서 정보를 포함한다. TLRN은 비선형 시계열 예측, 선형 등정과 임시의 패턴분류에 있어서 최신 기술이다.

2.2.7 recurrent networks

Fully recurrent networks는 그 자체에 있어서 숨겨진 층으로 되돌아간다. 부분적으로 반복적인 네트워크는 완전한 반복 망상조직에서 출발하고 정적인 메모리로서 반복적 부분을 효과적으로 취급하고, 반복을 우회하는 feedforward 연결을 추가한다. 이들의 recurrent networks는 무한한 메모리 깊이를 가지며 순간적인 입력공간을 통과할 뿐만아니라 시간을 통한 관계를 발견할 수 있다. 대부분의 실제세계 자료는 시간 구조에서 정보를 포함한다. recurrent networks는 비선형 시계열 예측, 시스템 등정, 그리고 임시적 패턴 분류에서 최신의 기술이다.

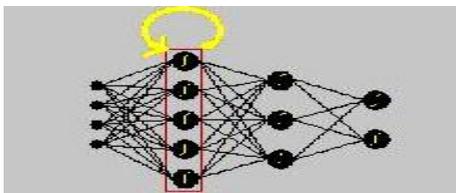


그림 9. recurrent networks

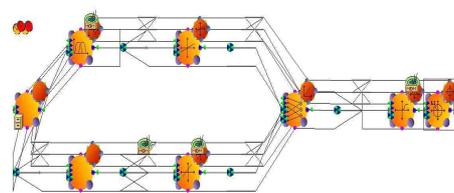


그림 10. CANFIS (Co-Active Neuro-Fuzzy Inference System)

2.2.8 CANFIS (Co-Active Neuro-Fuzzy Inference System)

CANFIS (Co-Active Neuro-Fuzzy Inference System)모델은 정확하게 복잡한 함수를 근사시키며 빠르게 모듈의 신경망 네트워크를 가진 적응 퍼지 입력을 통합한다. 퍼지 추론 시스템은 “블랙박스” 신경망에 멤버십 함수를 결합하여 사용한다.

2.2.9 Support Vector Machine (SVM)

Support Vector Machine (SVM)은 kernel Adatron algorithm을 사용하여 수행된다. kernel Adatron는 고차원 특징공간에 입력을 지도화하며, 그리고 이때 최적으로 자료경계에 가깝게 떨어지는 이들 입력을 고립시킴으로서 그들 각각의 분류로 자료를 분리한다. 그러므로, kernel Adatron은 특히 복잡한 경계를 공유하는 자료집합을 분리하는데 있어서 매우 효과적이다.

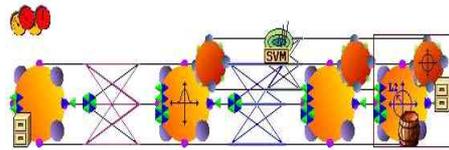


그림 11. Support Vector Machine (SVM)

2.3 대청댐 유입량 예측 적용결과

금강수계의 주요 다목적댐인 대청댐에 대하여 1981~2009년까지의 강우량, 유입량자료 등을 이용하여 2010년 유입량을 예측한 결과는 그림 12와 같다. 월별 수문자료에 대한 실측치와 신경망모형 결과값들과 비교를 시도하였다.

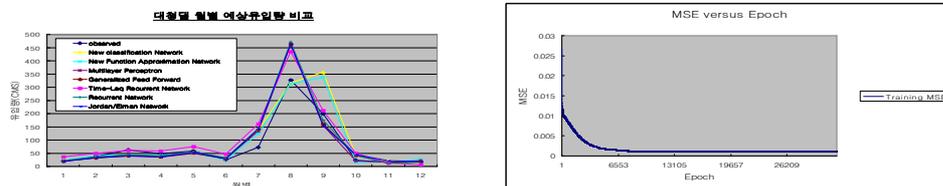


그림 12. 대청댐유입량에 대한 신경망모형 적용결과 및 MSE Versus Epoch(Generalized Feed Forward)

Best Network	Training
Epoch #	65533
Minimum MSE	0.001058
Final MSE	0.001058

Performance	inflow
MSE	2118.1665
NMSE	0.263223
MAE	25.9125
Min Abs Error	0.724418
Max Abs Error	135.41935
r	0.95664

표1. Minimum MSE(Generalized Feed Forward)

표2. 각 방법별 오차(Generalized Feed Forward)

3. 결 론

대청댐에 대한 다변량 유입량 예측방법을 수행하여 본 결과, New classification모형과 New Function Approximation Network모형이 타 모형보다 좋은 결과를 보여 주고 있음을 알 수 있었으며, Generalized Feed Forward모형의 경우 MSE는 2118.1665, NMSE는 0.263223, MAE는 25.9125, Min Abs Error가 135.41935, r이 0.95664의 결과를 보이고 있다.

참 고 문 헌

1. 아마리 슌이치, 방승양(역), 신경회로망 모델의 기초, 교학사, 1990
2. 이창복, GMDH 알고리즘을 이용한 전처리 선별과 인공신경망을 이용한 한국종합주가지수 예측에 관한 연구
3. 강권수, 빈도별 유입량과 신경망 모형의 비교 연구(2006, 대한토목학회 학술발표회 논문집)