

# 인공 신경망 모형을 활용한 저수지 군의 연계운영 기준 수립

나미숙<sup>1</sup> · 김재희<sup>2</sup> · 김승권<sup>3\*</sup>

<sup>1</sup>한국산업기술진흥원 기술전략본부 / <sup>2</sup>전북대학교 경영학부 / <sup>3</sup>고려대학교 정보경영공학전문대학원

## Development of Operating Guidelines of a Multi-reservoir System Using an Artificial Neural Network Model

Misuk Na<sup>1</sup> · Jaehee Kim<sup>2</sup> · Sheung-Kown Kim<sup>3</sup>

<sup>1</sup>Department of Technology Strategy, Korea Institute for Advancement of Technology

<sup>2</sup>Division of Business Administration, Chonbuk National University

<sup>3</sup>Graduate School of Information Management and Security, Korea University

In the daily multi-reservoir operating problem, monthly storage targets can be used as principal operational guidelines. In this study, we tested the use of a simple back-propagation Artificial Neural Network (ANN) model to derive monthly storage guideline for daily Coordinated Multi-reservoir Operating Model (CoMOM) of the Han-River basin. This approach is based on the belief that the optimum solution of the daily CoMOM has a good performance, and the ANN model trained with the results of daily CoMOM would produce effective monthly operating guidelines. The optimum results of daily CoMOM is used as the training set for the back-propagation ANN model, which is designed to derive monthly reservoir storage targets in the basin. For the input patterns of the ANN model, we adopted the ratios of initial storage of each dam to the storage of Paldang dam, ratios of monthly expected inflow of each dam to the total inflow of the whole basin, ratios of monthly demand at each dam to the total demand of the whole basin, ratio of total storage of the whole basin to the active storage of Paldang dam, and the ratio of total inflow of the whole basin to the active storage of the whole basin. And the output pattern of ANN model is the optimal final storages that are generated by the daily CoMOM. Then, we analyzed the performance of the ANN model by using a real-time simulation procedure for the multi-reservoir system of the Han-river basin, assuming that historical inflows from October 1st, 2004 to June 30th, 2007 (except July, August, September) were occurred. The simulation results showed that by utilizing the monthly storage target provided by the ANN model, we could reduce the spillages, increase hydropower generation, and secure more water at the end of the planning horizon compared to the historical records.

**Keyword:** neural network, operating guidelines, monthly storage target, multi-reservoir operation, CoMOM

### 1. 서론

담에 저수된 수자원을 효과적으로 이용하는 문제는 시스템의

관점에서 확보된 수자원을 댐 건설의 목적에 따라 시간 및 공간별로 적절하게 할당시키는 것이라고 할 수 있다(Kim, 1988; ReVelle, 2000). 그 운영 방법은 이수관점에서 용수공급을 위한

본 연구는 21세기 프론티어 연구개발사업인 수자원의 지속적 확보기술개발사업단의 연구지원(과제번호 1-6-3)과 2009년도 두뇌 한국21사업 지원에 의해 수행되었음.

\*연락처 : 김승권 교수, 136-701 서울시 성북구 안암동 5가 1번지 고려대학교 정보경영공학전문대학원,

Fax : 02-929-5888, E-mail : kimsk@korea.ac.kr

투고일(2009년 11월 18일), 심사일(1차 : 2010년 03월 03일, 2차 : 2010년 09월 08일), 게재확정일(2010년 09월 19일).

운영과 치수관점에서 홍수조절을 위한 운영으로 대별될 수 있는데, 본 연구는 이수 관점에서 효과적인 용수공급을 위한 댐 운영 방안을 모색하기 위한 것이다. 그리고 이 문제의 적절한 운영대안을 찾기 위해 다양한 최적화 기법과 시뮬레이션 기법들이 사용되어 왔다(Shih and ReVelle, 1995). 저수지 군 연계 운영을 위해서 최적화 모형이나 시뮬레이션 모형을 수립하여 저수지 운영에 임할 경우, 저수량과 방류량의 할당 기준이나 운영 수위의 운영기준(Guideline) 정보가 매우 중요하다. 그 운영기준이 존재한다는 가정 하에, 저수지 운영룰(Rule)을 도출하기 위하여 미래 예상되는 가용 수량에 비례해서 방류량을 결정하는 방법을 비롯하여 매우 다양한 형태의 간편한 운영룰이 활용되어 왔다(Clark, 1950; Maass *et al.*, 1962). 그러나 이들 운영룰은 단일 댐에서 지켜져야 할 기본적인 원칙을 직관적으로 잘 반영한다는 장점이 있어 널리 활용되어 왔으나 수자원 시스템 전체를 함께 고려하는 데는 한계가 있다.

한편, 시스템 측면에서 바람직한 저수지 운영 방안(solution)을 찾아보기 위한 목적으로 회귀분석모형(Regression Model)이나 신경망(Artificial Neural Network Model)이 단순 운영룰에 대한 대안으로 제시되었다. 이들 방법은 저수 상황이나 미래의 유입량 조건 등에 따른 바람직한 운영 대안을 미리 찾아 회귀분석이나 신경망 모형을 통해 바람직한 패턴을 학습하도록 한 후, 학습된 패턴을 토대로 상황별 운영 대안을 도출하는 개념을 따른다. 그 예로 Bhaskar and Whitlatch(1980)는 선형·비선형 회귀모형을 사용하여 월별 운영방안을 구하였고, Karamouz and Houck(1982)은 다중 선형회귀모형을 사용하여 중·장단기 운영룰을 도출하였다. 두 연구 모두 회귀분석모형을 위한 입력 자료는 저수지 운영을 위한 별도의 최적화 모형에서 나온 결과를 이용하였다. 이후에 Karamouz *et al.*(1992)은 각 저수지의 유입량과 최적 방류량 및 최적 저수량의 관계를 선형회귀모형으로 표현하여 저수지의 장기 운영룰을 제시하였다.

그러나 회귀분석모형은 입·출력 변수 사이의 복잡한 관계를 통상 선형모형으로 근사시키는 불합리한 점이 있다. 이에 입·출력 변수 사이의 비선형 관계까지 고려할 수 있는 신경망 모형의 장점이 부각되고 있다(Govindaraju, 2000b). 이런 연구 중 하나로 Raman and Chandramouli(1996)은 신경망 모형을 이용하여 단일 저수지의 운영룰을 도출하였다. 그들은 초기저수량, 유입량, 수요량을 입력변수로, 저수지 운영을 위한 최적화모형에서 도출된 방류량을 출력변수로 하였다. 그리고 물 부족량과 여수로 방류량을 평가 지표로 만들어 선형회귀모형과 신경망 모형의 결과를 비교 분석하였다. 이후 Chandramouli and Raman(2001)은 저수지들 간의 연계 운영룰 도출을 위해 초기 저수량, 유입량, 수요량을 입력변수로 하고, 별도의 최적화 모형을 통해 얻어낸 최적 방류량을 출력변수로 설정하여 3개 댐을 대상으로 한 신경망 모형을 구성하였다. 그리고 회귀모형과의 비교 분석을 통해 연계 운영의 경우에서도 신경망 모형이 효과적임을 입증하였다.

국내의 경우, Moon(1997)은 신경망 모형과 회귀분석모형을

이용하여 한강수계의 화천, 소양, 충주, 청평, 팔당 5개댐을 대상으로 월별 최적운영방안을 도출하고자 하였다. 그는 두 가지의 월별 신경망 모형을 제시하였다. 하나는 각 댐별로 한 개의 출력패턴을 갖는 신경망 모형 (I)이고, 다른 하나는 각 댐마다 5개의 출력요소를 갖는 신경망 모형 (II)이다. 각 모형이 제시해주는 저수지 연계운영방안을 동일한 상황 하에서 모의한 결과, 회귀분석모형보다는 신경망 모형이 보다 더 효과적인 것으로 나타났고, 용수공급보다 수력에너지의 생산을 더 중요하게 고려하는 발전위주의 운영에서는 신경망 모형 (II)이 적합한 것으로 분석되었다. 그러나 이 때 적용된 시뮬레이션은 유입량 정보가 새롭게 반영되어야 하는 실시간 상황을 모의하지 못하고, 미래의 유입량을 미리 안다는 가정을 함으로써, 현실 적용 상황과 다소 괴리가 있으며, 과거 29년 동안의 실적 유입량만으로 운영룰을 도출함으로써 보다 다양한 유입량 시나리오를 고려하지 못한 아쉬움이 있었다.

본 연구에서는 한강수계 저수지 군의 연계 운영을 위한 월별 저수 운영기준(guideline)의 도출을 목적으로 신경망 모형을 활용하여 그 실용성을 확인해 보고자 하였다. 이 과정에서 신경망 모형 학습을 위한 자료의 입력패턴으로 각 댐별 저수량, 예상 유입량, 수요량에 대한 정보를 활용하였으며, 출력패턴으로는 저수지 군 연계 운영 모형을 위한 최적화 모형(Coordinated Multi-reservoir Operating Model 4.2 : 이하 CoMOM, Kim and Park, 1998; Kim *et al.*, 2005)의 결과를 활용하였다. 특히 500개에 달하는 유입량 시나리오를 반영하여 신경망 모형의 학습 성과를 높이고자 하였으며, 신경망 학습을 위한 입출력 변수 선정 시 연계운영의 특성이 잘 반영될 수 있도록 하였다. 신경망 모형에서 제시된 소양강, 충주, 화천, 팔당의 한강수계 주요 4개 댐의 월별 운영 기준을 토대로 해서 CoMOM을 활용한 한강수계 10개 댐의 실시간 모의운영을 수행하고 그 결과를 과거 실적치와 비교하였다.

본 연구의 구성은 다음과 같다. 제 2장은 신경망 모형과 학습 방법에 대한 기본적인 이론을 요약하였고, 제 3장에서는 본 연구에서 제안하는 저수지 군 월별 연계운영 기준의 도출 절차와 모의운영에 대해 설명하고 제 4장에서는 그 결과를 분석하였다. 마지막으로 제 5장에서는 연구의 결과를 정리하고 결론과 추후 연구 내용을 제시한다.

## 2. 신경망 기법

### 2.1 다층 신경망

신경망 모형은 인간 두뇌의 정보처리 방식을 컴퓨터로 모의한 것으로 모형 자체의 비선형성(nonlinearity), 병렬 계산(parallel computation), 적응성(adaptivity) 등의 여러 장점으로 패턴인식(pattern recognition), 신호 처리(signal processing), 시계열 분석(time series analysis) 등에 널리 사용되어 왔다.

다층 신경망 모형은 입력층의 입력노드에서 입력 데이터를 받아서 가중 연결(weighted connection)로 은닉층 노드에 전달하고, 각 은닉층 노드에서는 가중합된 자료들을 전이 함수(activation function)로 변환시키고, 다시 가중 연결을 거쳐 출력층의 노드로 전달하고 전이 함수 변환을 거쳐 출력시키는 구조를 갖고 있다. 이러한 과정에서 신경망 모형은 어떠한 입력과 출력 데이터에 대해서도 관계를 맺어 주며, 함수근사(function approximation)와 패턴 인식기의 역할을 수행한다. 그리고 전이함수로는 <그림 1>과 같은 계단응답(threshold), 구간선형화(piecewise-linear), 또는 시그모이드(sigmoid) 형태의 함수가 활용된다(Rumelhart and McClelland, 1987).




그림 1. 전이 함수의 종류

2.2 역전파(Back-Propagation) 알고리즘

역전파 알고리즘은 1980년대 후반에 Rumelhart and McClelland (1987)에 의해 소개된 이래 신경망 모형 학습 방법 중 가장 단순하면서도 널리 이용된 모형으로서, 최소자승(least mean square) 알고리즘을 다층 네트워크와 비선형 미분 가능한 전이함수로 확장한 것이다. 이를 일반화시킨 것을 델타 규칙(generalized delta rule)이라고 하는데, 네트워크의 총 오차를 최소화하는 방향으로 강도를 조정해나가는 지도학습의 형태를 갖는다(Haykin, 1994). 즉, 학습 데이터 셋에서 입력층에 입력값을 주면, 이는 은닉층을 거쳐 출력값으로 변환되며, 역전파 과정을 통해 출력값과 목표값의 차이를 최소화하도록 식 (1)에 기초해서 연결 강도(connection weights),  $w_{ij}$ 가 조정된다.

$$\Delta w_{ij}(n) = -\varepsilon \times \frac{\partial E}{\partial w_{ij}} + \alpha \times \Delta w_{ij}(n-1) \quad (1)$$

여기서  $\Delta w_{ij}(n)$ 과  $\Delta w_{ij}(n-1)$ 은 n번째와 n-1번째 학습 과정에서 노드 i와 j에서의 연결강도 변화량을 의미하며,  $\varepsilon$ 는 학습율(learning rate)이고,  $\alpha$ 는 모멘텀(momentum)을 의미한다(Govindaraju, 2000a).

역전파 알고리즘은 종종 최적해를 찾지 못하고 지역 최소값(local minima)에 빠지기도 하며, 초기의 상태를 어떻게 선택하느냐에 따라서 진동(oscillation)하거나 학습이 한없이 계속되기도 한다. 그러나 이러한 한계에도 불구하고 이 알고리즘은 대부분의 분야들에 응용이 가능하고, 데이터의 크기가 크고 잡음(noise)이나 측정 오차(measurement errors)가 포함되어도 잘 동작하는 것으로 알려져 있다.

3. 역전파 인공 신경망 모형을 활용한 저수지군 월간 운영 기준 도출

3.1 절차의 개요

본 연구에서는 저수지 군 연계 운영을 위한 최적화 모형인 CoMOM이 제시하는 월말 저수량이 댐 운영 기준 도출의 출발점이 될 수 있음에 주목하였다. 즉, <그림 2>와 같이 CoMOM의 수행 결과를 신경망 모형의 학습을 위한 데이터로 사용하여 저수지 군 월간 연계 운영 기준을 도출하고 이를 토대로 실시간 모의운영을 하고 그 성과를 검증하는 방법을 제시하고자 한다. 이 절차에 대한 자세한 내용을 한강수계를 기준으로 서술하면 다음과 같다.

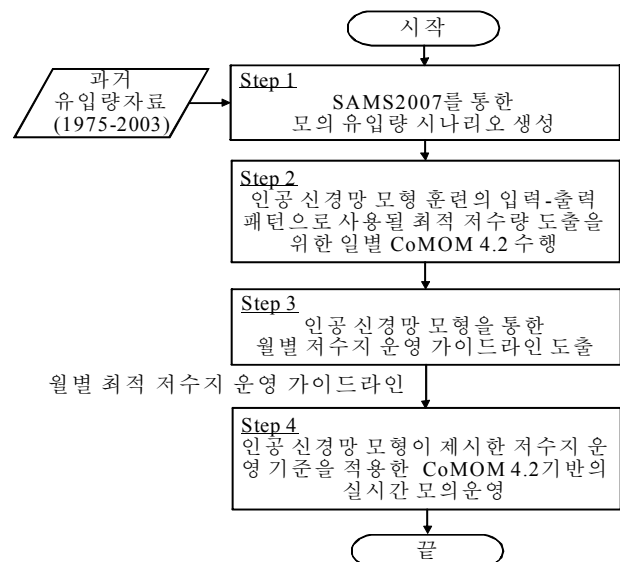


그림 2. 인공 신경망 모형을 활용한 저수지 군의 실시간 모의운영 과정

3.2 Step 1 : 모의 유입량 시나리오 생성

한강수계 저수지 군 연계 운영 기준을 도출하기 위해서는 과거 유입량 자료의 특성이 반영된 장기 유입량 자료가 필요하다. 이를 위해 월별 유입량(stream-flow)과 같은 시계열 수문(hydrologic) 자료에 대한 매개변수 보정 및 자료 생성에 적합하도록 개발된 통계 프로그램인 SAMS 2007(Sveinsson et al., 2007)을 활용하였다. 즉, 한강 수계의 유역 특성과 지점별 유입량 자료의 통계적 특성을 반영하여 보다 다양한 시계열 유입량 자료를 생성할 수 있도록 1975~2003년 기간의 과거 유입량 자료를 입력해서 MPA(1)(Multi-variate Periodic Auto Regressive) 모델로 500개의 모의 유입량 시나리오를 생성하였다.

3.3 Step 2 : CoMOM을 활용한 최적운영 패턴 도출

Step 2에서는 신경망 모형의 학습을 위한 자료를 준비하기

위해 저수지 군 연계운영을 위한 최적화 모형인 CoMOM을 수행한다. CoMOM은 Kim and Park(1998)에 의해 처음 제시된 모형으로 지역별 시기별로 가용성이 다른 수자원을 수요-공급의 관점에서 효율적으로 할당하고자 하는 Spacio-temporal Water Resource Allocation의 운영방식을 따르고 있다. 이는 수계 내 물의 물리적 또는 논리적 흐름 과정을 네트워크로 표현하여 저수지 운영의 다양한 현실을 반영한, 최소 비용 네트워크 모형을 근간으로 한 혼합정수계획 모형으로 설계되었다(Kim *et al.*, 2003). 현재는 수력발전식을 제 1차 Taylor Series로 근사하여 수력 발전량 계산을 직접 반영할 수 있는 기능 개선을 거쳐 버전 4.2로 개발되어 있다(K-water, 2008; Kim *et al.*, 2005; Lee *et al.*, 2006; Lee *et al.*, 2008). 한강 수계에 대한 실제 적용 과정에서는 소양강, 충주, 횡성, 화천, 팔당, 춘천, 의암, 청평, 괴산, 그리고 충주조정지댐 등의 10개 댐을 대상으로 했으며, 횡성 다목적댐이 완공된 2001년 이후 연도 중에서 유입량의 패턴이 평수년에 가까운 2004수문년의 초기 수계 조건과 수요량을 반영해서 CoMOM을 일별 단위로 수행하였다. 이 과정에서 Step 1에서 생성된 500개의 모의 유입량 시나리오를 적용함으로써 다양한 수문조건에 해당하는 최적 저수 패턴을 확보하였다. 그리고 이때의 분석 기간은 10월 1일부터 이듬해 6월 30일까지의 이수기(dry season)를 대상으로 하였다.

3.4 Step 3 : 인공 신경망 모형의 학습

이 단계에서는 Step 2에서 도출된 CoMOM의 최적운영 결과 셋(set)을 이용하여 월별로 별도의 신경망 모형 학습을 수행한다. 학습을 위한 신경망 모형의 입력 요소는 모의운영 시점에서 i) 각 댐별 저수량의 제어댐(팔당댐) 저수량에 대한 비율, ii) 모의 유입량 시나리오상의 각 댐별 월간 예상 유입량의 수계 전체 월간 예상 유입량에 대한 비율, iii) 각 댐별 월간 예상 수요량의 수계 전체 월간 예상 수요량에 대한 비율, iv) 수계 총 저수량의 팔당댐 유효저수용량에 대한 비율, v) 모의 유입량 시나리오상의 수계 전체 예측 총 유입량의 수계 총 유효저수용량에 대한 비율을 입력 변수로 사용하였다. 여기서 최하류

제어댐의 수문 및 댐 정보를 기준으로 활용한 것은 동일 수계 내 다른 댐의 상황을 함께 고려함으로써 연계 운영의 틀을 유지하고, 수계전체의 관점에서 저수량 결정에 중요한 역할을 하는 유입량과 수요량을 반영하고자 함이었다. 그리고 입력변수로 비율 값을 사용한 이유는 각 댐의 제원이 다르기 때문에, 같은 수량이라도 규모가 큰 댐과 작은 댐에 미치는 영향력의 차이를 공정하게 감안하기 위한 것이다.

한편, 신경망 모형의 출력변수로는 CoMOM에서 도출된 월말 저수량을 적용함으로써 학습된 신경망 모형이 주어진 수문 조건에 대한 바람직한 월말 목표 저수량을 도출할 수 있도록 하였다. 아울러 이 과정에서는 모형 적용 및 활용의 단순화를 위하여 모든 댐을 고려하는 대신 한강수계에서 상대적으로 규모와 영향력이 큰 소양강, 충주, 화천, 팔당댐에 대한 월말 저수량만을 출력요소로 고려하였다. <표 1>은 앞서 서술된 입·출력 요소의 정보를 요약한 것이다. 여기서 입력변수 중 화천댐의 수요량이 제외된 이유는 그 양이 무시해도 무방할 정도의 극히 작은 규모이기 때문이다. 아울러 <그림 3>은 이상의 개념 하에서 수립된 신경망 모형의 구조로, 입·출력 노드 수는 각각 13개, 4개에 해당한다.

한편, <그림 3>에서 은닉층의 노드 수는 월별로 다른 값을 가질 수 있도록 함으로써, 월별 상황에 맞는 신경망 모형이 수립될 수 있도록 하였다. 그리고 은닉층의 노드 수를 정하기 위해서 노드의 수를 변화시키면서 식 (2)에서 정의되는 평균제곱오차(Mean Square Error, MSE)가 가장 작은 경우의 값을 찾아보았다.

$$MSE = \frac{1}{2} \sum_{i=1}^q \sum_{j=1}^p (y_{ij}^{(t)} - y_{ij})^2 \tag{2}$$

위 식에서  $p$ 는 훈련을 위한 데이터 셋의 수이고,  $q$ 는 출력층의 노드 수를 의미하며,  $y_{ij}^{(t)}$ 는 훈련을 위한 목표 값(target value),  $y_{ij}$ 는 신경망 모형으로부터 계산된 출력 값(actual output value)이다. MSE는 결과 값의 적합 정도를 나타내는 기준이며, 신경망 모형의 효율성이나 수립정도를 알아보는데 주로 사용되는

표 1. 인공 신경망의 입·출력 요소

인공 신경망 요소			설 명
입력 요소	각 댐의 초기 저수량	$S_{SY}^{(t)}, S_{CJ}^{(t)}, S_{HC}^{(t)}, S_{PD}^{(t)*}$	팔당댐에 대한 각 댐의 초기 저수량 비율
	월간 예상 유입량	$I_{SY}^{(t)}, I_{CJ}^{(t)}, I_{HC}^{(t)}, I_{PD}^{(t)}$	수계 전체 월간 예상 유입량에 대한 각 댐의 월간 예상 유입량 비율
	월간 수요량	$D_{SY}^{(t)}, D_{CJ}^{(t)}, D_{PD}^{(t)}$	수계 전체 월간 총 수요량에 대한 각 댐별 월간 수요량 비율
	초기 총 저수량	$TS^{(t)}$	팔당댐의 유효저수용량에 대한 수계 전체 저수량의 비율
	예상 총 유입량	$TI^{(t)}$	수계 전체 유효저수용량에 대한 수계 총 예상 유입량 비율
출력 요소	월간 목표 저수량	$St_{SY}^{(t)}, St_{CJ}^{(t)}, St_{HC}^{(t)}, St_{PD}^{(t)}$	CoMOM에서 도출된 매 월의 기말 저수량

주) \* SY : 소양강댐, CJ : 충주댐, HC : 화천댐, PD : 팔당댐.

기준이다. MSE가 작다는 것은 목표 값과 실제 결과 값의 차이가 적음을 의미하고, 신경망 모형이 주어진 데이터를 충실하게 반영하고 있음을 의미한다(Rumelhart and McClelland, 1987). 본 연구에서 결정된 각 월별 은닉층의 노드 수와 그때의 MSE는 <표 2>에 정리하였다. <표 2>에서 제시된 노드 수를 적용한 결과 네트워크가 일정 학습시간 후에 수렴하였으며, 모형의 적절성을 확인할 수 있었다.




그림 3. 월별 운영기준(guideline) 도출을 위한 인공 신경망 구조

3.5 Step 4 : 인공 신경망 모형의 운영 기준을 적용한 실시간 모의운영

이 단계에서는 신경망 모형에서 제시된 월별 목표 저수량을 적용해서 저수지 군의 일별 최적 연계운영을 위한 CoMOM을 수행하고 여기서 도출된 결과를 실제 저수지 운영 상황을 상정한 모의운영을 통해 분석하였다.

<그림 4>는 그 과정을 도시한 것이다. 이 절차는 Kim(2006)에서 제시된 실시간 모의운영의 개념을 토대로 하여 신경망 모형을 활용한 저수지군 연계운영을 위해 새롭게 설계된 것이다. 각 단계를 살펴보면, 먼저 신경망 모형을 통해 현재의 수문 조건을 감안한 월말 저수량의 목표값( $S_t$ )을 결정한다. 이 과정

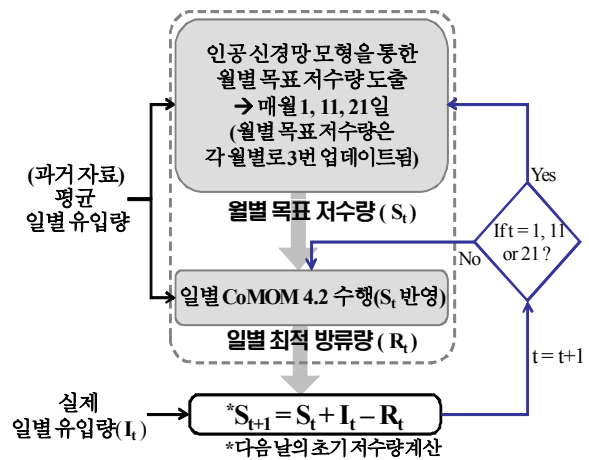


그림 4. 저수지군의 실시간 모의운영 절차

에서 유입량은 미래의 자료이므로 예측치를 적용해야 하는데, 본 연구에서는 미래 유입량에 대한 정보가 없다는 가정 아래, 보수적인 관점에서 과거의 일별 ‘평균 유입량’을 적용하였다. 아울러 이 수행은 매달 1, 11, 21일의 세 차례에 걸쳐 실시됨으로써 10일 간격으로 신경망을 통해 새로운 월말 목표 저수량이 도출될 수 있도록 하였다. 한편, 댐의 크기가 상대적으로 작아 인공 신경망 모형에서 목표저수량을 도출하지 않은 횡성, 춘천, 의암, 청평, 괴산, 충주조정지댐에 대해서는 최근 10년 동안의 실적 월말 저수량의 평균치를 적용하였다. 다음 단계에서는 앞서 도출된  $S_t$ 를 월말의 목표저수량으로 설정하여 일별 CoMOM을 수행한다.

한편, CoMOM에서 계산하는 다음 날의 저수량은 평균 유입량을 반영한 것이므로 실제 댐 운영 결과 실현되는 저수량과는 차이가 있다. 따라서 CoMOM이 제시한 일별 최적 방류량에 당일의 실제 유입량을 반영시켜 다음날의 초기 저수량을 계산하고, 다시 CoMOM에서 제시된 일별 최적 방류량을 적용하는 과정을 반복하는 실시간 모의운영을 실시한다. 이때 유입량을 적용함에 있어 앞 단계와 달리 당일의 실제 유입량이 사용되는 점에 유의할 필요가 있다. 즉, 이전 단계에서 매일의 방류량을 사전에 ‘결정’하는 단계에서는 유입량을 모르니 ‘평균 유입량’을 적용하여 최적방류량 값( $R_t$ )을 구하는 것이며, 여기서 실제 유입량을 적용하는 것은 최적방류량 시행 후 그 날( $t$ ) 마지막 시점(다음날 초)의 저수량( $S_{t+1}$ )을 계산하기 위한 것이다. 이 과정에서 일별 CoMOM의 중요한 입력 정보인 월별 목표 저수량은 매달 1, 11, 21일에 신경망 모형을 통한 예측 값으로 새롭게 변경된다. 다음의 제 4장은 이상의 절차를 적용하여 도출된 결과를 분석한 것이다.

표 2. 인공 신경망 모형의 월별 은닉층 노드 개수의 최적값

월	10월	11월	12월	1월	2월	3월	4월	5월	6월
은닉층의 노드 수	14	16	16	15	15	18	19	18	18
MSE( $10^6$ )	2.8414	2.5764	3.6902	3.1857	3.8262	3.4590	4.3488	5.4781	6.1375

4. 모형수행 결과

본 연구에서 제안한 절차의 운영 효과를 평가하기 위하여 실시간 모의운영의 결과를 과거 운영 실적과 비교하였다. 분석기간은 행정 다목적댐이 완공된 2001년도 이후의 기간 중, 2004~2006수문년의 3개년 중 이수기(10월 1일~이듬해 6월 30일)를 대상으로 하였다. 비교를 위한 5가지 지표는 분석기말 저수량, 분석기간 일 평균 저수량, 여수로 방류량, 발전 방류량, 발전량이다. 여기서 분석기말 저수량은 10월 1일부터 이듬해 6월 30일까지의 연속운영이 수행된 후 분석 기간 말 시점인 6월 30일의 한강수계 내 10개 댐의 총 저수량이고, 분석기간 일 평균 저수량은 분석기간 전체 9개월에 대한 한강수계 10개 댐의 저수량 일 평균값을 의미하며 모의운영 결과는 다음 <표 3>과 같다.

실시간 모의운영 결과를 자세히 살펴보면, 2004수문년은 분석기간 여수로 방류량의 총합이 약 248백만 $m^3$ (37.71%) 감소하고 일 평균 저수량이 약 31백만 $m^3$ (0.79%) 증가한 것으로 나타났다. 여기서 여수로(餘水路) 방류는 수력발전을 하고 남은 물을 저류하고도 남아서 월류되는 것으로 어쩔 수 없이 흘리는 물이다. 또한 발전량의 총합 역시 약 1.6GWh(0.13%) 증가하여 전체적으로 실적 대비 양호한 성과를 보였다. 특히 분석기말 저수량이 실적에 비해 약 91백만 $m^3$ (2.84%) 많았는데, 이는 학습된 신경망 모형에 의해 제시된 월말 목표 저수량을 준수함으로써 얻어진 효과로 장래 용수 부족 대비에 충실하고자 했음을 확인 할 수 있는 부분이다.

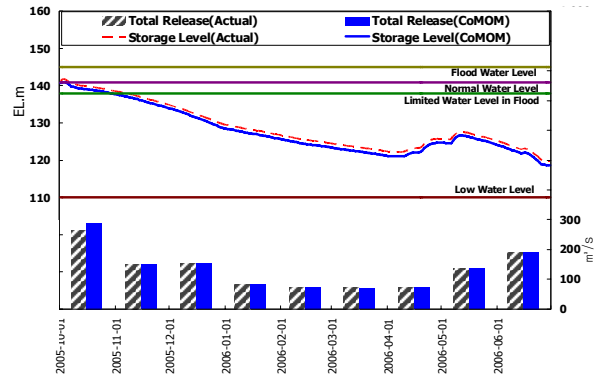


그림 5. 충주댐의 저수량 변화와 월별 총 방류량 (2005. 10~2006. 6)

2005수문년은 여수로 방류량을 약 579백만 $m^3$ (28.49%) 감소 시키면서 발전량이 약 11GWh(0.70%) 증가하고, 분석기말에 약 39백만 $m^3$ (1.27%)의 저수량을 추가로 확보 할 수 있었다. 그러나 분석기간 중 일 평균저수량이 약 22백만 $m^3$ (0.55%) 감소하였는데, 이는 <그림 5>에서 당시 충주댐의 실제 저수 상황을 살펴보면 이해 될 수 있다. 즉, 예년과 달리, 분석기간 초인 10월 초 급격한 유량 증가 상황에서 충주댐의 실제 저수위가 상시만수위를 초과하여 임기응변적인 운영으로 저수량을 확보 할 수 있었지만, 본 실험은 정해진 운영규정을 좇아야만 하는 시뮬레이션 결과로서 가급적 상시만수위를 초과하지 않으려는 CoMOM의 기본 원칙에 충실하도록 설계되었기 때문이다. 실제 운영 시에 CoMOM이 활용된다면, 똑같이 임기응변적인

표 3. 인공 신경망 모형을 활용한 한강 수계 모의운영 결과

기간	구 분	분석기말 저수량 ( $10^6 m^3$ )	분석기간 일 평균 저수량 ( $10^6 m^3$ )	총 여수로 방류량 ( $10^6 m^3$ )	총 발전 방류량 ( $10^6 m^3$ )	총 발전량 (GWh)
2004. 10. 01 ~ 2005. 06. 30	과거 운영 실적(H1)	3,201.29	3,957.99	658.69	17,291.06	1,249.17
	모의운영(S1)	3,292.22	3,989.44	410.31	17,372.68	1,250.77
	(S1)-(H1)	90.92	31.46	-248.38	81.62	1.60
	(S1)-(H1)(%)	2.84%	0.79%	-37.71%	0.47%	0.13%
2005. 10. 01 ~ 2006. 06. 30	과거 운영 실적(H2)	3,034.21	4,071.34	2,031.90	21,298.28	1,576.06
	모의운영(S2)	3,072.77	4,048.87	1,453.06	21,877.33	1,587.05
	(S2)-(H2)	38.56	-22.47	-578.84	579.05	10.99
	(S2)-(H2)(%)	1.27%	-0.55%	-28.49%	2.72%	0.70%
2006. 10. 01 ~ 2007. 06. 30	과거 운영 실적(H3)	2,886.12	3,828.04	223.92	16,696.68	1,177.84
	모의운영(S3)	2,966.97	3,857.27	67.14	16,644.81	1,172.42
	(S3)-(H3)	80.86	29.22	-156.78	-51.87	-5.41
	(S3)-(H3)(%)	2.80%	0.76%	-70.02%	-0.31%	-0.46%
3년 평균	과거 운영 실적(HA)	3,040.54	3,952.46	971.50	18,428.67	1,334.35
	모의운영(SA)	3,110.65	3,965.19	643.50	18,631.60	1,336.75
	(SA)-(HA)	70.11	12.74	-328.00	202.93	2.39
	(SA)-(HA)(%)	2.31%	0.32%	-33.76%	1.10%	0.18%

운영이 가능함은 물론이다. 그리고 2005년 소양강댐의 모의 운영 결과는 <그림 6>과 같으며, 실제 방류량보다 다소 적은 방류량을 도출하였다.

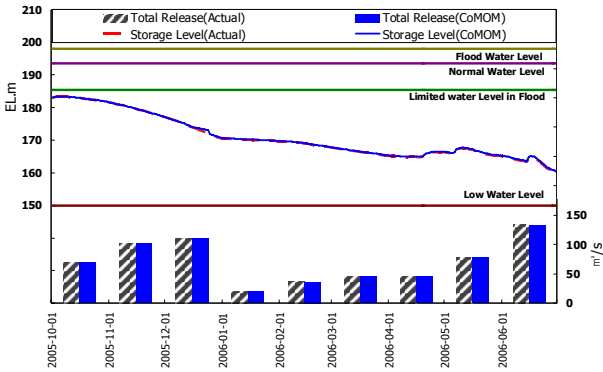


그림 6. 소양강댐의 저수량 변화와 월별 총 방류량 (2005. 10~2006. 6)

2006수문년의 결과를 살펴보면, 발전량이 약 5GWh(0.46%) 감소하였으나 그 차이가 미미하였다. 대신, 여수로 방류를 약 157백만 $m^3$ (70.02%) 감소시켜 분석기간 일 평균저수량을 약 29 백만 $m^3$ (0.76%) 높이고, 분석기말 저수량은 약 81백만 $m^3$ (2.80%) 증대시켜 용수 공급의 안정성을 확보 할 수 있는 것으로 나타났다. 실시간 모의운영 3개년 평균 결과를 살펴보면, 실적과 유사한 발전을 하면서도 여수로 방류를 감소시킴으로써, 분석기간 일 평균저수량과 분석기말 저수량을 증가시켜 실적보다 양호한 결과를 보였다. 이 결과는 3년 간 유입량에만 적용된 것이므로 실적 유입량 자료가 축적되어 감에 따라 추가 분석을 요 하지만, 이상의 결과만으로도 신경망 모형에서 제시된 월별 목표 저수량을 일별 운영 모형인 CoMOM의 월말 저수 운영기준(guideline)으로 활용할 경우 실적 운영 결과를 개선시킬 수 있음을 보여준 것으로 판단된다.

### 5. 결론 및 향후 연구과제

본 연구에서는 저수지 군 연계운영을 위한 일별 최적화 모형인 CoMOM(Coordinated Multi-reservoir Operating Model 4.2, CoMOM)에서 활용될 월말 목표 저수위의 도출을 위해 월별 신경망 모형을 활용할 것을 제안하였다. 이 과정에서 신경망 모형 학습을 위한 자료의 입력패턴으로 각 댐별 저수량, 예상 유입량, 수요량에 대한 정보를 활용하였으며, 최하류 제어댐의 수문 및 댐 정보를 기준으로 활용함으로써 동일 수계 내 다른 댐의 상황을 고려한 연계 운영의 개념을 반영할 수 있도록 하였다. 아울러 저수지 군 연계 운영 모형을 위한 CoMOM의 결과가 바람직할 것이라는 가정 하에서 CoMOM의 결과를 월별 신경망 모형의 출력패턴으로 활용하여 신경망 학습을 수행하였다. 그리고 학습된 신경망 모형에서 제시된 소양강, 충주, 화천, 팔당의

한강수계 주요 4개 댐의 월별 운영 기준을 토대로 해서 CoMOM을 활용한 한강 수계 10개 댐의 실시간 모의운영을 수행하고 그 결과를 과거 실적치와 비교하였다. 그 결과, 실적과 유사한 수준의 수력에너지를 생산하면서도 여수로 방류를 감소시키고, 분석기간 일 평균저수량과 분석기말 저수량을 증가시킨 것으로 나타났다. 이를 통해 신경망 모형에서 제시된 월별 목표 저수량을 적용하여 일별 CoMOM을 수행할 경우, 실적보다 나은 결과를 도출할 수 있음을 확인하였다. 그러나 본 연구에서 제시된 연구 결과에는 신경망 모형의 활용에 따른 성과 뿐 아니라, 일별 CoMOM의 기여가 일부 포함되어 있을 수 있다. 따라서 월별 목표 저수량을 정하는 방법으로서 신경망 모형의 성과를 보다 정확히 검증하기 위해서는 월별 목표 저수량의 결정을 위한 여타 방법, 예컨대 과거 실적 기말 저수량의 평균치를 활용하는 방법, 등을 적용하여 일별 CoMOM을 수행하고 이들을 서로 비교하는 것이 보다 바람직할 것으로 판단된다. 또한, 향후에는 신경망 모형의 학습 시 사용한 역전파 알고리즘 대신 Radial Basis Function과 같은 비선형 예측이 가능한 학습 방법을 활용할 경우 보다 나은 결과를 도출해 볼 수도 있을 것으로 기대된다.

### 참고문헌

Bhaskar, N. R. and Whitlatch, E. E. (1980), Derivation of Monthly Reservoir Release Policies, *Water Resources Research*, 16(6), 987-993.

Chandramouli, V. and Raman, H. (2001), Multireservoir Modeling with Dynamic Programming and Neural Networks, *Journal of Water Resources Planning and Management*, 127(2), 89-98.

Clark, E. J. (1950), New York Control Curves, *Journal of American Water Works Association*, 42(9), 823-827.

Govindaraju, R. S. (2000a), Artificial Neural Networks in Hydrology, I : Preliminary Concepts, *Journal of Hydrologic Engineering*, 5(2), 115-123.

Govindaraju, R. S. (2000b), Artificial Neural Networks in Hydrology, II : Hydrologic Applications, *Journal of Hydrologic Engineering*, 5(2), 124-137.

Haykin, S. (1994), *Neural Networks : a Comprehensive Foundation*, Macmillan College Publishing Company, New York.

Karamouz, M. and Houck, H. (1982), Annual and Monthly Reservoir Operating Rules, *Water Resources Research*, 18(5), 1337-1344.

Karamouz, M., Houck, M., and Delleur, J. (1992), Optimization and Simulation of Multiple Reservoir Systems, *Journal of Water Resources Planning and Management*, 118(1), 71-81.

Kim, J. H., Kim, S. K., and Park, Y. J. (2003), Utilization of a Mathematical Programming Data Structure for the Implementation of a Water Resources Planning System, *IE Interfaces*, 16(4), 485-495.

Kim, S. K. (1988), Methodologies for Reservoir Operation (Bibliographical Review), *Journal of Korea Association of Hydrological Sciences*, 21(1), 16-24.

Kim, S. K. (2006), Utilizations of Optimization Models in Water Resources Planning and Management, *Magazine of Korea Water Resources Association: Water for Future*, 39(9), 83-94.

Kim, S. K., Lee, Y. D., Kim, J. H., and Ko, I. H. (2005), A Multiple Objective Mathematical Model for Daily Coordinated Multi-reservoir Operation, *Water Science and Technology : water supply*, 5(3), 81-88.

- Kim, S. K. and Park, Y. J. (1998), A Mathematical Model for Coordinated Multi-reservoir Operation, *Journal of Korea Water Resources Association*, 31(6), 777-791.
- K-water(Korea Water Resources Corporation), *A Report for Development of Real-time Multi-reservoir Operating System (Mathematical Modeling Part)*, 2008.
- Lee, Y. D., Kim, S. K., and Ko, I. H. (2006), Two-Stage Stochastic Linear Programming Model for Coordinated Multi-Reservoir Operation, *The 2006 Operations Management Conference about Operating Reservoirs in Changing Conditions sponsored by EWRI of ASCE*, in Sacramento, California.
- Lee, Y. D., Kim, S. K., and Ko, I. H. (2008), Multistage Stochastic Linear Programming Model for Daily Coordinated Multi-reservoir Operation, *Journal of Hydroinformatics*, 10(1), 23-41.
- Maass, A., Hufschmidt, M. M., Dorfman, R., Thomas Jr., H. A., Marglin, S. A., and Fair, G. M. (1962), *Design of Water Resources Systems*, Harvard University Press, Cambridge, Mass., U.S.A.
- Moon, S. I. (1998), Comparison of Multiple Regression with Neural Network Model to Derive Optimal Operating Policies for Water Resources Management Systems, Master Thesis, Korea University
- Raman, H. and Chandramouli, V. (1996), Deriving a General Operating Policy for Reservoirs using Neural Network, *Journal of Water Resources Planning and Management*, 122(5), 342-347.
- ReVelle, C. (2000), Research Challenges in Environmental Management, *European Journal of Operational Research*, 121(2), 218-231.
- Rumelhart, D. E., and McClelland, J. L. (1987), *Parallel Distributed Processing : Explorations in the Microstructure of Cognition*, MIT Press, Cambridge, Mass., I and II.
- Shih, J. S. and ReVelle, C. (1995), Water Supply Operations during Drought : A Discrete Hedging Rule, *European Journal of Operational Research*, 82(1), 163-175.
- Sveinsson, O. G. B., Salas, J. D., Lane, W. L., and Frevert, D. K. (2007), *Stochastic Analysis, Modeling, and Simulation (SAMS)*, Technical Report, (11), Computing Hydrology Laboratory, Colorado State University, Colorado.



### 나미숙

서울산업대학교 산업정보시스템공학과  
고려대학교 정보경영공학전문대학원 석사  
현재 : 한국산업기술진흥원 기술전략본부  
연구원

관심분야 : R&D연구기획, R&D프로젝트관리



### 김재희

고려대학교 산업공학과 학사  
고려대학교 산업공학과 석사  
고려대학교 산업공학과 박사  
현재 : 전북대학교 경영학부 조교수

관심분야 : 대기질 의사결정, 수자원/교통/  
생산 시스템 분석



### 김승권

서울대학교 기계공학과 학사  
Stanford University 산업공학과 석사  
UCLA 시스템공학과 박사  
HARZA Engineering Co., Chicago, USA. System  
Analyst

현재 : 고려대학교 정보경영공학전문대학원  
교수

관심분야 : 대기질 의사결정 분석, SCM,  
수자원/환경 및 에너지  
시스템분석