

流域變更을 통한 貯水池시스템의 流出解析

朴 埼 鎭*, 池 洪 基**, 李 舜 鍾**

1. 서 론

우리 나라의 용수수요지역은 대구, 광주, 대전 등의 일부 내륙도시를 제외한 대부분의 대도시와 공업지역이 동해남부, 남해 및 서해안에 인접해 있다. 이러한 현상은 우리의 산업발달과 국토개발 과정에서 인위적으로 특정지역에 대한 산업입지 조성과 급속한 도시집중화로 인하여 중요 거점도시는 크게 비대해졌으며, 공업단지는 해안지역으로 계획배치 되면서 거대한 해안공업벨트가 형성되었다. 특히, 낙동강 유역에 인접한 동해남부의 포항지역과 울산지역은 각각 형산강과 태화강이 있으나 모두 자체유역에서의 용수공급에는 그 한계를 넘어 낙동강 본류와 지류로부터 유역을 변경시켜 용수공급을 해오고 있다.

특히, 형산강 유역의 용수수요는 포항철강공업의 확장과 포항시역의 팽창으로 인해서 날로 급증하고 있으며, 이 지역은 금호강 상류의 영천댐으로부터 유역변경방식에 의해서 형산강 유역으로 물을 전환시켜 공급받고 있으나 영천댐만으로는 용수공급에 한계가 있다. 그래서 영천댐은 임하댐으로부터 일 45만톤의 용수를 도수하기 위한 도수관로 건설이 진행되고 있으며, 앞으로 이들 수자원 시설 즉, 임하댐 - 영천댐 - 안계제로 연결되는 2단계 유역변경방식의 수자원 공급시스템에 대한 체계적인 연구가 시급한 실정이다.

따라서 기존의 저수지를 합리적으로 운영하기 위해서는 저수지에 유입되는 유출량의 정확한 추정과 저수지 하류부의 용수수요 및 공급계획이 선행되어야 하며, 연계된 저수지가 있을 경우는 저수지 시스템을 구축하여 저수지와 저수지 사이의 연계운영 방식을 도입해야 한다. 즉, 여러개의 저수지가 상호 유기적으로 결합되어 합리적으로 운영되기 위해서는 저수지 상류유역으로부터 발생하는 저수지 유입량의 정확한 추정방법과 저수지 운영기법 등의 개발이 필요하다.

그러므로 본 연구에서는 영천댐유역을 대상으로 저수지 유입량을 정확하게 추정할 수 있는 유출모델을 결정하기 위해서 Tank모델을 대상으로 모델의 최적 매개변수를 추정하는 방법을 분석도록 하였다.

2. 유출모델의 구조와 유출과정

유역유출모델 가운데서 장기유출모델은 Fig 2.1과 같이 탱크모델이 주로 사용되고 있다. 탱크모델은 직렬형과 병렬형이 있으나 용수공급 전용댐의 저수지 유입량을 추정하기 위해서는 장기유출해석이 필요하므로 2개의 저수지 유역에 각각의 탱크모델을 이용할 수 있다. 이때 강우량은 최상단 탱크에 유입되어 저류수가 점차 증가하면서 저류수 중에서 일부는 유출공으로 유출이 이루어지고 일부는 저면의 침투공으로 침투가 되어 하단 탱크인 제 2단 탱크로 유입된다. 이와 같이 유출 및 침투현상은 각 단의 탱크내에서 동일한 과정으로 이루어진다. 증발량은 최상단 탱크로부터 증발이 되며, 최상단 탱크내에 저류수가 부족할 경우는 순차적으로 하단 탱크로부터 증발이 발생하게 된다.

* 日本, 九州大 訪問研究員

** 嶺南大 教授

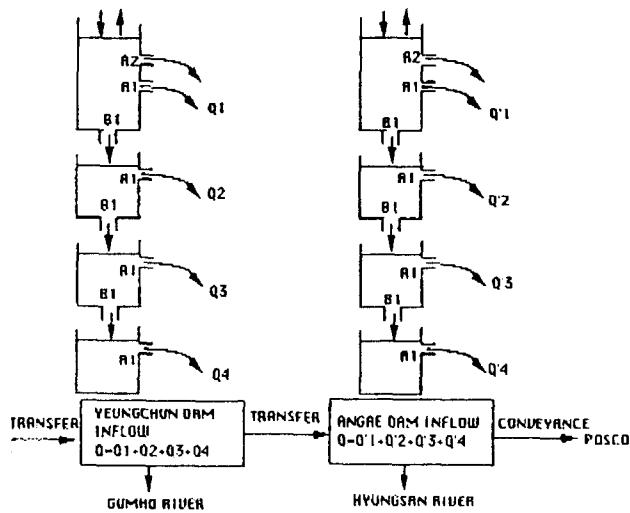


Fig. 2.1 Concept of Proposed Lowflow Model

3. 유출모델의 매개변수 추정기법

저수탱크모델의 매개변수를 추정하기 위하여 최적화기법인 증분동적계획기법(Incremental Dynamic Programming : IDP)을 적용해 보았으며, IDP 기법의 단점(계산시간의 과다)을 극복하기 위하여 뉴랄네트워크(Neural Network)중에서 계층형 뉴랄네트워크(Layer Neural Network : LN) 방법과 재현 뉴랄네트워크(Recurrent Layer Neural Network : RN) 방법을 적용토록 하였다. 매개변수의 최적화를 위하여 제시된 각 모델의 기본이론은 다음과 같다.

3.1 증분동적계획(Incremental Dynamic Programming : IDP) 방법

저수탱크의 경우 주로 4단의 탱크가 보편적으로 사용되고 있으나 장기유출의 경우 결정벡터와 상태벡터의 수가 너무 많아지기 때문에 이 때의 매개변수들을 전부 최적화하기에는 어려움이 많다. 그러나 IDP방법을 이용하면 시간은 걸리더라도 매개변수의 최적화가 가능하게 된다.

IDP방법은 관측치와 매개변수의 최적치에 의한 계산치가 최소오차에 이를 때 계산이 멈추게 되며, IDP 방법의 계산과정은 Fig.3.1 및 Fig.3.2와 같다.

3.2 뉴랄네트워크 (Neural Network) 방법

뉴랄네트워크방법은 신경세포와 관련된 생체기관을 단순화한 모델이다. 기억된 자료는 뉴런이라 불리는 신경세포에 직접 저장되지 않고 뉴런에 연결되어 분파된 신경세포에 분산되어 저장된다. 뉴랄네트워크의 이용사례는 시스템 모델링, 패턴의 인식 및 데이터의 압축분야로 크게 구분되며, 본 연구에서는 시스템 모델링의 특성이 이용되었다. 뉴랄네트워크는 완전한 블랙박스 모델로서 내부의 여러가지 매개변수, 경계조건 등이 없어도 비선형문제의 해법에 탁월한 효과를 나타낸다.

본 연구에서는 관측자료로 사전에 학습시킨 후 미리 세팅된 매개변수에 의해서 구한 유량의 시계열 값을 숨겨두고 출력된 최적의 매개변수를 구할 수 있도록 제안되었으며, 뉴랄네트워크의 기본적인 이론은 다음과 같다.

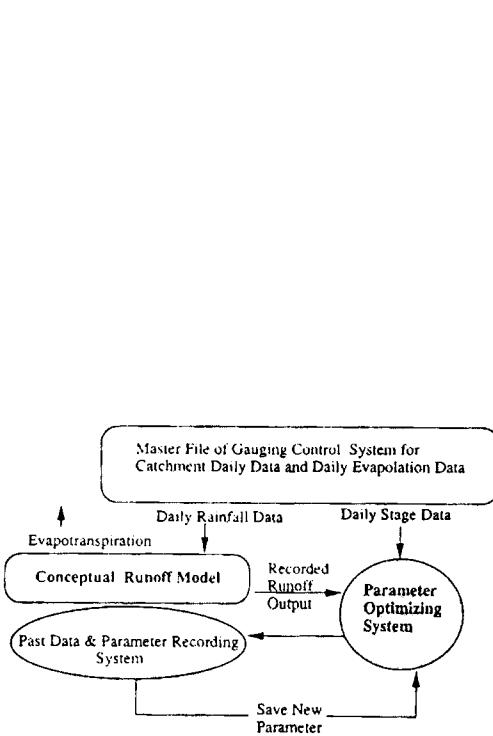


Fig.3.1 Concept of Tank Model Parameter Optimization with IDP

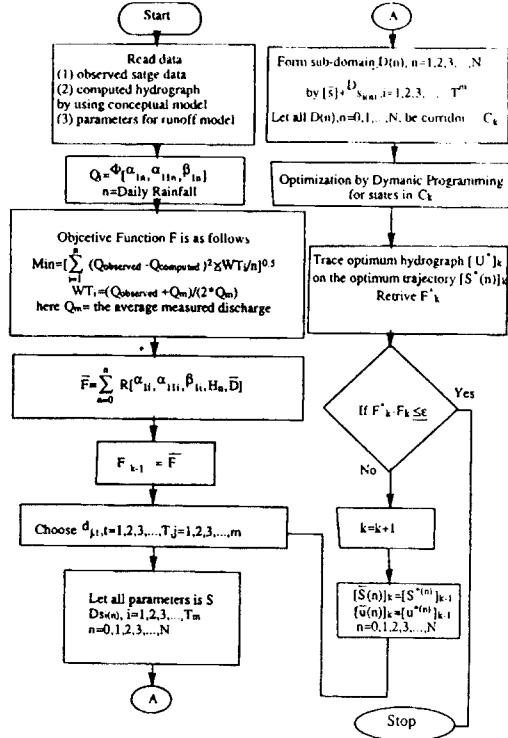


Fig.3.2 Flowchart of IDP Algorithm for Tank Model's Parameter

역변식의 알고리즘에 의해서 설계된 뉴럴네트워크는 관측치와 계산치의 오차를 최소화하는 방향으로 계산되는데 이를 위해서 연속미분이 가능한 식이 필요하며, 본 연구에서는 시그모이드라 불리는 식(1)과 같은 $f(a)$ 의 함수를 이용하였다.

$$f(a) = \frac{1}{1 + e^{-(a - \theta)}} \quad (1)$$

연속시계열 입력벡터 x_0, x_1, \dots, x_{N-1} 와 출력벡터 d_0, d_1, \dots, d_{m-1} 가 조건으로 미리 지정되어 있을 때 시그모이드 함수를 이용하여 출력벡터 y_0, y_1, \dots, y_{m-1} 가 계산된다. 숨겨진 노드 i 또는 입력 노드 j 의 가중치가 식(2)에 의하여 계산되고 이때 η 는 개인항이고 d_i 는 오차항이다..

$$W_{ij}(t+1) = w_{ij}(t) + \eta \delta_i x_i \quad (2)$$

만일 노드 j 가 출력노드라면 오차항 i 는 식(3)과 같이 나타낼 수 있다.

$$\delta_i = y_i(1-y_i)(d_i - y_i) \quad (3)$$

이때 d_j 가 희망 출력노드 j 라면 y_j 는 실제 출력치이고, 노드 j 가 숨겨진 노드라면 오차항은 식(4)와 같이 나타낼 수 있다.

$$\delta_j = x_j(1-x_j) \sum_k \delta_k W_{jk} \quad (4)$$

여기서, k 는 노드 j 의 상층노드이며, 운동항이 추가되면 가중치가 식(5)와 같이 계산되고, 다시 식(2)로 돌아가서 지정된 오차의 범위와 반복연산수를 만족시킬 때까지 반복 계산된다..

$$W_{ij}(t+1) = w_{ij}(t) + \eta \delta_i x_i + \alpha (w_{ij}(t) - w_{ij}(t-1)), \quad \text{here } 0 < \alpha < 1 \quad (5)$$

장기유출 탱크모델의 최적 매개변수를 추정하기 위하여 기존의 최적화기법을 이용하는 방법과 뉴럴네트워크를 이용하는 방법으로 나누어 적용하여 보았다. 본 연구에서 제시된 뉴럴 네트워크 모델은 계층형 뉴럴네트워크(LN) 방법과, 재현 뉴럴네트워크(RN) 방법이 이용되고 있다. 또한 네트워크의 학습 알고리즘으로서 백프로파게이션(Back Propagation : BP) 알고리즘과 확장칼만필터 알고리즘(Extended Kalman Filter : EKF)이 사용되고 있으며, 각 모델에 대한 간단한 내용은 다음과 같다.

계층형 네트워크 모델(LN)은 Fig. 3.3에 나타난 바와 같이 일반적인 3층의 네트워크로서 입력 층, 중간층 및 출력층으로 이루어진다. 각 층간의 유니트는 각기 접속되어 있고 신호는 좌측에서 우측으로 전달된다. 재현 뉴럴네트워크 모형(RN)의 경우, LN모형의 입력패턴을 출력패턴에 변환하는 범용적인 비선형사상을 실현하기 위한 시스템을 고려할 수 있다. 즉, LN의 경우 피드백의 결합이 가능하지 않아 구조상의 제약이 크다. 이와 같은 제약으로 인해서 피드백의 결합이 가능한 뉴럴네트워크를 재현 뉴럴네트워크(RN)라 하고 Fig. 3.4와 같이 나타낼 수 있으며, 이때 RN은 1개의 입력 패턴에 대하여 동적인 시계열의 패턴 출력이 가능하다.

본 연구에서는 2개의 네트워크에서 학습알고리즘으로서 BP 알고리즘과 확장칼만필터 알고리즘이 사용되었다. BP 알고리즘의 경우, 뉴럴네트워크를 구성하는 각 유니트 사이의 결합하중, 각 유니트에 있어서 시그모이드 함수를 수정학습하는 것이 가능하다. 즉, 출력층의 유출치 Or과 교차신호 Tr사이의 오차가 작아지는 방향의 신호를 출력층과 중간층의 순으로 계산하여 수정한다.

한편 확장 칼만필터(EKF) 알고리즘의 경우에 학습의 횟수를 시간축 t 에 나타내며, $\bar{x}(t/t)$ 는 결합하중의 추정치를 나타내고, 초기조건 ($t=0$)으로는 난수를 발생시키는 상태벡터 $\bar{x}(0/-1) = x_0$ (결합하중) 추정오차의 공분산 행렬 $p(0/-1) = \Sigma_0$ 및 잡음 공분산 행렬 $R = R_0$ 로 나타낸다.

한편 상태방정식($t = 0, 1, \dots$)은

$$X = \bar{x}(t/t-1) + k(t), [y(t - \phi(t)x(t/t-1))] \quad (6)$$

이며, 이때 $y(t)$ 는 관측치(교사 신호), $\phi(t)$ 는 관측행렬을 나타낸다. 칼만계인 $k(t)$ 는

$$k(t) = p(t/t-1)\phi^T(t)[\phi(t)p(t/t-1)\phi^T(t) + R]^{-1} \quad (7)$$

와 같이 나타낼 수 있으며, 추정오차의 공분산 행렬은

$$p(t/t) = p(t/t-1) - k(t)\phi(t)p(t/t-1) \quad (8)$$

로 나타낸다. 초기조건 x_0 , Σ_0 , R_0 가 주어져 있을 때 관측치 행렬은 이미 알고 있기 때문에 칼만게인 $K(t)$ 와 추정오차 공분산 행렬 $p(t/t)$ 가 계산된다. 따라서 상태방정식에 의해서 새로운 추정치를 구할 수 있다.

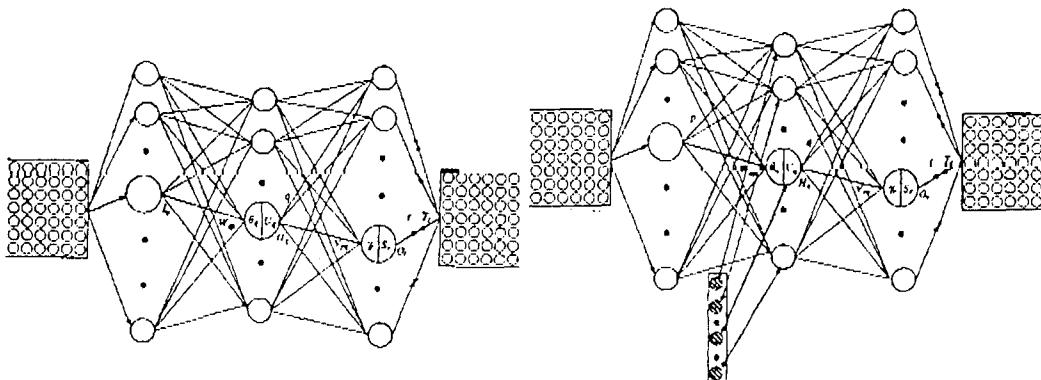


Fig.3.3 Layer Neural Networks Method

Fig.3.4 Recurrent Layer Neural Networks Method

4. 저수지시스템의 유출해석 적용

4.1 적용유역

본 연구에서 적용코자 하는 저수지는 금호강 상류에 위치한 영천댐을 중심으로 하였다. 영천댐은 Fig.4.1과 같이 포항지역의 용수공급과 댐 하류(금호강)의 하천유지용수를 포함한 용수공급을 종대시키기 위해서 형산강 유역에는 안계저수지가 운영되고 있으며, 임하댐으로부터 영천댐에 이르는 도수로가 건설되고 있다.

따라서 영천댐의 저수지 운영을 합리적으로 수행할 수 있는 방안을 모색하기 위하여 먼저 저수지 유입량을 추정할 수 있는 Tank 모델을 적용하여 강우-유출 시뮬레이션을 실시하고, 다음으로 임하댐-영천댐-안계제를 연계시키는 저수지 시스템의 최적운영방법을 분석하기 위하여 유출해석을 실시도록 하였다.

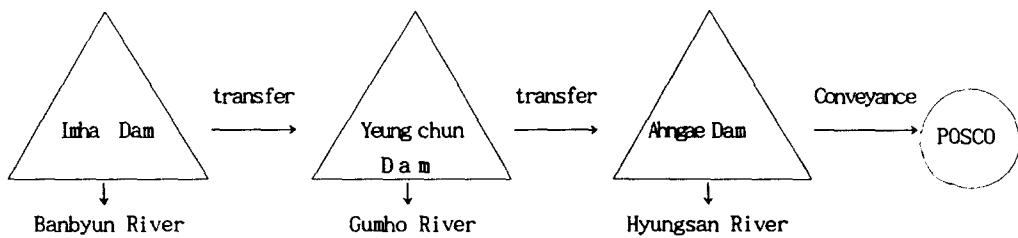


Fig. 4.1 Schematic Representation of the Yeungchun - Hyungsan Reservoir System

본 연구의 대상 저수지인 영천댐과 안계댐에 대한 저수시설의 주요 제원 즉, 유역면적 (A), 총 저수량(V), 유효 저수량(V'), 만수위 및 사수위(EL) 등은 다음 Table 4.1과 같다.

Table 4.1 Reservoir Characteristics

Item	Yeungchun Dam	Ahngae Dam
Basin Area (km ²)	235	6.7
Storage Capacity (10 ⁴ m ³)	9,640	1,765
Effective Storage (10 ⁴ m ³)	8,140	1,300
Normal High Water Level(EL. m)	156.8	43.9
Dead Storage level (EL. m)	138.0	31.0

4.2 유출모델의 매개변수 추정

한편 IDP모델, LN과 RN의 2개의 네트워크 구조, BP와 EKF의 2개의 알고리즘 등의 5종의 모델을 이용하여 매개변수 추정을 실시하였다. 먼저 학습단계로서 1992년부터 1994년의 영천댐 유역 및 안계댐 유역의 유출량 자료를 교사 신호로서 학습시킨다. 매개변수의 추정단계는 교사신호와 탱크모델에서 계산된 값사이의 오차를 최소로 하는 쪽으로 진행된다. RN모델과 LN모델을 비교해보면 시계열이 진행될수록 정도가 향상됨을 알 수 있다. EKF 알고리즘과 BP 알고리즘을 비교해보면 결과는 큰 차이가 없으나 1회의 학습시간에서 EKF가 BP보다 5배 정도가 더 소요됨을 알 수 있다. 각 모델에 의하여 추정된 매개변수의 값은 아래와 같다.

Table 4.2 Estimation of Parameters by each Method

Method Parameter	IDP	LN(BP)	LN(EKF)	RN(BP)	RN(EKF)
Tank1H ₂	23.01	23.22	23.21	23.23	23.23
- 1A ₂	0.21	0.22	0.22	0.21	0.22
- 1H ₁	15.12	15.22	15.27	15.19	15.23
- 1A ₁	0.14	0.15	0.15	0.14	0.13
- 1B ₁	0.20	0.22	0.23	0.23	0.22
Tank2H ₁	5.01	5.03	5.04	5.04	5.05
- 2A ₁	0.06	0.05	0.05	0.07	0.06
- 2B ₁	0.08	0.07	0.06	0.06	0.07
Tank3H ₁	5.31	5.22	5.22	5.24	5.24
- 3A ₁	0.02	0.02	0.02	0.02	0.02
- 3B ₁	0.03	0.04	0.04	0.04	0.03
Tank4H ₁	0	0	0	0	0
- 4A ₁	0.001	0.002	0.002	0.002	0.003
- 4B ₁	0	0	0	0	0

최적화 기법의 경우 상관계수의 값과 계산시간은 Table. 4.3과 Table. 4.4에 나타난 바와 같이 상관계수는 결코 나쁘지 않았으나 계산시간이 많이 걸리는 결점이 있다. 백프로파게이션 기법은 확장칼만필터 기법과 비교할 때 처음의 정도는 같았으나 시간이 진행되어 사전학습의 정보가 많아질수록 정도가 증가되는 고속 고정도의 모형이라 할 수 있다. 또한 네트워크의 구성을 계층 네트워크에서 재현 네트워크로 할 때 시계열의 변화를 만족시킬 수 있었고, 고정도 고속의 뉴럴네트워크의 모델구축이 가능했다.

Table. 4.3 Comparison of Correlation Coefficient of each Method

Method	1992	1993	1994
IDP	0.811	0.821	0.801
LN(BP)	0.668	0.699	0.711
LN(EKF)	0.683	0.736	0.703
RN(BP)	0.839	0.864	0.819
RN(EKF)	0.759	0.799	0.716

Table. 4.4 Comparison of Computation Time of each Method

Method	IDP	LN(BP)	LN(EKF)	RN(BP)	RN(EKF)
Time(Min)	113.9	7.4	36.4	8.2	33.1

4.3 유출해석 적용비교

영천댐과 안계제에 유입하는 유출량의 시뮬레이션은 영천댐 유역의 중심부에 위치한 죽장지점에서 발생한 최근 강우량(1992~1994년에 발생한 일강우량)을 탱크모델에 적용하여 일유출량을 모의하였으며, 이때 영천댐과 안계제에 유입하는 월유입량의 계산결과를 나타내면 Fig.4.1(a) 및 (b)와 같다.

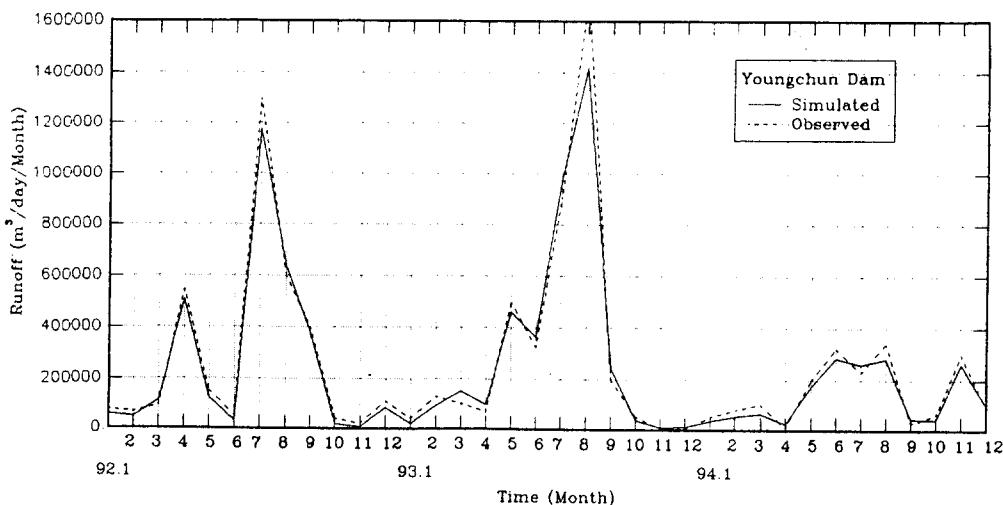


Fig. 4.1(a) Comparison of Observed and Simulated Monthly Runoff at Yeungchun Reservoir Basin

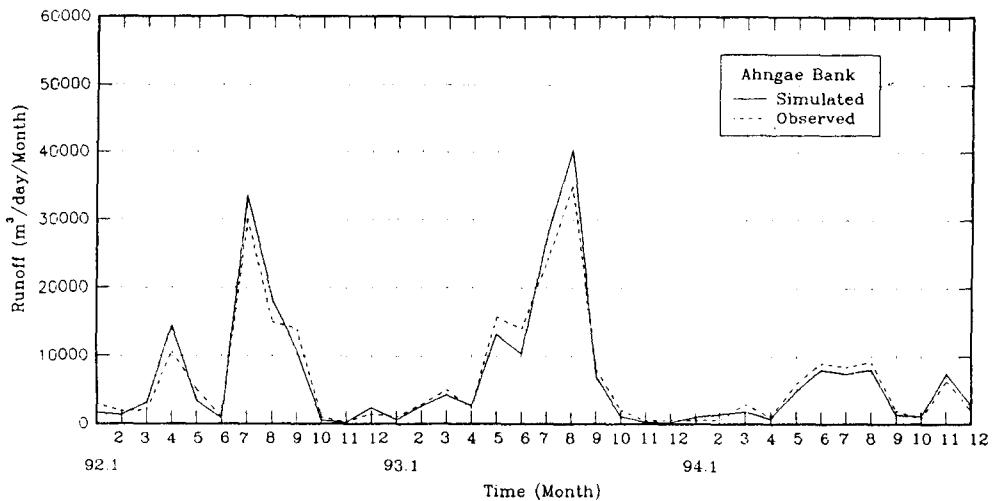


Fig. 4.1(b) Comparison of Observed and Simulated Monthly Runoff at Ahngae Reservoir Basin

5. 결 론

지금까지 임하댐-영천댐-안계제를 연계시킨 저수지 시스템에서 안계제와 임하댐의 일 유출량을 구하기 위하여 IDP기법, LN(BP)방법, LN(EKF)방법, RN(BP)방법을 적용하여 매개변수의 추정을 실시한 결과, IDP기법의 경우 상관계수의 값은 결코 나쁘지 않았으나 계산시간이 많이 걸리는 결점이 나타내었다. BP방법은 EKF방법과 비교할 때 처음의 정도는 같았으나 시간이 진행되어 사전학습의 정보가 많아질수록 정도가 증가되는 고속 고정도의 방법이라 할 수 있다.

또한 네트워크의 구성을 LN방법에서 RN방법으로 할 때 시계열의 변화를 만족시킬 수 있었고 고정도 고속의 뉴럴네트워크의 모델구축이 가능했다.

6. 참고문헌

- 1) Lee, Soontak,(1986) : Optimal Water Allocation Model through Inter-Basin Water Transfer, Proceedings of IWRA Beijing 6th World Congress
- 2) R.P.Lippmann(1987) : An Introduction to Computing with Neural, IEEE ASSP magazine, pp4-22.
- 3) Sugawara, M., Ozaki, E., Watanabe, I, and Katsuyama, Y. (1978). Method of Automatic Calibration of Tank Model(Second Report). Rep. 20, Nat. Res. Center for Disaster Prev., Tsukuba.