

◎ 논문

웨이블릿 해석과 인공 신경회로망을 이용한 원자력발전소의 급수유량 평가

유성식* · 박종호**

Feedwater Flow-rate Evaluation of Nuclear Power Plants Using Wavelet Analysis and Artificial Neural Networks

Sung-Sik Yu*, Jong-Ho Park**

Key Words: Feedwater Flow (급수유량), Venturi Meter (벤츄리계), Fouling (이물질침착), Wavelet (웨이블릿), Neural Networks (신경회로망), Denoising (잡음제거)

ABSTRACT

The steam generator feedwater flow-rate in a nuclear power plant was estimated by means of artificial neural networks with the wavelet analysis for enhanced information extraction. The fouling of venturi meters, used for steam generator feedwater flow-rate in pressurized water reactors, may result in unnecessary plant power derating. The back-propagation network was used to generate models of signals for a pressurized water reactor. Multiple-input, single-output hetero-associative networks were used for evaluating the feedwater flow rate as a function of a set of related variables. The wavelet was used as a low pass filter eliminating the noise from the raw signals. The results have shown that possible fouling of venturi can be detected by neural networks, and the feedwater flow-rate can be predicted as an alternative to existing methods. The research has also indicated that the decomposition of signals by wavelet transform is a powerful approach to signal analysis for denoising.

1. 서 론

원자력발전소에서 원자로 열출력을 정확하게 측정하는 것은 매우 중요하다. 원자로의 운전출력은 규제 기관의 인허가 요건에 의해 정격열출력 (rated thermal power)의 100% 이내로 제한되기 때문에, 과대평가가 되면 바로 전기출력 감소로 이어지고 과소평가의 경우에는 안전성에 영향을 미친다. 현재 원자로 열출력은

증기발생기내의 질량과 에너지 평형을 이용하는 고전적 열역학 방법에 의해 계산되는데 증기발생기의 급수 유량과 거의 선형적인 비례 관계를 가진다. 따라서 정확한 열출력 측정을 위해서는 급수유량의 정확한 측정이 필수적이다. 원자력발전소에서 급수유량 측정에 가장 범용으로 사용되는 장비는 벤츄리계이다. 벤츄리계는 벤츄리관을 가로지를 때의 압력강하를 벤츄리 입구와 목의 압력 탭을 이용하여 측정하고 급수관의 유량으로 변환한다.

벤츄리계를 이용한 급수유량 측정에서 가장 중요한 문제는 일정기간에 걸쳐 진행되는 벤츄리 목 부분에서

* 충남대학교 대학원, 한국전력기술(주)

** 충남대학교 기계공학과

의 부식 생성물 침적이다. 이것은 벤츄리에 의해 측정되는 압력강하를 증가시켜 실제보다 높은 유량을 지시 토록 한다. 이러한 잘못된 유량 지시는 열출력의 과대 평가를 야기하는데, 열출력이 과대평가 되면 열적여유도 (thermal margin)가 증가하여 안전성에는 문제가 없으나 통상적으로 약 2%의 부당한 전기출력 감소를 가져온다. 약 2%의 전기출력 감소는 800 MWe 발전소의 경우 kWh 당 \$0.05의 전기비용을 감안할 때 매일 2만불의 손실을 가져오고 원자력발전소 전체를 고려하면 총 손실은 매우 크다고 할 수 있다⁽¹⁾.

정확한 급수유량 측정을 위해 벤츄리 기기의 재교정이나 일부 해석적 방법에 의한 변환상수의 수정 또는 벤츄리계의 이물질 침적 방지 코팅과 같은 하드웨어 기반의 해결책들에 대한 많은 연구들이 진행되었다. 이를 결정론적인 접근방식들은 운전조건에 따른 적응 능력을 가질 수 없기 때문에 문제를 해결하는데 한계가 있다. 또한 이행하기 쉽고 상대적으로 비용이 저렴한 소프트웨어 기반 기술들의 개발에도 많은 진척이 있었지만 실제로 발전소에 적용하기에는 부족함이 있었다.

최근에는 해외 원자력발전소 일부에서 초음파유량계 (ultrasonic flowmeter: UFM)를 이용하여 급수유량을 측정하고 이를 근거로 벤츄리 상수를 교정하거나 아예 초음파유량계 측정값을 벤츄리계의 측정값 대신 열출력의 온라인 계산 입력으로 사용하는 사례가 늘고 있다. 국내 원자력계에서도 요즘 초음파유량계의 적용에 관한 연구가 진행되고 있다. 초음파유량계는 정확도 면에서 매우 우수하나, 발전소 적용을 위해서는 적지 않은 비용과 함께 규제기관의 인허가를 취득하기 위한 많은 연구들이 선행되어야 하는 점이 부담이다.

본 연구에서는 급수계통의 물리적 상태나 측정계통의 변화에 무관하게 급수유량을 평가할 수 있는 인공 신경회로망을 모델링하였다. 학습을 위해 역전파 (back-propagation) 알고리즘을 사용하는 다층 전방향 (feed-forward) 회로망을 이용하였다. 입력으로부터 출력으로의 비선형 사상 (mapping)을 학습하는 역전파 알고리즘의 능력과 디층망의 내고장성 (fault-tolerant) 특성은 전력산업에서의 다양한 응용을 가진다⁽²⁾. 사상은 서로 연결된 다층 이질연상 (hetero-associative)망을 이용하였다. 학습자료로는 한국표준형 원자력발전소의 실제 운전자료를 이용하였고, 신경회로망의 성능을 평가하기 위해 초음파유량계로 측정한 유량값과 비교분석하였다. 급수유량 평가의 정확도를 향상시키는 전략의 하나로서, 발전소 실측자료의 잡음을 분리, 제거하기

위해 웨이블릿 해석을 수행하였다. 또한 입력변수들의 급수 유량에 대한 중요도를 평가하기 위해 급수유량 평가 모델에 대한 민감도 분석을 수행하였다.

2. 원자력발전소에서의 급수유량 측정

원자력발전소의 원자로열출력은 규제기관의 인허가 조건에 의해 제한되기 때문에 열출력을 정확하게 측정하는 것이 경제적인 측면에서 매우 유익하다. 원자로 열출력을 나타내는 에너지평형식은 다음과 같이 단순하게 표현 가능하다(Fig. 1).

$$Q_{th} = m_{fw}(h_s - h_{fw}) + \dot{m}_{net} t \quad (1)$$

여기서 Q_{th} 는 이차축 기준으로 계산한 원자로 열출력, m_{fw} 는 급수 유량률, h_s 는 증기엔탈피, h_{fw} 는 급수 엔탈피, \dot{m}_{net} 는 원자로냉각재펌프 가동열이나 냉각재 누설에 의한 열손실 등을 고려한 증기발생기로의 순에너지 유입량을 의미한다. 열출력은 식(1)에서 보는 바와 같이 급수유량과 거의 선형적인 관계를 가지고 있고 열출력의 불확실도는 급수유량의 불확실도에 의해 가장 지배적인 영향을 받는다⁽³⁾. 주급수유량 측정 오차 (Δm_{fw})에 의한 절대 오차 E_a 는 식 (2)에 의해 표현될 수 있다.

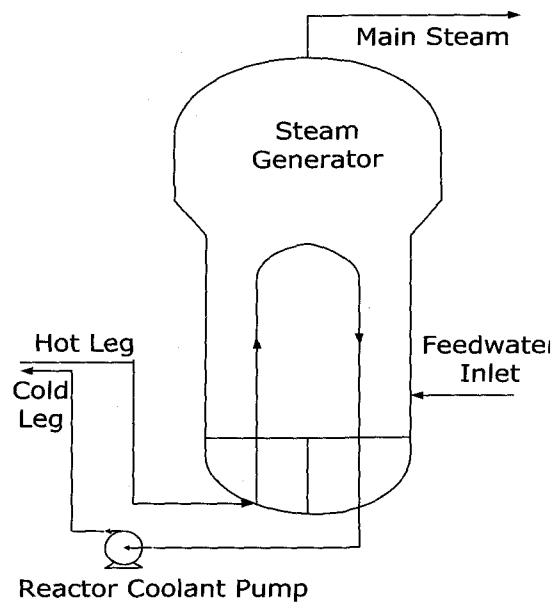


Fig. 1 Schematic of a steam generator

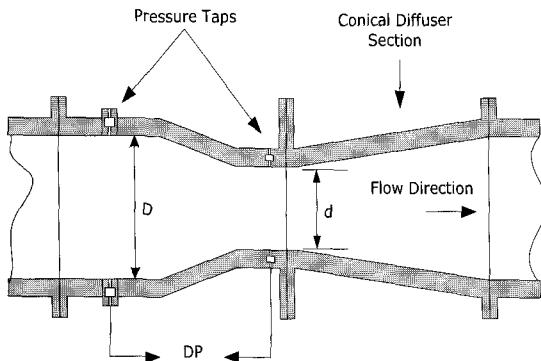


Fig. 2 Schematic of a venturi meter

$$E_a = \left| \Delta m_{fw} \cdot \frac{\partial Q_{th}}{\partial m_{fw}} \right| \quad (2)$$

급수유량의 5% 오차는 1000 MWe 가압경수로의 경우 출력계산에서 약 3%의 오차를 야기할 수 있다⁽⁴⁾.

대부분의 원자력발전소에서는 급수유량 측정을 위해 벤츄리계를 사용하는데 정확도와 적용성 그리고 적절한 가격 등이 그 이유다. 벤츄리계 (Fig. 2)는 대표적인 장애식 유량계로서 유체를 가속시켜 발생하는 입구와 목과의 압력차를 이용하여 통과하는 유량을 측정한다. 급수 벤츄리의 유량식은 다음과 같다^(5,6).

$$m_{fw} = C \left(\frac{C_d d^2 F_a}{\sqrt{1 - \beta^4}} \right) \sqrt{\frac{DP_{fw}}{v_{fw}}} \quad (3)$$

여기서 C 는 상수, C_d 는 유량계수 (discharge coefficient), F_a 는 열팽창계수, d 는 벤츄리 목 직경, β 는 직경비(d/D), D 는 벤츄리 배관 직경, DP_{fw} 는 벤츄리 측정 차압, v_{fw} 는 급수 비체적이다. 한국표준형원자력발전소 발전소 주전산기의 열출력 계산에서 사용되는 유량식은 다음과 같다.

$$m_{fw} = (C_1 + C_2 \cdot T_{fw}) \sqrt{\frac{DP_{fw}}{v_{fw}}} \quad (4)$$

여기서 C_1 은 벤츄리 유량상수, C_2 는 벤츄리 온도상수, T_{fw} 는 급수온도이다.

벤츄리계는 사용중에 다양한 문제에 직면하는데 가장 대표적인 문제가 발전소 출력 감소의 원인인 이물질침침적 현상이다. 벤츄리 이물질 침적은 증기발생기 급수에 포함한 철산화물이나 철수산화물 같은 부식생성

물이 벤츄리 수렴부에 침착되는 현상으로 정의된다.⁽⁷⁾ 원자로 운전동안 벤츄리의 이물질침침적 진행에 따라 압력강하는 증가하는데 이는 급수유량이 증가되었다는 거짓 지시를 유발한다. 이 경우 식(1)에 따라 원자로 열출력은 실제보다 과대평가된다.

원자로 열출력은 발전소의 인허가출력 이하로 제한되기 때문에 벤츄리계의 급수유량 과대평가로 인한 열출력의 과대평가는 바로 실제 열출력의 감소를 불러오고 이는 전기출력의 감소를 유발한다. 이때 급수유량은 설계값으로 일정하게 유지되는 것으로 지시되기 때문에 출력손실을 명확하게 감지하는 것은 어렵다. 급수유량의 거짓 지시에 따른 오차는 초음파유량계, 화학추적자 또는 발전소 표준 변수들의 주의 깊은 검토를 통해 확인될 수 있다.

3. 방법론

가압형 경수로의 급수유량 평가를 위해 역전파 알고리즘으로 학습되는 다층 전방향 신경회로망이 사용되었다. 본 연구에서 사용된 전방향 회로망의 구조는 Fig. 3과 같고 신경회로망의 가장 기본적인 요소인 노드의 구조는 Fig. 4와 같다. 하나의 노드에 대한 입력들의 가중합이 임계치를 초과하면 노드는 활성화되고 출력신호가 생성된다. 역전파 알고리즘은 원하는 목표 출력과 실제 출력값 사이의 오차제곱합으로 정의된 비용함수 (cost function)의 값을 경사하강법 (gradient-descent method)에 의해 최소화하는 방향으로 학습한다.

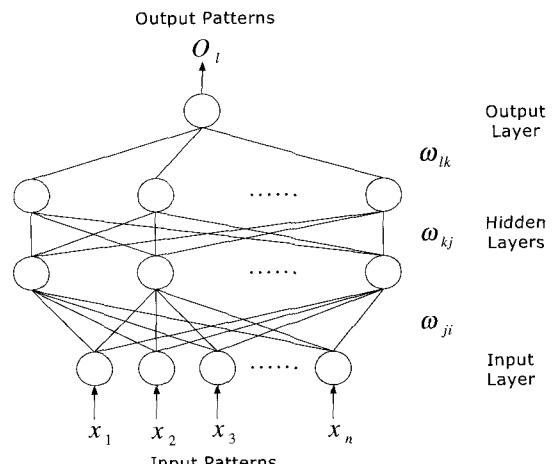


Fig. 3 Structure of a multi-layered feed-forward neural network for feedwater flow estimation

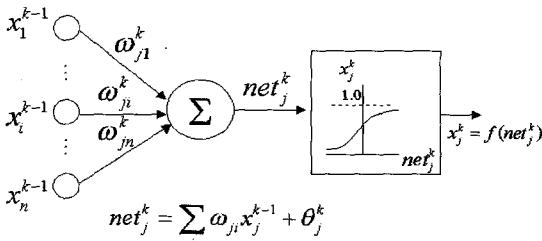


Fig. 4 Output processing in a node

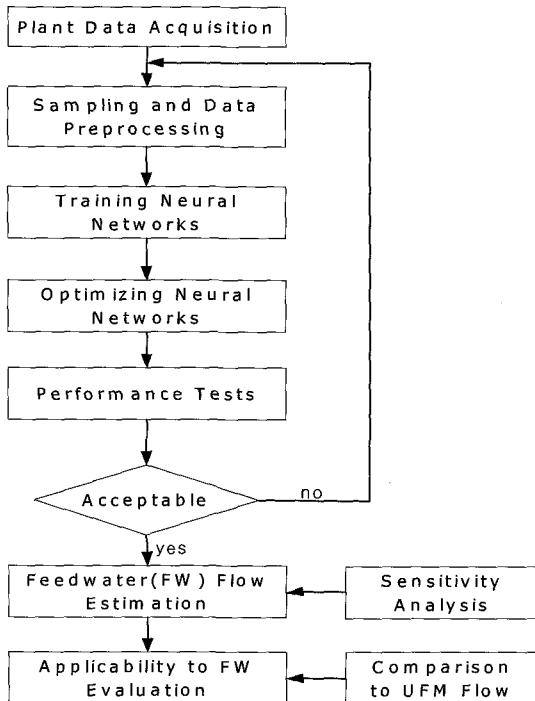


Fig. 5 Feedwater flow-rate evaluation process

급수유량 평가를 위한 신경회로망으로 입력되는 발전소 신호들을 설정하기 위해 증기발생기에 대한 거시적 에너지 및 질량 평형을 고려하였다.

급수유량 신호는 시간특성에 따라 세 종류로 분류할 수 있는데 바로 1) 이물질침적 현상 등에 의해 서서히 변하는 잡음, 2) 열적효과 등에 의한 빠르게 변하는 잡음, 그리고 3) 잡음이 없는 신호이다⁽²⁾. 빠르게 변하는 잡음들은 모든 종류의 측정계통들에서 임의로 나타날 수 있고 다른 운전변수들과 상호관계를 가지지 않는다. 그래서 상호관계에 기반한 기술들을 이용하여 빠르게 변하는 잡음을 제거하는 것은 불가능하다. 빠르게 변하는 잡음의 크기는 이물질침적등에 의한 서서히 변하는 잡음에 견줄만 하여서 이산(discrete) 학습 자

료를 이용하여 학습되는 신경회로망으로는 그 차이를 구별하기가 어렵다. 본 연구에서는 신경회로망의 정확도를 높이기 위해, 웨이블릿 변환을 이용하여 신경회로망의 입력으로 사용되는 발전소 실측자료들로부터 빠르게 변하는 잡음을 제거하였다.

신경회로망의 급수유량 평가 성능을 검증하기 위해 초음파유량계로 측정한 결과와 비교하였다. 본 연구에서 수행한 급수유량 평가의 개략적 절차는 Fig. 5와 같다.

3.1. 입력자료 전처리 (Preprocessing)

입력자료 전처리는 신경회로망을 적용하는데 있어서 매우 중요한 문제이다. 각 입력신호에 대해 정상적 범위를 벗어난 표본들을 제거하고, 시그모이드(sigmoid) 전달함수의 포화 효과를 극복하기 위해 세로방향(column-wise)으로 정규화를 적용하였다. 신호 각각의 최소값과 최대값을 계산하고 이에 맞춰 각 신호의 모든 값을 [0.2, 0.8]의 작은 구간으로 변환하였다.

학습자료의 선택은 지도학습(supervised) 신경회로망의 성능에 아주 중요한 역할을 한다. 일반적으로 좋은 재생(recall) 성능을 위해서 입력신호와 출력신호의 범위를 완전히 걸치는 학습 패턴을 이용하여야 한다. 원자력발전소에서 가장 정확한 자료는 핵연료 재장전 이후 초기 몇 주간에서 얻어지는 것으로 기대되는데 이는 재장전 정지기간동안 대부분의 계통에 대해 강도 높은 유지·보수 작업을 수행하기 때문이다. 급수유량 측정 벤츄리계도 재장전 보수기간동안 청소와 더불어 재교정되기 때문에 주기초에는 매우 정확한 신호를 시사할 것이다.

3.2. 웨이블릿 해석을 이용한 잡음제거

신호의 중요한 부분은 신호의 정체성을 가지는 저주파 성분이다. 그래서 학습자료의 잡음제거는 저주파 통과 필터링(low-pass filter)을 의미한다.

전통적으로 쿠퍼에 해석은 매우 유용한 기법이지만 중요한 단점을 가지고 있는데 바로 시간 정보가 주파수 공간에서 손실된다는 것이다. 그래서 웨이블릿 해석은 특정 주파수를 가진 순간 신호들이 시간 공간에서 감지되어야 할 때 매우 유용하다. 웨이블릿 해석에서는 시간-주파수 공간보다는 시간-스케일 공간이 가변의 윈도우함수(windowing) 기법에 사용된다⁽⁸⁾.

웨이블릿 해석을 이용한 잡음제거는 세단계로 구

성된다:

- (1) 웨이블릿 분리 (decomposition) : 웨이블릿 종류와 분리 레벨을 결정한 후, 하표본추출 (down sampling) 을 수행한다. 하표본추출은 주어진 레벨에 따라 반복된다.
- (2) 임계치 적용 : 상세 계수를 생성하기 위해 임계치를 선택하여 적용한다.
- (3) 웨이블릿 재편성 (reconstruction) : 이것은 웨이블릿 역변환으로도 불리운다. 분리된 신호는 초기 균사계수와 수정된 상세계수들을 이용하여 합성된다.

3.3. 신경회로망 구성

본 논문에서는 2개의 은닉층 (hidden layer)을 포함하는 4층망이 사용되었다. 최적의 은닉층 수와 노드 수를 결정하기 위해 학습에 사용되는 층과 노드수를 작은 수로부터 서서히 늘려가는 시행착오 방식을 사용하였다. 전달함수로는 시그모이드 함수 일종인 접선쌍곡 (tangent hyperbolic) 함수를 사용하였다. 역전파 알고리즘 학습에서 또 하나의 중요한 요소는 수렴 속도인데 이것은 학습계수 (learning coefficient)에 의해 결정된다. 일반적으로 빠르면서도 학습 반복이 불안전해 질 만큼 빠르지는 않게 학습하는게 바람직하다⁽⁶⁾.

3.4. 신경회로망의 민감도 분석

신경회로망의 입출력 모델은 하나의 입력신호에 대한 출력신호의 민감도를 구하기 위해 사용될 수 있다. 이러한 민감도들은 회로망 출력을 평가하기 위한 변수를 선택하는데 사용할 수 있다.

신경회로망 모델의 입력 x 에 대한 출력 y 의 상대적 민감도는 입력에 대한 출력의 편미분 ($(\partial y/\partial x)/(y)$)으로 정의된다. 이 편미분은 공칭값 근처의 작은 교란에 대해 다음과 같이 근사될 수 있다: $(\partial y/\partial x) \approx (\Delta y/\Delta x)$. 입력신호들을 미세하게 교란시켜 급수유량 예측 신경회로망 재생을 통해 민감도를 평가하였다.

3.5. 초음파유량계를 이용한 급수유량 측정

신경회로망의 성능을 평가하기 위해 측정 정확도가 매우 우수한 초음파유량계 측정자료를 활용하였다. 비

교분석을 위해 초음파유량계 측정이 이루어진 시간대의 운전자료를 취득하였다. 유량측정에 사용된 초음파유량계는 상관관계 (cross-correlation) 측정 방식이었고 약 2일간에 걸쳐 자료를 취득하였다

4. 결과 및 고찰

급수유량의 평가 분석을 위해 1000 MWe 한국표준형원자력발전소의 운전자료를 사용하였다. 벤츄리계의 이물질침식 특성을 고려하여 운전주기 초기와 주기 중간에 각각 2주간에 걸쳐 10분 간격으로 약 2000개씩의 자료를 취득하였다. 이 자료들을 시간단위로 평균한 후, 주기초의 자료는 학습과 시험용으로 사용하고 주기 중간 자료는 초음파유량계 측정결과와의 비교를 통한 신경회로망의 적용성 평가에 사용하였다. 이와 같이 본 연구에서는 계통의 장기간 성향을 분석하였고 이는 다른 연구들에서 좁은 구간의 순간 자료를 사용하여 분석한 것에 비해 강조될 수 있는 요소이다.

발전소 공정 신호 6개의 함수로서 급수유량을 평가하기 위해 4층 신경회로망을 개발하였다. 입력신호들은 Table 1과 같은데, 증기발생기의 질량 및 에너지 평형에 관련된 여러 변수들을 입력으로 한 신경회로망 분석을 통해 급수유량에 의미있는 관계를 가지는 변수들을 신경회로망의 최종 입력신호로 선택하였다. 여기서 의미있는 관계란 발전소 운전조건의 변화에 민감하지 않은 변수로서 해당 변수의 변화가 급수유량에 예측 가능한 방향으로 영향을 주는 관계를 의미한다. 두 개의 은닉층을 사용하였고 각 은닉층의 노드수는 최적 분석을 통해 10개씩으로 결정하였다.

신경회로망에서 사용되는 모든 신호들은 [0.2, 0.8]의 구간으로 정규화되었다. 취득한 발전소 자료중 정상적인 범위를 벗어난 신호들은 제거하고 시간단위로 평균한 뒤 분석에 사용하였다. 학습 및 시험을 위한 운전주기

Table 1 Signals used for feedwater flow analysis

Number	Signal
1	Feedwater temperature
2	Feedwater pressure
3	Steam generator pressure
4	Turbine impulse pressure
5	Hot leg temperature
6	Cold leg temperature

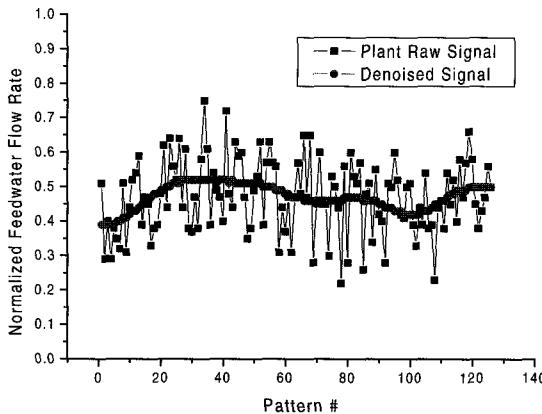


Fig. 6 Feedwater flow rate signal by wavelet denoising

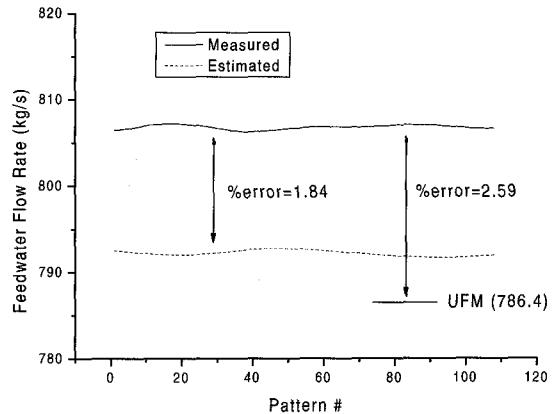


Fig. 8 Measured versus estimated feedwater flow-rates at MOC

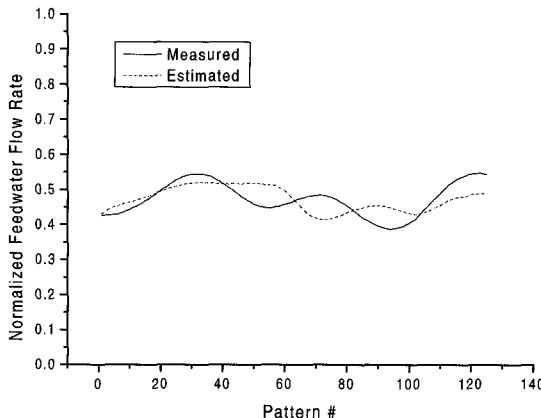


Fig. 7 Recall results for network validation

초 자료 그리고 신경회로망의 성능평가를 위한 주기증간 자료의 수 (pattern #)는 각각 126, 125, 108개이다.

발전소 신호들의 잡음을 제거하기 위한 웨이블릿 해석에는 레벨 4의 메이어 (Meyer) 계열 웨이블릿을 사용하였다. Fig. 6은 발전소 실측 자료인 급수유량 신호로부터 빠르게 변하는 잡음을 제거한 결과이다.

신경회로망은 10-3의 제곱평균 (root mean square: RMS) 오차까지 학습된 다음, 재생을 위해 사용되었다. 학습자료와 같은 시간대에 번갈아 표본추출된 검증자료를 이용한 재생 결과는 Fig. 7과 같다. 재생 RMS 오차는 4.9%이었다.

급수유량 평가를 위한 신경회로망의 실제 적용성 여부는 실제 유량을 얼마나 잘 예측할 수 있는지에 달려 있다. 이는 측정 정확도가 우수한 초음파유량계 측정 결과와의 비교를 통해 평가가 가능하다. 초음파 유량계 유량측정은 운전주기 중간 (middle of cycle: MOC)

Table 2 Results of performance analysis of artificial neural networks (ANN) by comparison with UFM

Data Source	Mean Flow Rates(kg/s)	%Deviation*
Plant Data	806.8	-
UFM	786.4	2.59
ANN	792.2	1.84

*deviation = (plant data - UFM or ANN) × 100/(UFM or ANN)

정도에서 수행되었는데, 측정결과, 발전소 지시값과의 %오차가 약 2.59%로 벤츄리계에 의한 급수유량이 높게 지시되고 있음을 보여주었다.

개발된 신경회로망으로 평가한 급수유량 결과는 Fig. 8에서 보여준다. 발전소 지시값과의 %오차는 약 1.84%로서 초음파유량계 결과와 가깝게 실제 급수유량을 잘 예측하고 있음을 알 수 있다. 이러한 신경회로망의 성능은 절대값에 대한 정확도는 부족하지만 이물질침적 여부나 이물질 침적 분리 등을 감지하기 위한 정보로서는 충분하다. Table 2는 신경회로망의 성능평가 결과를 보여준다.

신경회로망의 출력에 가장 크게 기여하는 입력을 결정하는데 입력력 모델의 민감도를 사용할 수 있다. Table 1에서 주어진 6개의 신호 각각에 대해서 영(0)에 가까운 작은 양만큼 교란시키고 출력의 영향정도를 회로망 재생을 통해 구했다. MOC때의 자료중 50개의 표본을 이용하여 각 신호의 교란에 따른 출력의 변화율을 구했다. 인공 신경회로망 특성상 입력과 출력간 변화의 방향성, 즉 양 또는 음의 기울기는 물리적인 의미를 가지지 못할 것이다. 따라서 출력 변화의 절대값을 취해 민감도를 평가하였다.

Table 3은 입력신호 각각에 대해 0.1%만큼의 교란이

Table 3 Sensitivities of feedwater flow-rate to 0.1% input perturbations

Order	Parameters	Sensitivity (%)
1	Turbine impulse pressure	0.83
2	Feedwater temperature	0.78
3	Cold leg temperature	0.65
4	Hot leg temperature	0.33
5	Feedwater pressure	0.24
6	Steam generator pressure	0.19

주어질 때 얻어지는 출력변화와 신경회로망에 대한 입력신호의 중요도를 보여준다. 터빈충동압력의 변화가 급수유량의 변화에 가장 큰 영향을 미치는 것으로 나타났다. 터빈충동압력은 실제 급수유량과 밀접한 관계를 갖는 변수이다. 증기유량이 증가하면 터빈충동압력은 증가하고, 발전소 제어계통의 제어를 통해 급수유량 또한 증가된다. 이물질침착에 의해 급수유량이 과대 평가되면, 발전소 감시계통에 의해 지시되는 급수유량은 정상범위에서 일정하게 유지되는 것으로 보이나 터빈충동압력은 실제 급수유량의 감소에 따라 서서히 감소하는 현상을 보여준다. 이러한 발전소 거동은 터빈충동압력이 급수유량의 실제 거동을 판단하는 인자로서 활용될 수 있음을 제시한다. 가장 덜 민감한 변수는 증기발생기 압력이었다.

5. 결론

본 연구의 결과들은 증기발생기의 급수유량이 인공 신경회로망에 의해 감시될 수 있음을 보여주었다. 특히 급수 벤츄리계의 이물질 침적 및 분리를 감지하기에 충분한 성능을 보여주었다 그러나 신경회로망을 이용하여 이물질침적 효과를 정확하게 정량화하는 것은 가능하지 않을 것이다. 그 이유로는 증기발생기 급수 유량과 관련한 운전조건의 변화가 다양하고 신경회로망 학습자료의 정확성을 검증하는게 어렵기 때문이다. 그렇지만 실제값 근처에서 상대적 유량을 평가하는 성능은 원자력발전소에 적용하기에 충분한 것으로 판단된다.

웨이블릿 해석을 통한 학습자료의 잡음제거는 신경회로망의 성능을 크게 개선하는 것으로 분석되었다. 학습자료의 양호한 품질은 신경회로망의 적용성 향상을 위해서 필수적인 요소이다. 발전소 신호 전처리 과

정에서 웨이블릿을 이용한 저주파 통과 필터는 빠르게 변하는 잡음을 최소화하고 궁극적으로는 신경회로망의 평가 성능을 개선하였다.

신경회로망 입력으로 어느 변수를 선택하느냐는 다분히 분석가에 달려있다. 적은 수의 입력신호를 사용하는 것은 신경회로망의 정확도를 감소시킬 수 있는 반면에 너무 많은 신호를 사용하는 것은 불필요한 복잡성 및 잘못된 결과를 가져올 수 있다. 신경회로망을 이용한 민감도 분석에서는 급수유량과 가장 크게 연관성이 있는 신호는 터빈충동압력이고 가장 덜 영향을 미치는 신호는 증기발생기 압력인 것으로 나타났다. 이러한 결과는 터빈충동압력의 기동 분석을 통해 실제 급수유량의 추이에 대한 개략적인 파악이 가능하다는 것을 보여준다.

참고문헌

- (1) 1993, Flowrate Measurement Causes Unneeded Derating, Nuclear News, pp. 39~40.
- (2) Kavaklıoglu, K. and Upadhyaya, B. R., 1994, "Monitoring Feedwater Flow Rate and Component Thermal Performance of Pressurized Water Reactors by means of Artificial Neural Networks," Nuclear Technology, Vol. 107, pp. 112~123.
- (3) 김범식 외, 2002, 가동원전 엔지니어링 서비스 기술개발, 한전기공(주), 3차년도보고서, pp. I-32~40.
- (4) 허균영, 1999, 신경회로망과 주성분 분석법을 이용한 원자력발전소 열출력 예측, 한국과학기술원 원자력공학과 석사학위 논문, pp. 18~19.
- (5) ASME Report, 1971, Application Part II of Fluid Meters, Research Committee on Fluid Meters, New York, pp. 230~232.
- (6) Doeblin, E. O., 1983, Measurement Systems Applications and Design, McGraw-Hill, New York, pp. 571~573.
- (7) Somerscales, E. F. C. and Knudsen, J. G., 1981, Fouling of Heat Transfer Equipment, Hemisphere Publishing Co., New York, pp. 527.
- (8) Rao, R. M. and Bopardikar, A. S., 1998, Wavelet Transforms: Introduction to Theory and Applications, Addison Wesley Longman, Inc., Massachusetts, pp. 183~189.