

'99 춘계학술발표회 논문집  
한국원자력학회

신경망을 이용한 빠른 속도의 부하추종운전모사 기법 개발  
Development of Fast-Running Simulation Methodology using Neural  
Networks for Load Follow Operation

성승환, 서용석, 허섭, 구인수  
한국원자력연구소

요 약

비선형시스템의 입/출력관계를 모델링하는 능력을 가진 신경망을 이용하여 부하추종운전 모사용 원자로해석방법을 개발하였다. 정확성을 평가하기 위하여 부하추종운전의 실측치와 개발된 모델의 모사치를 비교하였다. 새로운 해석방법론은 기존의 FPM(fast predict module)과 비교할 때 추가적인 공학적인자의 도입없이 정밀도와 계산 시간에서는 비슷한 결과를 보였다. 부하추종운전모사결과 AO(Axial Offset)은 최대 2.5% 이내, 임계봉산농도는 15 ppm 이내를 만족시킴을 보였다. 따라서 새로운 해석 모델은 빠른 수행시간과 공학적인자의 도입 없이 실측자료에 적응성을 보였다.

Abstract

The new analytic model to analyze the load follow operation was developed. It was based on the neural network theory with the capability of modeling the input/output relationships of a nonlinear system. In order to evaluate the accuracy and the capability, the measurement data of load follow operation of a PWR were compared to the simulated data using the developed model. The model had a comparable accuracy,

Required computing time for simulating the load follow operation was, also, comparable to that of fast predictor module without the additional engineering factors. The maximum errors of the axial offset and the critical boron concentration throughout the simulation are within 2.5% and 15ppm, respectively. The new model using the neural networks was proved for a fast-running capability and an adaptability without engineering factor.

## 1. 서론

본 논문에서는 현재 일반적인 다변수 함수에 대한 근사 추론의 가능성을 인정받고 있는 신경망(neural network) 이론을<sup>[1-4]</sup> 이용하여 노심해석을 수행하는 방법론을 개발하였다. 원자력 노심해석 분야에서도 신경망을 이용한 연구가 있어왔는데 그 연구 내용은 측정 가능한 운전변수로부터 원자로심의 열출력 예측(thermal power prediction)연구<sup>[5]</sup>와 장전모형 결정에 주요한 노심인자 예측(core parameter prediction) 연구<sup>[6][7]</sup>에 도입된 적이 있었다.

오류 역전파 신경망(Back Propagation Neural network:BPN)의 연속함수 근사 능력과 위에서 언급한 노심인자 예측 연구를 결부시키면 임의의 노심상태에 대한 노심인자를 추론하는 것이 가능하므로 본 논문에서는 신경망 모델을 이용하여 여러 상태의 원자로심내 노심인자를 근사하는 해석모델을 개발하였다.

기존의 노심해석 방법에서 어려운 문제중의 하나였던 복잡한 수학적 모델링이 필요없고 또한 신경망의 학습능력을 이용하여 공학적인자의 도입 없이도 운전중인 노심 측정자료에 근사한 추론이 가능하며, 또한 수치해석적인 노심해석 방법론과는 달리 평형 방정식의 해를 구하는 역행렬 연산을 요구하지 않으므로 빠른 시간내에 결과를 추론하는 노심해석 방법론을 개발하였다. 개발된 방법론의 검증을 위하여 부하추종운전과 같이 예측 가능한 노심의 과도현상을 모사할 수 있는 신경망 모델을 설계하여 실증 실험된 부하추종 운전의 실측 자료와 모사 결과를 비교한 결과 만족스러운 수준을 나타냈었다.

앞으로 신경망 이론의 발달과 함께 그 방법론을 일반적인 노심해석 방법론으로 확장한다면 원자력 발전소의 운전원이 좀 더 많은 노심 정보를 얻을 수 있고 빠른 시간내에 앞으로의 노심상태를 예측할 수 있으므로 발전소의 안전한 운전을 돕는 노심 정보 감시 분야의 연구개발에 도움을 줄 것으로 예상된다.

## 2. 기존의 부하추종운전 모사 알고리즘

앞에서 기술한 바와 같이 부하추종 운전은 잦은 출력 증감발을 요구하므로 제어 계통의 빈번한 작동이 요구되고, 이러한 제어 계통의 빈번한 작동은 노심내의 불안정한 변화를 야기시킬 가능성이 높다. 따라서 원자력 발전소의 운전원이 노심의 이상상태를 빠른 시간 안에 예측하여 적절한 제어 계통을 동작시키는데 필요한 자료를 제공하는 체계가 요구된다. 부하추종 운전을 할 때 효율적인 운전과 안전성을 높이기 위하여 부하추종 운전에 따른 제어봉의 변화와 수용성 봉산의 농도 변화에 따른 노심내의 AO(Axial Offset) 및 제논 진동 그리고 임계봉산농도를 빠른 시간내에 예측하는 연구들이 많이 수행되어 왔다.<sup>[8~10]</sup>

Westinghouse형 원자로에서 부하추종운전시 가장 주요한 운전인자는 AO이므로 빠른 시간에 노심상태를 예측하기 위하여 노심을 단지 상부와 하부로만 나누어 해석하는 FPM(Fast Predict Module)이 개발된 적이 있다.<sup>[8,10]</sup> 이는 노심을 상부와 하부로만 나누어 출력준위 변화, 제논 수밀도 변화, 임계봉산농도의 변화 그리고 제어봉의 위치 변화에 대한 AO의 변화량과 반응도의 변화량을 선형 독립이라고 가정하여 노심의 상태변화를 예측하는 방법이다. 먼저 반응도의 변화량을 나타내는 식은 아래와 같다.

$$\Delta K_{eff} = \frac{\partial K_{eff}}{\partial P} \Delta P + \frac{\partial K_{eff}}{\partial X_e} \Delta X_e + \frac{\partial K_{eff}}{\partial B} \Delta B + \frac{\partial K_{eff}}{\partial R} \Delta R \quad (3.1)$$

각 항의 의미는 다음과 같다.

P = 열출력(%)

X<sub>e</sub> = 제논(#/cm-barn)

B = 임계봉산농도(ppm)

R = 제어봉의 위치(step)

AO의 변화량은

$$\Delta AO = \frac{\partial AO}{\partial P} \Delta P + \frac{\partial AO}{\partial X_e} \Delta X_e + \frac{\partial AO}{\partial R} \Delta R \quad (3.2)$$

와 같고 봉산농도 변화에 따른 AO의 영향은 무시한다.

예측 속도는 가장 빠른 방법이지만 FPM이 동작하기 직전에 3차원 노심해석을 수행하여 FPM의 입력 자료를 매번 생산하여야 하고 각 변화량을 선형적으로 처리하므로 부하추종 운전의 경우 약 2~3시간 정도의 예측에서만 그 정확도를 보장하는 하는 단점들이 있어 완전한 부하추종 운전 모사기로 사용하기에는 어려움이 있다.

## 3. 개발된 부하추종운전 모사 알고리즘

신경망은 복잡한 수학적 모델링이 없이도 비선형시스템의 동작을 추론하는 능력을 가지고,

새로운 자료를 학습하여 스스로 내장하는 학습기능을 갖추고 있으므로 어떠한 적응인자 (adaptation factor)의 도입이 없이도, 초기에 생성된 학습자료가 실제 측정자료와 맞지 않는 경우에 실제로 측정된 자료를 학습한 이후에는 운전중인 노심의 측정 자료를 좀 더 정확하게 추적할 수 있는 장점도 가지고 있다. 따라서 신경망 모델은 적응인자의 도입 없이 학습에 의해 실측자료를 정확히 근사하며 각 입력인자의 비선형성을 이미 포함하고 있으므로 매번 입력 계수를 새로 생성해야만 하는 FPM의 단점도 극복할 수 있다.

부하추종 운전의 특징을 다시 한번 살펴보면 출력의 증감발, 제어봉의 삽입 및 인출, 그리고 봉산의 농도 변화가 운전원이 제어할 수 있는 양이고 이에 따라서 제논의 시간에 따른 분포 및 수밀도가 운전 이력에 따라 결정된다.<sup>[11]</sup> 부하추종 운전 모사용 신경망 모델은 크게 부

하추종운전에 따른 AO 추론 신경망, 반응도가 추론 신경망으로 구성되어 있고 부하추종운전중의 제논 분포를 계산하기 위한 과도 제논 방정식이 결합되어 있다.

AO 및 반응도가를 추론하는 신경망을 이용하여 부하추종 운전을 수행하는 알고리즘은 그림 1과 같다. 가장 먼저 부하추종 운전직전의 노심상태를 파악하기 위해 측정된 출력분포와 연소도 계산을 통하여 부하추종 운전 시작점의 연소도 분포나 제논 분포와 초기 조건을 구한다. 그 다음에 출력 준위의 변화와 제어봉의 변화를 입력조건으로 하여 과도 제논을 계산한 후에 AO와 임계봉산농도의 양을 추론 및 보정하고 다음 시간대로 진행한다.

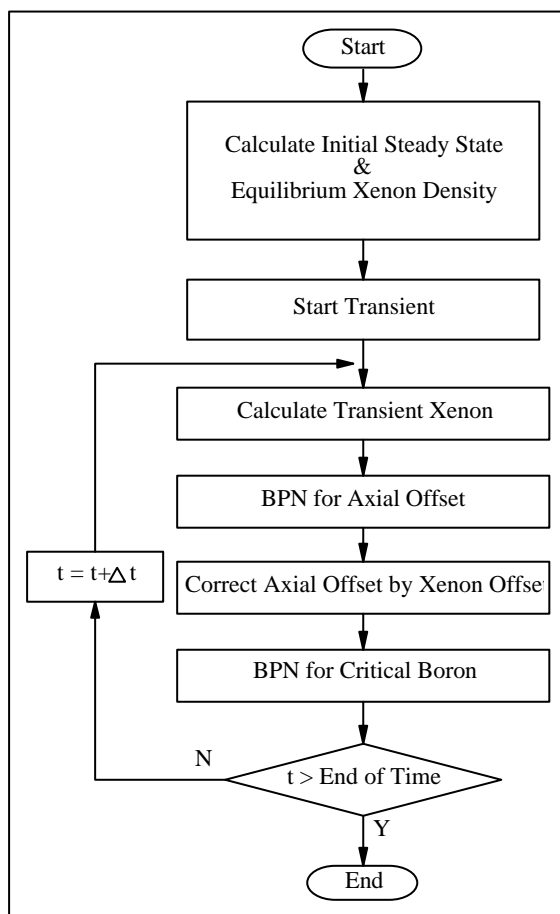


그림 1. 부하추종운전 모사 알고리즘

### 3.1 Axial Offset 추론 신경망

Westinghouse형 가압경수로에서는 전술한 바와 같이 AO 밴드가 가장 중요한 제한 요건이 된다. 따라서 부하추종 운전 기간 동안의 정확한 AO를 모사하는 것이 부하추종 운전을 모사하는 데 필수적인 요소이다. 따라서 AO에 영향을 미치는 노심인자들을 입력으로 AO를 추론하는 신경망 모델을 설계하였다. 또한 AO에 영향을 미치는 노심인자들 중에서 제논 분포와 수밀도는 그 시점까지의 노심 운전 이력이 주요한 변수이기 때문에 즉, 부하추종운전 이력마다 달라지는 변수이므로 학습자료로 삼기에

는 독립성이 떨어진다. 따라서 과도 제논 및 요오드 방정식에 의해서 제논의 수밀도와 분포를 계산하고 제논 분포 변화에 따른 AO의 변화를 선형적으로 가정한 후 제논 효과를 보정하였다. 그리고 실제로도 일반적인 3차원 해석코드에서 제논의 분포만을 출력분포나 제어봉의 변화없이 독립적으로 변화시킬 수가 없기 때문에, 제논 변화에 의한 무한증배계수의 변화와 출력분포만을 독립적으로 학습시키기가 어려운 점이 이러한 보정기법을 본 논문에서 적용한 이유이다. 제논 분포에 따른 AO의 변화는 서로 상쇄하는 효과가 있으므로 실제 AO는 추론된 AO에서 XAO(Xenon Axial Offset)를 빼주면 제논 분포의 변화에 따른 보정효과가 있다.

신경망의 입력노드는 연소도, 출력준위, 제어봉의 위치로 이루어지며 출력노드는 입력조건에 따른 AO로 구성한다. 그림 2에 AO 추론 신경망의 입력과 출력 관계 및 제논 효과 보정에 대해 명시되어 있다.

AO 추론 신경망의 AO 근사 정확도를 평가하기 위하여 학습자료로 이용되지 않은 출력준위와 제어봉 위치를 임의로 주고 3차원 노심해석 결과와 추론결과를 비교한 결과 AO 추론 신경망은 학습된 범위(출력준위 100~70%, 제어봉 위치 228~125 step) 내에서 최대 차이(노심해석 코드에 의한 ref. AO-추론 AO)가 0.5%를 넘지 않음을 알 수 있었다. 따라서 AO 추론 신경망은 신경망의 일반적인 특성인 연속함수 근사능력을 가지고 있음이 입증되었다.

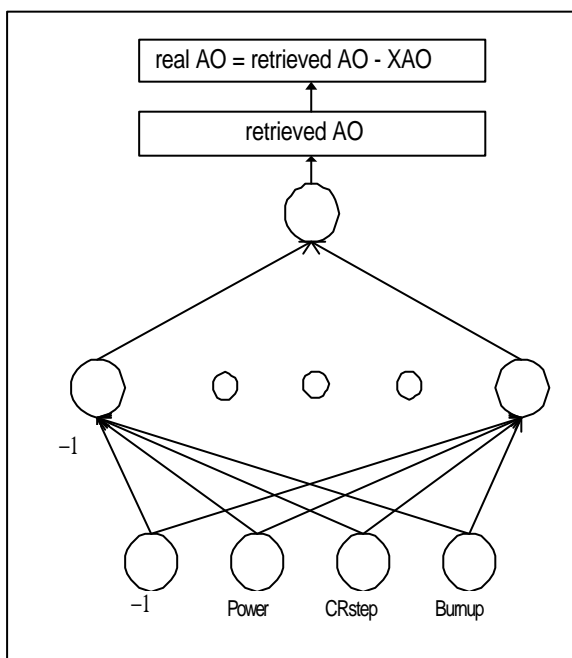


그림 2. AO 추론 신경망

자들의 반응도가는 3차원 노심해석을 통하여 각 연소도 별로 구한 후 신경망의 학습자료로 이용한다.

그런데 제논의 반응도가는 학습자료 생산용 3차원 해석 코드가 제논의 총량을 임의로 바꾸고 그 반응도가를 구할 수 없기 때문에 NDR의 100% 전출력에 대한 반응도가를 그대로 활용

### 3.2 반응도가 추론 신경망

부하추종 운전 전 기간동안 급격한 노심 출력준위의 변화를 방지하기 위하여 노심은 계속적으로 임계상태를 유지하면서 출력준위를 변화시킨다. 잉여반응도는 국부적인 값이 아니라 노심 전체의 평균 반응도이므로 평균 노심인자들을 이용하여 노심의 반응도가를 추론하는 신경망을 설계하였다. 부하추종 운전과 같은 노심 과도 현상에서 노심의 반응도가에 영향을 미치는 인자는 출력준위, 제어봉의 위치, 봉산 농도의 변화와 제논의 변화 등이다. 각 인

하고, 제논의 수밀도 변화에 따른 노심 반응도의 변화는 선형적이라고 가정하여 제논의 반응도 효과를 고려하였다.

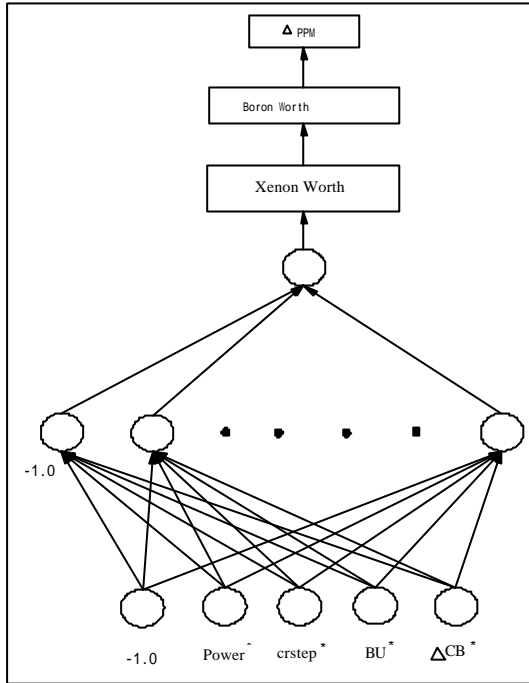


그림 3. 반응도가 추론 신경망

반응도가 추론 신경망의 구조는 AO 추론 신경망과 근본적으로 같은 구조를 가지며 입력층의 노드에 붕산 농도의 변화량이 추가되고 출력노드는 반응도가 된다. 위에서 설명한 바와 같이 제논의 수밀도 변화에 의한 효과를 학습자료로 생산하지 못하였기 때문에 신경망 모델의 출력노드에 제논 반응도가 계산과정이 독립적으로 추가되어 있다. 그림 3에 제논에 의한 반응도가 변화 효과를 포함한 노심의 반응도가 추론 신경망의 구조를 나타내었다.

반응도가 추론 신경망의 근사 정확도를 평가하기 위하여 학습자료로 이용되지 않은 출력준위와 제어봉 위치를 임의로 주고 3차원 노심해석 결과와 추론결과를 비교한 결과 반

응도가 추론 신경망은 학습된 범위(출력준위 100~70%, 제어봉 위치 228~125 step) 내에서 최대 차이(노심해석 코드에 의한 reference 반응도 - 추론 반응도)가  $10 \times 10^{-6}$ , 즉 10pcm를 넘지 않음을 보였다. 그리고 고리 4호기 3주기 1000 MWD/MTU에서 붕산 반응도가 약 10pcm/ppm이므로 추론 오차 최대값을 임계붕산농도로 환산하면 약 1ppm의 오차를 가지므로 반응도가 추론 신경망의 근사 능력은 우수하다고 판단된다.

### 3.3 Lumped 제논 모델

Lumped 제논 모델은 운전 상태 변수 중에서 노심출력과 AO자료를 이용하여 AO의 개념과 동일한 제논 Axial Offset (XAO)과 요오드 Axial Offset (IAO)을 이용하여 제논 및 요오드의 수밀도와 축방향 분포를 계산하는 모델이다. 제논 및 요오드의 평균 수밀도  $X$ ,  $I$ 와 XAO, IAO는 노심 상부와 하부의 수밀도  $X_t$ ,  $X_b$ ,  $I_t$ ,  $I_b$ 의 식으로 다음과 같이 주어진다.

$$I = \frac{I_t + I_b}{2} \quad (1)$$

$$X = \frac{X_t + X_b}{2} \quad (2)$$

$$IAO = \frac{I_t - I_b}{I_t + I_b} \quad (3)$$

$$XAO = \frac{X_t - X_b}{X_t + X_b} \quad (4)$$

요오드 및 제논 수밀도의 시간에 따른 변화를 기술하는 1-군 방정식은 다음과 같다.

$$\frac{dI}{dt} = -\lambda_I I + \gamma_I \Sigma_f \phi \quad (5)$$

$$\frac{dX}{dt} = -\lambda_{Xe} X - \sigma_{Xe} X \phi + \lambda_I I + \gamma_{Xe} \Sigma_f \phi \quad (6)$$

여기서

$\lambda_I, \lambda_{Xe}$  = 요오드, 제논의 붕괴상수

$\gamma_I, \gamma_{Xe}$  = 핵분열반응에 의한 요오드, 제논의 생성율

$\sigma_{Xe}$  = 미시적(microscopic) 제논의 흡수단면적

$\Sigma_f$  = 거시적(macroscopic) 핵분열단면적

$\phi$  = 중성자속

노심의 상부와 하부에서의 핵분열단면적이 같고, 시간에 따라 변하지 않는다고 가정하면 IAO와 XAO의 시간에 대한 변화율은 다음과 같이 표시된다.

$$\frac{dIAO}{dt} = \frac{d}{dt} \left[ \frac{I_t - I_b}{I_t + I_b} \right] = \gamma_I \Sigma_f \left( \frac{\phi}{I} \right) (AO - IAO) \quad (7)$$

$$\begin{aligned} \frac{dXAO}{dt} &= \frac{d}{dt} \left[ \frac{X_t - X_b}{X_t + X_b} \right] = -\sigma_{Xe} \phi (AO) (1 - XAO^2) \\ &+ \lambda_I \left( \frac{I}{X} \right) (IAO - XAO) + \gamma_{Xe} \Sigma_f \left( \frac{\phi}{X} \right) (AO - XAO) \end{aligned} \quad (8)$$

따라서 부하추종에 따른 노심상태의 변화에서 출력준위, 제어봉, 봉산의 변화는 신경망이 추론하고 제논의 수밀도 및 XAO는 Lumped 제논 모델이 계산해내므로 신경망 모델을 이용한 방법은 충분한 정밀도를 가지고 부하추종 운전 모사가 가능하다.

### 3.4 학습자료 생산

본 논문에서는 신경망 모델의 검증을 위하여 4절에 나타난 고리 4호기 3주기의 부하추종 운전 실증시험을 그 대상으로 삼았다. 따라서, 고리 4호기 3주기의 모든 연소도에 따른 출력준위, 제어봉 위치, 임계봉산농도를 각각 변화시키면서 수행된 3차원 노심해석 결과를 학습자

료로 삼았다.

본 논문에서 이용한 학습자료는 고리 4호기 3주기의 모든 연소도 단계에 따라서 출력준위를 각각 100%, 90%, 80%, 70%로 주고 100%단계에서 제어봉 D뱅크 위치가 각각 228step, 198step, 168step, 138step, 125step에 있을 때의 AO, 임계붕산농도를 3차원 정상상태 해석 코드를 통하여 구한다. 그리고 제어봉의 각 위치에 따른 계산을 90%, 80%, 70% 출력준위에서 반복하여 구한다. 이때 제논의 분포변화는 100% 전출력, 제어봉은 ARO 상태의 평형 제논 분포로 고정시키고 각각의 경우에 대해서 제논의 영향이 없도록 한다. 제논의 영향을 없애는 이유는 제논 분포가 출력분포 변화에 영향을 미치는데 학습자료 생성시에 제논 효과를 출력분포 및 제어봉 효과와 독립적으로 고려하기 위해서이다. 그리고 모든 연소도에 걸쳐서 각 출력준위, 제어봉 위치에서 임계붕산농도를 임의로 변화시킬 때 발생하는 노심 전체의 반응도가의 변화를 추가적으로 계산하여 출력준위, 제어봉의 위치, 연소도 그리고 붕산농도의 변화에 따른 반응도가의 변화량을 반응도가 추론 신경망의 학습자료로 활용한다.

계산된 학습자료들로부터 각각의 신경망 -AO추론, 반응도가 추론- 을 학습시킨 후에 제논 모델, 제논 효과 보정 알고리즘을 조합하여 부하추종 운전을 모사하였다.

#### 4. 부하추종 운전자료

신경망 모델의 검증을 위하여 고리 4호기 3주기의 부하추종 운전 예측 및 측정 자료와 비교 분석하였다. 고리 4호기는 출력 950MWe를 가지는 전형적인 Westinghouse형 가압경수로의 한 종류이므로 노외 계측기에서 측정하는 AO가 운전의 주요한 지표가 된다. 따라서 부하추종 운전시에 가장 중요한 제한요건도 AO가 target band를 벗어나는지의 여부이다. 실증 시험은 3주기의 550MWD/MTU에서 시작되어 약 5일간 지속되었다.<sup>[2]</sup>

그리고 전형적인 부하추종 방법인 MINB(minimum boron concentration) 전략이 채택되고 12-3-6-3의 방식으로 출력준위는 100-80-100%와 100-70-100% 두 가지 phase로 시험하였다. 또한 부하추종 실증 시험에 앞서 시험예측값을 먼저 구하고 실제 시험을 수행하면서 상황에 따라 제어봉 및 임계붕산농도를 보정하는 방식으로 수행되었다. 예측자료는 MINB방식으로 운전할 경우에 필요한 붕산변화량, 제어봉 위치 등을 구하고 가장 안정되게 제논을 조정할 수 있는 방법으로 반복계산을 통하여 얻어진 자료이다.

#### 5. 부하추종 운전 모사결과

개발된 모사 모델의 적합성을 검증하기 위하여 학습자료생산에 사용된 코드를 이용한 부하추종 해석결과와 개발된 방법론에 의한 모사결과를 비교하고 그 다음에 실제 부하추종운



전 실측자료 개발된 신경망을 이용한 모사모델간의 모사결과를 비교하였다. 그림 4에 나타난 모사 결과는 개발된 모델의 적합성을 검증하기 위해 학습자료를 생산한 노심해석체계를 이용하여 하루 동안의 부하추종운전을 모사하고 개발된 신경망 모델에 의한 모사결과를 비교하였다. 그 결과는 잘 일치하고 있음을 보인다.

실측 자료의 검증 역시 먼저 1일간의 부하추종 운전을 모사하였으며 그 결과는 그림 5에 제시하였다. 실측 자료와의 모사결과에서는 AO오차가 최대 5% 정도로 나타났다. 그 원인을 살펴보면, 실제 측정 자료의 경우 초기의 제어봉 D뱅크의 위치가 206 step인 상태에서 AO가 +1.7%로 측정되었는데 실제 학습자료를 생성한 해석 코드는 같은 초기 조건에서 약 -1.7%로 초기 AO를 계산한다. 해석코드와 실제 노심의 부하추종운전 초기 조건이 AO에서 3.4%의 차이를 보인다. 이를 극복하기 위하여 신경망의 학습능력을 이용하였다. 즉, 부하추종 1일 운전 자료를 새로운 학습자료로 구성하여 신경망 모델을 재학습시킨 후에 수정된 신경망모델을 이용하여 5일 동안의 부하추종운전을 모사하였다. 기존의 해석기법에서는 위와 같은 차이가 발생하는 경우에 공학적인자의 도입을 통해 해석치를 보정하지만 신경망은 자체적으로 새로운 상황을 학습하는 기능이 있으므로 이를 이용하면 공학적인자의 도입없이 실측치를 모사할 수 있다. 그림 6에 나타난 바와 같이 하루동안의 부하추종운전 실측자료를 재학습후의 결과를 보면 AO는 2.5% 이내, 봉산 15ppm 이내로 잘 만족하고 있음을 보인다. 실측자료의 검증에서는, 실측자료에 열출력 계측기의 측정오차, AO 측정 오차, 그리고 임계봉산농도 측정의 오차가 포함되어 있는 상황에서도 신경망 모델이 부하추종 운전을 잘 모사하고 있음을 알 수 있다. 따라서 개발된 신경망 모델은 운전중에 항상 새로운 자료를 획득함으로써 노심의 상태변화에 대한 적응성을 보이고 있으며 또한 노심의 실제측정치를 고려하기 위한 어떠한 공학적인자의 도입없이 노심의 상태 변화에 따른 정확한 모사 능력을 가지고 있다. 그리고 총 5일간의 부하추종 모사를 위해서 요구되는 전산시간이 IBM 호환 486PC에서 0.3초 이내이다. 즉, 이 모델은 FPM과 같은 정도의 계산시간을 가지고도 3차원 노심해석과 비슷한 정도의 정밀도를 가지게 되므로 실제 부하추종 운전 예측계통으로 설계되는데 장점이 있다. 그리고 FPM과는 달리 부하추종 모사 직전에 매번 3차원 노심해석 코드로 입력 계수를 조정해야 하는 단점이 없으며 학습기능을 잘 활용하면 3차원 노심해석 코드보다도 실제에 더 가까운 예측을 하게되므로 더 큰 장점을 가진다.

결론적으로 본 논문의 몇 가지 가정들, 즉 제논 재분포에 의한 AO에의 영향이 선형적이라고 가정한 것, 제논효과를 학습자료에 충분히 반영하지 못한 점들에 약간의 보완이 필요하나 실제 부하추종 운전을 모사한 결과를 보면 계산결과에 크게 영향을 미치지 않는 것으로 나타났다. 물론 앞으로 위의 가정에서의 문제점을 극복하여 좀 더 정확한 신경망 모델이 설계되면 실제 발전소에서도 간단히 PC 수준에서 부하추종 운전을 예측할 수 있으며, 모사하는 도구나 모델이 좀 더 넓은 범위의 학습자료를 확보한다면 사고해석이나 예견되는 발전소의 과도현상

전반에 대한 예측 도구로의 활용가능성이 매우 높은 것으로 판단된다. 그러기 위해서는 선결 문제로 발전소의 시험결과나 측정 자료들이 신경망의 학습자료로 충분히 활용되어야 하며 충분하고 정확한 학습자료를 구하여야 한다.

현재 원자력연구소에서 개발중인 SMART(System-intgrated Modular Advanced ReaTor)의 노심 특성 및 신경망 모델의 학습자료가 확보되면 SMART의 부하추종운전의 예측계산 및 성능향상에 도움을 줄 수 있을 것으로 예상된다.

### **Acknowledgement**

본 연구는 과학기술부의 원자력연구개발사업 일환으로 수행되었음.

### **[참고문헌]**

1. J. M. Zurada, Introduction to Artificial Neural Systems, West Publishing Co. (1992)
2. 최진영, "함수근사화를 위한 앞먹임 신경회로망에 관한 연구," 박사학위논문, 서울대학교 (1992)
3. 신성식, "신경회로망의 함수사상 특성에 관한 연구," 석사학위논문, 서울대학교 (1990)
4. I. W. Sandberg, "Approximations for Nonlinear Functionals," IEEE Trans. on Circuits and Systems, **39**, No. 1, 65, January (1992)
5. M. S. Roh, S. W. Cheon and S. H. Chang, "Power Prediction in Nuclear Power Plants Using a Back-Propagation Learning Neural Network," Nucl. Technol., **94**, 270 (1991)
6. H. G. Kim, S. H. Chang, and B. H. Lee, "Pressurized Water Reactor Core Parameter Prediction Using an Artificial Neural Network," Nucl. Sci. Eng., **113**, 70 (1993)
7. H. G. Kim, S. H. Chang and B. H. Lee, "Optimal Fuel Loading Pattern Design Using an Artificial Neural Network and a Fuzzy Rule-Based System, Nuc. Sci. Eng., **115**, 152 (1993)
8. J. H. Kim, "PWR Power Shape Monitoring System," EPRI-NP-1582, Electric Power Research Institute (1983)

9. 이은철 외, 부하추종 운전에 따른 국내원자력발전소 안전성 연구, 한국전력공사  
기술연구원 (1987)
10. 이은철 외, 부하추종 운전에 따른 원전 안전성연구(II) - 축방향 노심출력분포 감시계통  
개발 - 한국전력공사 기술연구원 (1990)
11. 송인호, "KNU 7 호기의 부하추종운전시 Xe Oscillation에 관한 연구," 석사학위논문,  
서울대학교 (1988)
12. 김종석 외, 부하추종 운전에 따른 원전 안전성 연구(II) - 고리 4호기 부하추종  
시험결과분석 -, 한국전력공사 기술연구원 (1989)




그림 4. 학습자료의 검증




그림 5. 재학습전 1일간 측정 자료 모사




그림 6 재학습후 측정자료 모사