

NARX 신경회로망을 이용한 원자로 부하추종운전 모사

Modeling of Nuclear Reactor in Load Following Operations with NARX Neural Networks

이상경, 이은철
서울대학교
서울시 관악구 신림동 산 56-1

장진욱
한국원자력연구소
대전광역시 유성구 덕진동 150

요 약

NARX(Nonlinear AutoRegressive with eXogenous input)신경회로망을 이용하여 부하 추종운전시 제어봉과 보론의 변화에 대해 원자로 출력, 제논반응도가, Axial Offset을 예측할 수 있는 모델을 만들었다. 신경회로망 학습방법으로는 Levenberg Marquardt 알고리즘을 사용하여 학습성능을 증가시켰고 ONED94 코드를 통해 학습자료를 구했다. 고리 1호기 9주기 일일부하추종운전을 모사해 본 결과에 의하면 장, 단기적 역학을 보이는 노심의 거동을 빠르고 정확히 예측할 수 있었으며 원자력발전소 모사기로 활용하는데 유용할 것으로 보인다.

Abstract

NARX(Nonlinear AutoRegressive with eXogenous input) neural network model is developed for prediction of reactor power, Xenon worth and axial offset in load following operations. Levenberg Marquardt algorithm is employed to speed up the training of the NARX neural network. Training and testing data are generated by ONED94 code. The test results presented exhibit the capability of the NARX neural network model to capture the long term and short term dynamics of the reactor core and show that it is an attractive tool for plant simulation.

1. 서론

원자력분야에서 신경회로망을 이용하여 시스템을 모델링하려는 연구는 많이 시도되고 있다.[1]-[4] 신경회로망을 이용한 모델링은 시스템의 입출력관계를 기반으로 하기 때문에 신경회로망은 시변특성, 부정확한 모델 등에 대한 실시간 적용보상이 가능하다. 또한 신경회로망은 임의의 비선형 시스템을 식별할 수 있는 범용 함수 근사자 역할을 할 수 있음이 밝혀져 있기 때문에 비선형 특성을 갖고 모델링이 어려운 부분에서 효율적으로 사용될 수 있다.

노심 모사기는 발전소 운전원에게 운전지침을 제시해 주는 중요한 역할을 하여 원자로를 신경회로망으로 모사하려는 연구도 시도되고 있다. 가압경수로형 원자로에서 제어봉과 보론을 사용하여 이로 인한 원자로 출력, A.O(Axial Offset), 반응도 의 변화를 신경회로망으로 계산하는 연구[1]가 있었으나 현재 시간에서의 상황이 만들어질 수 있는 다양한 경우에 대해 학습자료를 준비해야하고 신경회로망의 입력을 구성해야 하는 단점이 있다. 이에 반해 [2]에서는 원자로를 시간연속 시스템 관점에서 현재까지 오는 과거의 정보들로부터 다음 시간간격에서의 결과를 예측하는 신경회로망 모델을 만들었다. 이는 현재상태의 많은 주변정보들을 이용하기보다 과거정보를 이용하여 미래를 예측하는 방식이므로 부하추종운전같이 시간에 따른 원자로의 상태를 모사하는 데 적합한 방법이라 생각된다. 하지만 [2]에서는 오류역전파(Error Backpropagation) 알고리즘을 사용하여 학습성능이 떨어지고 부하추종운전에 사용되는 보론을 고려하지 않았다.

본 논문에서는 제어봉의 움직임으로 인해 반응도나 A.O 등에 단기적으로 영향을 주는 경우와 제논같이 장기적으로 영향을 주는 복합적인 역학을 보이는 원자로를 모사하기 위해서 NARX(Nonlinear AutoRegressive with eXogenous input) 신경회로망을 채택하였다. 학습방법으로는 오류역전파 알고리즘이 다양한 파라미터들을 적용하려는 문제에 따라 시행착오를 통해 조절해줘야 하며 학습하기전 가중치의 초기 설정치에 따라 민감한 학습성능을 보이고 수렴하는데 오랜 시간이 걸리는 단점이 있어서 Levenberg Marquardt 알고리즘을 사용하였다. 증기발생기 수위를 모사하는 신경회로망모델에 Levenberg Marquardt 알고리즘을 적용한 논문에서 이미 뛰어난 학습 성능을 보여주었다.[4] 신경회로망의 입력으로는 제어봉 위치, 보론 농도 의 현재 및 과거 시간 값과 모델의 출력에 해당하는 제논반응도가, 노심출력 그리고 A.O의 과거 시간 값들로 정의되며, 신경회로망의 출력으로는 현재이후 시간간격에서의 제논반응도가, 노심출력, A.O로 정의된다.

학습 및 검증을 위한 데이터를 만들기 위해 ONED94 코드로 고리 1호기 9주기에서의 일일부하추종운전을 수행하였다. 데이터 획득시간에 따른 영향을 파악하기 위해 시간 간격 5분과 10분인 자료에 대해 비교하였고, 제논이 부하추종운전에 주는 영향이 크기 때문에 정상적인 부하추종운전(100-50-100-2-6-2-14)을 한 자료로 학습한 신경회로망모델에 대해 다른 제논의 거동을 보이는 운전자료로 검증을 하였다.

2. 원자로 신경회로망 모델

1) 신경회로망 구조

제어봉과 보론의 농도를 변화시켰을 때 원자로 출력, 제논반응도가, A.O 의 값이 어떻게 되는지를 예측하기 위해 사용한 신경회로망의 구조는 그림 1과 같이 입력부분, 1개의 은닉층 그리고 출력층의 구조를 가지고 있다. 은닉층은 입력노드수의 2배에 해당하는 노드로 구성하였다. 신경회로망의 입력으로서는 현재(t)와 과거의 제어봉위치, 보론농도, 신경회로망모델의 출력인 원자로출력, A.O, 제논반응도가의 과거 값을 신경회로망 모델의 입력으로 케환하여 사용하며 출력은 현재 다음시간간격(t+1)의 원자로출력, A.O, 제논반응도가로 구성한다.[그림 2] 신경회로망의 입출력 관계를 표시하면 다음과 같다.

$$(P(t+1), Xe(t+1), A.O(t+1)) = F [Xe(t), \dots, Xe(t-q), P(t), \dots, P(t-q), A.O(t), \dots, A.O(t-q), CR(t), \dots, CR(t-p), BC(t), \dots, BC(t-p)]$$

여기서 P는 원자로출력, Xe는 제논반응도가, A.O는 Axial offset, CR은 제어봉위치, BC는 보론농도를 의미한다. 또한 p,와 q 는 시간지연단위를 나타내며 시스템의 차수를 사용한다.

이와 같이 다층신경회로망 구조에서 입력으로서 시간 지연된 값들과 신경회로망의 출력 값을 다시 케환하여 시간 지연된 값을 사용하는 모델을 NARX 신경회로망이라고 말한다. NARX 신경회로망은 장,단기적 역학이 동시에 나타나는 비선형 시스템을 모사하는데 있어 효과적이라고 보고되고 있다.[5]

2) 학습알고리즘

신경회로망을 학습하는 방법으로 기존에 신경회로망을 이용하여 원자로를 모사하였던 논문들은 기본적인 오류역전과 알고리즘을 학습방법으로 사용하였다.[1]-[3] 그러나 이것보다 학습능력과 계산속도가 빠른 방법으로 알려진 Levenberg Marquardt 알고리즘을 사용하였다.[5] 이 알고리즘은 최적화 방법 중에 목적함수의 2차 미분항까지 고려하는 Newton 방법에서 Hessian 행렬을 역행렬 계산이 가능하도록 보완한 방법으로 Batch Mode로만 학습이 가능하고 역행렬을 계산하기 위해 메모리를 많이 필요하다는 단점이 있으나 Pentium IV의 CPU와 메모리가 512MB인 컴퓨터에서 계산할 때 실시간보다 빠른 계산을 할 수 있었고 메모리 문제도 발생하지 않았다. 결국 해를 찾는 속도가 빠른 Newton 방법과 비록 느리지만 수렴성이 보장되는 steepest descent방법 사이에서 잘 절충한 방법이라 볼 수 있다.

Levenberg Marquardt 알고리즘의 간단한 계산과정은 다음과 같다.

[1단계] 신경회로망의 입력에 대해 각 뉴런들의 출력을 계산하고 F(x), 즉 자승오차의 합을 계산한다.

$$\begin{aligned} \mathbf{a}^0 &= \mathbf{p} \\ \mathbf{a}^{m+1} &= \mathbf{f}^{m+1}(\mathbf{W}^{m+1}\mathbf{a}^m + \mathbf{b}^{m+1}) \quad (\text{for } m=0,1,\dots,M-1) \\ F(\mathbf{x}) &= \sum_{q=1}^Q (\mathbf{t}_q - \mathbf{a}_q)^T (\mathbf{t}_q - \mathbf{a}_q) = \sum_{q=1}^Q \mathbf{e}_q^T \mathbf{e}_q = \sum_{q=1}^Q \sum_{j=1}^{S^M} (e_{jq})^2 = \sum_{i=1}^N (v_i)^2 \end{aligned}$$

[2단계] Jacobian Matrix를 계산하기 위해서는

$$\mathbf{J}(\mathbf{x}) = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_{1,1}^1} & \frac{\partial e_{1,1}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{1,1}}{\partial w_{S^1,R}^1} & \frac{\partial e_{1,1}}{\partial b_1^1} & \dots \\ \frac{\partial e_{2,1}}{\partial w_{1,1}^1} & \frac{\partial e_{2,1}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{2,1}}{\partial w_{S^1,R}^1} & \frac{\partial e_{2,1}}{\partial b_1^1} & \dots \\ \vdots & \vdots & & \vdots & \vdots & \\ \frac{\partial e_{S^M,1}}{\partial w_{1,1}^1} & \frac{\partial e_{S^M,1}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{S^M,1}}{\partial w_{S^1,R}^1} & \frac{\partial e_{S^M,1}}{\partial b_1^1} & \dots \\ \vdots & \vdots & & \vdots & \vdots & \end{bmatrix}$$

아래와 같은 Sensitivity 값을 $S^M \rightarrow S^{M-1} \rightarrow \dots \rightarrow S^2 \rightarrow S^1$ 순서로 계산한다.

$$\begin{aligned} \mathfrak{S}_q^M &= -\mathbf{F}^M(\mathbf{n}_q^M) \\ \mathfrak{S}_q^m &= -\mathbf{F}^m(\mathbf{n}_q^m)(\mathbf{W}^{m+1})^T \mathfrak{S}_q^{m+1} \end{aligned}$$

여기서,

$$\begin{aligned} \mathbf{F}^m(\mathbf{n}^m) &= \begin{bmatrix} \mathbf{f}^m(\mathbf{n}_1^m) & 0 & \dots & 0 \\ 0 & \mathbf{f}^m(\mathbf{n}_2^m) & \dots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & \mathbf{f}^m(\mathbf{n}_{S^m}^m) \end{bmatrix} \\ \mathbf{f}^m(\mathbf{n}_j^m) &= \frac{\partial \mathbf{f}^m(\mathbf{n}_j^m)}{\partial \mathbf{n}_j^m} \quad \text{이다.} \end{aligned}$$

Jacobian Matrix의 각 항들은 다음과 같이 구한다.

$$[\mathbf{J}]_{h,l} = \frac{\partial v_h}{\partial x_l} = \frac{\partial e_{k,q}}{\partial w_{i,j}^m} = \frac{\partial e_{k,q}}{\partial \mathbf{n}_{i,q}^m} \times \frac{\partial \mathbf{n}_{i,q}^m}{\partial w_{i,j}^m} = \mathfrak{S}_{i,h}^m \times \frac{\partial \mathbf{n}_{i,q}^m}{\partial w_{i,j}^m} = \mathfrak{S}_{i,h}^m \times a_{i,q}^{m-1}$$

이때, x_l 이 bias일 경우는 다음과 같다.

$$[J]_{h,l} = \frac{\partial v_h}{\partial x_l} = \frac{\partial e_{k,q}}{\partial b^m_i} = \frac{\partial e_{k,q}}{\partial n^m_{i,q}} \times \frac{\partial n^m_{i,q}}{\partial b^m_i} = \tilde{s}^m_{i,h} \times \frac{\partial n^m_{i,q}}{\partial b^m_i} = \tilde{s}^m_{i,h}$$

[3단계] 다음 식을 통해 가중치의 변화량을 계산한다.

$$\Delta \mathbf{x}_k = -[\mathbf{J}^T(\mathbf{x}_k) \mathbf{J}(\mathbf{x}_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}_k) \mathbf{v}(\mathbf{x}_k)$$

[4단계] 변화된 가중치를 적용하여 오차를 계산한 후 1단계에서 계산한 오차보다 작으면 μ 를 일정한 값으로 나누고 가중치는 변화된 것을 적용하여 1단계로 넘어간다. 오차가 줄지 않으면 μ 를 일정한 값으로 곱하여 3단계로 넘어간다.

3. 신경회로망 모델의 학습 및 검증

1) 학습 데이터의 수집

노심의 거동을 모사 계산하는데 사용한 ONED94 코드[6]는 Nodal방법을 사용하는 1차원 유사과도상태 코드로서 현재 국내 Westinghouse형 원전의 운전 지원용으로 사용되고 있는 ONED90을 CE형 노심에서도 사용할 수 있도록 개선한 것이다. 이 코드에 필요한 단면적 자료는 DIT-ROCS 체계로 생산하였으며 특정 노심 연소도에 대해 ROCS 계산치를 기준으로 Tuning 절차를 거친 후 사용한다.

ONED94 코드를 통해 고리 1호기 9주기에서 100-50-100-2-6-2-14 MINB 운전방식으로 부하추종운전한 자료를 얻었다. 이때 제논은 천이상태로 하였고 데이터 획득시간 간격은 5분과 10분을 사용했다. 구해진 자료로 신경회로망에 학습을 할 때 평균0, 분산1이 되도록 데이터 처리를 하였다.

실제 원자력발전소 자료를 활용할 때는 시간에 따른 제논반응도가의 정보는 없다. 그러나 코드를 통해 값을 구하여 학습을 해놓으면 제어봉과 보론의 변화에 따른 거동은 예측할 수 있는 것을 검증단계에서 볼 수 있다.

2) 학습 및 검증

신경회로망모델에서 p는 2, q는 5를 사용하였다. 시스템 차수를 변경시켜가며 성능을 검사해볼 수 있는데 시스템 차수가 늘어나면 신경회로망 입력벡터의 차원이 늘어나는 현상을 보이므로 가능하면 계산량을 줄이기 위해 적절한 시스템의 차수를 선택하는 것이 좋다. 입력의 개수는 총 24개이고 은닉층의 노드 수는 48, 출력의 개수는 3 이다. 신경회로망의 학습은 Levenberg Marquardt 알고리즘을 이용하여 Mean Squared Error가 10^{-5}

이하가 될 때까지 반복하였고 모든 경우가 10회 이하였다.

제어봉, 보론, 제논이 노심에 영향을 주는 시간간격이 다르기 때문에 이로 인한 학습상태를 알아보기 위해 데이터 획득 시간을 5분과 10분에 해당하는 자료로 학습을 해보았다. 그림 3 과 4는 이 결과를 나타내는데 학습능력에 있어 문제가 없고 시스템 특성을 반영하는데 무리가 없기에 10분 간격으로 얻는 자료를 이용하여 다음과 같이 검증을 수행하였다. 그림에서 ASI(Axial Shape Index)는 A.O 값과 부호만 반대이다.

첫 번째로 3일 동안의 부하추종운전과정에서 2일 동안의 자료로 학습을 하고 3일째 되는 날의 결과를 학습된 신경회로망 모델로 모사를 하였다. 일반적으로 신경회로망은 extrapolation보다 interpolation에 강한 성능을 보이는데 그림 5를 보면 3일째 운전결과가 앞의 2일째 운전이력과 크게 벗어나지 않기 때문에 예측결과가 잘 맞은 것으로 보인다.

두 번째로 그림 7은 정상적인 부하추종운전(100-50-100-2-6-2-14) 자료로 학습을 한 신경회로망모델에 정상적인 부하추종운전보다 2시간 빠르게 출력을 올린 경우(100-50-100-2-4-2-16)의 자료를 가지고 검증해 본 결과이다. 실제로 부하추종운전이 어려운 것은 제논의 영향이 크기 때문에 제논의 변화가 있을 때에도 잘 모사할 수 있는지 검증해 보았다. 그림 6은 학습과 검증을 위한 두 가지 운전 자료의 제어봉위치, 보론농도와 제논반응도가를 비교한 것이다. 출력이 복귀되는 이후부터 제논반응도가가 차이가 나는 것을 볼 수 있다. 결과를 보면 부하추종운전 방법(100-50-100-2-6-2-14)이 정해지면 제논 반응도가가 시간별로 변화하는 것은 추가자료 없이 모사 가능한 것을 볼 수 있다.

4. 결론

원자력 발전소의 부하추종운전시 제어봉과 보론의 변화에 따른 원자로 출력, A.O, 제논 반응도가를 예측하는 신경회로망 모델을 개발하였다. 노심은 장,단기적 역학이 함께 나타나는 비선형 시스템으로 이를 모사하기 위해 단일 NARX 신경회로망 구조를 채택하였고 학습 성능을 개선하기 위하여 Levenberg Marquardt 알고리즘을 적용하였다. 학습한 모든 경우에 대해 Mean Squared Error가 10^{-5} 이하를 만족하는데 반복 계산한 횟수는 10회 이하이다. 일일부하추종운전을 모사한 자료와 제논의 거동이 차이가 나는 자료로 검증을 해 본 결과, 제안된 신경회로망 모델은 기존 방식보다 근사 능력이 뛰어남을 알 수 있었다.

신경회로망 모델에 사용되어진 제논반응도가는 실제 원자력발전소에서 계측할 수 없다. 그러나 계산기를 통해 얻어진 제논반응도가 자료로 신경회로망을 학습하기만 하면 모사하려는 처음 시간의 제논반응도가는 정상상태에서의 초기 제논반응도가를 입력으로 사용하고 그 이후 시간의 제논반응도가 입력은 신경회로망에서 계산된 출력 값이 회귀되는 것이므로 더 이상 제논반응도가의 정보를 요구하지 않는 장점이 있다.

개발된 모델은 다른 시스템의 신경회로망 모델링과 연계하여 운전원 지원시스템으로서의 모사기를 구성하는데 활용 가능할 것이다.

참고문헌

1. S.H. Seong, et.al, "Application of neural networks to analyze load-follow operation in a pressurized water reactor." *Nuclear Technology*, vol 128, pp. 276-283, 1999.
2. Mehrdad, B., Mohammad B. G., Caro L., "Identification of a nuclear reactor core(VVER) using recurrent neural network." *Annals of Nuclear Energy*, vol. 29, pp. 1225-1240, 2002.
3. Mehrdad, B., Mohammad B. G., Caro L., Mohammad B. J., "An intelligent nuclear reactor core controller for load following operations, using recurrent neural networks and fuzzy systems." *Annals of Nuclear Energy*, vol. 30, pp. 63-80, 2003.
4. Sang Kyung Lee, et.al. " Neural network modeling of steam generator water level using Levenberg Marquardt algorithm," *Trans. ANS*, vol.86, pp. 135-136, 2002.
5. Medsker, L.R., Jain, L. C., *Recurrent neural network design and applications*. CRC Press, Boca Raton, 2000.
6. Hagan M.T. and M.Menhaj, "Training Feedforward Networks with the Marquardt Algorithms," *IEEE Transactions on Neural Networks*, vol. 5, no. 6, pp. 989-993, 1994.
7. KAERI, *User's manual ACE/ONED*, 1996.

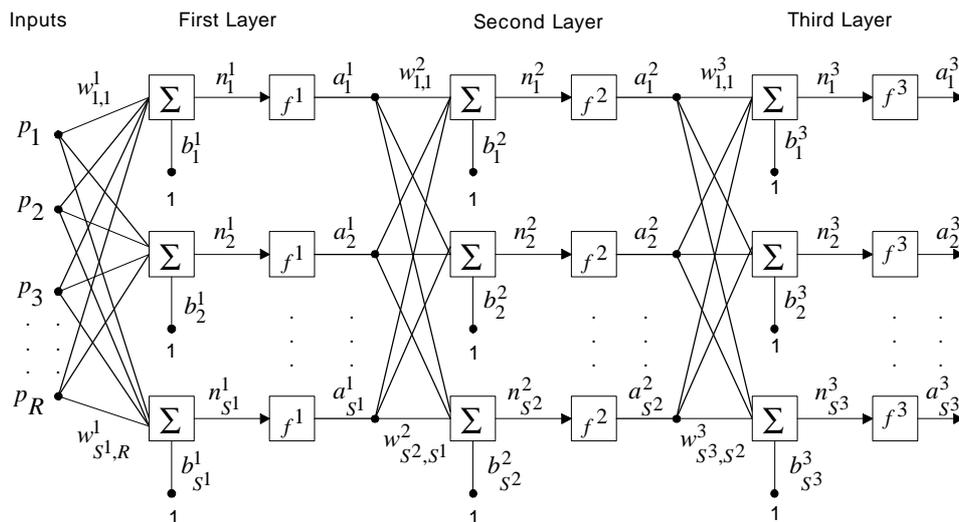


그림 1. 3-Layer 신경회로망

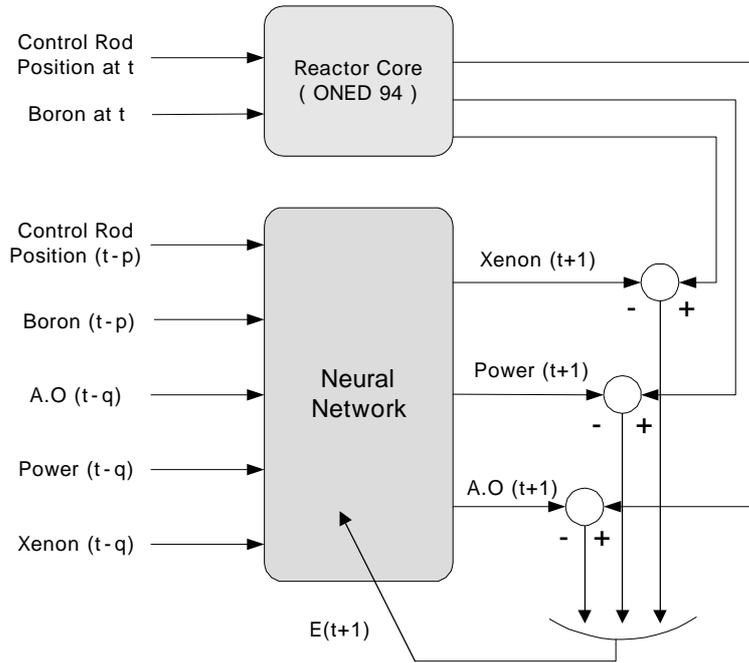


그림 2. 노심 모사를 위한 신경회로망 구조

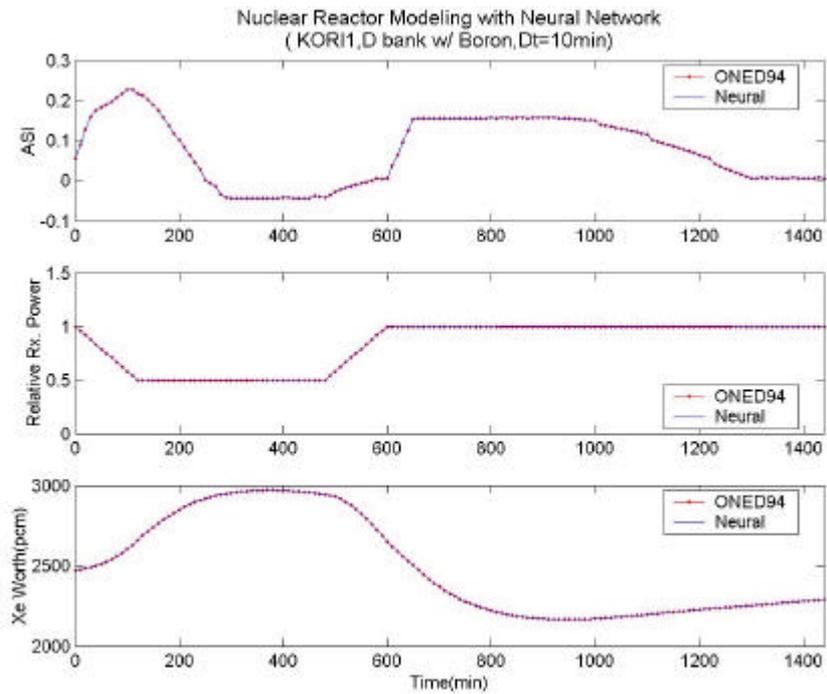


그림 3. 부하추종운전 자료를 통한 학습결과(시간간격 10분)

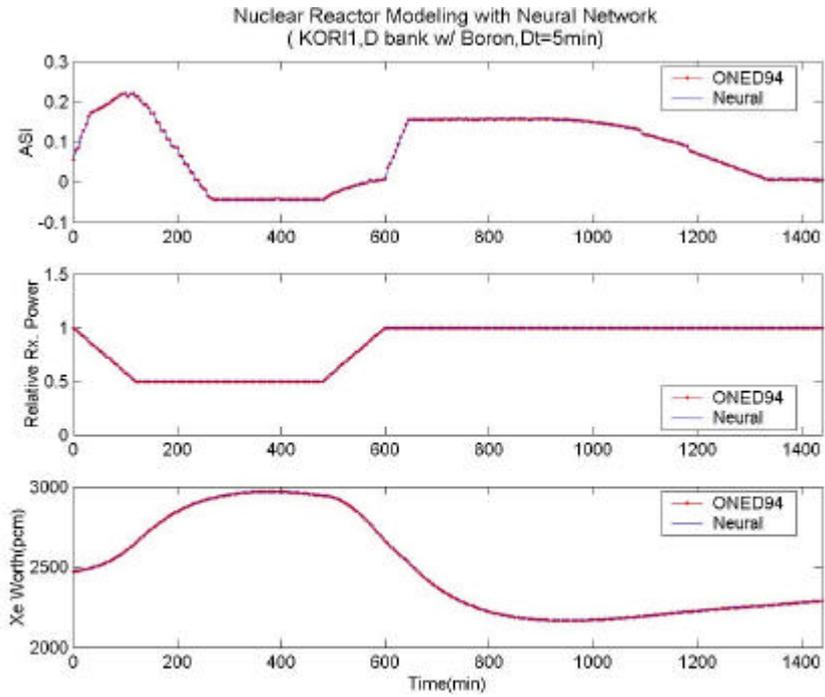


그림 4. 부하추종운전 자료를 통한 학습결과(시간간격 5분)

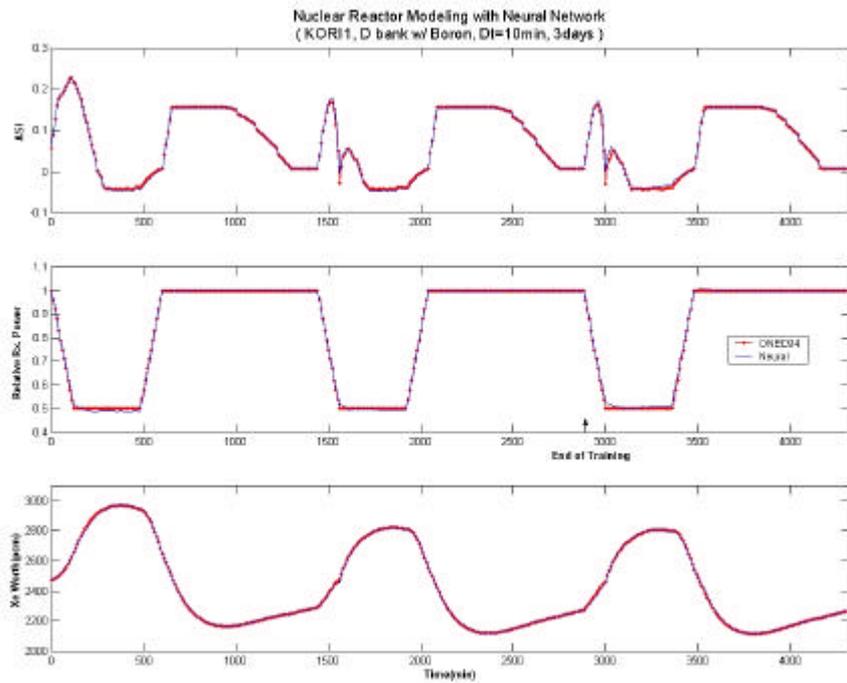


그림 5. 3일간의 부하추종운전을 통한 학습 및 검증 결과

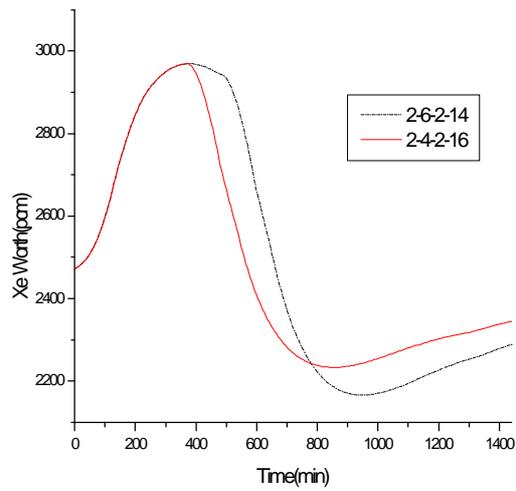
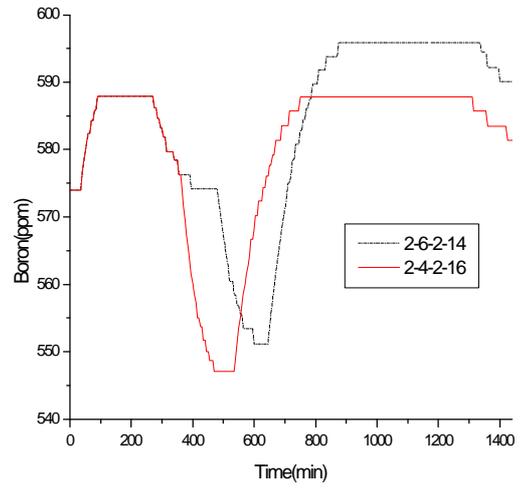
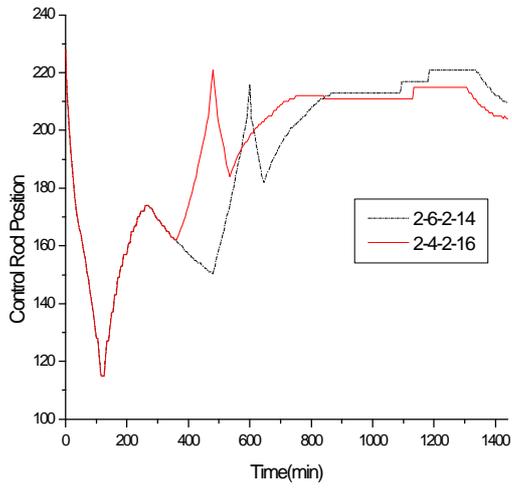


그림 6. 2가지 부하추종운전에 대한 제어봉위치, 보론농도 와 제논반응도가 비교

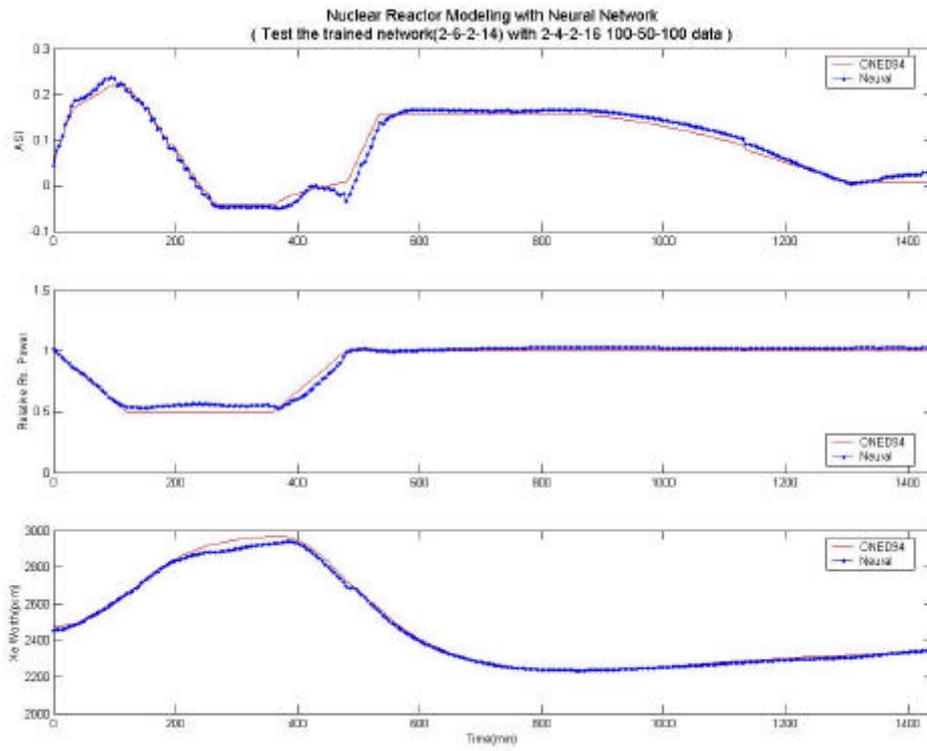


그림 7. 다른 부하추종운전 조건(100-50-100-2-4-2-16)에 대한 검증