

2003 추계학술발표회 논문집
한국원자력학회

신경회로망 앙상블을 이용한 원자력발전소 증기발생기 모델링

Modeling of Steam Generator in Nuclear Power Plant Using Neural Network Ensemble

이상경, 이은철

서울대학교

서울시 관악구 신림동 산 56-1

장진욱

한국원자력연구소

대전광역시 유성구 덕진동 150

요 약

최근 신경회로망이 증기발생기 모델링에 적용되고 있다. 그러나 본 논문에서는 신경회로망이 과잉학습이라는 문제에 접하기 쉬워서 이를 극복하기 위해 여러 신경회로망을 결합하는 신경회로망 앙상블을 증기발생기 수위거동을 모사하는 데 적용하였다. 단일 신경회로망 과도 비교를 하여본 결과 일반화가 향상되었고 학습자료에 대한 의존성이 낮아졌으며 학습 시간도 빨라진 것을 알 수 있었다.

Abstract

Neural network is now being used in modeling the steam generator is known to be difficult due to the reverse dynamics. However, Neural network is prone to the problem of overfitting. This paper investigates the use of neural network combining methods to model steam generator water level and compares with single neural network. The results show that neural network ensemble is effective tool which can offer improved generalization, lower dependence of the training set and reduced training time.

1. 서론

원자력발전소에서는 수학적 모델을 쉽게 구할 수 없는 복잡한 열수력학적 시스템을 가지고 있다. 그 중에 증기발생기가 대표적인 예인데 저출력에서 역현상을 발생함으로 인해 증기발생기 내부의 협역수위를 일정하게 유지하도록 제어하는데 많은 어려움을 겪고 있다. 만약 수위의 거동을 계산할수 있는 모델을 개발해 낼 수 있다면 제어 성능을 높이는 데 많은 도움이 될 것이다. 그러나 열수력학적 시스템의 물리적 현상은 매우 복잡하고 비선형이어서 수학적으로 쉽게 도출해 내기 어려운 실정이다.

신경회로망은 시스템의 입출력관계를 기반으로 하기 때문에 시변특성, 부정확한 모델 등에 대한 실시간 적응보상이 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.

원자력분야에서 신경회로망을 이용하여 모델링하는 연구는 많이 시도되고 있고 이 중에는 증기발생기의 수위거동을 모사하기 위한 연구도 이루어져 왔다.[2]-[4] 그러나 신경회로망을 적용하여 모델을 만들 때 처음부터 완벽한 학습자료가 주어지기는 현실적으로 불가능하고 주어진다고 하더라도 엄청나게 많은 자료를 다 섭렵하도록 학습하기는 불가능할 것이다. 다시 말하여 학습자료 부족으로 인한 외삽의 문제가 발생할 것이고 기존에 학습한 신경회로망에 추가로 주어진 자료를 통한 학습이 이루어지면 과거에 학습했던 것은 망각하게되는 문제가 발생할 것이다. 이러한 문제를 해결하기 위한 방안으로 신경회로망 앙상블이 제시되고 있다.[6] 신경회로망 앙상블은 독자적으로 훈련된 다수의 신경회로망을 결합한 시스템으로 이는 다르게 훈련된 각각의 신경회로망들이 에러공간 상에서 서로 다른 지역국소(Local Minima)에 빠지게 되고 이렇게 지역국소에 빠진 상태에서의 판단을 잘 결합하면 전체적인 성능은 단일 시스템에 비해 훨씬 더 향상되리라는 것이다. 하지만 효과적인 앙상블의 구축을 위해서는 앙상블 멤버들간의 상관관계가 아주 낮아야 하며 또한 각 앙상블 멤버들은 전체 문제를 어느 정도는 정확하게 학습하면서도 서로들간에 불일치 하는 부분이 존재해야 한다. 신경회로망의 구조(노드의 수, 연결개수 등)를 어떻게 설정할 것이며,, 각 신경회로망의 출력 값으로부터 최적의 결합 성능을 보이는 방법을 어떻게 선택할 것인지가 앙상블의 일반화 성능을 결정 짓는 중요한 요소이다.

본 논문에서는 NARX(Nonlinear AutoRegressive with eXogenous input) 신경회로망으로 만들어진 증기발생기 모델[4]을 기본 단일신경회로망으로 하여 앙상블을 구성하였다. 학습 및 모델 검증을 하기 위한 자료는 이윤준[1]의 열수력 모델을 통해 구하였고 단일 신경회로망과 앙상블을 이룬 신경회로망의 성능을 비교하였다.

2. 신경회로망을 이용한 증기발생기 모델링

1) 단일 신경회로망 구조

증기발생기의 수위에 영향을 주는 증기유량, 급수유량, 급수온도, 2차측 냉각재온도를 입력변수로 삼았다.[1] 현재 나와있는 열수력학적 모델은 대부분 선형으로 근사화된 모델을 사용하고 있고 이 선형화된 모델들의 경우 시스템 차수를 3으로 상대차수를 1로 하고 있다.[2] 시스템의 차수가 늘어나면 신경회로망의 입력벡터의 차원이 늘어나는 현상을 보이므로 이 논문에서도 같이 적용하였다. 따라서 입력변수들의 $t-\Delta t$, $t-2\Delta t$, $t-3\Delta t$, $t-4\Delta t$ 에서의 값과 출력인 수위의 과거, 즉 $t-\Delta t$, $t-2\Delta t$, $t-3\Delta t$ 값을 입력으로 궤환하여 사용한다.[그림2] 본 논문에서 사용된 신경회로망 구조는 1개의 은닉층에 노드 개수가 40개인 다층신경회로망을 사용하였다.[그림1]

2) 단일 신경회로망 학습알고리즘

신경회로망을 학습하는 방법으로 기본적인 오류역전파 알고리즘보다 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 필요하여 사이즈가 큰 신경회로망에선 단점으로 지적되고 있다. 결국 해를 찾는 속도가 빠른 Newton 방법과 비록 느리지만 수렴성이 보장되는 steepest descent방법 사이에서 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.

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

[2단계] Jacobian Matrix를 계산하기 위해서는

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

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

$$\tilde{\mathbf{S}}_q^M = -\dot{\mathbf{F}}^M(\mathbf{n}_q^M)$$

$$\tilde{\mathbf{S}}_q^m = -\dot{\mathbf{F}}^m(\mathbf{n}_q^m)(\mathbf{W}^{m+1})^T \tilde{\mathbf{S}}_q^{m+1}$$

여기서,

$$\dot{\mathbf{F}}^m(\mathbf{n}^m) = \begin{bmatrix} \dot{f}^m(\mathbf{n}_1^m) & 0 & \cdots & 0 \\ 0 & \dot{f}^m(\mathbf{n}_2^m) & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & \dot{f}^m(\mathbf{n}_{m_1}^m) \end{bmatrix}$$

$$\dot{f}^m(\mathbf{n}_j^m) = \frac{\partial \dot{f}^m(\mathbf{n}_j^m)}{\partial \mathbf{n}_j^m} \quad \text{이다.}$$

Jacobian Matrix의 각 항들은 다음과 같이 구한다.

$$[J]_{h,l} = \frac{\partial v_h}{\partial x_l} = \frac{\partial e_{k,q}}{\partial w_{i,j}^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \times \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = \tilde{s}_{i,h}^m \times \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = \tilde{s}_{i,h}^m \times a^{m-1}_{j,q}$$

이때, x_l 이 bias일 경우는 다음과 같다.

$$[J]_{h,l} = \frac{\partial v_h}{\partial x_l} = \frac{\partial e_{k,q}}{\partial b_i^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \times \frac{\partial n_{i,q}^m}{\partial b_i^m} = \tilde{s}_{i,h}^m \times \frac{\partial n_{i,q}^m}{\partial b_i^m} = \tilde{s}_{i,h}^m$$

[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 앙상블(Neural Network Ensemble)

신경회로망 앙상블의 구조는 그림 3 에 잘 나타나 있다. 앙상블을 구성함에 있어서 고려해야 할 것은 크게 2가지이다. 하나는 앙상블의 멤버로서 구성되는 각각의 신경회로망을 잘 구성하여 훈련시키는 것이다. 앞에서도 언급하였듯이 각각의 단일 신경회로망은 상관관계가 아주 낮아야 하며 또한 각 앙상블 멤버들은 전체 문제를 어느 정도는 정확하게 학습하면서도 서로들간에 불일치 하는 부분이 존재해야 한다. 이를 위해 초기 가중치를 다르게 주거나, 구조를 달리하거나, 중첩되지 않는 학습자료를 분배하는 등의 노력을 한다. 본 논문에서는 학습자료를 가능한 서로 다른 데이터를 가지도록 했다.

두 번 째로 각각 학습된 신경회로망을 어떻게 결합하느냐이다. Regression에서는 다양한 방법 중에 널리 사용되는 것이 Simple Averaging 과 Weighted Averaging 이다. 각각의 신경회로망에서 나온 출력 값에 weight 값을 곱한 후 더해서 최종 앙상블의 결과 값을 구해낸다. 이때 각 출력에 곱해지는 weight 값을 구하는 것 또한 최적화 문제이므로 유전 알고리즘 등 다양한 연구들이 진행되고 있으나 본 논문에서는 다음과 같이 사용하였다.

$$W_i = \frac{1 - E_i}{\sum_k (1 - E_k)}$$

여기서, E_i 값은 각 신경회로망을 학습시켰을 때의 MSE(Mean Squared Error)로 사용하였다. 따라서 최종 앙상블의 출력 Y 는 $\sum W_i y_i$ 가 된다.

8개의 기준 출력(5%, 10%, 15%, 20%, 25%, 30%, 40%, 50%)에 따른 학습자료를 구하여 사용하였으므로 8개의 단일 신경회로망이 결합되어 앙상블을 이루었다.

3. 신경회로망 모델의 학습 및 검증

각각의 신경회로망을 학습시키기 위한 자료는 이윤준[1]의 열수력 모델로 만들어진 코드에서 계산하였다. 8개의 기준 출력(5%, 10%, 15%, 20%, 25%, 30%, 40%, 50%)에서 증기유량, 급수유량, 급수온도, 2차측 냉각재온도를 50초 동안 ramp 증가시키고 500초까지 유지시켜서 구하였는데 이때 증가분은 급수온도는 5°C, 2차측 냉각재온도는 33°C, 증기유량과 급수유량은 5%일 때만 12.492 kg/sec 이고 다른 출력에서는 24.972 kg/sec을 사용하였으며 random noise를 첨가했다. 4개의 입력변수들을 동시에 변화시켜서 나온 증

기발생기 수위를 모사하려는 출력 값으로 사용하였다.

8개의 단일 신경회로망에 각각 5%, 10%, 15%, 20%, 25%, 30%, 40%, 50% 출력에서 ramp 증가시킨 자료를 개별적으로 학습을 한 후 최종 출력은 weighted averaging 한 앙상블과 8개의 출력에 대한 자료전체를 한꺼번에 학습을 한 단일 신경회로망과 학습 오차를 비교하여 보았다. 학습의 성능의 비교를 위해 iteration 횟수를 같게 하거나 CPU Time을 구하는 것이 필요할 수 있겠으나 단일 신경회로망이 $MSE=1\times 10^{-5}$ 까지 학습이 수렴되지 않았기에 의미가 없어졌다. 학습을 마친 단일 신경회로망과 앙상블에 학습에 사용되었던 각 출력에서의 데이터를 통해 MSE와 최대절대오차(MAE)를 구해보았다.[표1]

	Single Network		Ensemble	
	MSE	MAE	MSE	MAE
5%	0.0144	0.3368	8.4418×10^{-6}	0.0101
10%	0.0255	0.4460	1.1731×10^{-5}	0.0138
15%	0.0191	0.3886	6.3893×10^{-6}	0.0086
20%	0.0149	0.3401	2.8623×10^{-6}	0.0044
25%	0.0123	0.3085	2.4436×10^{-6}	0.0062
30%	0.0104	0.2834	3.0874×10^{-6}	0.0057
40%	0.0079	0.2485	5.2489×10^{-6}	0.0088
50%	0.0066	0.2224	8.2404×10^{-6}	0.0094

표 1. 단일 신경회로망과 앙상블의 학습오차 비교

학습된 신경회로망의 성능을 테스트하기 위한 자료는 100초 동안 ramp 증가시키고 100초 동안 유지하는 것을 계속 반복하여 1730초까지 생성된 자료를 가지고 실시하였다. 이렇게 만들어진 4개 입력변수의 그래프가 그림 4에 나와있고 모사한 결과는 그림 5와 6에 나와 있다. 단일 신경회로망을 통해 모사했을 때의 MSE는 0.0016, MAE는 0.1268 이고 앙상블에서의 MSE는 2.3264×10^{-4} , MAE는 0.0276 이다.

4. 결론

신경회로망을 이용하여 증기발생기를 모델링할 때 처음부터 여러 물리변수들의 변화 가능한 전체영역의 자료를 가지고 학습을 한다면 문제가 없겠지만 현실적으로 어렵고, 추가적으로 학습자료가 주어질 때 새로 행해지는 학습으로 인하여 과거 학습한 자료에 대해서는 좋은 결과를 내지 못하는 단점이 있다. 또한 Levenberg Marquardt 알고리즘은 역행렬 계산으로 인한 메모리 문제로 한번에 학습할 수 있는 자료의 양에 제한적이다. 이를 극복하고자 단일 신경회로망들의 결합으로 이루어진 신경회로망 앙상블을 증기발생기 수위 모델링에 적용하였다. 단일 신경회로망으로 학습한 것과 비교하여 학습 오차도 적을 뿐 아니라 외삽에 있어서도 나은 성능을 보여주었다. 따라서 앙상블 내의 신경회로망 간에 상관관계가 낮고 서로 불일치하도록 구성하는 것에 유의하면 유사한 시스템 모델링에서도 적용 가능할 뿐만 아니라 원전자료를 직접 활용할 수 있게 되었다.

참고문헌

1. 이윤준, 원자력발전소 증기발생기의 저출력 수위조절에 대한 연구, 서울대학교 박사학위논문, 1991
2. 이재기, 최진영, “신경회로망을 이용한 원자력발전소 증기발생기의 모델링”, *제어·자동화·시스템공학논문지*, vol.4, no.4, 1998
3. R.Masini, et al., "Dynamic simulation of a steam generator by neural networks," *Nuclear Engineering and Design*, vol.187, pp.197-213, 1999
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. 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.
6. A.Sharkey(Ed.), *Combining Artificial Neural Nets: Ensemble and Modular Multi-net Systems*, Springer, London, 1999.




그림 1. 3-Layer 신경회로망




그림 2. 증기발생기 수위 모사를 위한 신경회로망 구조




그림 3. 신경회로망 앙상블




그림 4. 신경회로망 모델 검증에 사용된 입력 데이터




그림 5. 단일 신경회로망 모델 검증 결과




그림 6. 신경회로망 앙상블 모델 검증 결과