

'95 추계학술발표회 논문집

한국원자력학회

비선형 적응 예측방식을 이용한 불안정 신호 예측

부인형, 최성남, 김복렬, 윤원영

한국원자력안전기술원

요 약

본 연구에서는 비선형 동적장치에 의해 발생하는 불안정 신호의 비선형 적응 예측을 위한 효과적 방법을 서술한다. 이 방법을 실제 원자력 발전소의 데이터를 이용하여 이상연상(hetero-association) 방식의 예측을 수행하였다. 다입력/다출력의 신경망은 이러한 비선형 예측에 이용할 수 있으나 학습되지 않은 상황에 대한 예측에는 어려움이 있었다. 본 연구에서 서술한 방법은 학습과 실행이 동시에 가능한 형태로 역전파 학습(backpropagation learning) 알고리즘을 이용한 다층 인식자(multilayer perceptron) 신경망과 비교하여 비선형 불안정 신호에 대한 우수한 예측 능력을 보여 주었다.

1. 서 론

신호의 예측이란 그 신호를 발생시킨 물리적 동력 장치의 모델링과 같은 의미이다. 실제 우리가 다루는 물리적 신호의 대부분은 비선형(nonlinearity) 그리고 불안정(nonstationary) 이라는 두가지 특성을 지니고 있다. 예를 들면 발전소의 압력, 온도, 급수에 따른 스팀 발생기(S/G)의 수위 변화 신호등이 그것이다. 이런 S/G 수위는 비선형이고 불안정한 동력계의 동작 결과이다. 이러한 신호의 불안정성을 다루기 위해 지금까지 다양한 방법이 이용되어 왔다. 즉, 전통적 다차원 방정식을 이용하거나 새로운 방식으로 인공 신경망을 이용하거나 또는 퍼지 시스템을 이용하였다. 특히, 신경망은 그 디자인의 비선형 특성과 주위 환경으로 부터의 학습 능력으로 인해 이러한 불안정 비선형 신호의 예측에 매우 잘 적용되어질 수 있었다. 이때 주된 문제점은 그 신경망을 어떻게 학습시키느냐 하는 것이다. 가장 널리 이용되는 지도 학습(supervised

learning) 은 off-line 학습 방식이어서 부적합하다. 즉, 요구되는 신경망은 on-line 으로 학습이 가능한 신경망이어야 한다. 즉, 순차 신호가 입력되면서 입력 신호의 통계적 변화에 적응하고 동시에 필터링을 수행해야 하는 것이다. 연속 학습(continuous learning) 이라 불리는 이런 형태의 학습은 어려운 문제이다.

한편, 이러한 실시간 회귀 학습 (real-time recurrent learning) 알고리즘은 여러 연구자들에 의해 연구되어왔다[1-7]. 본 연구에서는 계산량면에서 향상된 모습을 보여주는 파이프라인 회귀 신경망(pipelined recurrent neural network:PRNN)을 이용하여 이상연상 예측을 수행하였다.

2. 비선형 적응 예측기

2-1. 비선형 부분

PRNN 은 그림 1에서 보듯이 총 M 개의 부처리기를 가지고 있다. 각 부처리기는 신경 모듈을 가지고 있다. 이들은 그림 2에서 보듯이 비선형 입력 신호를 예측하여 선형 신호를 다음 단계로 입력시키는 역할을 한다. 그림 3에 상세한 블록도를 보였다. 또한 각각의 부처리기는 그림 4와 같다.

각 뉴런의 활성화 함수(activation function)은 시그모이드 함수(sigmoidal function) 로 다음 같이 표시된다.

$$y_{i,k}(n) = \phi(v_{i,k}(n)) = \frac{1}{1 + \exp(-v_{i,k}(n))};$$

$$i = 1, \dots, M; \quad k = 1, \dots, N \quad (1)$$

여기서, $v_{i,k}(n)$ 은 k 번째 뉴런의 내부합이고, $y_{i,k}(n)$ 은 k 번째 뉴런의 출력이다. 모두 n 시간에서 i 번째 모듈에서의 내용이다.

W 는 (p+N+1)-by-N 의 시냅스 가중치 행렬이다. 여기서, N은 각 모듈의 출력 노드수, p는 각 모듈의 외부 입력수이다. $w_{k,l}$ 은 l 번째 입력 노드에서 k 번째 뉴런으로의 연결가중치를 나타낸다. 가중치 행렬 W 는 다음과 같이 표현된다.

$$W = [w_1, \dots, w_k, \dots, w_N] \quad (2)$$

여기서 w_k 는 (p+N+1)-by-1 벡터로 다음과 같다.

$$w_k = [w_{k,1}, w_{k,2}, \dots, w_{k,p+N+1}]^T \quad (3)$$

한편 n 시간에서 모듈 i 로의 외부입력 p-by-1 은

N-by-1 의 피드백 벡터는 다음과 같이 표현된다.

$$r_i(n) = [r_{i,1}(n), r_{i,2}(n), \dots, r_{i,N}(n)]^T. \quad (4)$$

이때, n 시간에서 i 모듈의 k 뉴런 출력 $y_{i,k}(n)$ 은

$$y_{i,k}(n) = \phi(v_{i,k}(n)) \quad (5)$$

$$v_{i,k}(n) = \sum_{l=1}^p w_{k,l} s(n - (i + l - 1)) + w_{k,p+1} + \sum_{l=p+2}^{p+N+1} w_{k,l} r_{i,l-(p+1)}(n) \quad (6)$$

여기서, $w_{k,p+1}$ 은 조절 바이어스, $i=1,2,\dots,M$, $k=1,2,\dots,N$ 이다.

2-2 선형 부분

그림 5에 보인 선형 부분은 tapped-delay-line (TDL) 필터로 최소 평균 자승 (least mean squares) 알고리즘으로 각 가중치가 조절된다 [7].

2-3 Cost 함수

PRNN 각 모듈에서의 오차신호는

$$e_i(n) = s(n - i + 1) - y_{i,1}(n), \quad i = 1, 2, \dots, M \quad (7)$$

로 주어진다. PRNN 의 전체 cost 함수는 다음과 같이 주어진다.

$$\mathcal{E}(n) = \sum_{i=1}^M \lambda^{i-1} e_i^2(n) \quad (8)$$

여기서, λ 는 지수 가중치로 $0 \leq \lambda \leq 1$ 범위 값으로 망각인자 (forgetting factor) 이다.

3. 모의 실험 및 검토

국내 원자력 발전소의 S/G 수위예측에 대한 컴퓨터 모의 실험을 수행하였다. PRNN 의 입력으로는 급수 온도와 수증기 압력을 주었고, 출력으로 S/G 수위를 선정하였다. 300 초 간격으로 샘플링된 위 3 가지 신호 200 샘플치를 이용하였다. 이때 PRNN 에 이용한 각 파라메타 값은

다음과 같다.

> 비선형 부분

- . 모듈의 수 $M = 5$
- . 모듈당 뉴런의 수 $N = 2$
- . 각 모듈의 외부 입력 갯수 $p = 2$
- . 학습비(learning rate) $\eta = 0.00001$
- . 망각 인자(forgetting factor) $\lambda = 0.9$

> 선형 부분

- . TDL 필터의 길이 $q = 12$
- . 학습비(learning rate) $\mu = 0.01$

그림 6 은 대표적인 컴퓨터 모의 실험 결과를 보여준다. 그림에서 보듯이 여러 조건에 의해 변화하는 S/G 수위를 PRNN 이 빠른 예측을 하고있음을 보여준다. 여기서 다층 인식자 (MLP) 신경망은 초기 100 심플을 가지고 학습한후 실행한 결과이다. 이때 PRNN 은 학습을 따로 실행하지 않고 바로 예측을 할 수 있었고 출력 신호와 연관된 입력을 가지고 요구되는 출력 신호를 예측할 수 있었다.

4. 결 론

본 연구에서는 PRNN (pipelined recurrent neural network) 을 이용한 이상 연상 (hetero-association) 학습의 예측을 서술하였다. 이 방식은 따로 학습의 필요가 없이 실시간 학습과 실행이 동시에 이루어 지는 방식이다. 이러한 특성은 학습된 내용만을 실행하는 기존의 신경망에 비해 비안정 비선형인 신호의 예측에 우수한 특성을 보임을 실제 발전소의 데이터를 가지고 모의 실험으로 입증하였다. 이러한 방식은 예측뿐만 아니라 시스템 식별, 시스템 등화, 잡음 제거등 여러 분야에 이용 가능할 것이며 이에 대한 연구를 진행 중에 있다.

참고 문헌

- [1] J.M.Zurada, Introduction to Artificial Neural Systems. New York: West Publishing Company, 1992.
- [2] S.Haykin and L.Li, "Nonlinear adaptive prediction of nonstationary signals," IEEE Trans.

Signal Processing, vol. 43, pp. 526-535, Feb. 1995.

- [3] A. G. Parlos, A. F. Atiya, K. T. Chong, and W. K. Tsai, "Nonlinear identification of process dynamics using neural networks," Nuclear Technology, vol.97, pp.79-96, Jan. 1992.
- [4] B. R. Upadhyaya and E. Eryurek," Application of neural networks for sensor validation and plant monitoring," Nuclear Technology, vol. 97, pp.170-176, Feb. 1992.
- [5] Z. Guo and R. E. Uhrig," Use of artificial neural networks to analyze nuclear power plant performance," Nuclear Technology, vol. 99, pp.36-42, July. 1992.
- [6] E. B. Bartlett and R. E. Uhrig," Nuclear power plant status diagnostics using an artificial neural network," Nuclear Technology, vol. 97. pp.272-281, Mar. 1992.
- [7] B. Widrow and S. Stearns, Adaptive Signal Processing. Englewood Cliffs, NJ: Prentice-Hall, 1985.




그림 1. 비선형 적응 필터의 블럭도.




그림 2. 예측 목표 신호 $s(t)$ 와 중간 출력 $y(t)$ 사이의 관계.

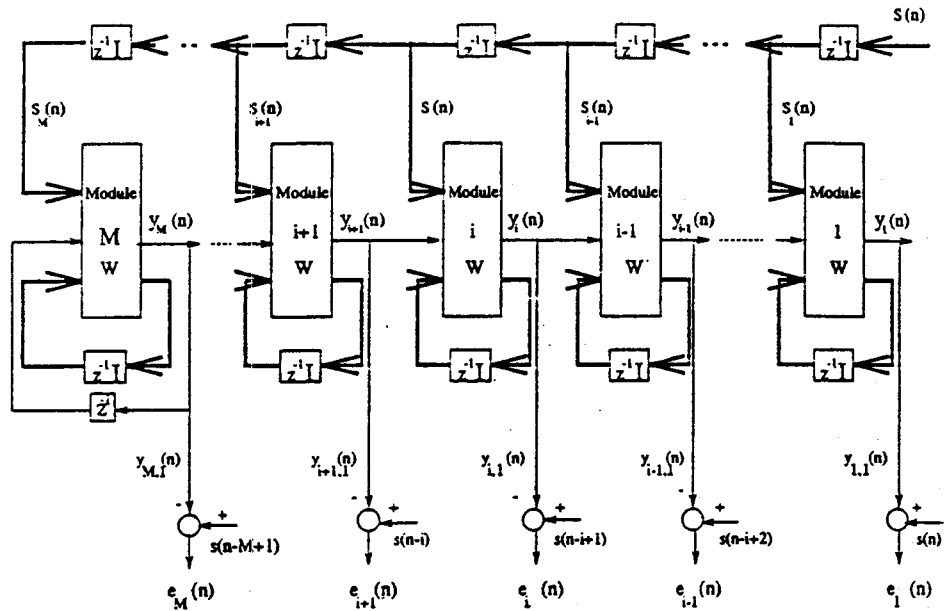


그림 3. PRNN 의 비선형 부분.




그림 4. PRNN 의 i 모듈의 세부 구조.




그림 5. TDL 필터인 선형 부분.

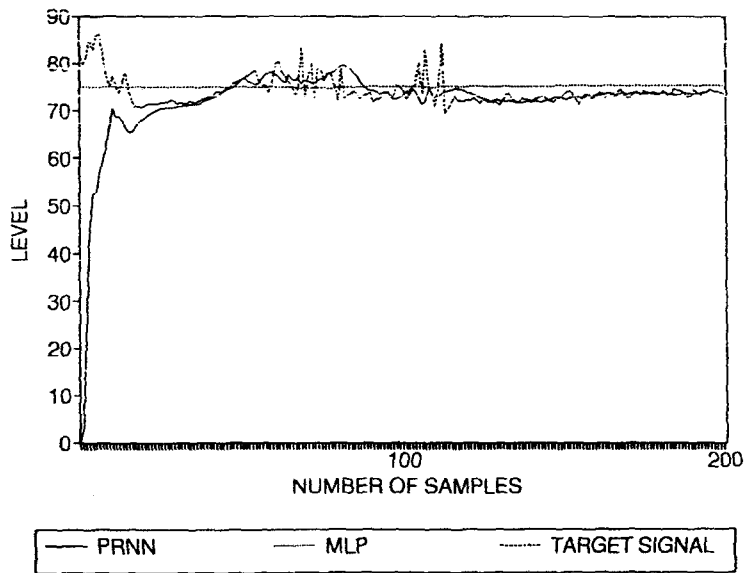


그림 6. PRNN 과 MLP 의 비안정 신호 예측 비교.