

동적 비선형 신호의 온라인 모델링

한정희 · 왕지남

아주대학교 산업공학과

ABSTRACT

This paper presents an on-line modeling method approach for the machine condition. The machine condition is continuously monitored with a sensor such as, a vibration, a current, an acoustic emission (AE) sensor. In this study, neural network modeling by radial basis function is designed for analysis a prediction error.

An on-line learning algorithm is designed using the RLS(recursive least square) estimation and the existing clustering method of Kohonen neural network. Experimental results show that the proposed RBNN modeling is suitable for predicting simulated data.

1. 서론

최근 생산설비의 장치나 기계류가 점점 대형화, 고속화, 복잡화 되어지고 각각의 설비가 자동화, 지능화 되어짐에 따라 설비의 고장이나 이상에 의한 손실비용과 안전면에서 상당히 중요한 문제가 된다. 더욱이 앞으로의 생산 시스템은 더욱더 고도로 발달되어, 자동화, 무인화가 더욱 가속화 될 것이며, 설비집약형의 산업이 전개 될 것으로 전망된다. 그러므로 이것에 상응한 설비 관리가 필요하며, 설비의 상태를 잘 표현할 수 있도록 모델링 하는 것이 쉽지 않은 문제가 되었다. 일반적으로 시스템이 복잡하거나 동적으로 변하는 경우 공정에 관한 실험을 통해 모델링을 하는데 이는 공정에서 임은 신호로부터 변수를 결정하여 수학적 모델을 세우는 것을 말하며 시스템 규명에 가장 중요하다고 볼 수 있다. 시스템 규명은 어떤 실험을 통해서 매개변수(parameter)를 결정하는 것으로 4단계로 나눌 수 있다. 첫째는 센서를 통해 공정에 대한 정보 즉 신호를 수집하고 둘째는 모델의 구조를 결정하고 세째는 모델 구조의 모수를 추정하여 마지막으로 모델 구조의 효율성을 평가하고 더 나은 모델을 구축 할 수 있는지를 조사하는 것이다.

최근 비선형 시스템 규명에 있어서 신경망(Neural Network)을 이용한 모델링 방법이 제시되고 있다. Wang의 연구에서는 기계상태 변화 탐지를 위한 2단계 신경망에 의한 모델링 방법으로 1단계에서 예측에러를 2단계의 입력벡터로 하여 모델링의 정확도를 높이고자 하였다.[2][4] Werbos는 시스템의 다단계 이후를 예측하는 것으로 입력과 출력이 서로 연쇄적인 관계를 갖으며 전단계 신경망의 일부 출력을 다음 단계 신경망의 일부 입력요소로 사용하는 반복적인 신경망을 제시하였다.[5] Elanayer와 Shine은 본연구에서 사용한 radial basis함수를 이용하여 Tool의 마모 상태를 추정하고자 하였다.[1] 또한 Jeong은 신경망의 연상 기억성을 이용하여 기계 시스템에서의 고장을 진단하고자 하였다.[17] 다음의 그림 1은 이러한 입력과 출력과의 관계를 일반적으로 나타낸 것으로 신경망을 이용하여 구조를 결정하고자 하는 것이다.

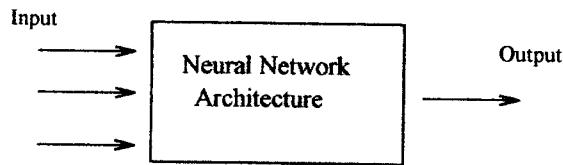


그림 1. 일반적인 신경망 모델링 접근

본 연구에서는 공정 중에 수집된 신호를 Kohonen 신경망을 이용하여 학습시켜 데이터를 clustering하고 이를 RBNN(Radial Basis Neural Network)의 구조를 결정하게 된다. 즉 연구의 목적은 입력되는 신호에 대해 radial basis 함수에 근거한 신경망으로 온라인 모델링을 하는 것이다. 신경망의 구조는 Kohonen 신경망의 학습에서 주어진 cluster 수, 중심벡터, 분산변수가 중간층의 노드 수와 각 변수로 나타내어 지정된다. 그림 2)는 위에 관한 전반적인 절차를 나타낸다.

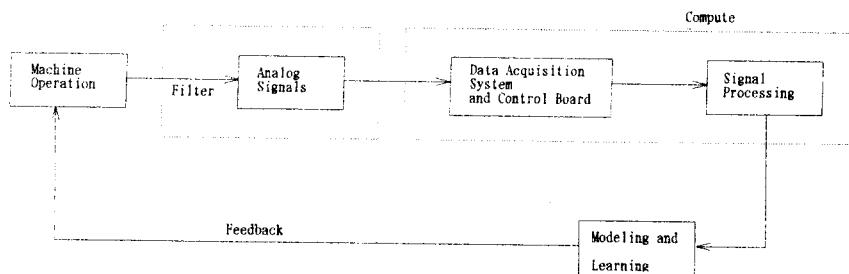


그림 2. A Diagram of Machine Condition System

2. 연구방법

2-1. 신호의 분류

신경망에서 mapping은 입력과 출력의 관계를 결정하는 것으로 신경망의 구조를 확립하는 것을 의미한다. 즉 입력과 출력의 수, 중간층의 노드 수, 중간 노드를 지나는 함수, 그리고 함수의 변수들을 결정하는 것이다.

본 연구에서 이용한 Kohonen 신경망[6][15]은 다음의 신경망에서의 구조 즉, 중간층의 Node 수, 중간층 함수의 중심벡터와 분산변수를 결정한다. 중심벡터는 각 cluster 벡터들의 평균값이며 분산변수는 벡터들간의 거리를 의미하고 중간층의 노드수는 cluster의 갯수를 나타낸다.

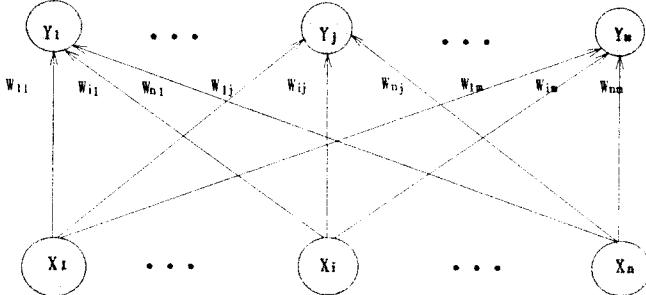


그림 3. Kohonen self-organizing map

그림3)은 Kohonen 신경망을 나타낸 그림으로 연속되는 n개의 입력에 대해 m개의 clustering을 보여준다. 여기서 cluster의 수의 증가는 Node 수의 증가를 의미하고 cluster 내의 분산을 감소시키며 학습할 연결부가 많아져 복잡한 입력신호에 적합한 장점이 있지만 학습시간이 길다. 따라서 cluster수 m을 결정하는 것은 상당히 중요한 의미를 갖는다. 이에 대한 알고리즘은 표 1)과 같다.

Table 1. Kohonen Neural Network

- 1 Measure $\vec{I}_t = (y_t, y_{t-1}, \dots, y_{t-N+1})$, Initialize weights w_{ij} ($0 < w_{ij} < 1$)
- Cluster의 수 N 결정, Learning rate α ($0 < \alpha < 1$) $\alpha(t+1) = \alpha \cdot \alpha(t)$
2. Calculation for each j $D(j) = \sum (w_{ij} - \vec{I}_t)^2$
3. D(j)가 최소가 되는 j와 Update $w_{ij}(n) = w_{ij}(0) + \alpha \cdot (\vec{I}_t - w_{ij}(0))$
- 4..Update Learning rate
5. Convergence weight matrices
6. return to step 1
7. 경험적인 cluster 수 결정

2-2. Radial Basis Neural Network

기존의 신경망에서는 중간 함수로 sigmoid나 step 함수 등을 사용하여 왔다. 본 연구에서는 기존의 중간 함수에 비해 변화에 좀더 적응적인 Radial basis 함수를 이용하였는데 Radial basis는 함수의 보간과 근사 그리고 곡면 fitting에 용이하며 최근에는 산포된 data 보간의 사용이 증가하고 Radial Basis 함수의 선형조합을 이용하여 함수에 근사화 될 수 있다.[1]

그림 4)는 진동 센서에 의한 신호들에 대한 입출력 관계로 하나의 출력과 하나의 중간층으로 구성된 신경망을 보여주고 있다.

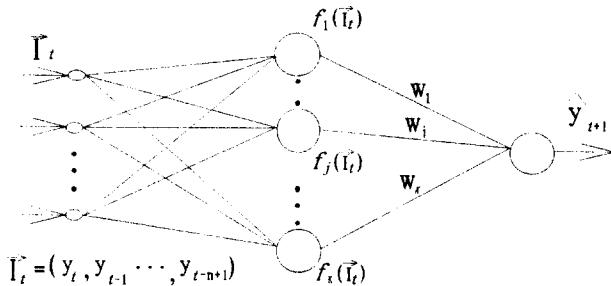


그림 4. The Radial Basis Neural Network

그림 4)에서 중간층은 Radial 함수로 구성되고 정규분포 확률 함수 형태의 함수로 나타내며. 입력벡터 \vec{I}_t 가 중간층의 Node j를 통과하는 식은 다음과 같다.

$$f_j(\vec{I}_t) = e^{-\frac{\|\vec{a}_j - \vec{I}_t\|}{2\sigma_j}} \quad \dots \quad (1)$$

(1)식에서 \vec{a}_j 는 중간층 node j에서의 중심벡터이고 σ_j 는 중간층 node j에서의 분산변수이다. 신경망의 중간층에 있는 전체 노드 수, 각 노드의 중심벡터와 분산변수는 Kohonen 신경망의 학습에서 clustering 되어 정해지게 된다. 중심벡터는 분할된 각 cluster의 평균을 나타내고 분산 변수는 각 cluster의 산포를 나타낸다. 주어진 입력벡터에 대하여 K개의 노드를 갖는 신경망의 출력 \hat{y}_{t+1} 는 각 함수와 연결강도의 선형조합으로 표시할 수 있다.

$$\hat{y}_{t+1} = \sum_{j=1}^K w_j(t) f_j(\vec{I}_t) \quad \dots \quad (2)$$

1단계 학습에서 중간층의 Node 수, 중심벡터, 분산변수가 정해진 후 각 신경망의 연결부를 새로 입력되는 신호들을 이용하여 수정하는 on-line 학습은 RLS(recursive least square)방법으로 한다. RLS에 의한 학습과정은 다음과 같다.

$$\hat{y}_{t+1} = \sum_{j=1}^K w_j(t) f_j(\vec{I}_t) = \varphi^T(t) W(t) \quad \dots \quad (3)$$

$$W(t+1) = W(t) + G(t) [y_{t+1} - \varphi^T(t+1) W(t)] \quad \dots \quad (4)$$

$$G(t) = P(t) \varphi(t+1) [1 + \varphi^T(t+1) P(t) \varphi(t+1)] \quad \dots \quad (5)$$

$$P(t+1) = [I - G(t) \varphi^T(t+1)] P(t) \quad \dots \quad (6)$$

$$\varphi(t) = [f_1(\vec{I}_t), f_2(\vec{I}_t), \dots, f_M(\vec{I}_t)]$$

\hat{y}_{t+1} 는 신경망의 출력을 나타내고 $W(t) = (w_1(t), w_2(t), \dots, w_k(t))$ 는 시간 t 에서의 신경망 연결 강도를 나타낸다. $\vec{I}_t = (y_t, y_{t-1}, \dots, y_{t-N+1})$ 는 시간 t 에서의 입력벡터이며 신경망 연결부 $W(t)$ 는 RLS에 의해서 각 단계별로 수정된다. 초기의 $P(t_0)$ 은 $[\phi^T(t_0)\phi(t_0)]^{-1}$ 로 구하고 $P(t)$ 는 식 (6)과 같이 순환적으로 수정해 나간다. 위 내용을 간단히 나타내면 아래의 표 2)와 같다.

Table 2. RBNN Modeling

1 Node 수, 중심벡터(\vec{a}_j), 분산변수 (σ_j) 설정
2. Calculation $\hat{y}_{t+1} = \sum_{j=1}^K w_j(t) f_j(\vec{I}_t)$ where, $f_j(\vec{I}_t) = e^{-\frac{\ \vec{a}_j - \vec{I}_t\ }{2\sigma_j}}$, $w_j(t)$ using RLS
3. Calculation $e_{t+1} = y_{t+1} - \hat{y}_{t+1}$

3. 실험결과

본 연구에서는 실제 데이터에 앞서 아래 모델구조식에 의해 발생한 시계열 데이터로 실험하였다. 신경망의 입력으로 시간 t 를 기준으로 과거 N 개의 data를 입력벡터(\vec{I}_t)로 사용하여 모델링을 한 후 모델링에 의한 예측에러를 계산하였다.

$$AR(2) : y_t = 1.49 y_{t-1} - 0.653 y_{t-2} + e_t \quad (7)$$

$$AR(3) : y_t = 2.146 y_{t-1} - 1.598 y_{t-2} + 0.409 y_{t-3} + e_t \quad (8)$$

$$AR(4) : y_t = 1.876 y_{t-1} - 1.781 y_{t-2} - 1.201 y_{t-3} - 0.373 y_{t-4} + e_t \quad (9)$$

$$AR(5) : y_t = 1.840 y_{t-1} - 0.893 y_{t-2} - 0.613 y_{t-3} - 0.879 y_{t-4} - 0.350 y_{t-5} + e_t \quad (10)$$

위모델에서 e_t 는 정규분포 $N(0,1)$ 을 따른다고 가정하고 실험 Data를 생성하였다. 처음 신호 100개에 대해 Kohonen 신경망 학습으로 다음단계의 구조를 결정하고 다음 단계에서의 RHNN에 의한 모델링으로 예측에러에 대한 분석을 보여준다. 그림 5.1)~ 5.4)는 AR(2) ~AR(5) 시계열 데이터의 예측에러를 나타내며 비교적 tracking이 잘되고 있음을 보여준다.

4. 결론

본 연구에서는 수집한 데이터를 Kohonen 신경망으로 학습하여 cluster 수를 결정하고 다음 단계의 RBNN의 구조를 결정하였고 시계열 데이터의 분석으로 RB(Radial Basis)함수에 근거한 신경망에 의한 온라인 모델링 방법을 제시하였다. 이때, Kohonen 신경망의 Clustering 방법에서 초기 Weight나 learning rate에 영향을 받음을 알 수 있었지만 반복적인 시행 차오로 Weight나 learning rate으로 인한 에러를 최소로 하였다. 전체 그림에서 보여주듯이 예측에러에 대한 분석이 비교적 정확함을 보여주고 있다. 본 결과는 기계설비의 감시 및 고장 진단 시스템에 활용이 가능하며 설비의 복수고장으로 신호가 혼합되어 나타나는 경우에 활용될 수 있다는 점에 의의가 있다.

5. 참고문헌

- [1] Elanayar,S. and Shin,Y.C., "Tool Wear Estimation in Turning Operations based on Radial Basis Functions," in Dagli, C.H., S.R.T. Kumar, and Y.C. Shin(Eds). Intelligent Engineering System Through Artificial Neural Networks (Proceedings of the Artificial Neural Networks in Engineering), pp.685-691, November 10-13, 1991..
- [2] Wang, G.N., Kim, G.S. and Jeong, Y.S., "Radial Basis Hybrid Neural Network Modeling for On-line Detection of Machine Condition Change," Journal of the Korean Institute of Industrial Engineers, vol 20, pp.113-134, December., 1994.
- [3] Gi-Nam Wang, Gwang-Sup Kim, and Y.S. Jung, "Two-Phase Radial Basis Hybrid Neural Network for On-line Modeling of Machine Condition, "Journal of the Society of Plant Engineers Japan. Vol.6,No.3, pp.20-28, 1994.12.
- [4] Gi-Nam Wang, "An Adaptive Hybrid Neural Network Approach to Prediction of Nonstationary Processes", Hybrid Intelligent System Applications, Edited by Dr. Jay Liebowitz, IOS Press, 1995.
- [5] Werbos, P.J., "Beyond Regression: New Tools for Prediction and Analysis in the Behavior Sience , " Ph.D Dissertation,Harvard University, Cambridge, MA, Committee on Applied Mathematics, Nov.1974. Also published as Report of the Cambridge Project, Cambridge, MA, the 1975.
- [6] Kohonen,T., "The Self-Organizing Map," Proceedings of the IEEE, pp.1464-1480, 1990b.
- [7] Egill Masson and Y.J Wang., " Introduction to Computation and Learning in Artificial neural network", European Journal of Operation Research, pp.1-28, November, 1989.
- [8] Raju. G. Khanchustambham and G.M. Zhang, "A Neural Network Approach to On-line Monitoring of a Turning Process, IEEE pp. II889- II894, 1992.
- [9] Ljung, L. and T.Söderström, "Theory and Practice of Recursive Identification", MIT press, 1983.
- [10] Q.Xu, K. Krishnamurthy, B. McMillin and W.Lu., "Identification of Cutting Force in End Milling Operation Using Recurrent Neural Networks", IEEE pp.3828-3833, 1994.
- [11] Y.Altintas, I.Yellowly and J.Tlusty., "The Detection of Tool Breakage in Milling Operations", Journal of Engineering for Industry, vol 110 August, 1988.
- [12] Y.Altintas and I.Yellowly., " In-Process Detection of Tool Failure in Milling Using Cutting Force Models", Journal of Engineering for Industry, vol 111 May, 1989
- [13] S. Rangwala and D. Dornfeld., " Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring", Journal of Engineering for Industry, vol 112 August, 1990.
- [14] K.T. Chong and D.P. Hong., "System Identification of Nonlinear System using Local Time Delayed Recurrent Neural Network", Journal of the Korean Society of Precision Engineering, vol 12. No 6. June. 1995.
- [15] Kohonen, T., "Self-Organized Formation of Topologically Correct Feature Maps," Biological Cybernetics, 43:59-69. Reprinted in Anderson and Rosenfeld pp.511-521, 1988.
- [16] Kil R.M. and Choi J.Y., "Time-Series Prediction Based on Global and Local Estimation" World Congress on Neural Networks(WCNN), Oregon, July 11-15, Vol 4, pp 617-621, 1993.
- [17] 정윤성, 왕지남, 김광설(1995), "흡펠드 네트워크에 의한 진동분석과 결합진단," 대한산업공학회, 95'춘계공동학술대회 논문집(II), p. 571 1995.