

다단계 뉴럴네트워크(Neural Network)에 의한 온-라인 기계상태감시

한정희 · 왕지남 · 허정준

아주대학교 산업공학과

ABSTRACT

컴퓨터에 의한 생산시스템의 통합체계화와 온-라인화에 따라 자동화된 설비진단 방법이 요구되어지고 있다. 이에따라 기계설비에 각종 센서를 부착하여 실시간으로 수집된 출력신호를 이용하여 기계설비를 온-라인으로 감시하는 여러가지 기법들이 제시되고 있다. 본 연구에서는 진동센서로 부터의 신호를 radial 함수에 근거한 다단계 뉴럴 네트워크(Neural Network)으로 모형화하여 기계설비 상태를 감시하는 방법을 제시한다. 또한 다단계 모델링 분석을 통하여 신호를 예측하고 설비고장 원인을 분류하며, 다른 모형과의 비교를 통하여 효율성 평가와 최적 단계수를 결정하였다. 온라인 학습 알고리즘은 recursive least squares와 clustering 방법을 이용한다.

1. 서론

최근 여러 제조업에서는 제품의 정밀성, 생산성, 품질의 향상과 유연한 생산을 위해 컴퓨터에 의한 통합 생산체계(CIM)가 활성화 되고 생산설비의 자동화, 무인화 경향에 따라 공정 변화와 환경에 적응적인 사고를 가진 시스템이 고려되고 있다. 이러한 적응적인 시스템을 구현하기 위해서는 우선 각종 센서를 이용한 정보수집이 이루어져야 한다. 일반적으로 시스템이 복잡하고 동적으로 변하는 경우의 완전한 모델링은 사실상 어렵기 때문에 시스템의 감시나 예측에 많은 어려움이 있다. 대체로 설비 상태에 변화가 있을 때 그 상황을 인지하고 적응적인 시스템을 만들기 위해서 다음의 3단계 방법으로 나눌 수 있는데 첫째는 압력센서, 음향센서, 진동센서 등의 센서로부터 시스템의 상태를 연속적으로 측정, 감시하는 것이고 둘째는 측정 신호로부터 유형을 분석하고, 마지막으로는 시스템의 상태를 규명하는 것이다.[2]

본 연구에서는 회전하는 모형 실험장치에 진동센서를 부착하여 진동 측정기(MK-500)에 입력되는 신호들을 filtering한 후 A/D converter로 데이터를 실시간으로 수집하고 분석하였다. 모터의 회전속도(RPM)는 PLC(Programmable Logic Controllers)를 이용하여 조절하였다. 그림 1에는 이에 관한 전반적인 절차가 나타나 있다.

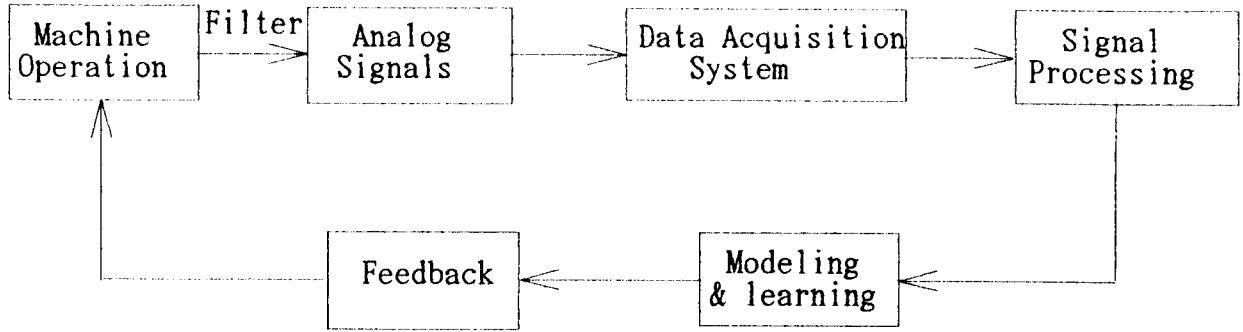


그림1 : A Diagram of Machine Condition

설비가동 상태에서 수집된 데이터를 off-line으로 Kohonen 신경망의 clustering 알고리즘으로 학습시킨 후 Radial Basis 함수를 근거로한 다단계 신경망(Neural Network)의 Mapping 메카니즘을 이용하여 새로운 신경망 조직을 확립하고 최적의 단계 수를 결정하였다. 입력되는 신호에 따라 온라인으로 학습하는 알고리즘은 recursive least square 방법을 이용한다.

2.Radial Basis 함수

기존의 신경망에서는 주로 sigmoid나 step 함수 등을 사용하여 왔다. Radial basis는 함수의 보간과 근사 그리고 곡면 fitting에 용이하고 최근에는 산포된 data 보간의 사용이 증가하고 Radial Basis 함수의 선형조합을 이용하여 함수에 근사화 될 수 있다.[1]

그림 2는 진동 센서에 의한 신호들에 대한 입력 출력 관계로 하나의 출력과 하나의 중간층으로 구성된 신경망을 보여주고 있다.

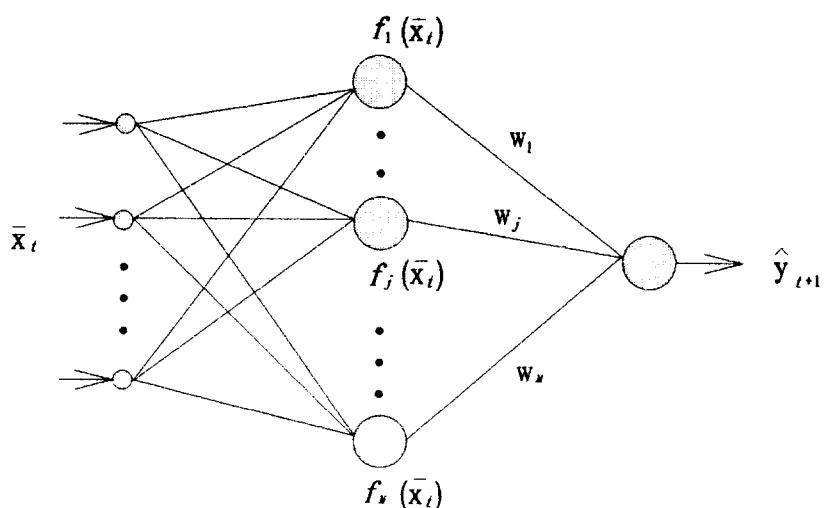


그림2. The Radial Basis Neural Network

그림 2)에서 중간층은 Radial 함수로 구성되고 정규분포 확률 함수 형태의 함수로 나타내며. 입력벡터 \vec{X}_t 가 중간층의 Node j를 통과하는 식은 다음과 같다.

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

(1)식에서 \vec{c}_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 off-line 학습에서 clustering 되어 정해지게 된다. 중심벡터는 분할된 각 cluster의 평균을 나타내고 분산 변수는 각 cluster의 산포를 나타낸다. 주어진 입력벡터에 대하여 M개의 노드를 갖는 신경망의 출력 \hat{y}_{t+1} 는 각 함수와 연결강도의 선형조합으로 표시할 수 있다.

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

cluster의 수의 증가는 Node 수의 증가를 의미하고 cluster 내의 분산을 감소시키며 학습할 연결부가 많아져 복잡한 입력신호에 적합한 장점이 있지만 학습시간이 길다. 따라서 최적의 clustering은 상당히 중요한 의미를 갖는다.

3. 다단계 모델링

본 논문에서는 센서로부터 얻어진 신호들에 대해 모델링에 필요한 변수들을 결정하였고 모델의 적정성 평가는 모델의 다단계 예측에러들의 분석으로 하였다. 그림 3)은 다단계 신경망 모델링 구조를 보여 준다.

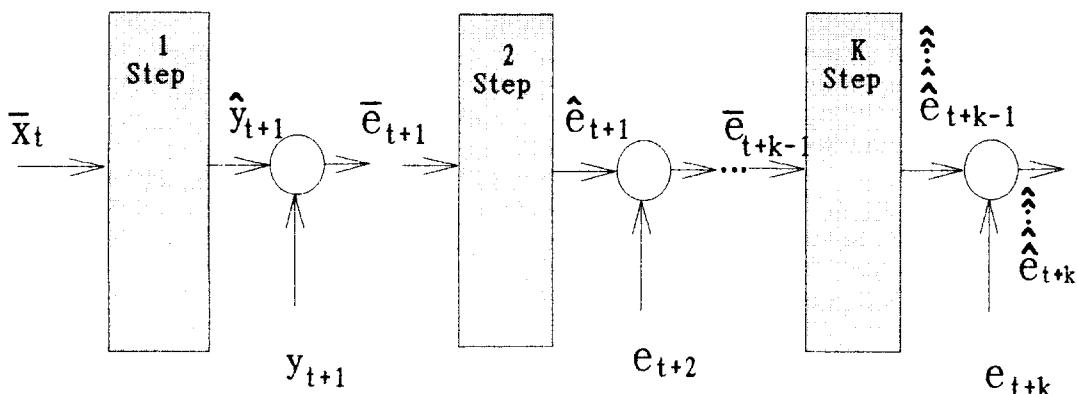


그림 3 K-Phase Radial Basis Neural Network

그림 3)의 Node 수 M, 중심벡터 \vec{c}_j , 그리고 분산변수 σ_j 는 다단계 모델링할 때의 결정변수로 off-line 학습에서 얻는 변수들이다. 과거 N개의 입력벡터 $\vec{x}_t = (y_t, y_{t-1}, \dots, y_{t-N+1})$ 를 이용하여 1단계의 신호 \hat{y}_{t+1} 를 예측하고 실제 신호 값 y_{t+1} 과의 차로 예측에러 e_{t+1} 를 구한다. 간단한 시스템에서는 1단계 모델링만으로도 정확하게 시스템을 구현하지만 시스템이 복잡할 경우는 신호들의 유형을 완벽하게 알아내기는 쉽지않다. 1단계 에러는 완전한 White-noise라고 볼수가 없기 때문에 다시 1단계 에러를 입력벡터 $\vec{e}_{t+1} = (e_{t+1}, e_t, \dots, e_{t-8})$ 로 하여 다음 시점의 예측 에러를 재예측한 \hat{e}_{t+1} 를 얻고 이를 입력벡터로 하여 \hat{e}_{t+1} 를 출력으로 얻는 과정을 반복하여 다단계 모델링을 설계한다. Radial Basis 신경망에 의한 다단계 모델링은 전단계 신경망의 출력이 다음단계 신경망의 입력으로 사용되어 예측에러를 출력으로 예측하는 즉, 전단계 출력 \hat{y}_{t+1} 을 이용하여 예측에러 e_{t+1} 를 계산하여 입력벡터로 사용하고 예측에러를 다시 재예측하는 반복적인 모델링을 사용하고 있다.

중간층의 Node의 수는 Radial 함수 신경망 구조 결정에 중요한 역할을 하는데 최적의 Node 수는 Kohonen Learning Algorithm을 이용하여 off-line으로 학습한다.[3] off-line 학습에서 중간층의 Node 수, 중심벡터, 분산변수가 정해진 후 각 신경망의 연결부를 새로 입력되는 신호들을 이용하여 수정하는 on-line 학습은 Recursive Least Square 방법으로 한다. RLS에 의한 학습과정은 다음과 같다.

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

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

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

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

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

\hat{y}_{t+1} 는 신경망의 출력을 나타내고 $W(t) = (w_1(t), w_2(t), \dots, w_M(t))$ 는 시간 t에서의 신경망 연결 강도이고 $\vec{x}_t = (y_t, y_{t-1}, \dots, y_{t-N+1})$ 는 시간 t에서의 입력벡터이며 신경망 연결부 $W(t)$ 는 RLS에 의해서 각 단계별로 수정된다. 초기의 $P(t_0)$ 은 $[\varphi^T(t_0) \varphi(t_0)]^{-1}$ 로 구하고 $P(t)$ 는 식 (6)과 같이 순환적으로 수정해 나간다.

RLS는 과거의 모든 신호를 각 단계에서 이용하지 않고 새로운 신호만으로 변수를 추정하므로 실시간 모델링에 적합하다. 시스템의 복잡성에 따라 다단계 모델링에서의 단계 수가 증가하게 되고 학습시간 또한 증가하여 최적의 단계 수를 결정하는 것이 요구되는 데 그 방법으로 각 단계에서의 예측에러들의 SSE(sum of squares error)

를 이용하였다. $SSE(k)/SSE(k+1)$ 가 1보다 작거나 같으면 k시점에서 단계 k를 결정한다. 다음의 테이블은 cluster 수 결정과 다단계 모델링에서의 단계 수를 결정하는 알고리즘이다.

Phase I

Kohonen algorithm

1 Measure $\vec{x}_t = (y_t, y_{t-1}, \dots, y_{t-N+1})$, Initialize weights w_{ij} ($0 < w_{ij} < 1$)

Cluster의 수 N 결정, Learning rate α ($0 < \alpha < 1$) $\alpha(t+1) = \alpha + \alpha(t)$

2. Calculation for each j $D(j) = \sum (w_{ij} - \vec{x}_t)^2$

3. D(j)가 최소가 되는 j와 Update $w_{ij}(n) = w_{ij}(0) + \alpha \cdot (\vec{x}_t - w_{ij}(0))$

4. Update Learning rate

5. Convergence weight matrices

6. $\sigma_{\text{err}}^2 = \sigma_{\text{err}}^2 + \frac{\sigma_{\text{err}}^2}{n} - C + \frac{\sigma_{\text{err}}^2}{C}$ $0.8 < C < 1.2$ 만족하는 cluster 수 결정

7. Return to step 1.

Phase II

Multi-phase Neural Network

1. Node 수, 중심벡터(\vec{C}_j), 분산변수 (σ_j) 결정

2. Calculation $y_{t+1} = \sum_{i=1}^M w_i(t) f_i(\vec{x}_t)$ where, $f_i(\vec{x}_t) = e^{-\frac{\|\vec{x}_t - \vec{C}_i\|^2}{2\sigma_i^2}}$, $w_i(t)$ using RLS

3. Calculation $e_{t+1} = y_{t+1} - \hat{y}_{t+1}$

4. Calculation $\hat{e}_{t+1} = \sum_{i=1}^M w'_i(t) f_i(\vec{e}_t)$ where, $\vec{e}_{t+1} = (e_{t+1}, e_t, \dots, e_{t-s})$

$w'_i(t)$ using RLS

5. Calculation SEE(k) at step k

6. Stop $SSE(k)/SSE(k+1) \leq 1$

4. 결론

본 연구에서는 수집한 데이터를 코호넨 알고리즘을 이용하여 off-line으로 학습하여 최적의 cluster 수와 다단계 모델링에서의 최적 단계를 결정하였다. 앞으로의 과제는 결정된 cluster 이외의 데이터가 다단계 모델링 과정에 발생했을 때 그것을 새로운 cluster로 인지하여 cluster 수를 추가하면 온라인으로 변수들을 결정하는 것이다.

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. Kumara, and Y.C. Shin(Eds), Intelligent

- Engineering Systems 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] Kohonen, T., "The Self-Organizing Map," Proceedings of the IEEE, pp.1464-1480, 1990b
 - [4] Egill Masson and Y.J. Wang., "Introduction to Computation and Learning in Artificial neural networks", European Journal of Operation Research, pp.1-28, November, 1989
 - [5] Raju. G. Khanchustambham and G.M. Zhang, "A Neural Network Approach to On-line Monitoring of a Turning Process, IEEE pp. II889-II894, 1992
 - [6] Ljung, L. and T. Söderström, "Theory and Practice of Recursive Identification", MIT press, 1983
 - [7] 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