

불확실성을 포함한 비선형 시스템에서 학습접근을 이용한 고장 진단 설계

송민철, 황영호, 양해원
한양대학교 전자전기제어계측공학과

Design of Fault Diagnosis Using a Learning Approach in Uncertain Nonlinear systems.

Min-Cheol Song, Young-Ho Hwang, Hai-Won Yang
Dept. of Elec. Elec. Con & Inst. Eng. Hanyang Univ.

Abstract - 본 논문에서는 미지의 유체를 가진 불확실성을 포함한 비선형 시스템에 대한 고장 진단 설계를 제안한다. 제안된 고장 진단 필터는 비선형 관측기 설계 기술에 기초하여 설계되며, 신경망을 이용하여 고장 성분과 불확실성 성분을 추정하고 추정된 불확실성의 상한값을 고장 진단에 이용한다. 제안된 근사기는 불확실성과 고장 함수를 추정함으로써 고장 검출뿐만 아니라 고장 진단을 확인할 수 있도록 설계된다. 모의실험을 통해서 제안된 고장 진단 설계의 성능을 검증하였다.

1. 서 론

많은 산업 현장에서 쓰이는 시스템 성능의 높은 신뢰도의 요구 때문에 고장 검출과 고장 진단의 방법으로 모델에 근거한 해석과 설계가 지난 20년간 연구되어 왔다 [1], [2], [3]. 지금까지 대부분 고장 진단 연구에서 시스템의 정상 모델은 선형이며 고장은 외부에서 더해지는 입력으로 모델화 되었다. 그러나 대부분 실제 시스템 모델은 비선형으로 존재하고 고장성분도 비선형 함수로 표현된다.

고장 진단에서의 한 가지 접근 방법으로 신경망 학습은 비선형 동적 시스템에서 고장 검출, 고장 식별, 그리고 고장 허용을 위해 사용된다. 온라인 근사 모델을 사용하는 고장 진단의 일반적인 방법은 [4]에서 소개되었다.

본 논문에서 고려된 시스템은 다변수 동적 비선형 시스템이고 비선형 근사기와 신경망으로 구성되어 있는 고장 진단 설계를 제안한다. 고장 진단 방법으로 서로 다른 기능을 하는 두 개의 신경망을 제안한다. 첫 번째 신경망 근사기는 불확실한 성분의 상한값을 얻는데 이용한다. 두 번째 신경망 근사기는 고장 성분을 추정하기 위하여 설계되었다.

2. 본 론

2.1 문제 제기 및 시스템 모델

다음과 같은 미분 방정식으로 표현된 다변수 비선형 시스템을 고려해 보자.

$$\begin{aligned} \dot{x}_1 &= \zeta_1(x, u) + \eta_1(x, t) + \beta_1(t-T)f_1(x, u), \\ \dot{x}_2 &= \zeta_2(x, u) + \eta_2(x, t) + \beta_2(t-T)f_2(x, u), \\ &\vdots \\ \dot{x}_n &= \zeta_n(x, u) + \eta_n(x, t) + \beta_n(t-T)f_n(x, u) \end{aligned} \quad (1)$$

여기서 $x = [x_1, x_2, \dots, x_n]^T \in R^n$ 은 시스템의 상태벡터, $u \in R^m$ 은 입력벡터, $\zeta_i: R^n \times R^m \rightarrow R$ 는 정상 시스템, $f_i: R^n \times R^m \rightarrow R$ 고장 함수를 나타낸다. $\eta(x, t)$ 은 시스템에서 모델 불확실성을 나타낸다. $\beta_i: R \rightarrow R, i = 1, \dots, n$ 고장에 대한 시간추이이다. 그리고 $T \geq 0$ 은 미지의 고장 발생 시간이다. 지금까지 많은

고장 진단에서 고장함수는 시간의 함수로 표현 되었지만, 대부분의 실제적인 고장은 상태 벡터 x 와 입력 벡터 u 로 이루어진 비선형 함수이다. $B(t-T)$ 는 시간추이 대각행렬 함수로써 다음과 같이 나타낼 수 있다.

$$B(t-T) = \text{diag}(\beta_1(t-T), \dots, \beta_n(t-T)). \quad (2)$$

본 논문에서는 두 단계로 고장 진단을 설계한다. 첫 번째 단계로 고장 성분이 존재하지 않는 시스템을 고려한다. 이 과정에서는 모델 불확실성 성분을 온라인 근사기를 이용해서 추정함으로써 고장 진단에 이용하고자 한다.

고장성분이 포함되지 않는 시스템은 다음과 같다.

$$\dot{\hat{x}}(t) = \zeta(x, u) + \eta(x, t) \quad (3)$$

여기서, 미분 방정식 $\dot{\hat{x}} = \zeta(x, u)$ 는 알고 있는 정상 모델이다. $\eta = [\eta_1, \dots, \eta_n]^T$ 은 모델 불확실성 성분을 나타낸다. 이 시스템에서 모델 불확실성 성분을 추정하기 위해 온라인 근사기 $\hat{\eta}$ 를 포함한 비선형 근사기를 고려하면 다음과 같다.


$$\dot{\hat{x}} = \zeta(x, u) + \hat{\eta}(x; \hat{W}) + G(\hat{x} - x) \quad (4)$$

여기서, $\hat{\eta}(x; \hat{W})$ 은 온라인 신경망 근사기가 된다. G 는 n 차 대각 행렬, 즉, $G = \text{diag}(g_1, \dots, g_n), g_i > 0$ 이다.

가정 1: x 가 집합 공간이 연속인 집합 M_x 에 속할 때 최적 파라미터 벡터 \hat{W}^* 는 아래와 같이 정의한다.

$$\hat{W}^* = \underset{\hat{W} \in M_{\hat{W}}}{\text{argmin}} [\sup_{x \in M_x} | \eta(x) - \hat{\eta}(x; \hat{W}) |]$$

본 논문에서는 학습방법으로 Radial Basis Function(RBF) 신경망을 이용한다.



은닉층

그림 1. RBF NN의 기본 구조
RBF의 기본구조는 그림 1에서와 같다. 은닉층은 RBF 뉴런들을 포함하며 활성 함수로 가우스 함수를 사용한다. 가우스 활성 함수는 다음과 같다.

$$\psi_i(x) = \exp\left(-\frac{((x - c_i)^T(x - c_i) + (u - c_i)^T(u - c_i))}{\sigma_i^2}\right)$$

여기서, x, u 는 신경망의 입력 벡터, σ_i 는 함수의 폭, $\psi_i(x)$ 는 은닉층 i 번째 뉴런의 출력을 나타낸다. \hat{W} 는 가중치이다. 출력으로 $y = \hat{\Omega}(x, u, \hat{W})$ 이다.

식 (4)에서 온라인 신경망 근사기는 다음과 같이 나타낼수 있다.

$$\hat{\eta}(x; \hat{W}) = \Psi(x)^T \hat{W}$$

여기서, 가중치 \hat{W} 의 적응칙은 다음과 같다.

$$\dot{\hat{W}} = \gamma \Psi \phi. \quad (5)$$

두 번째 단계로 고장이 발생했을 때 식 (3)에서 고장 성분이 추가된다.

$$\dot{z} = \zeta(z, u) + \eta(z, \hat{W}) + B(t-T)f(z, u) \quad (6)$$

재구성된 시스템에서 고장이 발생하기 전까지의 $\hat{\eta}$ 의 정보를 이용해서 불확실성 성분에 대한 상한값을 정할 수 있다. $f(z, u) = [f_1, \dots, f_n]^T$ 는 고장성분을 나타낸다.

각 시간추이 성분 β_i 는 다음과 같은 형태로 가정한다.

$$\beta_i(t-T) = \begin{cases} 0, & \text{if } t < T \\ 1 - \exp(-\alpha_i(t-T)), & \text{if } t \geq T \end{cases}$$

여기서, $\alpha_i > 0$ 상태변수 z_i 에서 고장을 전개하는 비율을 나타내는 미지의 상수이다. 위의 시간추이 성분은 작은 α_i 값에서는 천천히 변하는 고장에 대한 모델을 나타내고, 큰 값의 α_i 에서는 계단 함수 즉, 갑작스럽게 발생하는 고장 함수로 표현 된다.

2.2 고장 진단 설계

비선형 근사기와 신경망으로 구성된 고장 진단 설계 방법을 제시한다. 제안된 고장 진단 설계는 고장 함수를 추정할 뿐만 아니라 검출하는데 유용하다. 시스템 고장이 존재할 때, 시스템에서의 변화는 정상 시스템 모델과 고장성분이 존재하는 모델 사이에서 편차를 발생시킨다. 고장 진단 설계의 목적은 시스템에서의 변화를 검출할 뿐만 아니라 더 나아가 시스템에서의 고장을 추정한다.

식 (6)에 기초해서 첫 번째 단계에서와 같은 방법으로 비선형 근사기를 고려한다.

$$\dot{\hat{z}}(t) = -\Lambda(\hat{z} - z) + \zeta(z, u) + \hat{f}(z, u; \hat{\theta}) \quad (7)$$

여기서, $\hat{z} \in R^n$ 은 재구성된 모델에서 추정된 상태 변수이고 Λ 는 $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$, $-\lambda_i < 0$ 이다.

두 번째 신경망 알고리즘은 고장함수를 추정하는데 이용된다. 고장이 존재할 때 신경망 시스템 \hat{f} 는 고장 함수 학습을 위해 적용 구조는 다음과 같다.

$$\hat{f}(x, u; \hat{\theta}) = \Pi(x, u)^T \hat{\theta}.$$

여기서, $\hat{\theta}$ 는 적응 제어 즉 Lyapunov synthesis 방법으로부터 적응칙을 다음과 같이 선택한다.

$$\dot{\hat{\theta}} = \Gamma \Pi D[\phi], \quad \hat{\theta}(0) = \hat{\theta}_0 \quad (8)$$

여기서, $\Gamma = \Gamma^T \in R^{q \times q}$ 은 Positive definite, $\phi = z - \hat{z}$ 은 상태 추정 오차, 그리고 Π 는 다음과 같이 온라인 근사기 \hat{f} 의 Gradient를 나타낸다.

$$\Pi := \frac{\partial \hat{f}(x, u; \hat{\theta})}{\partial \hat{\theta}}$$

Dead-zone operator $D[\cdot]$ 은 다음과 같다.

$$D[\cdot] := \begin{cases} 0, & \text{if } (|\phi| < \bar{\eta}) \\ \phi, & \text{otherwise} \end{cases} \quad (9)$$

$\bar{\eta}$ 는 불확실성 성분 $\hat{\eta}$ 에 대한 상한값이다. 우리는 불확실성 성분에 대한 상한값을 미리 알고 있을 필요없이 $\hat{\eta}$ 를 통해 우리는 상한값을 정할 수 있다.

Dead-zone은 모델 불확실성에 대한 강인성을 높이기 위해 사용된다. 또한 불확실성 성분에 대한 고장 정보를

줄이기 위해 이용한다.

2.2.1 고장 진단의 안정성

식 (6), (7)에 의한 오차 방정식을 미분하면 다음과 같다.

$$\dot{\phi} = \Lambda \phi + Bf - \dot{f} + \eta - \dot{\hat{\eta}} \quad (10)$$

여기서, $\Lambda = -\lambda$, $\lambda > 0$ 이다. 식 (10)을 다음과 같이 표현 할 수 있다.

$$\dot{\phi} = \Lambda \phi - \Pi^T(\hat{\theta} - \hat{\theta}^*) - \psi^T(\hat{W} - \hat{W}^*) + \epsilon \quad (11)$$

여기서, ϵ 는 $f = \Pi^T \hat{\theta}^* + \epsilon_1$ 과 $\eta = \Psi^T \hat{W}^* + \epsilon_2$ 에서 발생하는 construction 오차 합($\epsilon_1 + \epsilon_2$)이다. $|\epsilon(x)| \leq \bar{\epsilon}$ 이고 $\bar{\epsilon}$ 은 알고 있는 상한 유계값이다. $\hat{\theta}^*$ 는 상수 파라미터 벡터이다. 앞에서 가정 1와 같이 $\hat{\theta}^*$ 이 집합 D 에 있을 때 $f(x, u)$ 와 $\hat{f}(x, u; \hat{\theta}^*)$ 사이의 오차를 최소화하는 $\hat{\theta}^*$ 의 값으로서 선택한다.

$$\hat{\theta}^* = \underset{\theta \in M_{\theta}}{\text{argmin}} \{ \sup_{(x, u) \in D} |f(x, u) - \hat{f}(x, u; \hat{\theta})| \}$$

Lyapunov 함수를 다음과 같이 선택하자.

$$V = \frac{1}{2} \phi^T \phi + \frac{1}{2} \hat{\theta}^T \Gamma \hat{\theta} + \frac{1}{2\gamma} \bar{W}^T \bar{W} \quad (12)$$

식 (12)를 미분하면 다음과 같다.

$$\begin{aligned} \dot{V} = & -p \phi^T \phi + \phi^T \epsilon - \hat{\theta}^T \Pi \phi + \hat{\theta}^T \Gamma^{-1} \dot{\hat{\theta}} \\ & - \bar{W}^T \Psi \phi + \frac{1}{\gamma} \bar{W}^T \dot{\bar{W}} \end{aligned} \quad (13)$$

여기서, $\hat{\theta} = \hat{\theta} - \hat{\theta}^*$ 이고 $\bar{W} = \bar{W} - \bar{W}^*$ 이다.

적용칙 식 (5), (8)에 의해 식 (13)은 다음과 같이 된다.

$$\begin{aligned} \dot{V} \leq & -p|\phi|^2 + \phi^T \epsilon \\ = & -\frac{p}{2}|\phi|^2 - \frac{p}{2}(|\phi|^2 - \frac{2}{p}\phi^T \epsilon) \\ \leq & -\frac{p}{2}|\phi|^2 + \frac{1}{2p}|\epsilon|^2. \end{aligned} \quad (14)$$

그러므로 식 (14)에서 $|\phi| > \frac{\bar{\epsilon}}{p}$, $p > 0$ 일 때, $\dot{V} \leq 0$ 임을 보장한다. 따라서 V 는 uniformly bounded 된다. 즉, $V, \phi, \hat{\theta} \in L_{\infty}$ 을 내포하고 있다.

2.3 모의 실험

본 논문에서 제안된 고장진단 방법을 위해 비선형 2차 동적 시스템을 고려한다.

$$\ddot{y} + 2u\zeta(\mu y^2 - 1)\dot{y} + w^2 y = u \quad (15)$$

여기서, u, ζ, μ 는 양의 상수이다. 이 시스템은 제어된 Van der Pol oscillator를 묘사한다. 이 모의실험에서 파라미터는 $w = 0.9, \zeta = 0.6, \mu = 0.95$ 로 한다. 모델 불확실성 성분을 $\eta(x, t) = 0.05 \sin(y)$ 로 한다.

고장성분이 존재하지 않는 모델을 고려하자.

$$\ddot{y} + 2u\zeta(\mu y^2 - 1)\dot{y} + u^2 y = u + \eta. \quad (16)$$

식 (16)을 상태 변수식으로 나타내면 식 (17)과 같다.

$$\dot{x} = \begin{bmatrix} x^2 \\ 2u\zeta(1 - \mu x_1^2)x_2 - u^2 x_1 + u \end{bmatrix} + \begin{bmatrix} 0 \\ \eta(x_1, t) \end{bmatrix} \quad (17)$$

여기서,

$$x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} y \\ y \end{bmatrix}$$

식 (17)을 기초로 근사 모델을 구성한다.

$$\dot{\hat{x}} = \begin{bmatrix} x_2 \\ 2u\zeta(1 - \mu x_1^2)x_2 - u^2x_1 + u \end{bmatrix} + \begin{bmatrix} 0 \\ \hat{\eta}(x_1, \hat{W}) \end{bmatrix} - g \begin{bmatrix} \hat{x}_1 - x_1 \\ \hat{x}_2 - x_2 \end{bmatrix}$$

여기서, $\hat{x} = [\hat{x}_1 \ \hat{x}_2]^T$ 이다. 모의 실험을 위해 제어 입력 u 는 0으로 한다. 신경망 근사기 $\hat{\eta} = \Psi(x)^T \hat{W}$ 는 가우스 RBF를 사용하고 모의 실험을 위해 $\sigma = 0.6$, 11개의 고정된 중심값 $c_i (N = 11)$ 이 균일하게 $[-2.1 \ 2.1]$ 사이에서 분포한다. 불확실성 근사기 $\hat{\eta}$ 을 이용해서 $\hat{\eta}$ 을 알 수 있다.

고장이 발생시 식 (17)을 근사기를 이용해서 모델을 재구성한다.

$$\dot{\hat{z}} = \begin{bmatrix} z_2 \\ 2u\zeta(1 - \mu z_1^2)z_2 - u^2z_1 + u \end{bmatrix} + \begin{bmatrix} 0 \\ \eta(z_1, \hat{W}) \end{bmatrix} + \begin{bmatrix} 0 \\ \beta f(z, u) \end{bmatrix} \quad (18)$$

여기서 $z = [z_1 \ z_2]^T$ 이다.

모의 실험을 위해 고장함수 $f(y) = 1.4 + 0.4 \cos(y)$ 는 $T = 10s$ 에서 발생한다고 하자. 마찬가지로 식 (18)의 근사 모델은 다음과 같다.

$$\dot{\hat{z}} = \begin{bmatrix} z_2 \\ 2u\zeta(1 - \mu z_1^2)z_2 - u^2z_1 + u \end{bmatrix} + \begin{bmatrix} 0 \\ f(z, u; \hat{\theta}) \end{bmatrix} - \lambda \begin{bmatrix} \hat{z}_1 - z_1 \\ \hat{z}_2 - z_2 \end{bmatrix}$$

여기서 $\hat{z} = [\hat{z}_1 \ \hat{z}_2]^T$ 이다. 같은 학습 방법으로 근사기

는 $\hat{f}(z_1; \hat{\theta}) = \sum_{i=1}^N \hat{\theta}_i \exp(-|z_1 - c_i|^2 / \sigma^2)$ 을 이용한다.

갑작스런 고장이 발생했을 때 time profile은 다음과 같다.

$$\beta(t-T) = \begin{cases} 0, & T < 10 \\ 1, & T \geq 10 \end{cases}$$




그림 2. 고장 함수 f (실선)와 온라인 근사기 \hat{f} (점선)




그림 3. 불확실성 η (실선)와 온라인 근사기 $\hat{\eta}$ (점선)

그림 2에서는 $T = 10s$ 에서 발생하는 고장함수를 근사기가 추정하는 것을 보여준다. 갑작스런 고장에 대해 고장 검출이 잘 일어난다는 것을 보여준다. 그림 3은 고장이 일어나기 전까지 불확실성 성분을 근사화해서 고장 신호 검출에 사용한다.

3. 결 론

본 논문에서는 온라인 근사 모델과 신경망을 사용해 고장 진단을 구성하였다. 두 개의 신경망을 이용해서 고장 검출과 고장 진단을 하였다. 제안된 관측기는 고장이 발생할 때 경보신호를 발생하고 고장 성분을 근사화하기 시작한다. 불확실성 성분에 대해서 신경망 근사기를 통해 추정함으로써 경보신호에 대해 강인함을 보인다. 미지의 상한값을 정함으로서 고장 알람에 대해 강인성과 고장 진단하는데 정보를 얻을 수 있다. 향후 갑작스러운 고장이 발생했을 뿐만 아니라 서서히 발생하는 고장 성분에 대해서도 고장을 검출하고 고장을 진단을 하는 방법과 경보신호와 고장 검출간의 균형에 대해서 앞으로 좀더 연구할 과제이다.

[참 고 문 헌]

- [1] Jie Chen, Ron J. Patton, "Robust Model-Based Fault Diagnosis for Dynamic Systems", KLUWER ACADEMIC PUBLISHERS, 1999
- [2] J.J. Gertler, "Survey of model based failure detection and isolation in complex plants", IEEE Contr. Syst. Mag., vol.8, Issue. 6, pp. 3-11, Dec. 1988
- [3] R. Isermann, "Process fault detection based on modeling and estimation methods: a survey", Automatica, vol. 20, Issue. 4, pp. 387-404, 1984
- [4] M.M. Polycarpou and A.J. Helmicki, "Automated fault detection and accommodation: a learning systems approach", IEEE Trans. Syst., vol.25, Issue. 11, pp.1447-1458, Nov. 1995