

동적퍼지모델기반 고장진단 시스템 및 응용

배 상욱 이 종렬 박 귀태
 경일대 제어계측공학과 대구공업대 전기공학과 고려대 전기전자전파공학부

Dynamic Fuzzy Model based Fault Diagnosis System and it's Application

Sang-Wook Bae Jong-Ryul Lee Gwi-Tae Park
 Kyungil Univ. Taegu Tech. College Korea Univ.

Abstract - This paper presents a new FDI scheme based on dynamic fuzzy model(DFM) for the nonlinear system. The dynamic behavior of a nonlinear system is represented by a set of local linear models. The parameters of the DFM are identified in on-line and aggregated to generate a residual vector by the approximate reasoning. The neural network classifier learns the relationship between the residual vector and fault type and used both for the detection and isolation of process faults. We apply the proposed FDI scheme to the FDI system design for a two-tank system and show the usefulness of the proposed scheme.

$$\begin{aligned}
 \text{THEN } y(t+1) &= A_l(q^{-1})y(t) + B_l(q^{-1})u(t) + C_l \quad (1) \\
 A_l(q^{-1}) &= A_l^1 + A_l^2 q^{-1} + \dots + A_l^n q^{-n+1} \\
 A_l^k &= [a_{kj}^l]_{p \times p} \\
 B_l(q^{-1}) &= B_l^0 + B_l^1 q^{-1} + \dots + B_l^{n-1} q^{-n+1} \\
 B_l^k &= [b_{kj}^l]_{p \times g} \\
 l &= 1, 2, 3, \dots, m, \quad \bar{n} = p \times n + g \times n
 \end{aligned}$$

여기서 R^l 은 l -번째 규칙을 나타내며 (A_l, B_l, C_l)은 l -번째 지역 모델(local model)의 파라미터, m 은 근사추론 규칙의 개수, $u(t) \in R^g, y(t) \in R^p$ 는 각각 계통의 입력 및 출력 변수이다. $q^{-1}y(t) = y(t-1)$ 이며 $z(t)$ 는 입출력으로 구성되는 벡터이다.

1. 서 론

최근 모델기반 고장검출 및 식별(FDI : fault detection and isolation)분야와 관련된 연구에 많은 진전이 있었다.[1] 그러나 모델기반 FDI 설계의 선결 조건인 계통 모델을 구하기 어려운 경우가 많으며, 특히 복잡한 비선형계통의 경우 문제는 더욱 심각하다. 현재까지 비선형계통에 대한 고장검출은 주로 특정 동작점 부근에서의 선형화 모델을 이용하여 설계되어 왔으며, 최근에는 복잡한 계통의 모델링에 유용한 것으로 알려진 퍼지모델, 신경망 모델을 이용한 FDI 설계에 관한 연구가 있었으며,[2,3] 특히 [3]에서는 동적퍼지모델(DFM: dynamic fuzzy model)을 이용한 잔차(residual)발생법을 제안한 바 있다.

본 연구에서는 해석적인 모델을 구하기 어려운 비선형 계통의 전 동작 영역에서 고장을 검출하고 진단할 수 있는 새로운 FDI 설계법을 제안한다. 제안되는 기법에서 고장검출 및 진단을 위한 잔차는 [3]에서 기술된 온라인 DFM 식별 알고리즘에 의해 식별되는 DFM의 파라미터 변화와 DFM을 구성하는 퍼지 선형지역모델들의 소속함수값들로 구성된다. 고장 검출 및 식별기는 고장 데이터로부터 얻은 각 고장 발생시의 잔차와 고장 종류들을 학습시킨 신경망으로 구성된다.

본 논문의 구성은 다음과 같다. 2장에서는 동적 퍼지 모델, 3장에서는 DFM의 온라인 식별법, 4장에서는 잔차발생에 대해 기술하며, 5장에서는 제안된 설계법을 이용하여 비선형 계통인 2-탱크 시스템에 대한 FDI를 설계하고, 시뮬레이션 연구를 통하여 제안된 방법의 유용성을 보이고, 6장에는 결론을 기술하였다.

2. 동적퍼지모델

복잡한 비선형 MIMO(multi-input multi-output) 계통을 표현하기 위해 다음과 같은 근사추론 규칙과 지역선형 모델을 포함하는 동적 퍼지모델을 고려한다.

$$R^l: IF z_1 \text{ is } F_1^l \dots \text{ AND } z_n \text{ is } F_n^l$$

$$\begin{aligned}
 z(t) &= [y(t)^T, y(t-1)^T, \dots, y(t-n+1)^T, \\
 &\quad \dots, u(t-1)^T, \dots, u(t-n+1)^T] \quad (2)
 \end{aligned}$$

모델의 출력은 식(1)의 모든 지역모델들에 대해 하중평균(weighted average)을 취함으로써 다음과 같이 추론될 수 있다.

$$y(t+1) = A(q^{-1}, \mu(z))y(t) + B(q^{-1}, \mu(z))u(t) + C(\mu(z)) \quad (3)$$

$$\text{단, } A(q^{-1}, \mu(z)) = \sum_{l=1}^m \mu_l(z) A_l(q^{-1})$$

$$B(q^{-1}, \mu(z)) = \sum_{l=1}^m \mu_l(z) B_l(q^{-1})$$

$$\mu(z) = (\mu_1(z), \mu_2(z), \dots, \mu_m(z))$$

3. 동적퍼지모델의 온라인 식별

[3]에서 기술한 동적퍼지모델의 온라인 식별법은 S.G.Cao 등[4]에 의해 제안된 오프라인 식별 알고리즘을 고장진단 목적에 적합하도록 온라인화한 것으로서, 식(1)의 동적퍼지모델의 전건부 소속함수 식별 알고리즘과 후건부의 지역모델 식별 알고리즘의 두 단계로 구성된다.

3.1 소속함수의 식별

입출력 데이터들에 대해 FCM(fuzzy c-means) 알고리즘과 같은 클러스터링 알고리즘을 이용하여 소속함수를 정의하는 것이 일반적이다. 본 연구에서는 지역 선형모델의 오차에 대한 보상항을 포함하도록 정의된 평가함수를 이용한 동적 퍼지 클러스터링(dynamic fuzzy clustering : DFC) 알고리즘[5]을 이용하여

전건부의 소속함수들을 식별하며, 식별 알고리즘을 간단히 기술하면 다음과 같다.

정의한 평가함수는 다음과 같다.

$$J(\mu, \bar{z}, a) = w_1 \left[\sum_{t=1}^N \sum_{i=1}^m \mu_i(t)^{\omega} \|z(t) - \bar{z}_i\|^2 \right] + w_2 \left[\sum_{t=1}^N \sum_{i=1}^m \mu_i(t)^{\omega} e_i(t)^2 \right] \quad (4)$$

$$e_i(t) = y(t)^T - \varphi(t-1)^T a^i$$

$$\varphi(t-1)^T = ((1, 1, \dots), y(t-1)^T, \dots$$

$$y(t-n)^T, u(t-1)^T, \dots, u(t-n)^T)$$

$$a^i = [a_1^i \ a_2^i \ \dots \ a_n^i]$$

$$a_j^i = [a_{j1}^i \ \dots \ a_{jn}^i]$$

단 $\bar{n} = p \times p \times n + g \times n$, m : 규칙의 수

\bar{z} : 중심값(center value), ω : (exponential weight),

w_1, w_2 : 하중값(weighting value)

$\|z(t) - \bar{z}_i\|$: 중심값으로부터 $z(t)$ 까지의 거리

평가함수 (4)의 첫 번째 항은 z 벡터와 각 클러스터의 중심값간의 거리를 최소화 하는 것이므로 입력공간의 퍼지분할로 생각할 수 있으며, 두 번째 항은 퍼지 계통과 지역 선형모델간의 출력오차가 최소가 되도록 입력공간을 최적 분할하도록 하기 위한 것이다. 평가함수 (4)를 최소화하는 필요조건은 다음과 같으며, DFM의 소속함수들 이를 만족하도록 구한다.

$$\bar{z}_l = \frac{\sum_{t=1}^N \mu_l(t)^{\omega} z(t)}{\sum_{t=1}^N \mu_l(t)^{\omega}}, \quad l=1, 2, \dots, m \quad (5)$$

$$a_l = [\Phi^T D_l \Phi]^{-1} \Phi^T D_l Y, \quad l=1, 2, \dots, m \quad (6)$$

$$D_l = \text{diag}[\mu_l(t)]_{N \times N} \quad (7)$$

$$\Phi = [\varphi(1) \ \varphi(2) \ \dots \ \varphi(N)]^T \quad (8)$$

$$Y = [y(1) \ y(2) \ \dots \ y(N)]^T \quad (9)$$

$$\mu_l(t)$$

$$= \left\{ \frac{\sum_{i=1}^m [w_1 \|z(t) - \bar{z}_i\|^2 + w_2 e_i(t)^2] \frac{1}{w-1}}{[w_1 \|z(t) - \bar{z}_j\|^2 + w_2 e_j(t)^2] \frac{1}{w-1}} \right\}^{-1} \quad (10)$$

$U = [\mu_{ij}]_{i=1,2,\dots,m, j=1,2,\dots,N}$: 분할행렬(partition matrix)

3.2 지역 선형모델의 온라인 식별

지역선형모델의 식별은 식(3)의 퍼지모델 출력과 계통 출력의 예측오차를 최소화 할 수 있는 선형모델의 파라미터를 추정하는 문제이며, l -번째 지역선형모델의 출력 및 파라미터의 추정값을 각각 $\hat{y}_l(t)$, $\hat{\theta}^l$ 라고 하면 계통출력은 다음의 식으로 표현될 수 있다.

$$\hat{y}_l(t) = v^T(t, \mu) \hat{\theta}^l \quad (12)$$

단, $v^T(t, \mu) = \mu_l(z(t-1)) \varphi(t-1)$

$$= [v_0(t, \mu) \ v_1(t, \mu) \ \dots \ v_M(t, \mu)]$$

$\hat{\theta}^l = (\theta_1^l, \theta_2^l, \dots, \theta_M^l)^T$ 는 l -번째 규칙의 파라미터

추정값이다.

$$\mu_l(z) = \left\{ \frac{\sum_{i=1}^m [w_1 \|z(t) - \bar{z}_i\|^2] \frac{1}{w-1}}{[w_1 \|z(t) - \bar{z}_j\|^2] \frac{1}{w-1}} \right\}^{-1} \quad (13)$$

오프라인 파라미터 추정은 다음과 같은 평가함수를 최소화하는 파라미터를 결정하는 것으로 정의할 수 있다. (N 은 데이터의 개수)

$$J(\hat{\theta}) = \|Y - \Phi(\hat{\mu}) \hat{\theta}\|^2 \quad (14)$$

$$\Phi(\mu) = \begin{bmatrix} v_0(1, \mu) & v_1(1, \mu) \dots & v_M(1, \mu) \\ v_0(2, \mu) & v_1(2, \mu) \dots & v_M(2, \mu) \\ \vdots & \vdots & \vdots \\ v_0(N, \mu) & v_1(N, \mu) \dots & v_M(N, \mu) \end{bmatrix} \quad (15)$$

식 (14)를 최소화하는 파라미터는 다음과 같이 계산된다.

$$\hat{\theta}_i = [\Phi(\mu)^T \Phi(\mu)]^{-1} \Phi(\mu)^T Y$$

FDI에의 응용을 위해서는 지역 선형모델을 온라인으로 식별해야 하며, 이를 위해 다음의 RLSA(recursive least square algorithm)을 이용할 수 있다

$$\hat{\theta}(t) = \hat{\theta}(t-1) + L(t)[y(t) - v(t, \mu)^T \hat{\theta}(t-1)] \quad (16)$$

$$L(t) = \frac{P(t-1) v(t, \mu)}{\lambda(t) + v(t, \mu)^T P(t-1) v(t, \mu)}$$

$$P(t) = [P(t-1) - Q(t)] \quad (17)$$

$$\text{단 } Q(t) = \frac{P(t-1) v(t, \mu) v(t, \mu)^T P(t-1)}{\lambda(t) + v(t, \mu)^T P(t-1) v(t, \mu)} \quad (18)$$

여기서 $v^T(t, \mu) = [v_0(t, \mu) \ v_1(t, \mu) \ \dots \ v_M(t, \mu)]$ 이며 $\lambda(t)$ 는 다음의 식으로 정의되는 망각인자(forgetting factor)이다.

$$\lambda(t) = \lambda_0 \left\| 1 - \frac{P(t)}{K_0} \right\| \quad (19)$$

여기서 λ_0 는 망각인자의 최대 값이며 K_0 는 이득행렬의 제한값이다. 이는 프로세스의 고장시 파라미터 변화의 민감성을 조절하기 위하여 도입하였다.

4. 고장진단시스템

고장진단 시스템은 잔차발생기와 고장 검출 및 진단기로 구성된다.

4.1 잔차발생기

제안되는 고장진단시스템에서의 잔차는 온라인으로 식별되는 DFM의 고장시 파라미터 변화분과 각 규칙의 소속함수값으로부터 구성된다.

온라인으로 식별되는 동적퍼지모델의 m 개 지역모델 파라미터 $\hat{\theta}^l$ 을 이용하여 전체적인(global) 파라미터 ${}^o\hat{\theta}$ 을 다음과 같이 근사 추론할 수 있다.

$${}^o\hat{\theta} = \frac{\sum_{l=1}^m \mu_l(z(t)) \hat{\theta}^l}{\sum_{l=1}^m \mu_l(z(t))} = \sum_{l=1}^m \mu_l(z(t)) \hat{\theta}^l \quad (20)$$

여기에서 각 지역선형모델은 상수항을 포함하여 모두 M 개의 후건부 선형파라미터를 갖는다.

같은 방법으로 공칭 DFM(고장이 없을 때 정상상태에 도달했을 때의 DFM)에 대한 글로벌 파라미터 ${}^n\hat{\theta}$ 을 추론할 수 있다. 계통의 운전 중 고장이 발생하면 ${}^o\hat{\theta}$ 과 ${}^n\hat{\theta}$ 간에는 차이가 발생하게 되는데 이 차이값

이 고장검출 및 식별을 위한 유용한 정보가 된다. 이런 관점에서 FDI를 위한 첫 번째 잔차는 다음과 같이 정의된다.

$$r_1 = \hat{y} - \hat{y}^0 \quad (21)$$

선형계통에 대한 FDI 설계문제인 경우 식(21)의 잔차로도 충분히 고장을 검출하고 진단할 수 있겠지만, 비선형 계통인 경우 고장에 의해 동작점이 변화할 수 있다. 이러한 동작점의 변화는 DFM 후건부 파라미터값에 상당한 변화를 나타낼 수 있다. 이러한 변화는 같은 고장에 대한 파라미터 변화 벡터의 일관성을 유지할 수 없도록 할 수 있다. 따라서 본 연구에서는 동작점을 나타냄과 동시에 각 지역선형모델의 적합도를 나타내는 DFM의 소속함수값을 두 번째 잔차로 정의하여 사용함으로써 동작점 변화에 대해서도 고장요소의 식별이 용이하도록 한다. 본 연구에서 제안하는 FDI의 잔차벡터는 다음과 같이 구성된다.

$$r = [r_1 \mu_1(z) \mu_2(z) \dots \mu_m(z)]$$

4.2 고장 검출 및 식별기

고장 검출 및 식별은 신경망 분류기에 의해서 수행된다. 신경망 분류기에 대한 학습데이터는 계통의 고장시 입력력 데이터로부터 얻는다. 즉 각 고장발생시 입력력 데이터로부터 잔차벡터 r 을 구하여 이를 $[1 \ 0 \ \dots \ 0]$, $[0 \ 1 \ \dots \ 0]$ 형태로 표시되는 고장 종류와 함께 신경망에 학습시킨다. 고장 검출 및 고장요소 식별은 신경망 출력 요소 d_0, d_1, \dots, d_p (p 는 고장 종류의 개수, d_0 는 정상)들에 대한 문턱치 검사에 의해 다음과 같이 수행된다.

IF $d_i > \text{Threshold}$ Then Fault. ($i=1,2,\dots,p$)

일단 고장이 검출되면 d_i 의 값이 가장 큰 것을 고장요소로 식별한다.

본 논문에서 제안된 고장검출 및 진단시스템의 구조를 그림1에 블록선도로 나타내었다.




그림 1. 고장진단시스템의 구조

5. 시뮬레이션 연구

본 장에서는 제안된 FDI 설계법의 유용성을 보이기 위하여 2탱크 계통에 대한 퍼지동적모델을 식별하고 고장진단을 위한 잔차발생기를 설계하고 그 결과를 보인다. 시뮬레이션에 사용한 2탱크계의 수학적 모델은 다음과 같다.

$$A_1 \frac{dh_1}{dt} = Q_1 - a_1 \sqrt{2g h_1}$$

$$A_2 \frac{dh_2}{dt} = a_1 \sqrt{2g h_1} - a_2 \sqrt{2g h_2}$$

계통출력은 2번째 탱크의 출력유량 $Q_3 = a_2 \sqrt{2g h_2}$ 이며 계통의 파라미터는 $A_1=1.2$, $A_2=1$, $a_1=0.2$, $a_2=0.23$ 이며 가정된 고장은 고장1): 밸브1의 부분

막힘, 고장2): 밸브2의 부분 막힘, 고장3): 밸브3의 부분 막힘 3가지이다. DFM의 소속함수 식별은 정상적인 계통 운전 상태에서 0.1~0.9 사이의 랜덤한 입력에 대한 입력력데이터를 구하여 수행하였으며, 그 결과 식별한 소속함수의 중심값들은 다음과 같다.

$$\bar{z}_1 = [0.8071 \ 0.7961 \ 0.8243 \ 0.8384]$$

$$\bar{z}_2 = [0.5391 \ 0.5279 \ 0.5410 \ 0.5694]$$

$$\bar{z}_3 = [0.3528 \ 0.3532 \ 0.3525 \ 0.3399]$$

$$\bar{z}_4 = [0.1703 \ 0.1854 \ 0.1669 \ 0.1570]$$

식별알고리즘의 파라미터는 $m=4$, $\omega=1.1$, $\omega_1=1$, $\omega_2=0.1$, $\lambda_0=0.98$, $K_0=0.1$ 로 정의하였다.

고장 검출 및 식별기로 사용되는 신경망의 학습을 위한 고장 데이터는 0.3~0.9사이의 임의의 입력레벨에 대하여 5%에서 50%까지 임의의 고장 크기를 발생하여 133개를 얻었다. 이들로부터 고장시 잔차를 구하고, 여기에 정상상태의 데이터를 14개 포함시켜 2개의 은닉층 (각 층의 뉴런의 개수는 15개)을 갖는 신경망을 학습하였다. 신경망 학습법으로는 일반 역전파 알고리즘을 사용하였다.

구축된 고장진단시스템을 이용하여 학습한 133개의 고장과 비학습 고장 데이터 140개, 총 273개의 고장 데이터에 대해 고장을 검출하고 고장요소를 식별하였다. 고장검출을 위한 문턱치를 0.7로 하였다. 이때 학습된 고장의 경우 1개의 고장만을 검출하지 못하였다. 그러나 비학습 고장데이터에 대해서는 7개의 고장을 검출하지 못하였으며, 12개의 고장에 대해서는 고장을 검출하였으나 고장요소를 잘못 식별하였다. 1번 고장을 2번 고장, 3번 고장으로 판별한 경우가 각각 1회였으며, 2번 고장을 3번 고장으로, 3번 고장을 2번 고장으로 판별한 경우가 각각 3회와 5회였다. 주로 2번 고장과 3번 고장에 대한 판별을 잘못 식별하였는데, 이 응용에서는 계통의 입력력데이터만 가지고 계통의 고장을 판별하는데, 이는 2번 고장과 3번 고장의 경우 출력이 거의 같은 양상을 보이기 때문이다.

6. 결론

본 연구에서는 온라인 동적 퍼지모델 식별기법과 신경망을 이용하여 비선형 계통의 전 동작영역에서의 고장을 검출하고 진단할 수 있는 새로운 FDI 설계기법을 제안하였으며, 이를 2탱크계의 FDI 설계에 적용하여 입력력 데이터만으로 계통의 3가지 고장을 검출하고 고장요소를 식별할 수 있음을 보였다. 향후에는 측정잡음이 존재할 경우에 대한 연구와 고장 검출 및 식별기로 사용된 신경망은 학습데이터를 많이 요구하므로 고장 발생 데이터가 적은 경우에 대한 고장 검출 및 식별기에 대한 연구가 필요할 것으로 사료된다.

[참고 문헌]

- [1] Iserman, R., P. Balle. "Trends in the Application of Model-based Fault Detection and Diagnosis of Technical Process", 13th IFAC World Cong., San Francisco, pp.709-719, 1996.
- [2] P.Balle, D.Juricic, A.Rakar, S.Ernst, "Identification of Nonlinear Processes and Model Based Fault Isolation Using Local Linear Models", AACC, 1997.
- [3] 이종렬, 배상욱, 이기상, 박귀태, "비선형계통 고장진단을 위한 온-라인 퍼지동적모델식별", 98 한국퍼지 및 지능시스템 학회 추계학술대회, 제8권 2호, pp.204-210, 1998.
- [4] S.G.Cao, N.W.Rees and G.Feng, "Analysis and Design for a Class of Complex Control Systems, Part I: Fuzzy Modelling and Identification", Automatica, Vol.33, No. 6, pp. 1017-1028, 1997.