

동적퍼지모델기반 고장진단 시스템의 설계 Design of Fult Diagnosis System based on Dynamic Fuzzy Model

이종열 · 배상욱* · 이기상** · 박귀태***

Jong-Ryeol Lee, Sang-Wook Bae,* Kee-Sang Lee** and Gwi-Tae Park***

대구공업대학 전기과

* 경일대학교 제어계측공학과

** 단국대학교 전기공학과

*** 고려대학교 전기전자전파공학부

요 약

본 논문에서는 미지의 비선형 계통에 대한 동적 퍼지모델 기반 고장 검출 및 진단(FDI) 계통 설계 기법을 제시한다. 비선형 계통에 대한 일반적인 모델기반 FDI 계통에서는 선형화된 모델을 이용하고 있다. 이러한 방법은 계통에 대한 정확한 수학적 모델을 요구하게 되어 복잡한 비선형 계통에의 적용 시 많은 어려움이 있다. 제안되는 FDI 계통에서는 미지의 비선형 계통을 다수의 선형 모델을 갖는 동적 퍼지모델 형태로 식별한다. 잔차벡터는 온라인 알고리즘에 의해 추정되는 파라미터의 변동치와 비선형 계통의 동작 영역을 나타내는 퍼지 규칙들의 소속값들로 구성된다. 계통의 고장 검출 및 진단은 잔차벡터와 고장종류간의 관계를 학습한 신경망 분류기에 의해 수행된다. 제안된 FDI 계통 설계법을 이용하여 2 탱크 계통에 대한 FDI 계통을 설계하고, 시뮬레이션 연구를 통하여 그 유용성을 보였다.

ABSTRACT

This paper presents a new FDI scheme based on dynamic fuzzy model(DFM) for the unknown nonlinear system, which can detect and isolate process faults continuously over all ranges of operating condition. The dynamic behavior of a nonlinear process is represented by a set of local linear models. The parameters of the DFM are identified by an on-line methods. The residual vector of the FDI system is consisted of the parameter deviations from nominal model and the set of grade of membership values indicating the operating condition of the nonlinear process. The detection and isolation of faults are performed via a neural network classifier that are learned the relationship between the residual vector and fault type. We apply the proposed FDI scheme to the FDI system design for a two-tank system and show the usefulness of the proposed scheme.

1. 서 론

최근의 산업플랜트는 대량생산 및 경비절감을 위하여 대형화, 자동화로 급속히 발전되었으며, 이에 따라 더욱 복잡해진 계통을 효율적으로 운용하기 위해서는 고도의 제어성과 신뢰성을 함께 가진 제어계 구성이 필요하게 되었다. 특히 계통 운전 중 발생하는 프로세스의 고장은 계통의 제어 성능 저하뿐만 아니라 경우에 따라 큰 경제적 손실을 입힐 수 있으므로 이들 고장을 검출하고 식별할 수 있는 고장 검출 및 진단 계통은 제어계의 제어성능 유지와 신뢰성 확보를 위해 필수적인 것으로 인식되고 있다. 이러한 이유로 지난 수십년 동안 프로세스의 고장 검출 및 식별(Fault Detection and Isolation : FDI) 기법에 대한 많은 연구가 있어 왔다[1-3].

일반적으로 FDI 계통은 프로세스에 대한 모델을 기반으로 설계되며, 이러한 모델기반 FDI 계통 설계

기법에서는 프로세스의 입출력 특성을 표현하는 수학적 모델과 실제 프로세스간의 동작의 차이를 정량적으로 나타낸 잔차(residual)를 발생하고, 이 잔차를 통해 고장을 검출하고, 고장에 대한 정보, 즉 고장의 크기 및 위치 등에 대한 정보를 추출한다. 그러나 모델기반 FDI 설계의 선결 조건인 계통 모델을 구하기 어려운 경우가 많으며, 특히 복잡한 비선형 계통의 경우 문제는 더욱 심각하다. 최근까지 모델기반 FDI 설계기법에 대한 연구는 거의 선형계통에 대한 것으로서, 현재까지 비선형 계통에 대한 FDI 계통은 모델링 오차를 고려한 비선형 관측자를 이용한 방법 또는 특정 동작점 부근에서의 선형화 모델을 이용하여 설계된 것들이 대부분이며[4-7], 이러한 기법들의 경우 불확실성이 일부 존재하더라도 비선형 계통에 대한 해석적인 모델을 알고 있어야 한다는 기본적인 제약성을 갖는다는 문제점이 있다. 특히 비선형 계통의 전 동작영역에서의 프로세스 고장을 검출하고 식별할

수 있는 FDI 설계기법에 대한 연구 결과는 현재까지 매우 미흡한 실정이다. 최근에는 복잡한 비선형 계통의 모델링에 유용한 것으로 알려진 퍼지 모델, 신경망 모델을 이용한 FDI 계통 설계에 관한 연구가 있었으며[8,9] 특히 [10,11]에서는 해석적인 모델을 구하기 어려운 비선형 계통에 대한 FDI 계통 설계에 활용될 수 있는 동적퍼지모델(dynamic fuzzy model: DFM)을 이용한 잔차발생법을 제안하고 그 유용성을 보인 바 있다.

본 논문에서는 해석적인 모델을 구하기 어려운 비선형 계통에 대해 전 동작 영역에서 고장을 검출하고 진단할 수 있는 새로운 FDI 계통 설계기법을 제안한다. 제안되는 기법에서는 온라인으로 식별되는 동적퍼지모델로부터 잔차 벡터(residual vector)를 발생하고, 고장 검출 및 진단을 위한 잔차 벡터는 온라인 식별 알고리즘에 의해 식별되는 DFM의 파라미터 변동 벡터와 비선형 계통의 동작환경을 나타내는 퍼지분할 소속함수 값들로 구성된다. 고장 검출 및 식별은 과거 고장데이터로부터 습득한 잔차 벡터와 고장 종류들간의 관계를 학습한 신경망 분류기에 의해 수행된다.

본 논문의 구성은 다음과 같다. 2장에서는 비선형 계통의 동특성을 나타내는 동적 퍼지 모델을 정의하며, 3장에서는 동적 퍼지 모델의 온라인 식별기법을 제안하며, 4장에서는 동적 퍼지 모델 기반 FDI 계통을 제안하며, 5장에서는 제안된 기법을 이용하여 비선형 계통인 2탱크 계통에 대한 FDI 계통을 설계하고, 시뮬레이션 연구를 통하여 제안된 방법의 유용성을 보이고, 6장에는 본 논문에서의 결론을 기술하였다.

2. 동적퍼지모델

비선형 다변수(multi-input multi-output : MIMO) 계통의 동특성을 표현하기 위해 근사추론 규칙과 지역선형 모델들로 표현되는 다음과 같은 동적퍼지모델(dynamic fuzzy model: DFM)을 고려한다[12].

$$\begin{aligned}
 R^l : & \text{ IF } z_1 \text{ is } F_1^l \text{ AND } \dots \text{ AND } z_n \text{ is } F_n^l \\
 \text{ THEN } & = A_l(q^{-1})y(t) + B_l(q^{-1})u(t) + C_l \quad (1) \\
 A_l(q^{-1}) & = A_{1l} + A_{2l}q^{-1} + \dots + A_{nl}q^{-n+1} \\
 B_l(q^{-1}) & = B_{0l} + B_{1l}q^{-1} + \dots + B_{m,l}q^{-m+1}, \\
 A_k^l & = [a_{kj}^l]_{p \times p} \quad B_k^l = [b_{kj}^l]_{p \times g} \\
 l & = 1, 2, 3, \dots, m, \quad n = p \times n + g \times n
 \end{aligned}$$

여기서 R^l 은 l -번째 근사 추론규칙을 나타내며, F_j^l 은 해당규칙의 퍼지집합, (A_l, B_l, C_l) 은 l -번째 지역선형모델(local linear 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 식(2)와 같이 입출력으로 구성되는 벡터이다.

$$z(t) = [y(t)^T, y(t-1)^T, \dots, y(t-n+1)^T, \dots, u(t-1)^T, \dots, u(t-n+1)^T] \quad (2)$$

DFM의 최종출력은 식(1)의 모든 지역선형모델들에 대해 하중평균(weighted average)을 취함으로써 추론되며, DFM 식(1)은 다음의 해석적인 전역모델(global model)로 변환될 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

S.G.Cao등은 DFM 식(1)의 소속함수 F_l 와 지역선형모델의 파라미터 (A_l, B_l, C_l) 들을 식별하는 오프라인 식별 알고리즘을 제안하였다[12]. 본 논문에서 제안하는 FDI 기법은 비선형 프로세스에 대한 DFM의 파라미터 추정값에 근거하는 것으로서, 프로세스 고장 발생시 고장에 의한 파라미터 변동을 온라인으로 알 수 있어야 한다. 따라서 본 논문에서는 S.G.Cao 등[12]에 의해 제안된 오프라인 식별 알고리즘을 고장진단 목적에 적합하도록 온라인화 한 동적 퍼지모델의 온라인 식별법을 제안한다. 일반적으로 식(1)의 동적 퍼지모델의 식별법은 전건부 소속함수 식별 알고리즘과 후건부의 지역모델 식별 알고리즘의 두 단계로 구성된다. 본 논문에서의 식별법에서 전건부 소속함수는 [12]에서 제안된 방법에 의해 오프라인으로 식별되고, 후건부인 지역모델만 온라인으로 식별한다.

3.1 소속함수의 식별

일반적으로 소속함수의 식별은 FCM(fuzzy c-means)과 같은 클러스터링 알고리즘을 이용하여 수행되나, 일반적인 FCM은 정적 데이터에 적합한 것으로서, 시간적 특성을 갖는 동적계통의 퍼지 모델 식별을 위한 입출력 데이터 퍼지 분할에는 부적합하며, 따라서 Cao[12] 등은 퍼지 모델의 추정 오차에 대한 보상항을 포함하도록 정의된 평가함수를 사용한 동적 퍼지 클러스터링(dynamic fuzzy clustering : DFC) 알고리즘을 이용하여 전건부 소속함수들을 식별하는 알고리즘

을 제안하였으며, 본 논문에서도 [12]에서의 알고리즘을 이용하여 전전부 소속함수들을 식별하며, 식별 알고리즘을 간단히 기술하면 다음과 같다.

정 의한 평가함수는 식(4)와 같다.

$$J(\mu, \bar{z}, \alpha) = w_1 \left[\sum_{t=1}^N \sum_{l=1}^m \mu_l(t)^\omega \|z(t) - \bar{z}\|^2 \right] + w_2 \left[\sum_{t=1}^N \sum_{l=1}^m \mu_l(t)^\omega e_l(t)^2 \right] \quad (4)$$

$$e_l(t) = y(t)^T - \varphi(t-1)^T \alpha^l \quad (5)$$

$$\varphi(t-1)^T = ((1, 1, \dots), y(t-1)^T \dots y(t-n)^T, u(t-1)^T, \dots, u(t-n)^T) \quad (6)$$

$$\alpha^l = [\alpha_1^l \ \alpha_2^l \ \dots \ \alpha_p^l], \quad \alpha_j^l = [\alpha_{j1}^l \ \dots \ \alpha_{jn}^l] \quad (7)$$

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

\bar{z} : 중심값(center value),

ω : (exponential weight),

w_1, w_2 : 하중값(weighting value)

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

$$\sum_{l=1}^m \mu_l(t) = 1$$

평가함수 식(4)의 첫 번째 항은 벡터 $z(t)$ 와 각 클러스터의 중심값 $\bar{z}_l(t)$ 간의 거리를 최소로 하기 위한 것이므로 입력공간의 퍼지분할에 해당되며, 두 번째 항은 퍼지 계통의 출력과 지역 선형모델 출력간의 추정오차가 최소가 되도록 입력공간을 최적 분할하기 위한 것이다.

평가함수 식(4)를 최소화하기 위한 필요조건은 다음과 같다.

$$\bar{z}_l = \frac{\sum_{t=1}^N \mu_l(t)^\omega z(t)}{\sum_{t=1}^N \mu_l(t)^\omega}, \quad l=1, 2, \dots, m \quad (8)$$

$$\alpha_l = [\Phi^T D_l \Phi]^{-1} \Phi^T D_l Y, \quad l=1, 2, \dots, m \quad (9)$$

$$D_l = \text{diag}[\mu_l(t)]_{N \times N}, \quad (10)$$

$$\Phi = [\varphi(1) \ \varphi(2) \ \dots \ \varphi(N)]^T \quad (11)$$

$$Y = [y(1) \ y(2) \ \dots \ y(N)]^T \quad (12)$$

$$\mu_l(t) = \left\{ \frac{\sum_{j=1}^m \left[w_1 \|z(t) - \bar{z}_j\|^2 + w_2 e_j(t)^2 \right]^{w-1}}{\sum_{j=1}^m \left[w_1 \|z(t) - \bar{z}_j\|^2 + w_2 e_j(t)^2 \right]^{w-1}} \right\}^{-1} \quad (13)$$

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

위 조건식을 만족하는 DFM의 분할행렬 U 는 해석적인 방법으로는 해를 얻을 수 없기 때문에 반복적인 방법으로 구해야 하며 그 과정은 다음과 같다.

Step 1: 클러스터의 수($2 \leq m \leq N$)와 $\omega(1 < \omega < \infty)$, w_1, w_2 의 값을 정하고 초기의 분할 행렬 $U^{(0)}$ 및 최종한계값 $\varepsilon > 0$ 를 설정한다. 단, (반복회수 $k=0$)

Step 2: $U^{(k)}$ 와 식(8)을 이용하여 중심값 $\bar{z}_l^k (l=1, 2, \dots, m, k=0, 1, \dots)$ 를 구한다.

Step 3: \bar{z}_l^k 와 식(13)을 이용하여 새로운 분할행렬 $U^{(k+1)}$ 를 구한다.

Step 4: $\|U^{(k+1)} - U^{(k)}\| \leq \varepsilon$ 이면 stop, 아니면 Step 2로 되돌림.

하나의 주어진 데이터가 각 규칙에 소속되는 정도의 합은 반드시 1이 되어야 하므로 초기의 분할행렬 $U^{(0)}$ 를 설정할 때 다음의 조건을 만족해야 한다.

$$\sum_{j=1}^m \mu_{ij} = 1, \quad j=1, 2, \dots, N \quad (14)$$

식(13)은 퍼지모델의 전전부 소속함수를 구할 때 사용하는 소속함수식이며, 실제 퍼지모델로부터 출력을 추정하기 위해서는 식(13)에서 지역선형모델 오차에 대한 보상은 제외한 다음의 식(15)에 의해 각 규칙의 소속값을 계산한다.

$$\mu_l(z) = \left\{ \frac{\sum_{j=1}^m \left\{ \frac{\|z(t) - \bar{z}_j\|^2}{2} \right\}^{w-1}}{\sum_{j=1}^m \left\{ \frac{\|z(t) - \bar{z}_j\|^2}{2} \right\}^{w-1}} \right\}^{-1} \quad (15)$$

3.2 지역 선형모델의 온라인 식별

지역선형모델의 식별은 식(3)의 퍼지모델 출력과 계통 출력의 예측오차를 최소화 할 수 있는 지역선형모델의 파라미터 (A, B, C)를 추정하는 문제이며, l -번째 지역선형모델의 출력 및 파라미터의 추정값을 각각 $y_l(t), \hat{\theta}^l$ 라고 하면 퍼지모델의 출력 $\hat{y}(t)$ 는 다음의 식으로 표현될 수 있다.

$$\hat{y}(t) = \sum_{l=1}^m \hat{y}_l(t) = \sum_{l=1}^m v^T(t, \mu_l) \hat{\theta}^l \quad (16)$$

단, $v^T(t, \mu_l) = \mu_l(z(t-1))\varphi(t-1) = [v_{0l}(t, \mu_l) \ v_{1l}(t, \mu_l) \ \dots \ v_{nl}(t, \mu_l)]$, $\hat{\theta}^l = (\theta_0^l, \theta_1^l, \dots, \theta_M^l)^T$ 는 l -번째 규칙의 파라미터 추정값이다.

따라서 파라미터 (A, B, C)의 오프라인 추정은 다

음과 같은 평가함수를 최소화하는 파라미터를 결정하는 것으로 정의할 수 있다[12].

$$J(\hat{\theta}^l) = \| Y^l - \Phi(\mu_l)\theta^l \|^2 \quad (17)$$

여기서 $Y^l = \mu(z(t-1))Y$ (18)

$$\Phi(\mu_l) = \begin{bmatrix} v_0(1, \mu_l) & v_1(1, \mu_l) & \dots & v_M(1, \mu_l) \\ v_0(2, \mu_l) & v_1(2, \mu_l) & \dots & v_M(2, \mu_l) \\ \vdots & \vdots & & \vdots \\ v_0(N, \mu_l) & v_1(N, \mu_l) & \dots & v_M(N, \mu_l) \end{bmatrix} \quad (19)$$

여기서 N은 데이터의 개수이다.

식(17)을 최소화하는 파라미터는 식(16)이 $\hat{\theta}^l$ 에 대한 선형식으로 표현되므로 최소자승법(least-square method)에 의해서 구해질 수 있다.

$$\hat{\theta}^l = [\Phi(\mu_l)^T \Phi(\mu_l)]^{-1} \Phi(\mu_l)^T Y^l \quad (20)$$

프로세스 고장 발생 여부를 파라미터 변동값으로부터 알기 위해서는 퍼지 모델 후건부 파라미터들을 온라인으로 식별해야 한다. 본 논문에서는 이를 위해 다음의 수정된 RLSA(recursive least square algorithm)을 이용한다.

$$\hat{\theta}^l(t) = \hat{\theta}^l(t-1) + L(t)[y(t) - v(t, \mu)^T \hat{\theta}^l(t-1)] \quad (21)$$

$$L(t) = \frac{P(t-1)v(t, \mu_l)}{\lambda(t) + v(t, \mu_l)^T P(t-1)v(t, \mu_l)} \quad (22)$$

$$P(t) = \left[P(t-1) - \frac{P(t-1)v(t, \mu_l) v(t, \mu_l)^T P(t-1)}{\lambda(t) + v(t, \mu_l)^T P(t-1)v(t, \mu_l)} \right] \quad (23)$$

식(23)에서 $\lambda(t)$ 는 식(24)로 정의되는 망각인자(forgetting factor)이다.

$$\lambda(t) = \lambda_0 \left\| 1 - \frac{P(t)}{K_0} \right\| \quad (24)$$

여기서 λ_0 는 망각인자의 최대값이며 K_0 는 이득행렬 $P(t)$ 의 제한 값이다. 이와 같은 망각인자조정기법(forgetting factor tuning technique)은 프로세스 고장 발생시 파라미터 변화의 민감도(sensitivity)를 조절함으로써 계통 측정잡음에 대한 강인성을 제고하고, 고장검출시간을 조정하기 위하여 도입하였다.

4. 고장진단시스템

고장 검출 및 진단(FDI) 계통은 일반적으로 1) 잔

차발생기(residual generator), 2) 고장검출기(fault detector), 3) 고장식별기(fault isolator)로 구성되며, 장에서는 DFM을 기반으로 하는 새로운 FDI 계통을 제안한다. 제안되는 FDI에서는 3.2절에서 기술한 온라인 식별알고리즘에 의해 식별된 각 지역 선형모델의 파라미터들로부터 근사추론된 전역(global) 파라미터 벡터와 소속함수들로부터 잔차벡터를 발생하고, 잔차벡터와 고장종류간의관계를 학습한 신경망을 이용하여 고장을 검출하고, 식별하게 된다. 제안된 FDI 계통의 각 구성요소들에 대해 기술하면 다음과 같다.

4.1 잔차발생기 구성

계통 운전시 고장이 발생하게 되면 계통의 각 파라미터들은 정상 운전시의 파라미터와는 다른 값을 갖게되며, 따라서 고장 발생시 온라인으로 추정된 파라미터와 정상운전시의 파라미터 사이의 차이를 고장진단을 위한 잔차로 활용할 수 있게 된다.

온라인으로 식별되는 동적 퍼지모델의 m 개 지역 선형모델 파라미터 $\hat{\theta}^l$ 을 이용하여 전역 파라미터 ${}^o\hat{\theta}$ 을 다음과 같이 근사 추론할 수 있다.

$${}^o\hat{\theta} = \frac{\sum_{l=1}^m \mu_l(z(t)) \hat{\theta}^l}{\sum_{l=1}^m \mu_l(z(t))} = \sum_{l=1}^m \mu_l(z(t)) \hat{\theta}^l \quad (25)$$

여기서 각 지역선형모델은 상수항을 포함하여 모두 $M+1$ 개의 후건부 선형파라미터를 갖는다. 공칭 DFM(고장이 발생치 않았을 때의 DFM)에 대한 글로벌 파라미터 ${}^o\hat{\theta}$ 도 식(25)와 같은 방법으로 추론할 수 있다. 계통의 운전 중 고장이 발생하면 ${}^o\hat{\theta}$ 과 ${}^o\hat{\theta}$ 간에는 차이가 발생하게 되는데 이 차이값이 고장검출 및 식별을 위한 유용한 정보가 된다. 이런 관점에서 FDI를 위한 첫 번째 잔차벡터는 식(26)으로 정의한다.

$$r_1 = {}^n\hat{\theta} - {}^o\hat{\theta} \quad (26)$$

선형계통에 대한 FDI 설계문제인 경우 식(26)의 잔차 만으로도 고장을 충분히 검출하고 진단할 수 있지만, 비선형 계통인 경우 같은 입력 레벨에 대해서 고장의 크기에 따라 동작점이 변화할 수 있다. 이러한 동작점의 변화는 식(25)에서 추론된 ${}^o\hat{\theta}$ 의 값에 상당한 변화를 나타낼 수 있다. 이러한 변화는 같은 고장에 대한 파라미터 변화 벡터의 일관성을 유지할 수 없게 되므로 고장의 식별을 어렵게 한다. 따라서 제안된 FDI 계통에서는 동작점을 나타냄과 동시에 각 지역선형모델의 적합도를 나타내는 DFM의 소속함수

표 1. 고장종류의 이진벡터 표현
Table 1. Binary vector representation of fault type

Fault Type	Target Vector [d ₀ d ₁ d ₂ ... d _p]
no fault	[1 0 0 ... 0]
fault 1	[0 1 0 ... 0]
fault 2	[0 0 1 ... 0]
...	...

값을 두 번째 잔차로 정의하여 사용함으로써 동작점 변화에 대해서도 고장요소의 식별이 용이하도록 하였다. 제안된 FDI 계통의 두 번째 잔차 벡터를 다음과 같이 정의한다.

$$r_2 = [\mu_1(z) \mu_2(z) \dots \mu_m(z)] \quad (27)$$

최종적으로 본 연구에서 제안되는 FDI 계통의 잔차 벡터는 식(28)로 정의한다.

$$r = [r_1 \ r_2] \quad (28)$$

4.2 고장 검출 및 식별기

제안된 FDI 계통에서 고장 검출 및 식별은 신경망 분류기에 의해서 수행된다. 신경망 분류기에 대한 학습데이터는 계통의 고장시 입출력 데이터로부터 얻는다. 즉, 각 고장 발생시 입출력 데이터로부터 식(28)의 잔차벡터 r 을 구하여 이를 신경망의 입력패턴으로, [1 0 ... 0], [0 1 ... 0]과 같은 이진벡터 형태로 표현된 고장 종류를 출력 패턴으로 하여 이들 간의 관계를 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 정상들에 대한 문턱치 검사(threshold test)에 의해 동시에 수행된다.

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

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

그림 1은 본 논문에서 제안된 고장 검출 및 진단계통을 도식적으로 표현한 것이다.

5. 시뮬레이션 연구

본 장에서는 제안된 FDI 계통 설계법의 유용성을 보이기 위하여 2-탱크 계통에 대한 고장 검출 및 진단 계통을 설계하고, 시뮬레이션 연구를 통하여 그 유용성을 보인다.

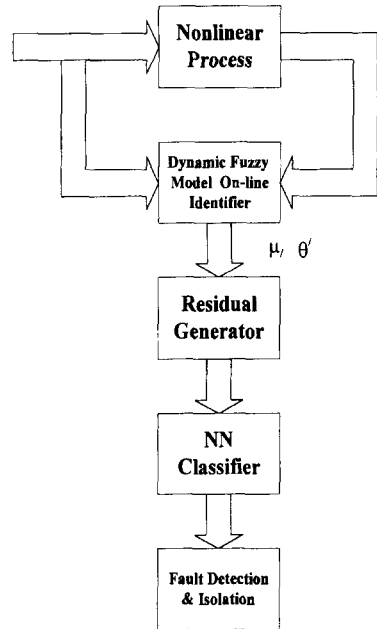


그림 1. FDI블록선도

Fig. 1. Block Diagram of FDI Scheme




그림 2. 2 탱크 시스템

Fig. 2. Two-tank system

사용된 2-탱크 계통은 그림 2와 같으며, 그 수학적 모델은 식(29)와 같다.

$$A_1 \frac{dh_1}{dt} = Q_1 - a_1 \sqrt{2gh_1}$$

$$A_2 \frac{dh_2}{dt} = a_1 \sqrt{2gh_1} - a_2 \sqrt{2gh_2} \quad (29)$$

계통출력은 2번째 탱크의 출력유량 $Q_2 = a_2 \sqrt{2gh_2}$ 이며, 계통의 파라미터는 $A_1=1.2$, $A_2=1$, $a_1=0.2$, $a_2=0.23$ 이며, 가정된 고장의 종류는 3가지로서 각각 고장 1) 밸브1의 부분 막힘, 고장 2) 밸브2의 부분

막힘, 고장 3) 밸브3의 부분 막힘이다.

먼저 DFM의 소속함수 식별을 위하여 구성된 입력 및 출력 데이터를 각각 그림 3과, 그림 4에 나타내었다. 식별알고리즘의 파라미터들을 각각 $m=4$, $\omega=1.1$, $\omega_1=1$, $\omega_2=0.1$ 으로 선정하고 오프라인으로 식별한 DFM의 전건부 파라미터 \bar{z}_i 와 후건부 파라미터 (A_i, B_i, C_i)은 다음과 같다.

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

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

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

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

$$f_i = A_i' y(t) + A_2' y(t-1) + B_0' u(t) + B_1' u(t-1) + C_i$$

$$\Theta_i = [C_i \ A_1' \ A_2' \ B_0' \ B_1']$$

$$\Theta_1 = [0.1942 \ 7.4257 \ -4.9804 \ -0.3513 \ -1.3124]$$




그림 3. 입력 데이터
Fig. 3. Input data




그림 4. 출력데이터
Fig. 4. Output data

$$\Theta_2 = [-0.0496 \ 3.9164 \ -1.9403 \ -0.3230 \ -0.5448]$$

$$\Theta_3 = [0.0028 \ 0.7530 \ -0.1286 \ 0.2466 \ 0.1405]$$

$$\Theta_4 = [0.0260 \ 0.2206 \ 0.2609 \ 0.7310 \ -0.1792]$$

계통 운전시 잔차벡터 구성을 위한 지역선형모델의 온라인 식별 알고리즘의 파라미터는 $\lambda_0=0.98$, $K_0=1000$ 으로 정의하였다.

고장 검출 및 식별기로 사용되는 신경망의 학습을 위한 고장 데이터는 0.3~0.9사이의 입력레벨에 대하여 5%에서 50%까지 임의 크기의 고장을 입구, 중간, 출구밸브에 발생시켜 133개를 추출하였으며, 이들

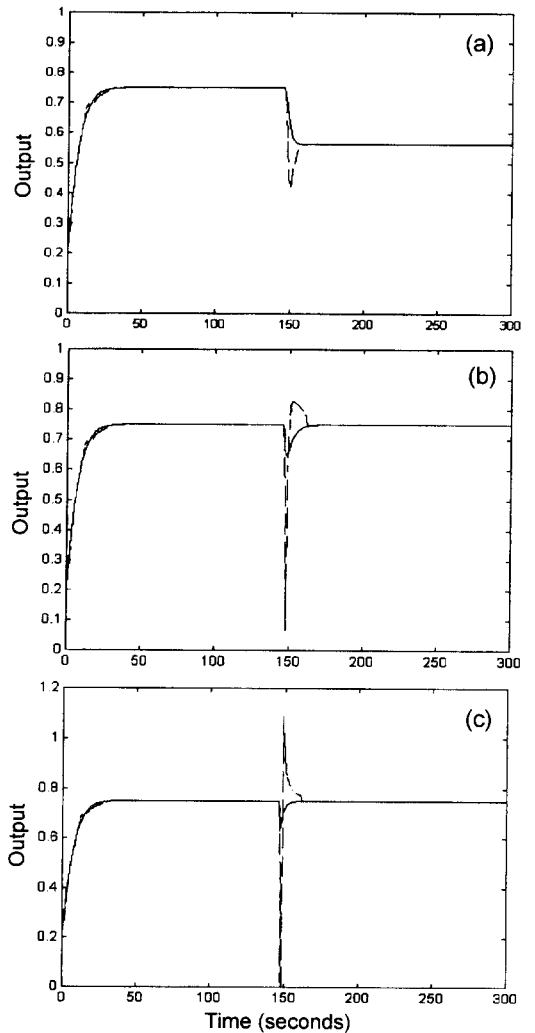


그림 5. 고장 발생시 출력특성 (a) 고장1 (b) 고장2 (c) 고장3
Fig. 5. Output Response when Fault occurred :
(a) fault 1 (b) fault 2 (c) fault 3

로부터 고장 발생시 잔차백터를 구하였다. 여기에 정상 운전 상태의 데이터 14개를 포함시켜 입출력 층과 2개의 은닉층(각 층의 뉴런의 개수는 15개)을 갖는 신경망에 학습시켰으며 신경망 학습법으로는 일반 역전파 알고리즘을 사용하였다. 구축된 FDI 계통을 이용하여 학습한 133개의 고장과 비학습 고장 데이터 140개, 총 273개의 고장 데이터에 대해 고장을 검출하고 고장 종류를 식별하였다. 이때 고장검출을 위한 문턱치(threshold)는 0.7로 하였다.

설계된 FDI 계통을 이용하여 고장을 검출하고 식별한 결과예를 그림 5~7에 나타내었다. 그림 5는 입력

레벨이 0.75인 경우에 각 고장이 발생했을 때의 출력 특성을 나타내며, 그림 6은 고장 발생에 따른 잔차백터 r_1 의 변화 양상, 그림 7은 진단 특성을 나타낸다. 고장 검출 및 식별 결과를 요약하면 다음과 같다.

학습된 고장의 경우 1개의 고장만을 검출하지 못하였으며, 비학습 고장데이터에 대해서는 7개의 고장을 검출하지 못하였다. MAR(miss alarm rate)는 2.9%였다. 10개의 고장에 대해서는 고장을 검출하였으나 고장요소를 잘못 식별하였다. 고장 1을 고장 2와 고장 3으로 판별한 경우가 각각 1회였으며, 고장 2를 고장 3으로, 고장 3을 고장 2로 판별한 경우가 각각 3회와 5회였다(표 2). 주로 고장 2와 고장 3에 대해 잘못

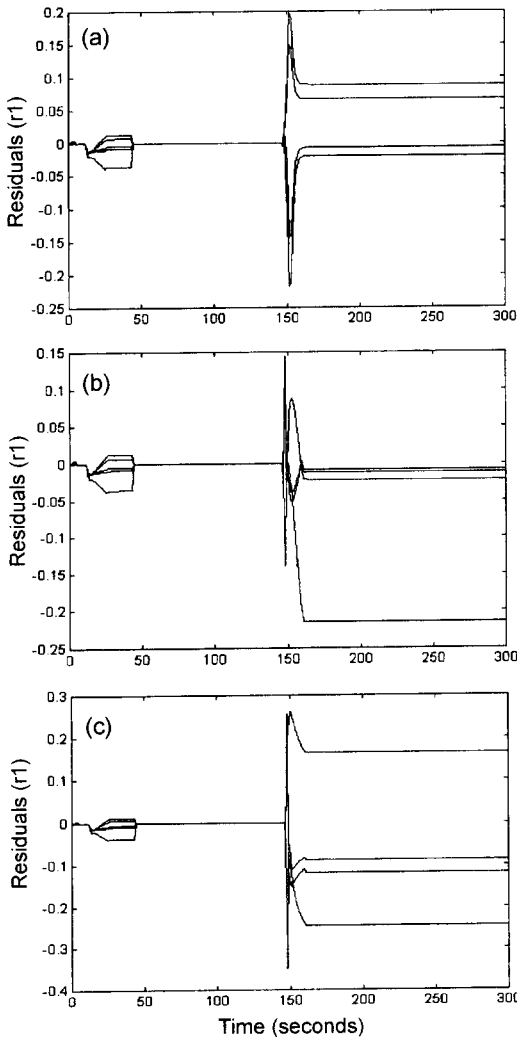


그림 6. 파라미터 잔차 양상 (a) 고장 1 (b) 고장 2 (c) 고장 3
Fig. 6. Parameter residuals for each faults
(a) fault 1 (b) fault 2 (c) fault 3

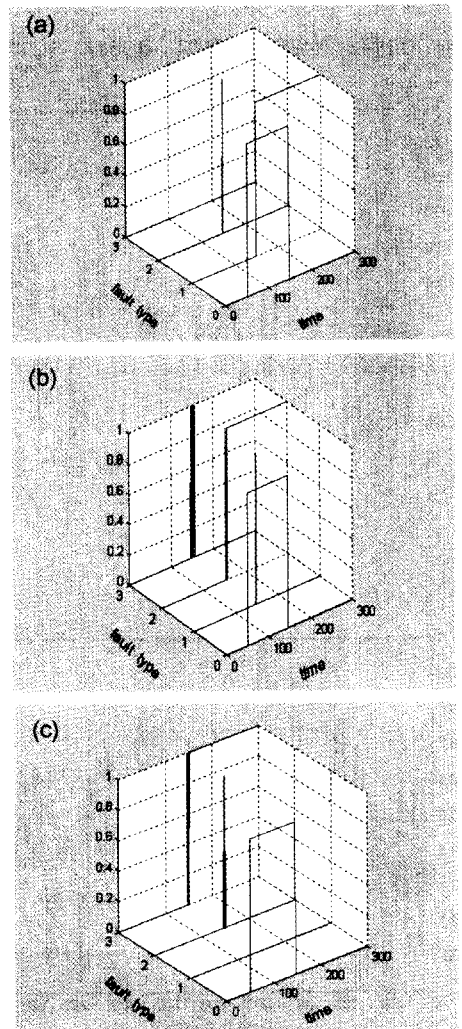


그림 7. 고장진단 특성, (a) 고장 1, (b) 고장 2, (c) 고장 3
Fig. 7. Isolation results, (a) fault 1, (b) fault 2, (c) fault 3

표 2. 고장 검출 및 진단성능
Table 2. Fault detection & isolation performance

고장데이터	Miss Alarm Rate	False Isolation Rate
학습된 고장(133개)	1/133(0.75%)	0
		10/133(7.5%)
		고장1→고장2 : 1회
비학습 고장(140개)	7/140(5%)	고장1→고장3 : 1회
		고장2→고장3 : 3회
		고장3→고장2 : 5회

식별하였는데, 이는 본 응용의 경우 계통의 입출력 데이터만 가지고 계통의 고장을 판별하는데, 그림 5에서 볼 수 있는 바와 같이 고장 2와 고장 3의 경우 출력이 거의 같은 양상을 보이기 때문이다.

참고적으로 계통의 모델을 사용하지 않는 정성적인 FDI 계통 설계 기법중의 일종으로서 복잡한 비선형 계통의 고장 검출 및 진단에 활용되는 Sign Directed Graph에 의한 FDI 계통의 경우에는 다수의 출력을 가져야만 다수의 고장을 검출할 수 있다. 같은 적용 대상 계통을 사용한 연구[9]에서는 2개의 출력을 측정하여야 계통의 고장을 식별할 수 있다. 1개의 출력 정보만으로 3가지 종류의 고장을 검출할 수 있다는 것이 본 논문에서 제안된 FDI 계통의 또 다른 특징이라 할 수 있다.

6. 결 론


본 논문에서는 온라인으로 식별되는 동적 퍼지모델을 이용하여 비선형 계통의 전 동작영역에서 프로세스의 고장을 검출하고 진단할 수 있는 새로운 FDI 계통 설계기법을 제안하고, 시뮬레이션 연구를 통하여 그 유용성을 보였다. 제안된 FDI 계통에서 잔차 벡터는 온라인으로 식별되는 동적 퍼지모델의 파라미터 벡터와 동작영역을 나타내는 소속함수로 정의되며, 고장 검출 및 식별은 과거 고장데이터로부터 습득한 잔차 벡터와 고장 종류들간의 관계를 학습한 신경망 분류기에 의해 수행된다. 또한 제안된 FDI 계통 설계 기법을 이용하여 간단한 비선형 계통인 2-탱크계통의 FDI 계통을 설계하고, 시뮬레이션 연구를 통하여, 계통의 전동작 영역에서 입출력 데이터만으로 계통의 3 가지 고장을 검출하고 고장요소를 식별할 수 있음을 보였다.

향후에는 측정잡음이 존재할 경우 강인하게 고장

을 검출하고 진단할 수 있는 방법에 대한 연구와 아울러, 고장 검출 및 식별기로 사용된 신경망은 학습데이터를 많이 요구하므로 고장 발생 데이터가 적은 경우에 대한 FDI 설계 기법에 대한 연구가 필요할 것으로 사료된다.

참고문헌

- [1] Iserman, R. and P. Balle, "Trends in the Application of Model-based Fault Detection and Diagnosis of Technical Process", *Control Eng. Practice*, Vol. 5, No. 5, pp. 709-719, 1997.
- [2] Iserman, R., "Supervision, fault detection and fault diagnosis methods", *Control Eng. Practice*, Vol. 5, No. 5, pp. 639-652, 1997.
- [3] 김용민, 이태연, 박재홍, "모델 기반의 고장 검출 기법에 관한 고찰", *전기학회지*, 제48권, 4호, pp. 9-20, 1999.
- [4] Frank, P. M., "Fault Diagnosis in dynamic Systems Using Analytical and Knowledge-based Redundancy-A Survey and Some New Results", *Automatica*, Vol. 26, No. 3, pp. 459-474, 1990.
- [5] Frank, P. M., "On-line Fault Detection in Uncertain Nonlinear Systems using Diagnostic Observers: a Survey", *International Journal of Systems Science*, Vol. 25, pp. 2129-2154, 1994.
- [6] A. T. Vemuri and M. M. Polycarpou, "Robust nonlinear fault diagnosis in input-output systems", *Int. J. Control*, Vol. 68, No. 2, pp. 343-360, 1997.
- [7] O. K. Kwon, D. W. Kim and Y. S. Kim, "Robust On-line Fault Detection Method for Boiler Systems", *제어·자동화·시스템공학 논문지*, 제5권, 1호, pp. 16-23, 1999.
- [8] P. Balle, D. Juricic, A. Rakar, S. Ernst, "Identification of Nonlinear Processes and Model Based Fault Isolation Using Local Linear Models", *AACC*, 1997.
- [9] 김성호, 김정수, 박태홍, 이종열, 박귀태, "퍼지-신경망 기반 고장진단 시스템의 설계", *전기학회논문지*, 제48권, 10호, pp. 1272-1278, 1999.
- [10] 이종열, 배상욱, 이기상, 박귀태, "비선형계통 고장진단을 위한 온-라인 퍼지동적모델식별", 98 한국퍼지 및 지능시스템학회 추계학술대회, 제8권 2호, pp. 204-210, 1998.
- [11] J. R. Lee, S. W. Bae, K. S. Lee and G. T. Park "Fault Diagnosis of Nonlinear System based on Fuzzy Dynamic Model" *Proc. FUZZ-IEEE'99* Vol. 1 pp. 245-250, 1999
- [12] 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.



이 종 열 (Jong-Ryeol Lee)

1981년 : 고려대학교 전기공학과 졸업
(공학사)
1986년 : 고려대학교 대학원 전기공학과
졸업(공학석사)
현재 : 대구공업대학 전기과 조교수



배 상 욱 (Sang-Wook Bae)

1985년 : 고려대학교 전기공학과 졸업
(공학사)
1987년 : 단국대학교 대학원 전기공학과
졸업(공학석사)
1994년 : 고려대학교 대학원 전기공학과
졸업(공학박사)
1995년 3월~현재 : 경일대학교 제어계
측공학과 조교수

주관심분야 : 퍼지이론응용, 지능제어, 고장진단



이 기 상 (Kee-Sang Lee)

1978년 : 고려대학교 전기공학과 졸업
(공학사)
1981년 : 고려대학교 대학원 전기공학과
졸업(공학석사)
1984년 : 고려대학교 대학원 전기공학과
졸업(공학박사)
현재 : 단국대학교 전기공학과 교수



박 귀 태 (Gwi-Tae Park)

1975년 : 고려대학교 전기공학과 졸업
(공학사)
1977년 : 고려대학교 대학원 전기공학과
졸업(공학석사)
1981년 : 고려대학교 대학원 전기공학과
졸업(공학박사)
현재 : 고려대학교 전기전자전파공학부
교수