

탄약운반 자동화 시스템의 고장 검출 및 분류 기법

A Fault Detection and Isolation Method for Ammunition Transport Automation System

이승연, 강길순, 유준^{*}
(Seung-Youn Lee, Kil-Sun Kang, and Joon Lyou)

Abstract : This paper presents a fault diagnosis(detection and isolation) approach for the Ammunition Transport Automation system(ATAS). Due to limited time and information available during its cyclic operation, the on-line fault detection algorithm consists of sequential test logics referring to the normal states, which can be considered as a kind of expert system. If a failure were detected, the off-line isolation algorithm finds the fault location through trained ART2 neural network. By the results of simulations and some on-line field test, it has been shown that the presented approach is effective enough and applicable to related automation systems.

Keywords : ATAS, FDI, expert system, ART2 neural network, hybrid simulation

I 서론

현대 산업 공정 시스템은 규모가 크고 복잡하며, 많은 공정이 자동화 되면서 시스템의 신뢰성 및 안전성의 유지에 대한 관심이 고조되고 있다. 이는 시스템의 규모가 방대해짐에 따라 고장의 요인과 발생 빈도가 증가하고 사소한 고장의 발생에도 생산성의 저하를 초래할 뿐만 아니라 경우에 따라서는 사람의 생명까지 위협할 정도로 파급 효과가 크기 때문이다. 그러므로 시스템의 신뢰성과 안전성을 높이기 위해 고 신뢰성 부품을 사용하여 완벽한 설계 및 제작 과정을 거쳐 생산하고 운용간 예방 정비를 철저히 수행하는 원천적 회피 방법이 있으나 이러한 방법은 많은 경제적인 문제와 기술적인 한계로 현실적으로 구현이 불가능 하므로 시스템의 개별 부품 및 모듈에서의 고장 발생 확률은 항상 존재할 수밖에 없다. 이에 따라 공정의 변화 또는 정상 동작시 발생하는 고장을 사전에 검출하고 발생 위치와 원인을 파악하는 기법이 개발되어 왔다.

고장 진단은 세단계로 수행된다. 첫 번째는 고장 검출 단계로서 시스템의 오동작 여부를 판단하는 역할을 하며 두 번째는 고장발생 위치와 원인을 파악하는 고장 분류(isolation)단계이며 마지막 단계는 고장의 경중을 결정하는 고장 식별(identification)이다. 특히 고장 검출(detection)과 분류 과정만을 포함할 경우 이를 시스템의 FDI(Fault Detection and Isolation) 문제라고 한다[1].

고장 검출 및 분류 기법은 크게 모델에 근거한 기법과 모델에 근거하지 않는 기법으로 구분된다[1-3]. 모델에 근거한 기법은 시스템의 수학적 모델에 근거하여 시스템의 출력을 연속적으로 감시함으로써 수행될 수 있다. 이는 고장

이 없는 정상 조건 하에서는 출력이 불규칙한 시스템의 외란과 잡음에 의해 유기되는 제한된 범위 내에서 전파되며, 고장이 발생할 경우 출력은 정상적인 상태 또는 전파되는 모양에서 벗어나게 되기 때문이다.

지금까지 연구된 모델에 근거한 기법은 상태추정기법과 파라미터추정기법으로 나눌 수 있다. 먼저 상태추정 기법으로는 패리티 공간, 칼만 필터, GLR(Generalized Likelihood Ratio), SBE(Separate Bias Estimation) 등이 있으며 대부분 추정된 상태와 풍차모델 상태간의 오차를 이용하여 고장을 검출한다[2]. 파라미터 추정 기법은 추정된 매개변수를 이용하여 모델의 매개변수와 시스템 매개변수의 관계로부터 시스템 매개변수의 변화를 계산하여 고장을 검출하는 방법이다[3].

모델에 근거하지 않은 기법은 시스템의 측정값, 경험 또는 물리적 특성을 기초로 하며 측정값이 제한된 범위를 벗어나는지 유무를 통해 고장을 검출하는 한계치 검사, 추이 곡선 검사, FFT(Fast Fourier Transform) 또는 웨이블릿 변환(wavelet transform) 등과 같은 신호해석 기법, 전문가시스템(expert system) 및 신경회로망(neural network) 등이 있다. 한계치 검사기법은 정해진 최소값과 최대값 사이의 존재유무를 비교하는 방법이며, 신호해석을 통한 방법은 신호변환을 통하여 시간 및 주파수영역에서 특성을 파악하여 고장유무를 판단하는 방법이다. 전문가시스템을 이용하는 방법은 시스템이 복잡하고 완전한 지식이 없는 경우에 모델에 근거한 기법을 보완할 수 있는 기법으로, 시스템에 대한 정성적인 지식에 근거하여 특정규칙을 생성하고 이를 통하여 점검을 수행한다[4]. 신경회로망은 물리적, 수학적, 기능적으로 정해진 관계식이 필요하지 않으며 처리단위간의 정보흐름이 모두 연결되어 병렬처리가 가능하므로 처리 속도 면에서 이점이 있으며 입력이 다소 불완전하고 잡음을 포함한 경우라도 큰 효과를 발휘할 수 있다[5].

탄약 운반 자동화 시스템(Ammunition Transport Automation System; ATAS)은 여러 단계의 많은 장치들로 복잡하게 구

* 책임저자(Corresponding Author)

논문접수 : 2004. 11. 16., 채택확정 : 2005. 8. 1.

이승연, 강길순, 유준 : 충남대학교 전자공학과

(syacts@cnu.ac.kr/s_kanks@cnu.ac.kr/jlyou@cnu.ac.kr)

※ 본 연구를 수행하는 데 있어 자료 및 실험 환경 제공 등 많은 도움을 주신 국방과학연구소, (주)삼성테크원 관계자 여러분께 감사드립니다.

성되어 있으며, 탄약의 고속 운반을 위해 이 장치들이 다축 제어를 통해 순차적, 동시적으로 동작한다. 공간상의 제약으로 많은 장치들의 구조적 배열이 밀집되어 있기 때문에 정밀제어(설계 요구 정밀도: 1mm)가 필요하며 매 순간 정밀한 위치로 제어되지 않는다면 탄/장약 이송기의 충돌로 인한 파손이 생길 뿐 아니라 탄/장약이 폭발하는 심각한 사태까지 발생할 수 있다. 이를 예방하기 위해 전류한계치 초과 시간 및 전압 초과 여부를 이용한 고장 검출 기법이 내부적으로 구현되어 있으나 이보다 조기에 고장을 검출하여 큰 사고를 예방하는 기법이 필요하다.

따라서 본 연구의 주된 목적은 ATAS의 동작 상태를 감시하여 조기에 고장을 검출하고, 고장의 발생 위치와 종류를 알아내는 알고리즘을 개발 적용하는 것이다. ATAS는 모든 제어를 총괄하는 주제어기와 각 모듈별 하부 제어기가 있으며 주제어기에서 서보제어기와 2msec 주기로 통신을 수행함으로 제어한다. 2msec의 짧은 시간 내에 제한된 운용정보를 가지고 고장 검출과 분류를 동시에 수행하기는 어려우므로 정상 운용(온라인) 시 시스템의 감시를 통한 고장 검출 기능을 구현하였고, 검출될 경우에 별도 운용 모드(오프라인)에서 고장을 분류하는 기능으로 나누어 구현하였다. 상기 도출된 알고리즘을 검증하기 위해 ATAS와 동일한 파형을 생성하는 공정 시뮬레이션 프로그램을 구축하였다. 이에 고장검출 및 분류 알고리즘을 시뮬레이션 프로그램에 적용하여 이의 타당성을 검증하고, 실제 ATAS에 적용하여 알고리즘의 적용 가능성을 보였다.

II. 탄약 운반 자동화 시스템

고장 검출 및 진단 알고리즘의 개발을 위해서는 먼저 대상시스템에 대한 명확한 이해가 필요하므로 본 장에서는 탄약운반 자동화 시스템의 구조와 고장 유형에 대해서 알아본다.

1. 전체적인 시스템 구성

탄약운반 자동화 시스템은 그림 1에서 보는 바와 같이 탄 적치대, 수평 탄 이송기, 수직 탄 이송기, 장약 적치대, 장약 이송기, 중간 전달, 외부 전달로 구성되어 있으며, 각 장치들은 다시 몇 개의 전동기 축과 센서로 이루어져 있다. 본 논문에서는 장약 이송부분에 대해 간략하게 설명한다.

장약 이송기는 상하, 좌우, 연결, 추출, 회전의 다섯 축으로 구성되며, 동작 순서는 좌우와 상하 축이 동시에 움직여서 목표로 하는 장약 적치대에 위치하고 연결 축에 의해 추출기가 장약 밀대의 회전축에 연결되면 추출 축에 의해 추출기가 회전하여 장약 밀대의 회전축을 회전시키어 밀대가 장약을 밀어내면 연결 축의 연결기가 분리되고 좌우축과 상하 축에 의해 보조 전달로 위치한 후 회전축이 체인을 회전시켜 장약을 보조 전달로 이송한다. 장약 적치대는 장약을 보관하기 위한 여러 개의 통들과 그 각각마다 볼트와 너트에 의해 움직이는 밀대가 달려 있다. 중간 전달은 하나의 회전축만으로 구성되며 회전축이 체인을 회전시켜서 장약을 장약 이송기에서 외부 전달로 이송한다. 외부 전달은 보조 전달로부터 받은 탄이나 장약을 회전축에 의해 컨베어를 회전시켜 밖으로 내어 보내지게 된다.

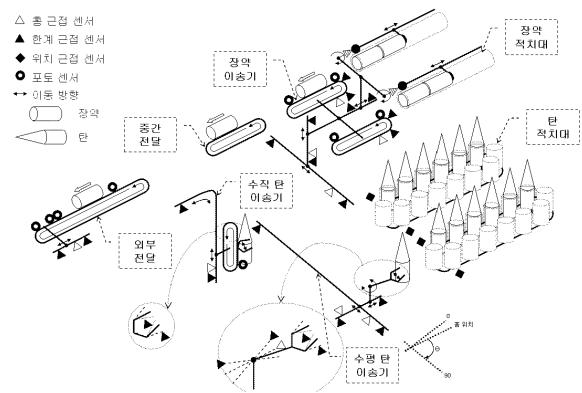


그림 1. 탄약운반 자동화 시스템의 전체 구조.

Fig. 1. Overall structure of the ATAS.

ATAS의 제어는 위치제어, 속도제어, 토크제어의 총 3가지로 이루어진다. 여기서 가장 큰 비중을 차지하고 정밀한 제어를 필요로 하는 위치 제어 축을 대상으로 고장검출 및 분류 기법을 적용하도록 한다.

2. 고장 유형

고장의 분류기준에는 여러 가지가 있지만, 일반적으로 파국고장(=돌발고장)과 열화고장으로 분류할 수 있다. 이중 파국고장은 고장을 조기에 감지할 수 없으나 열화고장은 마모, 부식, 피로 등이 서서히 진행되어 이완, 누설, 친동, 탈락, 파괴 등의 이상이 발생하고 이로부터 부품고장, 시스템 고장으로 진행하게 된다. 고장이 진행함에 따라 나타나는 친동, 음, 압력 또는 온도 등의 상태량은 고장의 특징점이 되며 이를 통해 조기에 고장을 감지 할 수 있다. ATAS의 경우 잦은 반복동작으로 인한 특정 위치 마모, 렉이나 퍼니언 등 기구부 특정 위치에 파손이나 이물질 끼임으로 인한 동작 불안정, 미끄럼 방지 부품의 마모, 센서 위치 틀어짐 등의 열화고장이 발생할 수 있다.

III. 고장 검출 및 분류 알고리즘

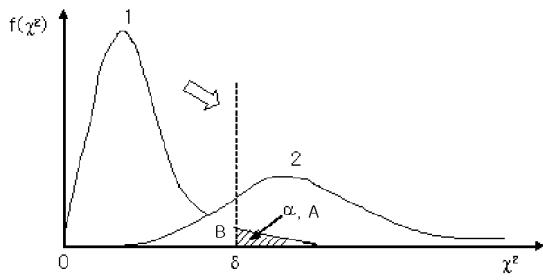
1. 온라인 고장 검출 알고리즘

온라인 고장 검출 알고리즘은 오차의 한계치검사를 통한 방법과 특정 위치에 기계의 마모, 파손에 의해 유발되는 위치 오차를 이용하여 발생되는 오차의 크기, 시간, 위치 등의 특징을 찾아내어 고장 여부를 판단하는 방법으로 구현하였으며, 센서의 경우는 운용 중 동작 시간과 기준 시간을 비교해 고장을 검출하도록 하였다.

위의 온라인 고장검출 알고리즘의 절차 중에서 일차적으로 고장여부를 판단하기 위한 문턱값을 설정하는 방법은 다음과 같다[14]. 실제 시스템의 출력과 기준 값 사이의 오차를 계산하며, 윈도우내에서의 오차가 아래와 같은 조건을 만족하여 설정한 문턱값을 넘으면 고장이 발생된 것으로 인식한다.

$$\lambda(k) = \sum_{i=k-L+1}^k e^2(i) > \delta \quad (1)$$

여기서 e 는 시스템 출력과 기준 값과의 오차이고, δ 는 고장 검출을 위한 문턱값이며 L 은 윈도우 크기이다.

그림 2. χ^2_L 오차 분포.Fig. 2. χ^2_L error distribution.

시스템이 오랜 시간 정상적으로 운행된 후 고장이 발생된다면 고장 발생 전의 오차는 시스템 잡음과 거의 같은 성질을 가진다. 따라서 오차 e 는 정규분포 $N(0, \sigma^2)$ 를 따른다. 그러므로 원도우 내에서의 L 개의 정규화된 자승오차 $e^2(i)/\sigma^2$ 의 합은 아래와 같이 자유도 (degree of freedom)가 L 인 χ^2_L (chi-square) 분포를 따르게 된다.

$$\bar{\lambda}(k) = \sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} \simeq \chi^2_L \quad (2)$$

그림 2에서 그래프 1은 시스템이 정상적으로 동작중일 때 $\bar{\lambda}$ 의 분포로서 χ^2_L 분포이고, 그래프 2는 고장으로 인해 시스템에 변화가 생겼을 때의 밀도 함수분포이며, 정화한 χ^2_L 분포는 아니지만 전체적으로 χ^2_L 와 유사한 분포가 시스템 출력과 추정 출력과의 오차로 인해 우측으로 이동된 형태로 볼 수 있고, 추정이 완료되어 천이영역을 벗어나면 그래프 1의 χ^2_L 분포로 돌아간다.

위 그림에서 허위고장신호 발생확률을 α 라고 하면 A부분은 시스템이 정상적으로 동작중이나 잡음에 의해 허위고장신호가 발생하는 영역이며, B부분은 시스템 고장임에도 불구하고 시스템 출력과 기준값 사이의 오차가 작은으로 인해 고장신호를 발생시키지 못하는 영역이다. 따라서 고장 검출을 위한 문턱값 δ 는 잡음에 의한 허위고장신호 발생 확률과 고장을 인지하지 못하는 확률을 동시에 줄이는 방향으로 설정해야 한다.

고장검출을 위한 문턱값 δ 를 시스템이 정상적으로 동작함에도 불구하고 고장 발생 신호를 내는 허위고장신호 발생확률을 최대한 줄이는 방향으로 설정해야 하므로 시스템이 정상일 때 허위고장신호 발생확률의 허용한계를 α 라고 하면

$$\Pr \left(\sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} > \delta \right) = \alpha \quad (3)$$

라고 놓을 수 있다. 여기서 χ^2_L 분포표로부터 문턱값 δ 를 구한다. 허위고장신호 발생확률을 최소화하는 방향을 통계적 방법에 의해서 고장 검출 문턱값 δ 를 구했다 하더라도 고장에 의한 영향이 작을 경우 δ 가 너무 커서 실제 고장

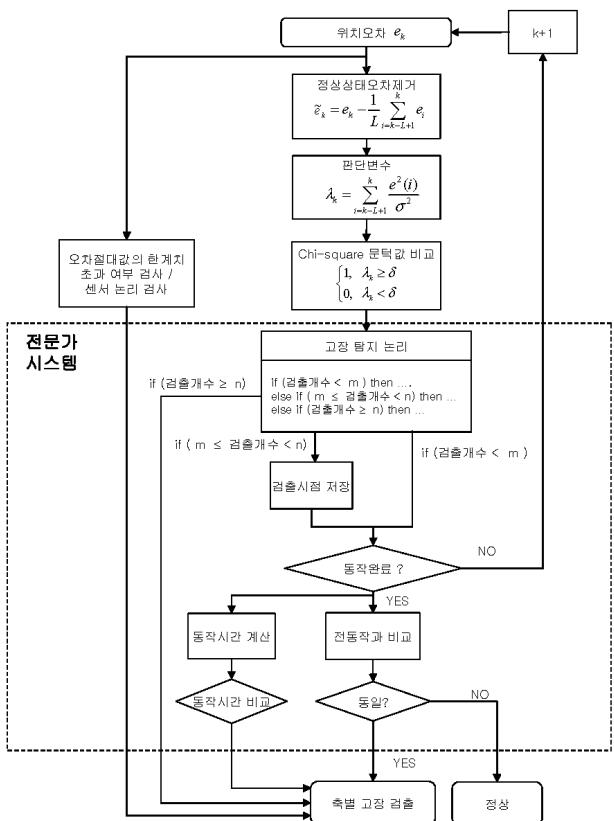


그림 3. 온라인 고장 검출 알고리즘.

Fig. 3. On-line fault detection algorithm.

에 의한 변화를 검출하지 못하는 경우가 발생할 수도 있으므로, 통계적 방법에 의해서 구한 δ 값을 기준으로 경험적 요소를 가미하여 문턱값을 적절하게 설정할 필요가 있다. 최종 도출한 온라인 고장검출 알고리즘은 그림 3과 같으며 각 단계에 대한 설명은 아래와 같다.

단계 1 : 실시간으로 제공되는 위치정보와 위치 기준값을 이용하여 위치오차 계산.

$$e_p(k) = P_r(k) - P_m(k) \quad (4)$$

P_r : 기준 위치정보, P_m : 측정 위치정보,

e_p : 위치오차

단계 2 : 고장 발생시 판단변수와 문턱값을 용이하게 결정하기 위해 정상상태 바이어스 성분 제거.

$$\tilde{e}_p(k) = e_p(k) - \frac{1}{L} \left\{ \sum_{i=k-L+1}^k e_p(i) \right\} \quad (5)$$

\tilde{e}_p : 바이어스 성분이 제거된 위치오차

단계 3 : 허위 고장 검출 확률을 줄이기 위해 원도우를 설정하여 이 구간의 값을 이용한 판단변수 선정.

$$\lambda(k) = \sum_{i=k-L+1}^k \frac{\tilde{e}_p^2(i)}{\sigma^2} \quad (6)$$

λ : 판단변수, σ : 정상상태시 \tilde{e}_p 의 표준편차,

L : 원도우 크기

단계 4 : 계산된 판단변수를 문턱값과 비교하여 일차적으로 고장을 검출.

$$\begin{cases} 0, & \lambda(k) < \delta \\ 1, & \lambda(k) \geq \delta \end{cases} \quad (7)$$

δ : 자유도 L 과 유효수준의 해 χ^2 분포표에서 선정된 문턱값

단계 5 : 전문가 시스템을 이용한 고장탐지 논리

- 탐지 1 : 고장으로 검출된 시점을 저장하여 전 동작과 검출시점이 동일하면 고장으로 판단.

$$\begin{aligned} IF (m \leq N_\lambda < n) THEN & save DT_k \text{ and} \\ IF (DT_{k-1} - DT_k) THEN & on-line fault \end{aligned} \quad (8)$$

N_λ : 단계 4의 문턱값을 초과한 검출개수.

DT_k : k 시점에서 검출시간.

m : 고장으로 판단한 N_λ 의 최소 개수.

n : 고장으로 판단한 N_λ 의 최대 개수.

- 탐지 2 : 검출개수(N_λ)가 연속적으로 일정개수 이상 반복되면 고장으로 판단.

$$IF (n \leq N_\lambda) THEN on-line fault \quad (9)$$

- 탐지 3 : 동작 완료시 기준 동작시간과 비교하여 허용 오차 시간을 초과 하면 고장으로 판단.

$$\begin{aligned} IF (k = end) \text{ and } (|k - MT| > \Delta) \\ THEN on-line fault \end{aligned} \quad (10)$$

MT : 동작시간 기준값,

Δ : 동작지연 및 초과 허용범위 시간

2. 오프라인 고장 분류 알고리즘

오프라인에서는 온라인에서 고장이 검출된 축을 대상으로 고장의 발생 부문이 모터인지, 기구인지, 센서인지 분류하는 기능을 구현하였다. 오프라인은 온라인에 비하여 시간의 제약을 받지 않고 위치 정보뿐만 아니라 속도, 전류 등의 다양한 정보를 얻을 수 있다. 2차식으로 표현된 모터 모델을 RLS(Recursive Least Square) 기법을 이용하여 각 파라미터를 추정하고, 추정된 모터 파라미터를 패턴으로 간주하고 ART2 알고리즘을 이용하여 고장의 원인을 분류하였다. ART2 신경망은 그림 4와 같은 저장된 패턴과 유사한 입력에 대하여 반응을 하여 이를 학습하기 위한 계층1과 저장된 패턴과 유사성이 없는 패턴이 입력될 경우, 계층2로 구성된다. 계층1은 입력총과 출력총을 가지는 신경망으로 구성되며, 각 노드들은 학습 패턴들이 기억되는 가중치로 연결되어 있다. 최초의 입력패턴이 ART2 신경망에 전달되면 출력총에는 생성된 클래스가 없으므로 첫 번째 클래스로 분류하여 입력패턴을 첫 번째 출력노드와 입력노드들 사이의 가중치에 저장한다. 다음에 다른 패턴이 입력되면 첫 번째 클래스와의 유사성을 검사하여 같은 클래스로 학습하거나 새로운 클래스를 생성시키게 된다.

그림 5에 최종 도출한 오프라인 고장 분류 알고리즘을 제시하였으며 단계별로 상세히 설명하면 다음과 같다. 여기서 d_j 는 입력패턴과 출력 노드 사이의 놈(nom)이며, M 개의 클래스가 분류 알고리즘에 의해서 생성되어 있다고 가정하고, 신경회로망의 기중치로 저장된 M 개의 패턴을 각 클래스의 템플릿패턴이라고 하며 N 차원의 입력벡터와 j 번째 출력노드에 대한 N 차원의 가중치벡터를 각각 X 와 W_j 로 표현한다.

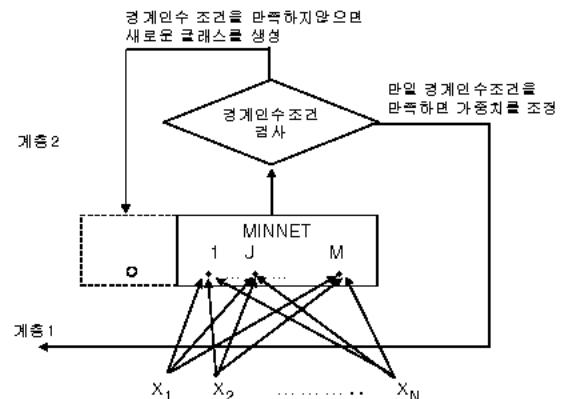


그림 4. ART2 신경망.

Fig. 4. ART2 neural net.

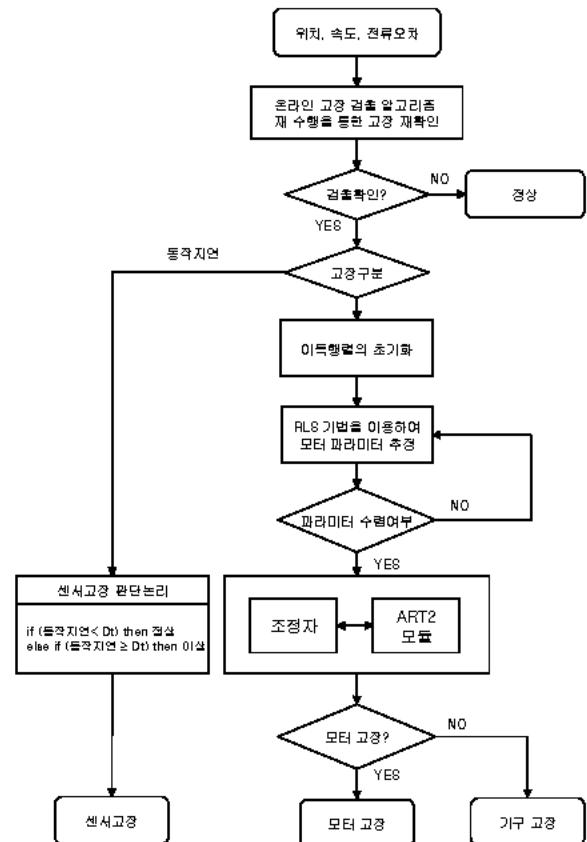


그림 5. 오프라인 고장분류 알고리즘.

Fig. 5. Off-line fault isolation algorithm.

단계 1 : 온라인에서 고장이 검출된 축에 대하여 온라인 고장 검출 알고리즘과 동일한 알고리즘을 수행하여 고장의 여부 재확인

단계 2 : 이득행렬의 초기화 수행

단계 3 : RLS기법을 이용하여 2차 모델로 간주된 모터 파라미터 추정

단계 4 : 새로이 추정된 모터 파라미터가 입력되면, MINNET(MINimum NET)이 입력패턴과 각 출력노드와의 거리를 아래와 같이 계산하여, 거리가 최소인 출력노드를 선택하고 이 노드를 승리노드라고 하며 J 로 표시

$$d_j = \|W_j - X\|, \quad j = 1, 2, \dots, M \quad (11)$$

여기서 $\|\cdot\|$ 은 임의의 놈(norm)

단계 5 : 승리노드 J 의 거리가 아래와 같은 경계인수조건을 만족하면 경계인수검사를 통하여 단계7)로 가며, 그렇지 못하면 단계6)으로 이동

$$\text{경계인수조건} : \|W_J - X\| < \rho \quad (12)$$

ρ : 각 클래스의 분류반경을 결정하는 값

단계 6 : 새로운 클래스 k 가 만들어지며, 이때 기중치는

$$W_k = X \quad (13)$$

단계 7 : 승리노드 J 의 기중치의 재조정

$$W_J^{new} = \frac{X + W_J^{old} [class_J^{old}]}{[class_J^{old}] + 1} \quad (14)$$

여기서 W_J^{old} 와 W_J^{new} 는 각각 J 번째 출력 노드에서의 조정전후의 기중치 벡터, $[class_i]$ 는 클래스 i 에 속한 패턴들의 개수이다.

단계 8 : 모터의 고장여부 판단을 통한 고장 분류.

IV. 시뮬레이션을 통한 검증

실제 ATAS에 알고리즘을 적용한 후 고장을 일으키거나 축적된 고장 데이터를 이용하여 상기 도출된 알고리즘을 검증하는 것이 최선의 방법이다. 하지만 ATAS는 고가의 장비이므로 임의로 고장을 일으키기에는 무리가 있다. 그러나 어느 정도 고장이 일어날 경우의 과정을 예상할 수 있기 때문에 ATAS와 동일한 과정을 형성하는 시뮬레이션 프로그램을 구축하고 고장 모델을 만들어 본 논문에서 제안한 알고리즘을 적용하여 이의 타당성을 검증하고자 한다.

1. Hybrid 시뮬레이션 프로그램 구현

Hybrid 시뮬레이션은 실제 기구부에서 주제어기와 서보제어기 간에 통신이 이루어지듯이 주제어기와 서보 제어기의 이산 사건 모델(stateflow로 구현)과 서보 제어기와 모터 그리고 기구의 연속 시간 모델(simulink로 구현)을 command 와 event 신호를 주고받도록 구축하였다. 구현된 시뮬레이션을 검증하기 위해 표 1의 ‘장약 이송기 전달 우’축 파라미터에 대하여 실제 과정과 비교를 수행하였고 그 결과를 그림 6에 제시하였으며 실제 시스템과 거의 비슷한 과정을 생성해 내는 것을 확인 할 수 있다.

표 1. ‘장약이송기 전달 우’축 파라미터.

Table 1. Axis parameters for ‘Charging right gunpowder tray’.

구 분	파라미터	단위	값
모터 파라미터	모터 관성	$Kg \cdot m^2$	0.62
	점성 계수	$Nm/rad/s$	$9.30e^{-6}$
	저항	ohm	5.10
	인덕턴스	mH	10.00
	토크상수	$Nm/Arms$	0.75
	역기전력상수	$V_p/rad/s$	0.62
	부하토크(최대)	Nm	3.75
	부하토크(정상)	Nm	1.89
	관성(모터축 환산)	$Kg \cdot m^2$	17.00
	마찰계수	·	0.5
기구 파라미터	단위이동량	mm	44.25719
	감속비	·	4.0

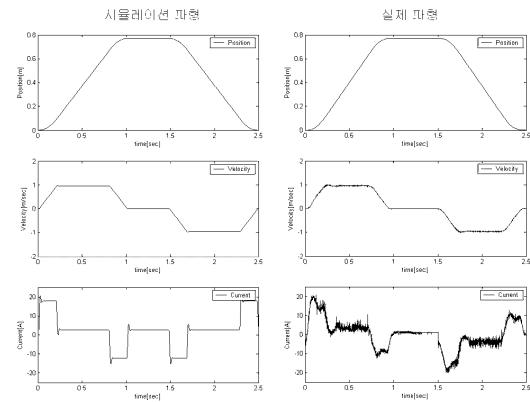


그림 6. 실제와 시뮬레이션 과정의 비교.

Fig. 6. Comparison of real and simulated waveforms.

2. 고장 모델의 구현

2.1 모터부 고장 모델

모터에 고장이 발생할 경우는 여러 가지 원인이 있을 수 있으나 ATAS의 경우 모터 자체의 무게만 200Kg인 부분도 있으며 탄을 실을 경우 50~60Kg정도의 무게가 더 실리기 때문에 과부하로 인해 모터가 과열이 되는 경우가 많다. 이를 방지하기 위해 모터 입력 부분에 전류와 전압을 일정한 값 이상으로 초과하지 못하도록 제한시키거나 자체적으로 과열 방지 보호회로를 사용하기도 한다. 하지만 이런 방지 장치에도 불구하고 찾은 과부하는 모터의 정격, 파라미터의 특성을 변화시키며 심할 경우 고정자 권선의 단선과 개방, 스트레스에 의한 회전자 바의 파손으로 이어질 수도 있다 [9,15]. 이로 인해 모터의 출력이 정격 출력 보다 감소하며 정확한 위치 추정에 문제가 발생한다. 따라서 위 영향을 모터의 PID값의 변동으로 고려하였다.

2.2 기구부 고장 모델

ATAS의 기구부에 고장이 발생하는 경우는 동작 중 여러 가지 원인으로 속도 저령 값과 속도 추종 값 사이에 차이가 커지는 경우이다. 기구부의 부하파라미터에 램프/펄스 형태의 외란을 부가함으로 고장을 유도하였다. 램프형태의 외란은 동작 구간의 임의의 시점부터 증가하는 계수의 변화가 발생하는 고장으로 여러 가지 원인으로 탄/장약 이송 기가 특정 위치에서 서서히 부딪치거나 위치 기준값을 초과하는 경우에 해당한다. 펄스형태의 외란은 동작 반복 중에 특정위치에서 위치 오차가 뒤는 형태의 고장으로 이물질

끼임. 특정부분 파손에 해당된다.

2.3 센서부 고장 모델

ATAS의 동작은 센서와 연동되어 이루어진다. 예를 들어 장약 보급공정의 경우 외부 전달에 장약이 실려 나갈 때 특정 센서가 인식하고, 이 신호를 받아 장약 이송기가 다음 동작을 수행한다. 이때 어떤 원인으로 인해 센서의 위치가 이탈되거나 감지하지 못하거나 잘못 감지할 경우 동작 시간의 지연뿐만 아니라 시스템의 치명적인 고장으로 발전될 가능성이 높다. 센서의 입력 시간은 예측 가능하므로 이 시간을 기준시간으로 삼아 실제 입력 시간과 비교를 통해 고장을 검출한다.

3. 온라인 고장 검출 시뮬레이션

상기 구현된 알고리즘을 고장 모델과 결합한 후 시뮬레이션 상에서 시스템에 고장을 일으켜 알고리즘을 검증해 보았다. ‘장약 이송기 전달 우’축의 위치 오차의 한계치는 5mm로 설정하였으며 위치 오차의 한계치를 100msec 초과 할 때 고장으로 검출하도록 하였다. 이는 노이즈 성분에 의한 허위 고장 검출 가능성을 고려한 값이다. 판단변수의 문턱값은 자유도(L)가 10이고 오경보 확률이 0.5%인 경우인 25.188로 선정하였다.

그림 7에서 램프 형태의 외란에 대해 전류 값이 한계치 11A를 초과하기 전에(12.21초) 오차의 한계치(10.57초)에 의해 고장이 조기에 검출 되었다.

그림 8에서 펄스 형태의 외란에 대해 오차의 한계치를 초과하였으나 100msec를 초과하지 않았으므로 고장이 검출 되지 않았다. 하지만 동일한 위치(0.8m)에서 문턱 값을 초과했으므로 판단변수의 문턱 값에 의해 고장이 검출됨을 알 수 있다.

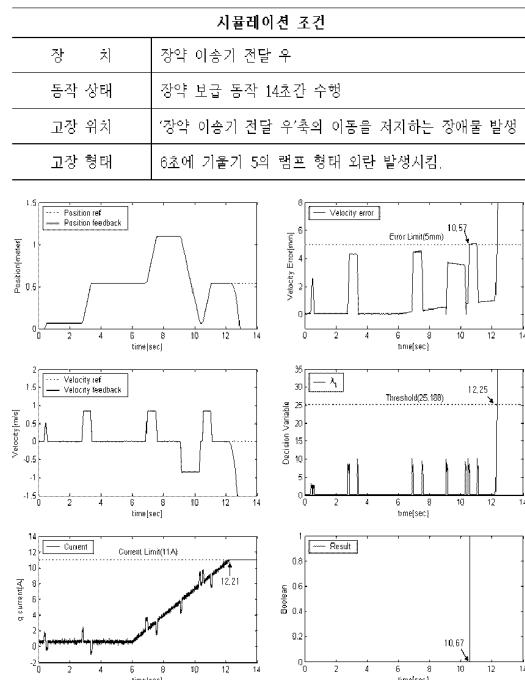


그림 7. 램프 형태 외란의 경우 시뮬레이션 결과.

Fig. 7. Simulation results in case of a ramp type disturbance.

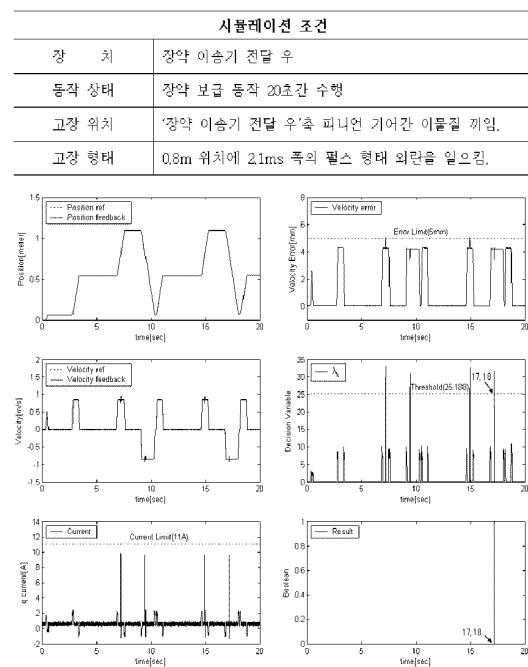


그림 8. 펄스 형태 외란의 경우 시뮬레이션 결과.

Fig. 8. Simulation results in case of a pulse type disturbance.

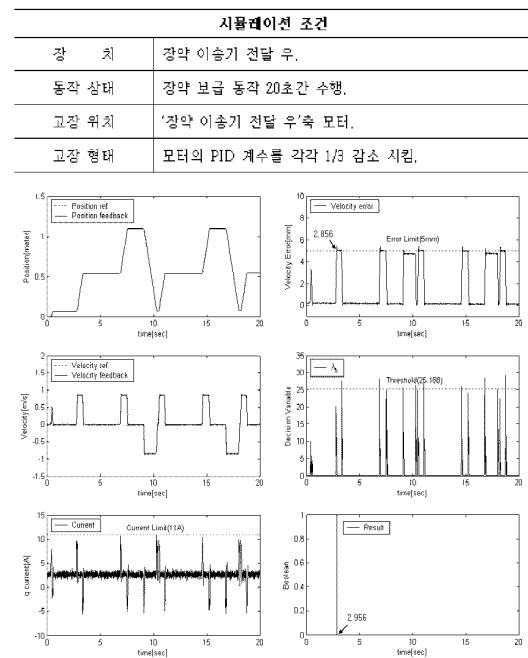


그림 9. 모터 고장 경우의 시뮬레이션 결과.

Fig. 9. Simulation results in case of a motor failure.

그림 9에서 모터 고장의 경우 전류 한계치를 넘지 않았으나 오차의 한계치를 초과함(2.856)으로 고장이 검출됨을 (2.956) 알 수 있다.

위 시뮬레이션을 통해서 위치 오차의 문턱값을 통해서 전류한계치 보다 조기에 고장을 검출 할 수 있음을 보였고, 또한 판단변수의 문턱값 (δ)을 통해 펄스형태의 고장을 효과적으로 검출 할 수 있음을 보였다.

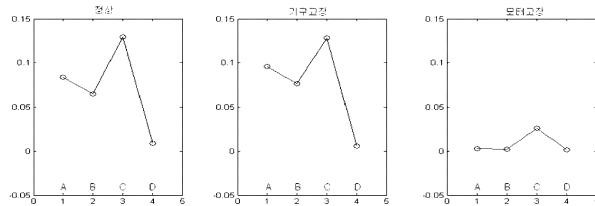


그림 10. 세 경우에 대한 모터 파라미터 식별 값 비교.

Fig. 10. Estimated motor parameters for three cases.

표 2. ART2 신경망의 학습 결과.

Table 2. ART2 learning results.

순서	Pattern	승리노드	Test Value(J)	Decision	Cluster 1 Centroid	Cluster 2 Centroid
1	(0.0936, 0.0647, 0.1294, 0.0285)	-	-	new cluster	(0.0836, 0.0647, 0.1294, 0.0285)	-
2	(0.016, 0.0072, 0.0631, 0.0086)	-	0.1970	fail → new	(0.0336, 0.0647, 0.1294, 0.0285)	(0.0105, 0.0072, 0.0631, 0.0086)
3	(0.0939, 0.0768, 0.1281, 0.0058)	1	0.0284	pass	(0.0897, 0.0707, 0.1287, 0.0072)	(0.0105, 0.0072, 0.0631, 0.0086)
4	(0.0840, 0.0650, 0.1390, 0.0199)	1	0.0345	pass	(0.0878, 0.0688, 0.1322, 0.0114)	(0.0105, 0.0072, 0.0631, 0.0086)
5	(0.0198, 0.0062, 0.0531, 0.0289)	2	0.0203	pass	(0.0878, 0.0688, 0.1322, 0.0114)	(0.0105, 0.0067, 0.0631, 0.1631)
6	(0.0939, 0.0768, 0.1281, 0.0058)	1	0.0301	pass	(0.0909, 0.0714, 0.1314, 0.0103)	(0.0105, 0.0067, 0.0631, 0.1631)

4. 오프라인 고장 분류 시뮬레이션

오프라인에서는 고장이 검출된 축을 대상으로 모터의 입·출력 정보를 이용하여 2차로 모델링된 모터 모델의 파라미터를 RLS 알고리즘으로 추정한 후 추정된 파라미터를 ART2 신경망의 입력으로 사용하여 모터고장인지 기구고장인지 분류하며 센서 고장은 별도로 확인하였다.

최종 식별값을 비교하면 그림 10과 같으며 정상시와 기구부고장일 경우의 파라미터 값이 비슷하며 모터에 이상이 있는 경우 파라미터 식별결과가 정상 또는 기구부 고장일 경우와 뚜렷한 차이가 있음을 알 수 있다. 이를 ART2 신경망에 입력패턴으로 사용하여 분류한 결과를 표 2에 나타내었다. 여기서 경계인수 ρ 는 0.1로 설정하고 Euclidean norm를 사용하였다.

첫 번째 패턴은 정상 패턴이며 이를 입력했을 때 처음 입력이므로 1번 출력 노드로 설정된다. 두 번째 패턴은 모터 고장 패턴이며 입력시 경계인수 값보다 작으므로 새로 운 노드로 설정된다. 세 번째 입력은 기구부 고장으로 입력시 승리 노드가 1번으로 표시되며 가중치의 값이 바뀌게 된다. 네 번째, 다섯 번째, 여섯 번째는 각각 정상, 모터고장, 기구고장시의 패턴에 변화를 준 것이며 정상시와 기구부 고장 발생시는 1번 노드로, 모터 고장 발생시는 2번 노드로 출력됨을 보아 패턴값이 약간 바뀌어도 효과적으로 분류함을 알 수 있다.

V. 시스템 운용을 통한 알고리즘 검증

상기 도출된 알고리즘을 실제 ATAS에 적용하여 온라인 알고리즘을 검증해 보았다. ATAS는 고가의 장비이며 실제로 고장을 일으켜 볼 수 없으므로 모터의 PID 계수 부분을 조절하여 지령 값을 추종하지 못하는 고장을 임의로 발생시켜 온라인 알고리즘의 타당성을 알아보았다. 온라인 고장 검출 알고리즘에서 위치 오차의 문턱값과 판단변수의 문턱

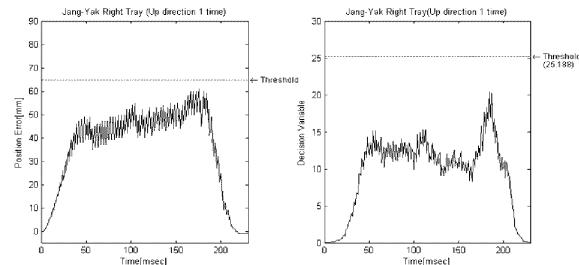


그림 11. 정상 운용시 시험 결과.

Fig. 11. Test results in case of a normal operation.

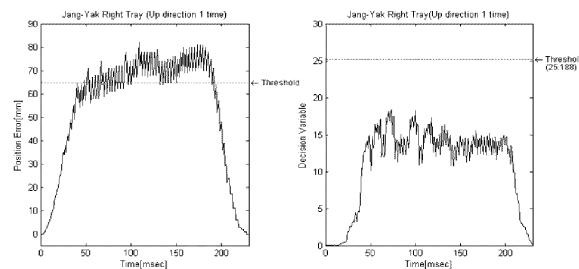


그림 12. 고장 발생시 시험 결과.

Fig. 12. Test results in case of a failure generation.

값 δ 두 가지 문턱값을 설정해야 한다. 위치 오차의 문턱값으로는 여러 번의 경험을 바탕으로 오차의 최대값(65mm)을 기준으로 설정하였다. 또한 판단변수의 문턱값 δ 은 χ^2 테이블을 이용하여 자유도(L)=10이고 오경보 확률 0.5%인 경우의 문턱값인 25.188로 설정하였다. ATAS의 각 축에 대해서 반복 시험을 실시하였으며 본 논문에는 ‘장약 트레이 우’ 축에 대한 결과를 제시한다.

그림 11은 정상 운용시 그래프를 나타내며 원쪽과 오른쪽이 각각 오차한계치, 판단변수를 나타낸다.

그림 12는 PID 이득 조정 후의 그래프이며 오차 한계치에 의해서 고장이 검출됨을 알 수 있다.

VI. 결론

본 논문에서는 탄약운반 자동화 시스템 내에서 일어날 수 있는 고장의 유형을 분석하고 주제어기에서 가용한 신호를 조사하여 고장검출 및 분류 기법을 도출하였다. 온라인에서는 고장으로 인하여 생성된 위치 오차요소에 대한 한계치와 판단변수를 감시함으로써 고장을 검출하는 알고리즘을 도출하였으며 검출된 축을 대상으로 고장의 위치와 종류를 분류해 내는 오프라인 고장분류 알고리즘을 도출하였다.

상기 도출된 알고리즘을 검증하기 위해 ATAS와 동일한 과정을 생성하는 시뮬레이션 프로그램을 개발하였으며 여기에 고장 과정을 일으킴으로 알고리즘의 타당성을 검증하였다.

도출된 온라인 알고리즘을 실제 ATAS에 적용하였다. 정상 동작 상태에 대해서 알고리즘의 정상적인 수행을 확인하였고 모터의 PID 이득 조정을 통한 고장에 대해 효과적

으로 검출함을 확인 할 수 있었다.

상기 도출된 고장 검출 및 분류 알고리즘은 다른 자동화 시스템에도 폭넓게 적용 될 수 있을 것으로 사료된다.

참고문헌

- [1] J. J. Gertler, "Survey of model-based failure detection and isolation in complex plants," *IEEE Contr. Syst. Mag.*, vol. 8, pp. 3-11, 1988.
- [2] R. J. Patton, *Fault diagnosis in dynamic systems*, Prentice Hall, pp. 22-45, 1989.
- [3] R. Isermann, "Model based fault detection and diagnosis methods," *Proc. Acc*, pp.1605-1609, 1995.
- [4] B. Freyermuth, "Knowledge based incipient fault diagnosis of industrial robots," *IFAC Proc*, Fault Detection, Supervision and Safety for Technical Process, Baden-Baden, Germany, pp. 369-375, 1991.
- [5] M. A. Kramer and J. A. Lenard, "Diagnosis using back propagation neural networks-analysis and criticism," *Computers Chem. Engng.*, vol. 14, no. 12, pp. 1323-1338, 1990.
- [6] R. Doraiswami and J. Jiang, "Performance monitoring in expert control systems," *Automatica*, vol. 25, no 6, pp. 799-811, 1989.
- [7] C. H. Pagli, *Artificial Neural Networks for Intelligent Manufacturing*, Chapman and Hall, 1994.
- [8] J. Banks, et al., *Discrete-Event System Simulation*, Prentice-Hall, pp. 12, 2001.
- [9] P. J. Tavner and J. Penman, *Condition monitoring of electrical machines*, Letchworth, UK: Research Studies Press, 1987.
- [10] R. Isermann and B. Freyermuth, "Process fault diagnosis based on process model knowledge-Part I: Principles for diagnosis with parameter estimation," *J. Dynamic Syst., Measurement, Contr.*, vol. 113, pp. 620-626, 1991.
- [11] R. Isermann, "Fault diagnosis of machines via parameter estimation and knowledge processing," *Automatica*, vol. 29, no. 4, pp. 815-835, 1993
- [12] L. Ljung, *System identification theory for the user*, Prentice Hall, 1987.
- [13] M. T. Hagan, *Neural Network Design*, PWS Publishing company, 1996.
- [14] 이인수, 신필재, 전기준, "ART2 신경회로망을 이용한 선형 시스템의 다중고장진단," 제어·자동화·시스템 공학 논문지, 제3권, 제3호, pp. 244-251, 1997.
- [15] 임호순, 정길도, "진동 신호 이용 모델 기반 고장 검출 시스템 개발," 제어·자동화·시스템공학 논문지, 제9권, 제11호, pp. 874-882, 2003.

이승연



1980년 12월 27일생. 2003년 충남대학교 학사 및 2005년 동 대학원 석사 졸업. 제어 전공. 현재 국방과학연구소 재직중. 관심분야는 시스템 모델링, 고장 검출 및 분류, 이동로봇.

강길순



1977년 6월 10일생. 2003년 충남대학교 학사 및 2005년 동 대학원 석사 졸업. 제어 전공. 현재 삼성전자 연구소 재직중. 관심분야는 결합 진단, 영상처리.

유준



1956년 3월 22일생. 1978년 서울대 전자공학과 졸업. 1984년 한국과학기술원 전기 및 전자공학박사. 1984년~현재 충남대학교 정보통신공학부 교수. 관심분야는 고장진단, 산업공정, 센서 신호 처리 등.