

유도전동기를 위한 고 신뢰성 고장 검출 및 분류 알고리즘 연구

황 철 희[†] · 강 명 수^{**} · 정 용 범[†] · 김 종 면^{***}

요 약

본 논문에서는 유도전동기 고장 검출 및 분류를 위한 3-단계 (고장 신호의 전 처리, 고장 신호의 특징 추출, 고장 신호의 고장 유형별 분류) 알고리즘을 제안한다. 먼저 전 처리 단계에서는 저역 통과 필터를 통해 취득한 신호의 고주파 대역에 영향을 미칠 수 있는 잡음 성분을 제거하며, 다음으로는 이산 코사인 변환(discrete cosine transform)과 통계적 방법을 이용하여 고장 유형별 신호의 특징을 추출하고, 마지막 단계에서는 추출된 특징을 입력으로 하는 역 전파 신경 회로망(back propagation neural network)를 이용하여 신호를 고장 유형별로 분류한다. 시스템의 성능을 평가하기 위해 모의실험에 사용된 신호는 유도전동기의 진동 신호로, 정상 및 각종 이상 상태에 대해 8kHz의 샘플링율을 갖는 1초 길이의 데이터를 사용하였다. 모의실험 결과, 제안한 알고리즘은 학습된 상황의 고장 분류에서는 100%의 정확도를 보였으며, 기존의 공분산을 이용한 고장 검출 및 분류 알고리즘과 비교하여 약 50%의 정확도 향상을 보였다. 또한 고장 신호 취득 시 사용하는 센서의 종류나 주변 환경으로 인해 잡음이 추가될 수 있는 상황을 고려하여 취득한 데이터에 백색 가우시안 잡음을 인위적으로 추가한 모의실험에서도 98%이상의 고장 분류 정확도를 보였다. 더불어, 본 논문에서는 TI사의 TMS320F2812 디지털 신호 처리기에 제안한 고장 검출 및 분류 알고리즘을 탑재하여 실제 산업현장에서의 사용여부를 검증하였다.

키워드 : 유도전동기, 고장 검출 및 분류 알고리즘, 이산 코사인 변환, 역 전파 신경 회로망

Highly Reliable Fault Detection and Classification Algorithm for Induction Motors

Chul-Hee Hwang[†] · Myeongsu Kang^{**} · Yong-Bum Jung[†] · Jong-Myon Kim^{***}

ABSTRACT

This paper proposes a 3-stage (preprocessing, feature extraction, and classification) fault detection and classification algorithm for induction motors. In the first stage, a low-pass filter is used to remove noise components in the fault signal. In the second stage, a discrete cosine transform (DCT) and a statistical method are used to extract features of the fault signal. Finally, a back propagation neural network (BPNN) method is applied to classify the fault signal. To evaluate the performance of the proposed algorithm, we used one second long normal/abnormal vibration signals of an induction motor sampled at 8kHz. Experimental results showed that the proposed algorithm achieves about 100% accuracy in fault classification, and it provides 50% improved accuracy when compared to the existing fault detection algorithm using a cross-covariance method. In a real-world data acquisition environment, unnecessary noise components are usually included to the real signal. Thus, we conducted an additional simulation to evaluate how well the proposed algorithm classifies the fault signals in a circumstance where a white Gaussian noise is inserted into the fault signals. The simulation results showed that the proposed algorithm achieves over 98% accuracy in fault classification. Moreover, we developed a testbed system including a TI's DSP (digital signal processor) to implement and verify the functionality of the proposed algorithm.

Keywords : Induction Motor, Fault Detection and Classification Algorithm, Discrete Cosine Transform, Back Propagation Neural Network

※ 이 논문은 2011년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2011-0017941).

† 준 회 원 : 울산대학교 전기공학부 석사과정

** 준 회 원 : 울산대학교 컴퓨터정보통신공학과 박사과정

*** 정 회 원 : 울산대학교 전기공학부 교수(교신저자)

논문접수 : 2011년 1월 31일

수정일 : 1차 2011년 4월 22일

심사완료 : 2011년 4월 25일

1. 서 론

산업현장이 자동화됨에 따라 전동기의 활용범위가 확대되어왔다. 로봇 시스템 등의 특별한 용도의 전동기와는 달리 일반적인 성능이 요구되는 산업현장의 설비에서 간단한 구조와 기계적 견고함을 갖춘 유도전동기는 전체 계통에 대한 동력을 공급하는 경우가 대부분이다[1]. 이러한 대전력 공급에 사용되는 유도전동기의 고장은 막대한 경제적 손실을 초래하기 때문에 고장을 사전에 방지하고 고장발생 시 손실을 최소화하기 위한 고장진단 기법과 같은 모니터링 시스템에 대한 연구가 활발히 진행되고 있다. 일반적인 고장진단은 정상적으로 운행되는 이상적인 시스템의 정보를 데이터베이스로 구축하고, 실제 시스템의 동작 및 상태를 사전에 구축된 데이터베이스와 비교 분석하여 고장을 검출 하는 방법으로 이루어져왔다[2, 3].

하지만 최근 유도전동기의 고장 검출 및 고장 유형별 분류를 위해서는 고장 유형별 신호를 사전에 분석하고, 신호의 특징들을 추출하여 패턴 매칭 알고리즘이나 신경 회로망의 입력으로 사용하여 분류하는 기법들이 소개되고 있는데 [4, 5], 신호의 특징을 효과적으로 추출하여 분류 알고리즘의 입력의 개수를 최소화하는 연구가 활발히 진행되고 있다. 이와 같은 유도전동기의 고장 상태를 효과적으로 표현할 수 있는 특징 추출 기법에는 고정자와 회전자의 주파수를 직류 성분으로 변환하여 교류전동기의 해석이 용이한 d-q 변환에 의한 추출하는 방법[6], 고속 푸리에 변환(fast Fourier transform)을 이용하여 특정 주파수를 추출하는 방법[7] 등이 주로 사용되어 왔다. 하지만 d-q 변환의 경우 다양한 고장 상태별로 고유의 패턴을 얻기가 어렵고, 잡음이 존재하는 환경 하에서는 고장 패턴을 분류하는데 어려움이 있다 [8]. 고속 푸리에 변환의 경우, 부하 변동 또는 입력 전원의 고주파 성분 때문에 주파수 성분이 변동되고, 고장 상태별로 정확한 주파수 스펙트럼을 추출하는데 한계점이 있다[8, 9]. 또한 신호의 주파수 특성을 자세히 알아 볼 수 있는 특징을 가지고 있는 반면, 연산 시간이 비교적 오래 걸리는 단점이 있으며, 특히 시스템의 입력으로 사용할 특정 파라미터를 추출하는데 어려움이 있다.

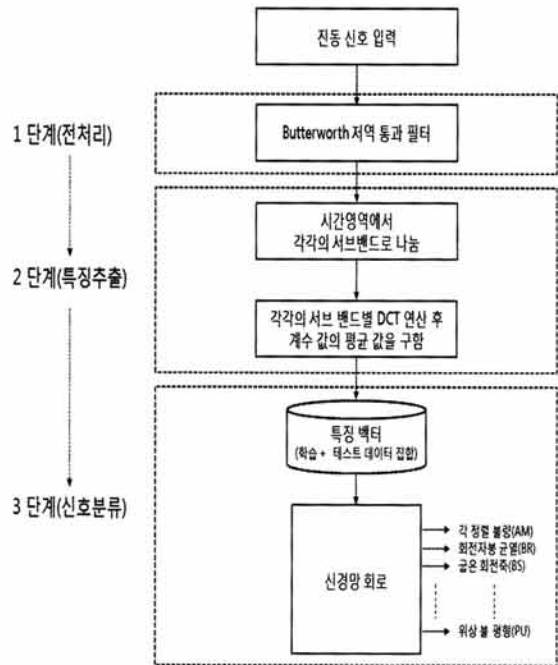
본 이러한 문제점을 해결하기 위해 입력 신호의 전 처리 단계, 이산 코사인 변환(discrete cosine transform: DCT)과 통계적 방법을 활용한 고장 신호의 특징 추출 단계, 역 전파 신경 회로망(back propagation neural network)을 이용한 고장 분류 단계의 3-단계로 구성된 고 신뢰성 고장 검출 및 분류 알고리즘을 제안한다. 이러한 고 신뢰성 알고리즘을 검증하기 위해서 실험에 사용된 데이터는 유도전동기에서 추출한 정상 상태 및 비정상 상태의 진동 신호 8개를 사용하여 모의실험을 실시하였다. 각 고장 신호별 8개의 특징을 신경 회로망의 입력으로 하여 모의 실험한 결과, 고장 신호의 유형별 학습된 상태에서는 100%의 분류 정확도를 보였다. 또한, 본 논문에서는 TI사의 TMS320F2812 디지털 신호 처리기상에 제안한 알고리즘을 탑재하여 실제 산업현

장에서의 사용여부를 검증하였다.

본 논문의 구성은 다음과 같다. 2장에서는 입력 신호의 전 처리 방법과 고장 검출 및 분류를 위한 제안한 고 신뢰성 알고리즘을 설명하고, 실제 산업현장에의 사용여부 확인을 위해 구현한 테스트베드 시스템에 대해 소개한다. 3장에서는 제안한 알고리즘과 기존의 고장진단 알고리즘과의 성능을 비교·분석하고, 마지막으로 4장에서 본 논문의 결론을 맺는다.

2. 고장 검출 및 분류를 위한 고 신뢰성 알고리즘

본 논문에서는 유도전동기의 고장 검출 및 고장 유형별 분류를 위한 고 신뢰성 알고리즘을 제안하며, (그림 1)은 이를 위한 블록도이다.



(그림 1) 제안한 고 신뢰성 고장 검출 및 분류 알고리즘의 블록도

첫 번째 단계에서는 저역 통과 필터를 이용하여 입력된 고장 신호의 고주파 대역에 영향을 미칠 수 있는 잡음 성분을 제거한다. 다음으로는 전 처리된 신호를 분석하여 특징을 추출하고, 마지막으로 추출된 특징을 역 전파 신경 회로망의 입력으로 사용하여 고장 신호를 유형별로 분류한다.

2.1 유도전동기의 진동 신호

본 논문에서는 유도전동기의 고장 검출 및 분류를 위해 진동 신호를 사용하였으며, 이는 부경대학교 지능기계연구실에서 제공한 것으로 정상 상태(normal, norm)를 비롯한 일곱 가지의 비정상 상태의 고장에 대한 신호이다[10]. 본 논문에서 사용한 일곱 가지 비정상 상태의 진동 신호는 다음과 같다.

- 회전자 불균형(rotor unbalance, run) - 회전자에 8.4g의 불균형 질량을 회전자에 부착하여 취득한 진동 신호
 - 위상 불균형(phase unbalance, pun) - 위상에 8.4%의 저항을 추가하여 취득한 진동 신호
 - 각, 평행 정렬불량 - 축 지지대를 조절하여 각 정렬불량(angular misalignment, amis)과 평행 정렬불량(parallel misalignment, pmis)의 상태를 가지게 함으로써 취득한 진동 신호
 - 베어링 결함(fault bearing, fb) - 여러 가지 원인 중 외륜에 고장을 발생시켜 취득한 진동 신호
 - 굽은 회전자(broken rotor shaft, br) - 최대 0.075mm로 회전자를 굽혀서 측정된 진동 신호
 - 회전자봉 균열(broken rotor bar, brb) - 34개의 회전자봉 중에서 12개의 봉을 파손하여 취득한 진동 신호
- 취득한 진동 신호의 샘플링율은 8kHz이며, 역 전파 신경 회로망의 학습과 고장 검출 및 분류 성능 평가를 위한 충분한 데이터를 만들기 위해 취득한 신호를 1초 길이로 나누어 각 고장 유형별로 105개의 신호를 추출하여 사용하였다. 또한, 저역 통과 필터의 차단 주파수를 결정하기 위해서 고속 푸리에 변환을 이용하여 고장 신호별로 주파수 분석을 하였다.

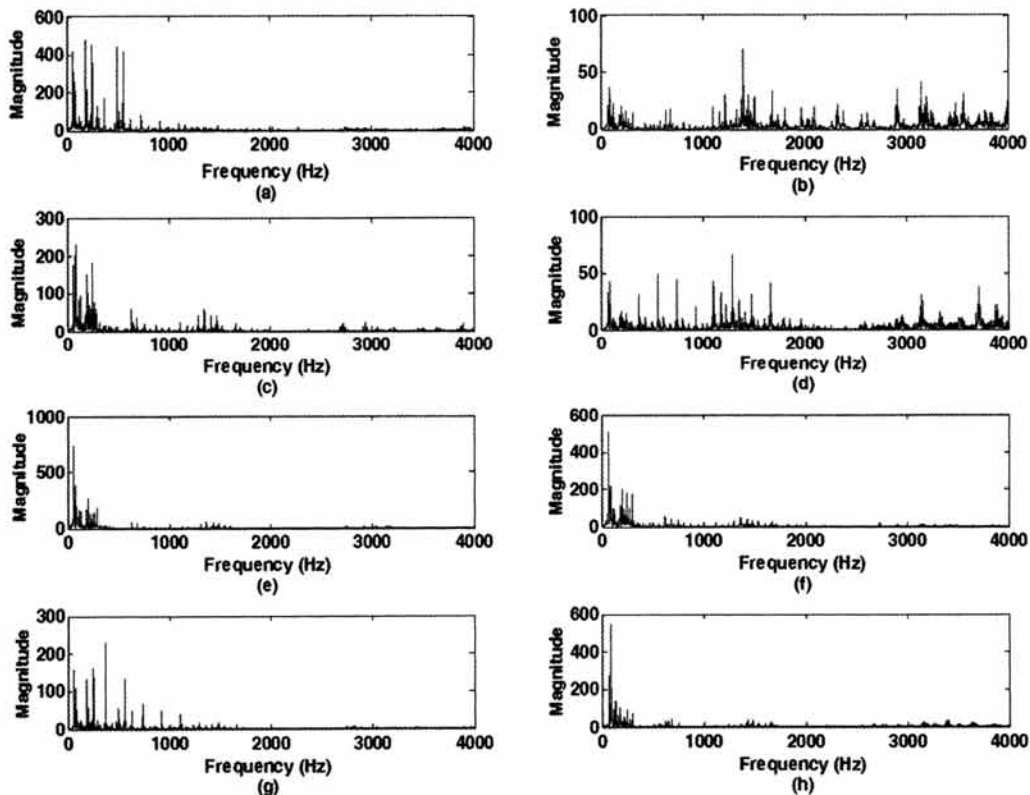
(그림 2)는 정상상태와 일곱 가지 비정상 상태에 대한 스펙트럼의 크기 응답(magnitude response)을 보여준다. (그림 2)에서 주파수 영역에서의 진동 신호는 2kHz이하에서 고장

유형별 특징이 나타나는 것을 확인할 수 있다.

2.2 입력 신호의 전 처리

고장 검출 및 분류를 위해 사용되는 신호로는 음향 신호, 진동 신호, 전류 및 전압 신호등 다양한 종류의 신호를 취득하여 사용한다. 이와 같은 신호는 취득 시 센서에 의한 잡음이 추가되게 되는데 센서의 의한 잡음은 일반적으로 백색 가우시안 잡음(white Gaussian noise)으로 간주되며, 이러한 백색 가우시안 잡음은 주파수 영역 전 대역에 걸쳐 영향을 미친다. (그림 2)에서 굽은 회전자와 베어링 결함 신호를 제외한 나머지 진동 신호의 경우 2kHz 이후에서 그 크기가 매우 작은 것을 확인할 수 있는데, 이는 신호 취득에 사용되는 진동 센서의 종류 및 주변 환경의 요인으로 인해 원치 않는 잡음 신호가 포함되어 2kHz 대역 이후의 신호에 영향을 줄 가능성이 있다. 반면 (그림 2)의 굽은 회전자와 베어링 결함 고장 신호의 경우는 고주파 대역의 정보도 중요하지만 1kHz - 2kHz 대역의 신호 특징만으로 다른 고장 신호와 구분이 가능하므로 본 논문에서는 2kHz 대역 이후에 원치 않는 잡음이 포함되는 것을 제거하기 위해 디지털 저역 통과 필터 사용을 고려한다.

디지털 저역 통과 필터로는 버터워스(butterworth), 체비셰프(chebyshev), 엘립틱(elliptic) 등이 있다. 버터워스 저역 통과 필터는 통과 대역에서 아무런 굴곡(ripple)도 발생시키지 않으며, 이 대역 밖의 원하지 않는 주파수를 감쇠시킨다.



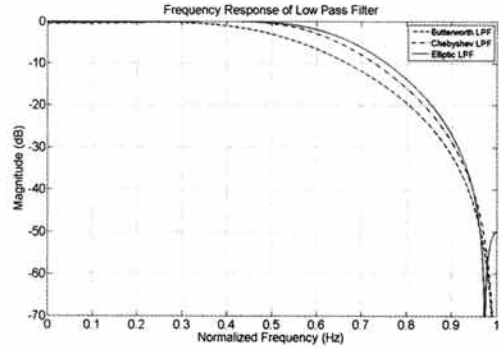
(그림 2) 주파수 영역에서의 진동 신호. (a) 각도 정렬불량 (b) 굽은 회전자 (c) 회전자봉 균열 (d) 베어링 결함 (e) 회전자 불균형 (f) 정상 (g) 평행 정렬불량 (h) 위상 불균형

반면, 체비세프 저역 통과 필터 역시 원하지 않는 대역의 주파수 성분을 감쇠시키지만 통과 대역에서 굴곡이 발생하는 특징이 있다[11]. 이와 같은 디지털 저역 통과 필터를 사용할 경우, 실시간 고장 검출 및 분류 시스템을 개발함에 있어 추가적인 회로의 구현이 요구되지 않지만 추가적인 연산 과정이 요구된다. 반면, 아날로그 저역 통과 필터를 사용할 경우, 고장 검출 및 분류 알고리즘의 수행이외의 추가적인 연산 과정은 요구되지 않지만 필터 설계를 위한 회로가 추가적으로 요구된다. 이와 같은 아날로그 저역 통과 필터를 설계할 경우 회로의 설계로 인한 원치 않는 추가적인 잡음이 발생할 가능성이 있어 본 논문에서는 신호의 전 처리를 위해 2차 버터워스 저역 통과 필터를 이용한다.

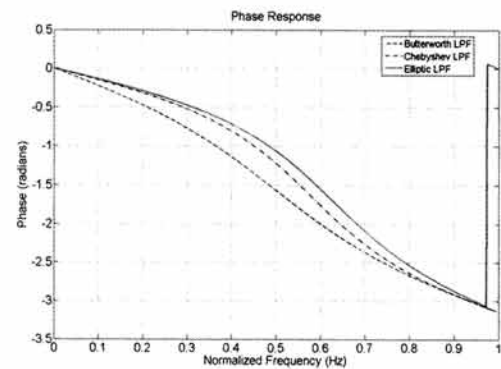
(그림 3)은 여러 가지 디지털 저역 통과 필터의 크기 응답과 위상 응답(phase response)을 보여주며, 버터워스 저역 통과 필터는 체비세프나 엘립틱과 같은 저역 통과 필터들과는 달리 통과 대역이나 차단 대역에서 굴곡이 나타나지 않아 원하는 주파수 대역을 왜곡 없이 전달하고 원치 않는 주파수 대역을 완전히 차단할 수 있다[12]. 또한, 버터워스 필터는 통과대역에서 최대 평탄(maximally flat) 형태의 필터이며, 위상 응답은 주파수에 따라 비선형으로 변하지만 이득은 통과 대역의 모든 주파수에서 동일하다.

$$G^2(\omega) = |H(j\omega)|^2 = \frac{G_0^2}{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}} \quad (1)$$

식 (1)은 2차 버터워스 저역 통과 필터의 이득을 나타내며 G_0 는 0Hz에서의 이득을, n 은 필터의 차수를, ω_c 는 차단 주파수(cut-off frequency)를 나타낸다. 앞서 설명하였듯이 대상 고장 신호의 경우 2kHz 이하에서 그 특징이 나타나므로 본 논문에서는 2차 버터워스 저역 통과 필터의 차단 주파수를 2kHz로 설정하였다. (그림 4)는 각도 정렬 불량 신호에 대한 저역 통과 필터의 결과로 원 신호와 비교하여 저역 통과 필터를 사용한 경우 2kHz 이후에서 고주파 성분이 많이 제거되었음을 확인할 수 있다.



(a)

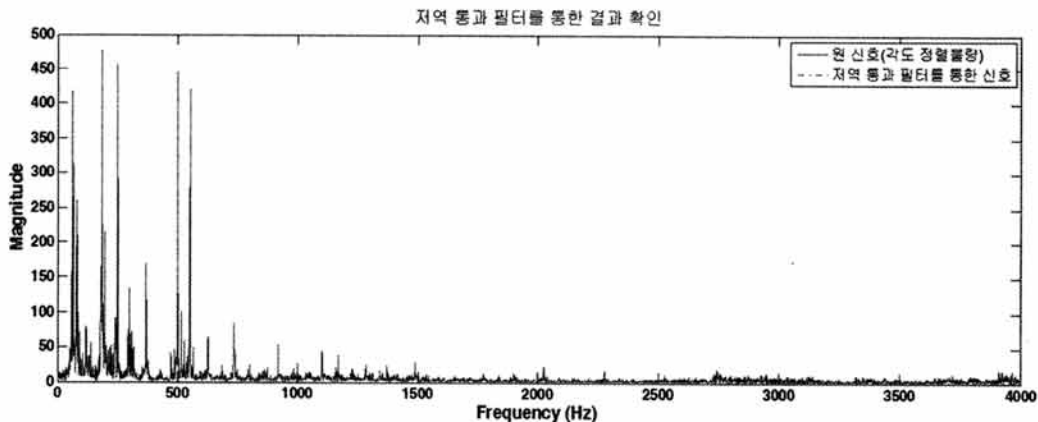


(b)

(그림 3) 버터워스(Butterworth), 체비세프(Chebyshev), 엘립틱(Elliptic) 저역 통과 필터의 (a) 크기응답, (b) 위상응답

2.3 이산 코사인 변환과 통계적 방법을 이용한 고장 신호의 특징 추출

입력된 고장 신호 전체를 특징으로 하여 고장 검출 및 분류에 사용하기에는 매우 비효율적이므로 적은 수의 데이터를 이용하여 보다 정확하고 연산 과정이 적은 알고리즘을 이용하여 고장을 검출하고 분류하는 것이 범용 디지털 신호 처리기(TMS320F2812)를 이용한 테스트베드 시스템 구현을 위해 바람직하다. 본 논문에서는 효율적인 고장 유형별 신



(그림 4) 각도 정렬 불량 원 신호와 저역 통과 필터링 후의 신호에 대한 스펙트럼

호의 특징 추출 방법으로 서브밴드(subband)별 이산 코사인 변환 계수에 대한 평균(mean)값을 이용하는 방법을 제안한다. 제안하는 방법은 이산 코사인 변환을 이용하여 신호의 주파수 특징을 효율적으로 추출할 뿐만 아니라 기존의 고속 푸리에 변환과는 달리 허수 항이 없어 메모리 공간의 절약과 알고리즘 실행 시간을 줄일 수 있는 장점이 있다. 이산 코사인 변환 계수는 식 (2)와 같으며, $X(m)$ 은 입력 신호데이터, M 은 입력 데이터의 길이, $Y_x(k)$ 는 k 번째 이산 코사인 변환 계수를 나타낸다[13].

$$Y_x(0) = \frac{\sqrt{2}}{M} \sum_{m=0}^{M-1} X(m)$$

$$Y_x(k) = \frac{2}{M} \sum_{m=0}^{M-1} X(m) \cos \frac{(2m+1)k\pi}{2M}, k=1,2,\dots,(M-1).$$

(2)

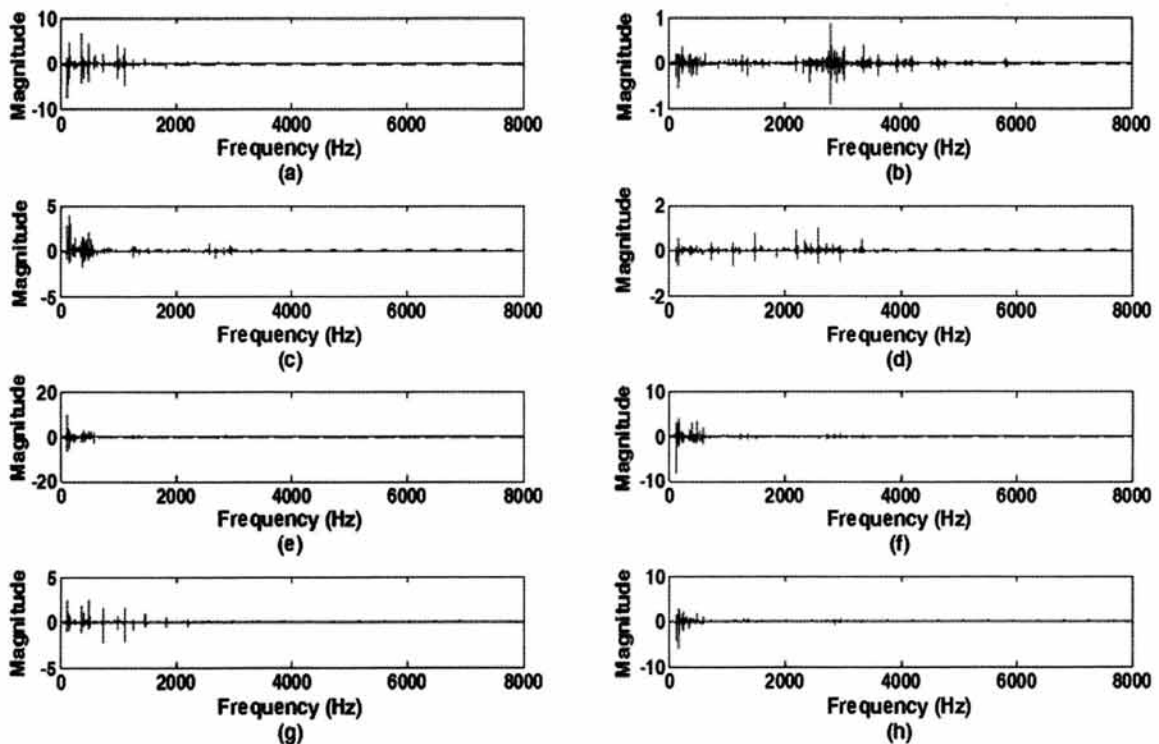
본 논문에서는 고장 유형별 신호의 특징을 추출하기 위해 1초 길이의 고장 유형별 진동 신호에 이산 코사인 변환을 수행하였고, (그림 5)는 고장 유형별 각 신호의 이산 코사인 변환 결과를 보여준다.

(그림 5)에서와 같이 이산 코사인 변환 결과 고장 유형별 신호에 특징이 모두 다르며 주파수 대역별로 뚜렷한 특징을 보인다. 하지만 이산 코사인 변환 계수 전체를 고장 분류를

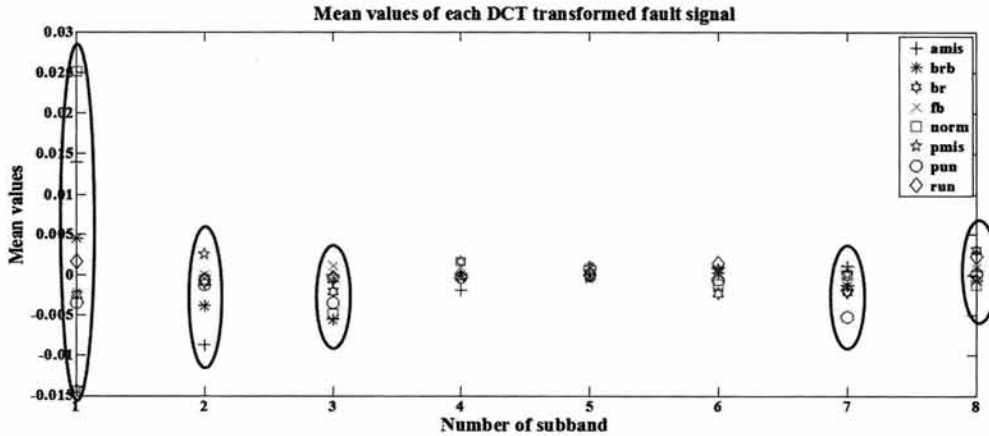
위한 역 전파 신경 회로망의 입력으로 사용하게 될 경우 알고리즘 수행에 있어 상당히 많은 시간이 소요되므로 적합하지 않다. 따라서 본 논문에서는 취득한 신호를 1,000개의 샘플 단위로 나누어 각 서브밴드별 평균(mean) 값을 고장 신호별 특징으로 추출하였다. (그림 6)은 각 서브밴드별 이산 코사인 변환 계수에 대한 평균을 보여준다. 그림 6에서 보는 바와 같이 서브밴드별 이산 코사인 변환 계수의 평균 값은 각 고장 신호를 분류하기 위한 좋은 특징이 될 수 있다. 따라서 본 논문에서는 고장 유형별 8개의 이산 코사인 변환 계수의 평균 값을 역 전파 신경 회로망의 입력으로 사용한다.

2.4 고장 유형별 분류를 위한 역 전파 신경 회로망

추출된 신호의 특징들을 이용하여 신호를 고장 유형별로 분류하는 방법에는 여러 가지가 있다. 대표적인 분류방법으로는 다층 신경망(multi-layer perceptron)을 이용한 방법, 동적 시간 교정법(dynamic time warping), 지지 벡터 기계(support vector machine, SVM)을 이용한 방법 등이 있다. 동적 시간 교정법은 한 패턴이 다른 패턴과 최대한 일치할 때까지 시간 축을 와핑(warping)함으로써 패턴간의 시간차를 제거한다. 서로 길이가 다른 시간 축 상에서의 비선형 신축을 허용하며, 2차원 동적 계획법과 역 추적(backtracking)을 통해서 패턴별 거리를 최소화하는 경로를 찾는다. 이와 같이 동적 시간 교정법은 시간 정보를 포함하고 있는 특징을 이용하여 패턴을 인식하는 방법으로 본 논




(그림 5) 이산 코사인 변환 후의 신호 (a) 각도 정렬불량 (b) 굵은 회전자 (c) 회전자봉 균열 (d) 베어링 결함 (e) 회전형 불균형 (f) 정상 (g) 평행 정렬불량 (h) 위상 불균형



(그림 6) 고장 유형별 신호의 이산 코사인 변환 계수의 평균(mean)

문에서와 같이 이산 코사인 변환 계수의 평균을 이용한 패턴 분류에는 적용할 수 없다[14, 15]. 지지 벡터 기계를 이용한 방법은 다 차원의 벡터들을 분류하여 여러 그룹의 데이터를 클러스터링(clustering)하는 방법으로 추출한 특징이 1차원인 데이터들을 분류하는 방법에는 직접적으로 적용할 수 없다. 따라서 유도전동기의 고장 유형별 분류를 위해 본 논문에서는 역 전파 신경 회로망을 사용하였으며, 역 전파 신경 회로망의 사용은 유도전동기 결함에 대한 자세한 지식의 요구 없이 결함에 대한 형태를 분류할 수 있도록 한다. (그림 7)은 본 논문에서 사용한 역 전파 신경 회로망으로, 8개의 입력 뉴런(input neuron), 1개의 은닉 층(hidden layer), 12개의 은닉 뉴런, 8개의 출력 뉴런(output neuron)으로 구성되며 각각의 뉴런은 완전 연결되어있다. 역 전파 신경 회로망을 이용한 고장 신호의 분류 절차는 피드 포워드(feed-forward) 과정과 역 전파(back propagation) 과정을 통해 연결 강도(connection weight)를 조절하고, 계산된 결과 값과 목표 값과의 오차를 최소화하는 과정을 통해 이루어진다[16]. 신경 회로망의 학습을 위해 Levenberg-Marquardt 알고리즘을 이용하였고, 학습 정도는 표준 오차 평균(mean squared error)의 학습 임계 값을 $1.00e-10$ 로 정하여 신경망 회로를 학습하였다.




(그림 7) 고장 분류를 위한 신경망 회로

역 전파 신경 회로망의 학습과 테스트를 위한 데이터는 특징 추출 알고리즘으로부터 추출한 특징 벡터의 80%(고장 유형별 84개)를 학습을 위한 데이터로, 20%(고장 유형별 21개)를 테스트를 위한 데이터로 사용하였다. 또한 Kearns의 권장사항으로 학습 데이터의 20%(고장 유형별 21개)를 검증에 위한 데이터로 사용하였다[17].

2.5 고장 검출 및 분류를 위한 테스트베드 시스템

(그림 8)은 제안한 고장 검출 및 분류 알고리즘을 TI사의 TMS320F2812 디지털 신호 처리기상에 구현한 테스트베드 시스템을 보여준다. 즉, 입력 신호의 증폭 및 쉬프트를 위한 회로를 테스트베드 상에 구현하였으며, 고장 유형별 신호의 특징을 추출하여 고장 유형별로 분류하는 등의 알고리즘은 디지털 신호 처리기에 구현하여 검증하였다. 여기서 블루투스, GPS, 온도·습도 센서 등은 전문가에게 무선으로 위치 정보와 유도전동기의 온도 및 습도 정보를 실시간으로 전송하여 유도전동기의 현재 상태와 유도전동기 주변의 상태를 알 수 있도록 하였으며, 현장에서 TFT LCD를 통해 유도전동기의 상태를 바로 확인할 수 있도록 하였다.



(그림 8) 제안한 고장 검출 및 분류 알고리즘을 위한 테스트베드 시스템

3. 모의실험

3.1 실험 결과 및 성능비교

<표 1>은 제안한 알고리즘을 이용한 유도전동기 고장 분류 성능을 보여준다.

<표 1> 제안한 알고리즘을 이용한 고장 검출 및 분류 결과

21 input signals	고장유형							
	norm	amis	pmis	fb	brb	br	run	pun
norm	21	0	0	0	0	0	0	0
amis	0	21	0	0	0	0	0	0
pmis	0	0	21	0	0	0	0	0
fb	0	0	0	21	0	0	0	0
brb	0	0	0	0	21	0	0	0
br	0	0	0	0	0	21	0	0
run	0	0	0	0	0	0	21	0
pun	0	0	0	0	0	0	0	21

<표 1>에서 볼 수 있듯이 본 논문에서 제안한 이산 코사인 변환 + 역 전파 신경 회로망 기반 고장 검출 및 분류 시스템의 성능 평가 결과 분류 정확도가 매우 우수함을 확인할 수 있었다. 또한 제안한 알고리즘의 성능 평가를 위해 동일한 유도전동기의 진동 신호를 사용한 공분산(cross-covariance) 기반 고장진단 방법[18]과의 성능을 비교하였다.

공분산 기반 고장진단 방법은 먼저 이산 웨이블릿 변환(discrete wavelet transform)을 이용하여 진동 신호를 4가지 대역으로 분리하는데, band1(0~1kHz), band2(1~2kHz), band3(2~4kHz), band4(4~8kHz)와 같다. 다음으로 신호의 중요한 성분들이 저주파 대역에 분포해있다는 점을 고려하여 band1 신호와 band2 신호만을 고장 검출 및 분류에 이용한다. 그리고 추출된 샘플과 데이터베이스에 저장된 정상/비정상 신호와의 공분산 값을 구하여 그 값이 가장 큰 값에 해당하는 목록으로 고장 신호를 분류하며, 실험 결과는 <표 2>와 같다[19].

<표 2> 공분산 기법을 사용한 고장 분류 결과

18 input signals	고장유형							
	norm	amis	pmis	fb	brb	br	run	pun
norm	18	0	0	0	0	0	0	0
amis	0	13	5	0	0	0	0	0
pmis	0	4	14	0	0	0	0	0
fb	2	0	2	14	0	0	0	0
brb	2	0	0	0	16	0	0	0
br	7	0	0	0	0	9	2	0
run	8	0	0	0	0	0	10	0
pun	12	0	0	0	0	0	0	6

공분산 방법은 서로 다른 두 신호에 대해 얼마나 상관관계를 가지는지 판별하는 방법으로 이는 데이터베이스를 구축하고 있는 참조 신호가 결과에 많은 영향을 미친다. 또한 이러한 참조 신호는 시간 변화에 따른 특성을 반영할 수 없으므로 <표 2>에서와 같이 다소 정확도가 떨어지는 결과를 보였다. 하지만 제안한 고장 검출 및 분류 알고리즘의 경우는 많은 양의 데이터를 이용하여 사전에 학습한 결과를 바탕으로 고장 검출 및 분류가 이루어지므로 공분산 방법에 비해 높은 분류 정확도를 보였다. <표 3>은 제안한 고장 검출 및 분류 알고리즘과 기존의 공분산을 이용한 고장진단 기법과의 성능 비교 결과로, 제안한 알고리즘은 기존의 공분산을 이용한 알고리즘보다 분류 정확성 면에서 약 50%의 정확도 향상을 보였다.

<표 3> 제안한 알고리즘과 공분산 기법과의 성능비교

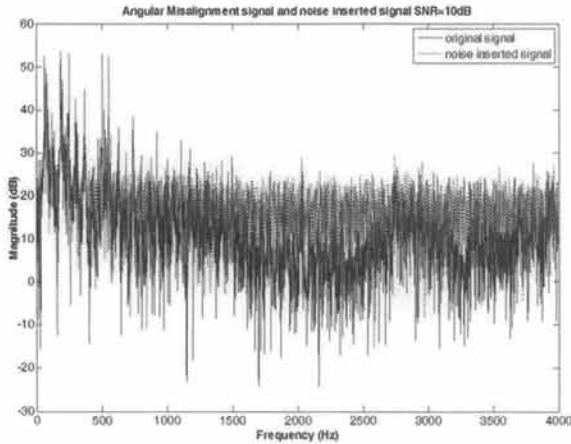
파라미터	진단 방식에 따른 정확도 (%)	
	공분산 기법	제안된 알고리즘
norm	100	100
amis	72	100
pmis	77	100
fb	77	100
brb	88	100
br	33	100
run	33	100
pun	44	100
전체 정확도(%)	66	100

이와 더불어 본 논문에서는 고장 신호를 취득함에 있어 취득에 사용되는 진동 센서나 주변 환경으로 인해 신호에 잡음이 추가되는 상황을 고려하여 취득한 신호에 인위적으로 백색 가우시안 잡음(white Gaussian noise)을 추가한 모의실험을 실시하여 잡음 환경에 대한 성능을 평가하였다. 이때 잡음은 원 신호와 잡음이 추가된 신호의 신호 대 잡음 비(signal-to-noise ratio: SNR)가 20dB가 되도록 하였고, 두 신호의 신호 대 잡음 비는 식 (3)을 이용하여 구할 수 있다[20].

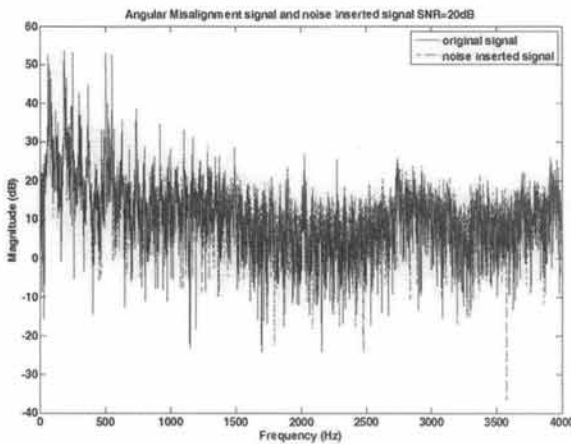
$$SNR = 10 \log \left(\frac{X}{X - X_n} \right) \tag{3}$$

여기서 X 는 원 고장신호, X_n 은 백색 가우시안 잡음이 추가된 고장 신호이다. 원 신호와 잡음이 추가된 신호의 신호 대 잡음 비를 20dB로 한 이유는 (그림 9)에서 보이는 바와 같이 20dB이하의 백색 가우시안 잡음을 추가하였을 경우에는 원 신호와의 스펙트럼 비교에서 현저한 차이를 보여 고주파 대역에서 그 신호의 특성이 사라졌기 때문이다.

<표 4>는 백색 가우시안 잡음이 추가된 각 정렬 불량 고장 신호를 이용한 모의 실험결과로 잡음이 추가된 상황에서도 고장 검출 및 분류 정확도가 98% 이상임을 보여줌으로써 제안한 고장 검출 및 분류 알고리즘이 잡음이 포함된 환경에서도 고장 분류에 강인함을 알 수 있다.



(a)



(b)

(그림 9) 각 정렬 불량 신호와 잡음이 추가된 신호의 스펙트럼.
(a) SNR = 10dB, (b) SNR = 20dB

<표 4> 백색 가우시안 잡음(20dB)이 추가된 고장 신호를 이용한 모의실험 결과

21 input signals	고장유형							
	norm	amis	pmis	fb	brb	br	run	pun
norm	21	0	0	0	0	0	0	0
amis	0	18	0	0	0	0	3	0
pmis	0	0	21	0	0	0	0	0
fb	0	0	0	21	0	0	0	0
brb	0	0	0	0	21	0	0	0
br	0	0	0	0	0	21	0	0
run	0	0	0	0	0	0	21	0
pun	0	0	0	0	0	0	0	21

4. 결 론

본 논문에서는 유도전동기 고장 검출 및 분류를 위한 3-단계 고 신뢰성 알고리즘을 제안하였다. 첫 번째 단계에서는 취득한 고장 신호를 저역 통과 필터를 이용하여 취득에 사용되는 진동 센서와 주변 환경 등의 영향으로 고주파 대역에 원치 않는 신호가 포함되는 것을 제거하였다. 다음으로는 이산 코사인 변환과 통계적 방법을 이용하여 고장 유형별 신호의 특징을 추출하였고, 마지막 단계에서는 추출된 특징을 입력으로 하는 신경 회로망을 이용하여 신호를 고장 유형별로 분류하였다. 고장 검출 및 고장 유형별 분류를 위한 모의실험 결과, 제안한 알고리즘은 학습된 상황의 고장 진단 알고리즘에 비해 약 50% 이상의 분류 정확도를 보였다. 또한, 본 논문에서는 고장 신호 취득 시 취득에 사용되는 진동 센서와 주변 환경으로 인해 추가될 수 있는 잡음을 고려하여 유도전동기의 진동 신호에 인위적으로 백색 가우시안 잡음을 추가한 모의실험에서도 98%의 정확도를 보였다. 더불어, 본 논문에서는 TI사의 TMS320F2812 디지털 신호 처리기상에 제안한 고장 검출 및 분류 알고리즘을 탑재한 테스트베드 시스템을 제작하여 산업 현장에서의 사용여부를 검증하였다.

참 고 문 헌

- [1] 김승석, 김형배, 유정웅, 전명근, "조건부 FCM과 방사기저함수 네트워크를 이용한 유도전동기 고장 검출", 한국퍼지 및 지능시스템학회, 제14권 제1호, pp.321-324, 2004.
- [2] S. Nandi, H. A. Toliyat, and X. Li, "Condition monitoring and fault diagnosis of electrical motors - A review," IEEE Transaction on energy conversion, Vol.20, No.4, pp.719-729, 2005.
- [3] W. Li and C. K. Mechefske, "Detection of induction motor faults: A comparison of stator current, vibration and acoustic methods," Journal of Vibration and Control, Vol.12, No.2, pp.165-188, 2006.
- [4] 강아람, 구미란, 신정호, 강대성, "유도전동기 고장자전류의 웨이블릿분석과 신경망을 이용한 자동 고장 진단 시스템 구현", 한국정보기술학회 하계종합학술발표논문집, pp.836-841, 2009.
- [5] Hyungseob Han, Sangjin Cho, Uipil Chong, "Fault Diagnosis System using LPC coefficients and Neural Network," Proceedings of the 2010 IFOST, pp.86-89, 2010.

[6] H. Nejjari, and M. E. H. Benbouzid, "Monitoring and diagnosis of induction motors electrical faults using a current Park's vector pattern learning approach," in IEEE International Conference on Electric Machines and Drives, pp.275-277, May, 1999.

[7] F. Zidani, M. E. H. Benbouzid, D. Diallo, and M. S. Mait-Said, "Induction motor stator faults diagnosis by a current Concordia pattern-based fuzzy decision system," IEEE Transactions on Energy Conversion, Vol.18, No4, pp.469-475, Dec., 2003.

[8] M. Haji and H. A. Toliyat, "Pattern recognition a technique for induction machines rotor broken bar detection," IEEE Trans. on Energy Conversion, Vol.16, No.4, pp.312-317, 2000.

[9] A. M. Trzynadlowski and E. Ritchie, "Comparative investigation of diagnostic media for induction motors : a case of rotor cage faults," IEEE Trans. on Industrial Electronics, Vol.47, No.5, pp.1092-1099, 2000.

[10] B.-S. Yang, K. J. Kim, T. Han, "Fault Diagnosis of Induction Motors using Data Fusion of Vibration and Current Signal," Transaction of the Korean Society for Noise and Vibration Engineering, Vol.14, No.11, pp.1091-1100, Nov., 2004.

[11] 이종석, 박철훈, "향상된 자동 독순을 위한 새로운 시간영역 필터링 기법", 정보처리학회논문지, 제15-B권 제2호, pp.123-130, 2008.

[12] 강두병, 김성진, 황정호, 정찬수, "평탄한 통과 대역과 급격한 경사도를 위한 대역통과필터 설계에 관한 연구", 대한전기학회, 하계학술대회 논문집, pp.1942-1943, 2009.

[13] N. Ahmed, T. Natarajan, and K. R. Rao, "Discrete Cosine Transform", IEEE Trans. Computers, pp.90-93, Jan., 1974.

[14] 이재현, 배현, "DTW를 이용한 유도전동기 베어링 및 회전자봉 고장진단", 한국마린엔지니어링학회지, 제31권 제1호, pp.95-102, 2007.

[15] Sakoe, H. and Chiba, S., "Dynamic programming algorithm optimization for spoken word recognition", IEEE Transactions on Acoustics, Speech and Signal Processing, Vol.26, No.1, pp.43-49, 1978.

[16] I. A. Basheer, M. Hajmeer, "Artificial Neural Network: Fundamentals, Computing Design, and Application," Journal of Microbiological Methods, Vol.43, Vol.1, pp.3-31, Dec., 2000.

[17] S. Haykin, "Neural Networks: A Comprehensive Foundation," Prentice-Hall, New Jersey, pp.156-248, 1999.

[18] I. A. Basheer, M. Hajmeer, "Artificial Neural Network: Fundamentals, Computing Design, and Application," Journal of Microbiological Methods, Vol.43, Vol.1, pp.3-31, Dec., 2000.

[19] 한형섭, 노창수, 조상진, 황갑주, 정의필, "Cross-Covariance를 이용한 유도전동기의 고장 분류", 한국신호처리·시스템학회 하계학술대회, 제10권 제1호, pp.168-171, 2009.

[20] 강명수, 조상진, 정의필, "음질 열화를 줄이고 공격에 강인한 오디오 워터마킹 알고리즘", 한국음향학회지, 제28권 제7호, pp.653-660, 2009.



황 철 희

e-mail : irnus@hanmail.net
 2008년 울산대학교 컴퓨터정보통신공학부 (학사)
 2008년~현 재 울산대학교 석사과정
 관심분야: 임베디드 시스템, 신호처리, 컴퓨터구조



강 명 수

e-mail : ilmareboy@ulsan.ac.kr
 2008년 울산대학교 컴퓨터정보통신공학부 (학사)
 2010년 울산대학교 컴퓨터정보통신공학부 (공학석사)
 2010년~현 재 울산대학교 컴퓨터정보통신공학부 박사과정
 관심분야: 임베디드시스템, 음향신호처리, 멀티미디어응용, 워터마킹, 고장진단 등



정 용 범

e-mail : smartnow@nate.com
 2009년 울산대학교 컴퓨터정보통신공학부 (학사)
 2009년~현 재 울산대학교 석사과정
 관심분야: 병렬처리, 임베디드시스템, 컴퓨터구조, 임베디드 소프트웨어



김 종 면

e-mail : jmkim07@ulsan.ac.kr

1995년 명지대학교 전기공학과(학사)

2000년 Electrical & Computer

Engineering, University

of Florida, USA(공학석사)

2005년 Electrical & Computer

Engineering, Georgia Institute of Technology, USA(공학박사)

2005년~2007년 삼성종합기술원 전문연구원

2007년~현 재 울산대학교 컴퓨터정보통신공학부 교수

관심분야: 임베디드시스템, 시스템-온-칩, 컴퓨터구조, 병렬처리, 신호처리 등