

유전 알고리즘을 사용한 유도전동기 고장진단

이 흥 희

(울산대 전기전자정보시스템공학부 교수)

1. 서론

유도전동기는 산업 공정에서 가장 많이 사용되는 구동장치이고 이에 대한 상태 모니터링과 고장진단은 유도전동기 파손을 사전에 막을 수 있는 중요한 수단이다. 유도전동기의 일반적인 고장 종류는 회전자 결함, 고정자 결함, 베어링 결함을 들 수 있는데 본고에서는 베어링의 느슨함, 베어링의 손상, 회전자의 불균형 그리고 고정자의 결함 등을 효과적으로 진단할 수 있는 방법을 소개하고자 한다.

전동기에 고장이 생기면 진동, 소음 및 온도에 영향을 미치고 이러한 신호들을 효과적으로 추출하여 진단을 위한 정보로 사용된다. 전동기의 고장진단 방법은 크게 전동기에 흐르는 전류의 거동을 분석하는 방법과 진동을 기반으로 하는 방법이 있다. 전동기에 흐르는 전류나 진동을 이용해 고장 원인을 찾기 위해 결정트리(Decision Tree), Support Vector Machine(SVM), 적응형 네트워크 기반 퍼지추론 시스템(Adaptive network-based fuzzy inference system, ANFIS), 인공 신경망, 그리고 전동기 전류 분석과 같은 신호처리기법이 주로 사용되고 있다. 이 가운데 결정 트리기법은 고장의 분류에 좋은 성능을 보이고 있으며^[1-4], 반면에 SVM^[1,5]와 인공신경망^[6,7]은 베어링의 고장진단에 잘 이용되며 ANFIS^[8]은 복합적인 고장 진단에 매우 좋은 특성을 가지고 있다. 또한, 유도전동기 고정자 전류 분석을 통한 고장진단기법은 주파수 영역에서 고정자 전류를 분석하여 유도전동기 회전자의 결함을 검출한 경우가 있으나^[9] 여전히 전류 데

이터를 분석하기 어려운 문제점을 안고 있다.

주파수 영역이나 시간 영역에서 특성분석을 기반으로 하는 신호처리기법 이외에, 해석적인 접근법을 사용하는 모델기반 접근법도 전동기의 고장진단의 또 다른 형태이다. 모델기반 접근 방식은 유도전동기의 전기적 거동을 수학적으로 모델링할 수 있다는 전제하에 가능하다. 그러나 이 방법은 매우 정확한 수학적 모델을 필요로 할뿐 아니라 실제 응용분야에서 발생할 수 있는 불확실성을 보상하기 어려운 단점을 가지고 있다. 더구나 모든 고장 형태를 모델을 사용해 시뮬레이션 할 수 있는 것은 아니다. 한편, 모델기반 접근에서 필요한 모델을 설계하는데 신호처리기법을 이용할 수 있는데, [12]에서는 고속 푸리에 변환을 사용하는 신호처리기법이 고장의 특징을 추정하기 위하여 모델기반 기법과 함께 사용되었다. 이 방법은 매우 효과적이긴 하지만 극히 제한적인 조건하에서만 적용이 가능하다.

고장진단의 궁극적인 목적은 고장 원인을 알아내는데 있다. 이를 위한 많은 고장 종류 분류 알고리즘이 존재하지만 모든 고장의 경우에 최상의 성능을 보이는 단일 알고리즘이 없는 것이 현실이다^[13]. 이 점을 고려하여 진단 조건에 알맞도록 우수한 분류 성능을 보장할 수 있는 데이터 처리 기법을 찾는 것이 중요하다. 고장진단에 필요한 유효한 데이터 확보를 위한 많은 알고리즘들이 공통적으로 사용하는 것이 특징선택(feature selection)과 특징추출(feature extraction)이다. 특징추출은 주어진 데이터 집합에서 가능한 한 많은 정보를 추출하여 데이터의 크기를 줄이는 것이 중요한데 특징추출을

위해서는 주로 Principal component analysis(PCA)와 Independent component analysis(ICA) 기법이 사용되고 있다. 특히, PCA 기법을 사용한 결정트리 기법은 만족할 만한 성능을 가진 것으로 알려져 있다^[2]. 특징선택을 위해서는 거리 평가기준(Distance Criterion)이 일반적으로 사용되고 있으나 몇몇의 연구자들이 특징 집합에서 가장 뚜렷한 특징을 선택하기 위해 유전알고리즘(Genetic Algorithm: GA)을 사용하기도 한다^[6-8]. 가장 좋은 특징선택은 시스템 성능 개선에 도움을 줄 뿐만 아니라 진단의 성능을 떨어트릴 수 있는 필요 없는 특징을 제거할 수도 있다.

고장진단에서 시스템 성능 향상을 위해 가장 어려운 일은 적절한 중요 특징을 추출하고 선택하는 것이다. 본고에서는 유도전동기의 고장을 분류하기 위한 매우 효과적인 거리 평가기준과 유전 알고리즘을 기반으로 하는 간단한 선택 기법을 소개하고자 한다.

2. 결정트리와 K-NN

2.1 결정트리(Decision Tree)

결정트리는 사례별 이력으로부터 귀납적 추론에 의해 지식 기반 시스템을 구축하는 고장진단용 도구라고 말할 수 있다. 결정트리는 잎과 가지를 포함하고 있으며 잎과 가지는 각각 분류와 그 분류를 위한 특징들의 결합을 의미한다. 결정트리의 구조는 트리의 뿌리에 대한 선택 과정과 밀접한 관계가 있다. 주어진 트리의 뿌리를 선택하기 위한 기준은 Quinlan's 정보이론(정보이득)이다^[14]. 이 이론에 따르면 메시지를 통해 전달된 정보는 그 확률적이고 결정트리는 다른 경우들의 집합을 포함하고 있는 트레이닝 집합 T 를 기반으로 만들어진 다. 각각의 경우들은 속성의 모음과 클래스의 값들을 명시한다. 각 클래스는 $\{C_1, C_2, \dots, C_k\}$ 로 표현한다. 트레이닝 집합 T 를 $\{T_1, T_2, \dots, T_n\}$ 으로 표현되는 부분집합으로 나눌 수 n 개의 결과가 나올 수 있도록 테스트가 가능하다고 하자. S 를 모든 경우들의 집합이라 두고 $freq(C_j, S)$ 는 클래스 C_j 에 속되는 경우의 수라고 둔다. 그리고 $|S|$ 는 집합 S 에 속하는 경우 수라고 한다. 그러면 집합 S 에서 무작위로 뽑은 한 가지 경우가 클래스 C_j 에 속할 확률은 (1)과 같이 표현할 수 있다.

$$\frac{freq(C_j, S)}{|S|} \quad (1)$$

여기서 전달하는 정보는 (2)와 같다.

$$-\log_2 \frac{freq(C_j, S)}{|S|} \text{ bits} \quad (2)$$

또한 S 에 존재하는 경우의 클래스를 식별하기 위해 필요한 예상 정보는 (3)과 같다.

$$info(S) = -\sum_{j=1}^k \frac{freq(C_j, S)}{|S|} \times \log_2 \left(\frac{freq(C_j, S)}{|S|} \right) \text{ bits} \quad (3)$$

트레이닝 경우의 집합에 적용할 때 $info(T)$ 는 T 내에서 어떤 경우의 클래스를 식별하기 위해 필요한 정보의 평균을 측정한다. T 이후의 비슷한 측정은 테스트 X 의 n 개의 결과에 따라 나누어진다.

$$info_x(T) = \sum_{i=1}^n \frac{|T_i|}{|T|} \times info(T_i) \text{ bits} \quad (4)$$

여기서 그 양은 (5)와 같고 테스트 X 에 따라 T 를 분할하여 얻어진 정보를 측정한다.

$$gain(X) = info(T) - info_x(T) \quad (5)$$

따라서 이득기준은 정보이득을 최대화 할 수 있도록 하나의 테스트를 선택한다.

2.2 K-nearest neighbour

k-NN 패턴 인식 알고리즘은 테스트 패턴과 모든 트레이닝 패턴 사이의 거리를 계산하는 것을 기반으로 하고 있다. 만약 트레이닝 집합이 n 개의 패턴, 즉 $\{x_1, x_2, \dots, x_n\}$ 과 같다면 n 개의 거리가 계산되고 k 개의 가장 가까운 트레이닝 패턴들이 이웃으로 구분되어지고 테스트 패턴의 유형은 대부분의 이웃이 가진 클래스로 정해진다.

테스트 패턴 x 와 트레이닝 패턴 x_k 사이의 거리는 (6)과 같이 계산된다.

$$d(x, x_k) = [(x - x_k)^T (x - x_k)]^{1/2} \quad (6)$$

여기서, x 와 x_k 는 두 개의 벡터이고 d 는 이들 사이의 거리이다.

k-NN 알고리즘은 다음과 같이 수행된다.

Step1 : 가장 가까운 이웃의 수를 나타내는 파라미터 k 를 정의한다.

Step2 : 대상 데이터 집합에 대한 각각의 쿼리 패턴과 모든 트레이닝 패턴 사이의 거리를 계산한다.

Step3 : k 번째 최소거리를 기준으로 거리를 정렬하고 가장 가까운 이웃을 정의한다.

Step4 : 가장 가까운 k 이웃을 검사하여 이웃의 대다수가 속해 있는 유형을 결정하고 검사한 패턴에 유형을




그림 1 The 1-nearest neighbour (x is classified as positive) and 5-nearest neighbour (x is classified as negative)

정한다.

Step5 : 대상 집합의 모든 패턴에 대하여 위의 순서를 반복한다.

k-NN 알고리즘에서 모든 k이웃들은 모두 같은 중요도를 가진다. k-NN의 분류 성능은 k의 값을 어떻게 선택했는가에 따라 결정된다. 예를 들어 그림 1에서 만약 k=1이라면, 테스트 패턴은 가장 가까운 이웃의 유형에 따라 결정된다. k가 증가함에 따라, 테스트 패턴의 클래스 라벨은 k이웃의 다수에서 발생하는 클래스 라벨에 따라 틀려진다.

3. 특성추출 및 선택

3.1 특성추출

필요한 데이터를 획득하기 위한 실험장치는 그림 2와 같다. x, y 그리고 z축 방향의 진동신호를 측정하기 위하여 3축 가속도 센서를 전동기의 베어링과 가까운 곳에 설치하였다. 데이터는 20KHz의 샘플링 주파수로 저장되었으며 이때 전동기는 정속운전을 한다. 가속도 센서는 베어링 하우징의 바깥쪽에 설치되었다. 측정된 진동신호는 데이터 기록기에 저장되었다.

이 시험에서 유도전동기의 고장을 유발하기 위해 베어링 케이지와 손상된 볼을 사용했다. 또한 회전자에 불균형을 만들어주기 위해서 회전자에 구멍을 뚫고 이물질들을 첨가하였다. 전동기 베어링의 느슨함은 업체로부터 느슨함의 결함을 가진 전동기를 제공받아 시험하고 고정자의 결함은 입력전압의 한상을 변화시켜서 시험하였다.




그림 2 데이터 측정 장치

표 1 시간 도메인에서의 특징

Feature	Equation
Root mean square	$Rms = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$
Variance	$Var = \sigma^2 = \frac{\sum_{n=1}^N (x(n) - \text{mean}(x))^2}{(N-1)}$
Skewness	$Skewness = \frac{\sum_{n=1}^N (x(n) - \text{mean}(x))^3}{(N-1)\sigma^3}$
Kurtosis	$Kurtosis = \frac{\sum_{n=1}^N (x(n) - \text{mean}(x))^4}{(N-1)\sigma^4}$
Crest factor	$Crest = \frac{\max x(n) }{rms}$
Maximum value	$Max = \max x(n) $

본 시험에서 전동기의 상태를 진단하기 위해서 rms 거리, variance, skewness, kurtosis, crest factor, 그리고 최대값 등을 포함하는 특정 시간영역에서의 특징들을 추출하였다. 이러한 특징들은 에너지, 진동의 크기, 시간영역에서 시간에 따른 분포 등을 나타낸다. 이들의 값은 표 1에 나타내었다.

Skewness는 신호의 대칭 또는 비대칭성을 측정한다. Kurtosis는 데이터의 형태가 정상 분포에 대하여 상대적으로 평평한 형태 또는 피크 형태를 가지는지를 측정한다. Crest factor는 시간 파형에서 얼마만한 영향이 발생하는지를 측정하는 것이고 Variance는 파형의 평균에 대한 분산을 측정한다. 마지막으로, 신호의 최대 크기 및 rms는 결함의 심각도를 표시하는데 사용될 수 있다.

특징 집합은 총 18가지의 특징들을 가지고 있으며 각 신호의 방향에 따라 각각 6개의 특징이 추출되었다. 각각의 특징들을 대응하는 최대값의 절대치로 나눠줌으로써 정규화시켰다. 즉, 모든 특징들은 0.0~1.0 사이의 값으로 정규화 되었다. 단 Skewness의 범위는 -1.0~1.0으로 한다. 특징들의 형태는 {rms(a), variance(a), skewness(a), kurtosis(a), crestfactor(a), maximum(a), rms(h), variance(h), skewness(h), kurtosis(h), crestfactor(h), maximum(h), rms(v), variance(v), skewness(v), kurtosis(v), crestfactor(v), maximum(v)}와 같이 나타내었다. 그림 3은 3축 가속도 센서에서 측정된 5대의 전동기에 대한 특정 시간 동안의 파형을 보여준다. 5대의 전동기는 베어링 손상, 베어링 느슨함, 회전자 불균형, 고정자 권선 결함 그리고 정상상태에 있는 전동기를 의미한다.

3.2 유전 알고리즘

유전 알고리즘은 적자생존의 진화과정을 시뮬레이션 하여 해답을 제공하는데 개체군 가운데 최고의 개체만이 생존하게

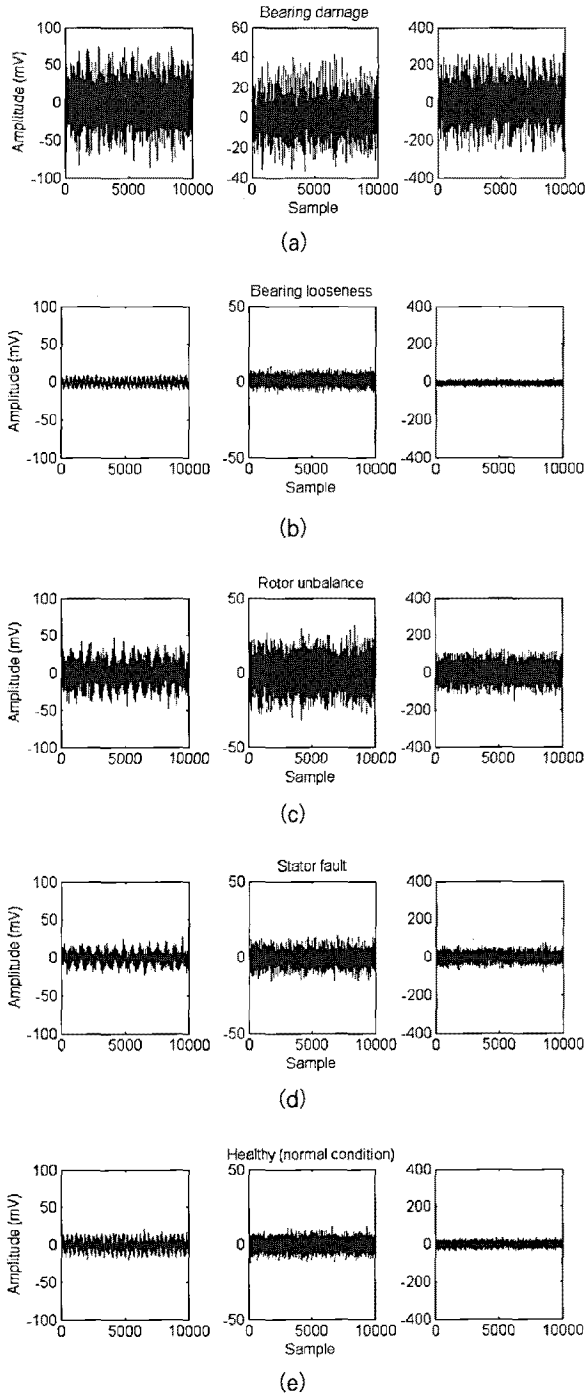


그림 3 3축 방향(수평방향-축방향-수직방향)에 대한 파형 : (a)베어링 손상 (b)베어링 느슨함 (c)회전자 불균형 (d)고정자 권선 결함 (e)정상상태

된다. 여기서 소개하는 유전 알고리즘은 개체군으로 불리는 해답의 집합체(염색체)로 시작한다. 유전 알고리즘을 살펴보면 먼저 임의의 염색체를 가진 개체군을 생성한다. 그 다음 각 염색체의 적합성이 계산하여 부모의 쌍을 선택하고 자손을 얻기 위해 이들을 교배시켜 다음 세대를 재생성 한다. 재생성 도중 자손에게서 돌연변이가 발생한다. 종합적으로 최상의 해답을 얻을 때까지 전체 과정을 반복한다.

3.3 적합성 함수(Fitness function)

여기서 염색체는 18개의 2진 비트 코드로 구성된 특징들의 차례를 나타내고 있다. 2진 비트가 '1'이면 해당 특징이 선택된 것을 의미하고 '0'이면 해당 특징이 선택되지 않았음을 의미한다. 유전 알고리즘은 두 가지의 목적을 가지고 처리되어진다. 첫 번째는 클래스 내부에서 최소의 거리를 결정하는 것이고 두 번째는 클래스간의 거리의 평균값에 대한 최대값을 결정하는 것이다. 클래스 내부의 거리는 (7), (8)과 같이 표현된다.

$$J_c = \sum_{i=1}^c p_i J_i \quad (7)$$

$$J_i = (1/n_i) \sum_{k=1}^{n_i} (x_k^i - m_i)^T (x_k^i - m_i) \quad (8)$$

여기서 i 는 클래스의 차수를 의미하며 $i = 1, 2, \dots, c$ 이다. m_i 는 클래스 i 의 평균 벡터, n_i 는 클래스 i 에서 샘플의 개수, p_i 는 전체 샘플의 수에 대한 클래스 i 의 샘플의 수 사이의 비율 계수, 클래스사이의 거리는 (9)와 같다.

$$J_b = \sum_{i=1}^c p_i (m_i - m)^T (m_i - m) \quad (9)$$

여기서 m 은 모든 클래스들의 평균 벡터이다. 적합성 함수는 (10)과 같이 정의된다.

$$J = J_i + (1/J_b) \quad (10)$$

적합성 함수를 최소화 하는 염색체가 각각의 세대에서 선택되고 특징의 하위집합으로 디코딩 된다. 이 하위집합에 속한 특징들은 가중치를 사용해 업데이트될 수 있다. 선택된 하위 집합에서 각각의 특징의 가중치는 (11)과 같이 증가된다.

$$W = W + \alpha(1/J_{\min})W_k \quad (11)$$

여기서 α 는 사용자 정의 상수, W 는 가중치 벡터, 그리고 W_k 는 선택된 특징을 표현하는 기본 벡터이다.

가중치 벡터는 각 세대에서 업데이트 되고 가장 큰 가중치를 가진 특징들이 선택된다. 이렇게 선택된 특징들은 C4.5와 k-NN 분류기를 이용해 전동기의 상태를 분류하는데 사용되어진다.

4. 실험 결과

유전 알고리즘의 변수를 살펴보면 개체군의 길이는 96, 염색체 코드는 18 bits, 돌연변이 확률은 0.8, 교차 확률은 0.8 이고 교차점은 한 지점, 한 세대의 수는 1000 그리고 α 는 0.1로 정의 한다. 특징 평가결과는 그림 4에 나타내었고 10보다 큰 가중치를 가지는 특성들은 표 2에 차례로 나열하였다.

측정된 샘플들은 트레이닝 집합과 테스트 집합으로 나누었으며 트레이닝 데이터는 최적의 특징을 선택하도록 사용되고 분류기들을 훈련시킨다. 반면 테스트 데이터는 분류기의 분류 규칙을 평가하는데 사용된다. 본 실험에서는 775개의 샘플을 가진 트레이닝 집합과 413개의 샘플을 가진 테스트 집합 그리고 표 2에 보인바와 같이 10개의 특징들이 선택되었다. 가중치에 따라 3번째에서 10번째로 큰 가중치 특징들을 포함하는 8개의 하위집합들이 형성되고 이들 하위 집합들은 결정트리^[14,15]와 k-NN분류기의 입력으로 사용된다.




그림 4 유전 알고리즘에 의한 18가지 특징들의 가중치

결정트리에서 뿌리로부터 잎까지의 경로는 "if-then" 규칙으로 표현 할 수 있다. 따라서 하나의 잎에 대해 하나의 규칙

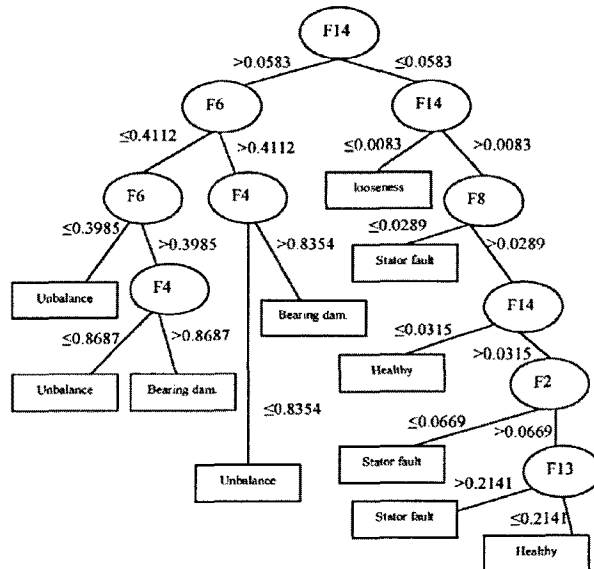


그림 5 모든 특징들을 가진 결정트리

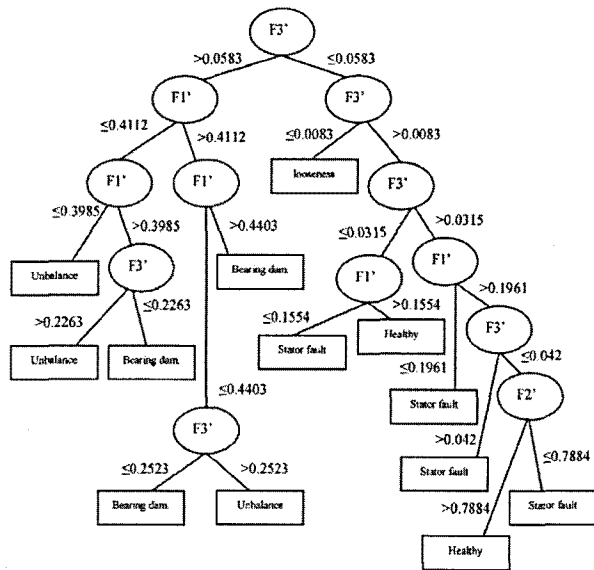


그림 6 세 가지 특징을 선택한 결정트리

표 2 가중치가 큰 10개의 특징들

Feature no.	14 (F1')	10 (F2')	6 (F3')	2 (F4')	13 (F5')	1 (F6')	16 (F7')	4 (F8')	8 (F9')	18 (F10')
Weight	64.2	60.3	56.7	48.3	45.4	40.6	34.5	34.4	34.4	19.8

'F' is abbreviation of 'Feature'.

표 3 특징을 선택하기 전후의 결정트리 성능 비교

No. of features	Size	Test data (%)					Average evaluation of training data (%)	Average evaluation of test data (%)
		Normal	Looseness	Bearing damage	Unbalance	Stator fault		
Full (18)	21	100	100	90.1	93.6	75.5	99.9	90.1
10	21	100	100	90.1	93.6	75.5	99.9	90.1
9	21	100	100	90.1	93.6	75.5	99.9	90.1
8	25	100	100	90.1	93.6	75.5	99.9	90.1
7	27	100	100	100	95.7	75.5	99.2	92.7
6	27	100	100	100	95.7	75.5	99.2	92.7
5	27	100	100	100	95.7	78.3	99.2	93.5
4	27	100	100	100	95.7	78.3	99.2	93.5
3	25	100	100	100	98.9	90.6	94.3	95.9

표 4 특징을 선택하기 전후의 k-NN 분류기 성능 비교

No. of features	k	Test data (%)					Average evaluation of test data (%)
		Normal	Looseness	Bearing damage	Unbalance	Stator fault	
Full (18)	7	80.4	68.2	100	91.5	53.8	78.5
10	3	94.6	59.1	100	95.7	84.9	87.9
9	5	98.2	36.4	100	96.8	84.9	85
8	3	98.2	37.9	100	96.8	89.6	86.4
7	11	100	87.9	100	98.9	92.5	95.9
6	7	100	100	100	95.7	93.4	97.3
5	9	100	100	100	96.8	95.3	98.1
4	1	100	100	100	94.7	86.8	95.4
3	5	91.1	100	100	98.9	89.6	95.9

을 가지는 결정트리로부터 결정규칙들을 얻을 수 있다. 결정 트리의 정확성을 측정하기 위해서 이들 결정규칙들은 테스트 데이터를 사용하여 검증된다. 그리고 이러한 검증으로부터 얻어진 결과는 실제 전동기의 상태와 비교되어진다. 이러한 결과로부터 올바른 결과의 숫자와 테스트 샘플들의 숫자와의 비율을 결정하여 결정트리의 정확도를 계산한다. 그림 5는 특징들을 선택하기 전의 트리이고 그림 6은 3가지 특징을 선택했을 때의 트리이다. 처음 결정트리의 구조는 특징을 선택한 후에 변형되었다. 원래의 결정트리는 6개의 테스트 속성(F2, F4, F6, F8, F13, F14)을 가지고 있으며 그 크기는 21이었으나 실제로 사용된 결정트리는 세 가지 테스트 속성(F1', F2', F3')을 가진 크기는 25이다.

특징을 선택한 후, 전체 결정트리의 크기는 약간 커졌으나

그 정확도는 증가되었다. 특징을 선택하지 않았을 경우 테스트 데이터를 통해 평가한 결과 90.1%의 정확도를 보인 반면 특징을 선택한 경우 90.1%에서 95.9%로 정확도가 증가되었음을 표 3을 통해 알 수 있다. 표 4는 특징을 선택한 경우와 선택하지 않은 경우 k-NN 알고리즘을 적용했을 때의 정확도를 나타내고 있다. 표에서 보인 것과 같이 특징을 선택하지 않은 경우 78.5%의 정확도를 가지고 있었으며 5가지의 특징을 선택한 경우 98.1%의 정확도를 가지는 것을 볼 수 있다. k값은 실험적으로 찾아내었으며 k값의 선택에 따라 분류 성능이 달라짐을 알 수 있다. 결론적으로 특징들을 선택함으로써 결정트리와 k-NN 분류기 모두 더 나은 진단 성능을 가지는 것을 볼 수 있다.

k-NN 알고리즘의 경우 간단하지만 많은 계산을 처리해야

한다. 그리고 트레이닝 데이터 집합이 클수록 계산량은 더욱 더 늘어나게 된다. 결정트리는 좀 복잡하긴 하지만 이해하기 쉬운 간단한 구조를 가지고 있다. 이들 두 알고리즘이 가진 각각의 취약점에도 불구하고 이들 알고리즘은 전동기 고장진단을 위한 좋은 분류기이다. 이들은 결합의 종류에 따라 분류의 정확도에서 차이가 있다. 좀 더 구체적으로 살펴보면 결정트리는 정상상태 또는 느슨함과 같은 결합에 대해서는 k-NN 보다 더 좋은 정확도를 가지고 있지만 고정자 결합에 대해서는 k-NN이 더 좋은 정확도를 가진다.

5. 결론

본고에서 특징 선택을 위해 유전 알고리즘이 어떻게 적용될 수 있고 이렇게 선택된 특징들을 사용해 결정트리와 k-NN 알고리즘을 이용해 유도전동기의 상태를 진단하는 방법을 소개하였다. 최적의 특징들을 선택하면 그렇지 않은 경우에 비해 더 좋은 고장 분류 성능을 보인다. 또한 실험의 결과를 통해 결정트리와 k-NN 알고리즘이 유도전동기 고장진단을 위한 유망한 분류기임을 알 수 있다.

k-NN 알고리즘과 함께 최적 특징 선택 기능을 가진 결정트리는 높은 정밀도를 가지고 있을 뿐만 아니라 중복되고 관련이 없는 정보의 제거로 인하여 높은 성능을 가진다. 특히, 적절한 특징의 선택은 시스템의 계산 시간을 단축시키면서 결합 분류 성능을 크게 개선할 수 있다는 것이다. 온라인 진단의 경우, 한번 유전 알고리즘을 통해 최적 특징들이 선택되면 유전 알고리즘을 다시 사용할 필요가 없기 때문에 고장 진단 알고리즘을 실행하기 위한 시간이 상당히 줄어들 수 있다.

(주) 본고는 저자가 논문지 "Proceedings of the Institution of Mechanical Engineers, Part C, Journal of Mechanical Engineering Science" 222권 C8호에 게재한 논문 "Improvement of Induction motor diagnosis performance by using genetic algorithm-based feature selection"을 번역, 편집한 것임을 밝힙니다.

참고 문헌

- [1] Sugumaran, V., Muralidharan, V., and Ramachandran, K. I. Feature selection using decision tree and classification through proximal support vector machine for fault diagnostics of roller bearing. *Mech. Syst. Signal Process.*, 2007, 21, pp. 930-942.
- [2] Sun, W., Chen, J., and Li, J. Decision tree and PCA-based fault diagnosis of rotating machinery. *Mech. Syst. Signal Process.*, 2007, 21, pp. 1300-1317.
- [3] Yang, B. S., Park, C. H., and Kim, H. J. An efficient method of vibration diagnostics for rotating machinery using a decision tree. *Int. J. Rotating Mach.*, 2000, 6(1), pp. 19-27.
- [4] Lim, D. S., Yang, B. S., and Kim, D. J. An expert system for vibration diagnosis of rotating machinery using decision tree. *Int. J. COMADEM*, 2000, 3, pp. 31-36.
- [5] Yang, Y., Yu, D., and Cheng, J. A fault diagnosis approach for roller bearing based on IMF envelope spectrum and SVM. *Measurement*, 2007, pp. 40, pp. 943-950.
- [6] Samanta, B. and Al-Balushi, K. R. Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mech. Syst. Signal Process.*, 2003, 17, pp. 317-328.
- [7] Samanta, B., Al-Balushi, K. R., and Al-Arjami, S. A. Artificial neural networks and genetic algorithm for bearing fault detection. *Soft Comput.*, 2006, 10, pp. 264-271.
- [8] Lei, Y., He, Z., Zi, Y., and Hu, Q. Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs. *Mech. Syst. Signal Process.*, 2007, 21, pp. 2280-2294.
- [9] Benbouzid, M. E. H. and Kliman, G. B. What stator current processing-based technique to use for induction motor rotor faults diagnosis. *IEEE Trans. Energy Convers.*, 2003, 18(2), pp. 238-244.
- [10] Combastel, C., Lesecq, S., Petropol, S., and Gentil, S. Model-based and wavelet approaches to induction motor on-line fault detection. *Control Eng. Pract.*, 2002, 10(5), pp. 493-509.
- [11] Kim, K. and Parlos, A. G. Model-based fault diagnosis of induction motors using non-stationary signal segmentation. *Mech. Syst. Signal Process.*, 2002, 16(2.3), pp. 223-253.
- [12] Lim, H. S., Chong, K. T., and Su, H. Motor fault detection method for vibration signal using FFT

- residuals. *Int. J. Appl. Electromagn. Mech.*, 2006, 24(3.4), pp. 209-223.
- [13] Niu, G., Son, J. D., Widodo, A., Yang, B. S., Hwang, D. H., and Kang, D. S. A comparison of classifier performance for fault diagnosis of induction motor using multi type signals. *Struct. HealthMonit.*, 2007, 6(3), pp. 215-229.
- [14] Quinlan, J. R. *C4.5: programs for machine learning*, 1993 (Morgan Kaufmann Publisher, Inc., San Mateo, California).
- [15] The C4.5 code comes from the Internet, available from <http://rulequest.com/personal/c4.5r8.tar.gz>
- [16] Rao, J. S. *Vibratory condition monitoring of machines*, 2003, pp. 361-382 (Alpha Science International Ltd, Pangbourne, UK).

〈 필 자 소 개 〉



이홍희(李弘熙)

1957년 10월 15일생. 1980년 서울대 공대 전기공학과 졸업. 1982년 동 대학원 전기공학과 졸업(석사). 1990년 동 대학원 전기공학과 졸업(공학박). 1994년~1995년 Texas A&M 방문교수. 현재 울산대 전기전자정보시스템공학부 교수.