

지능형 디지털 보호계전 알고리즘 연구

Study of an Algorithm for Intelligent Digital Protective Relaying

신현익, 이성환**, 우천희*, 강신준*, 우광방*, 김정한**, 김상철**

*연세대학교 전기공학과 (Tel: 361-2767; Fax: 312-7735; E-mail: shi@auto.yonsei.ac.kr)

**현대중공업(주) 중전기 개발부문 시스템제어개발실(Tel: (0331)289-5119; Fax: (0331) 283-8365)

Abstracts A new method for on-line induction motor fault detection is presented in this paper. This system utilizes unsupervised-learning clustering algorithm, the Dignet, proposed by Thomopoulos etc., to learn the spectral characteristics of a good motor operating on-line. After a sufficient training period, the Dignet signals one-phase ground fault, or a potential failure condition when a new cluster is formed and persists for some time. Since a fault condition is found by comparison to a prior condition of the machine, on-line failure prediction is possible with this system without requiring information on the motor or load characteristics.

Keywords induction motor, unsupervised learning, on-line fault detection

1. 서론

유도전동기는 전 분야에 걸쳐 널리 사용되는 기기이며 전체 전력사용량의 많은 부분을 차지한다. 따라서, 전동기를 각종 사고로부터 보호하여 안정적 동작을 보장하기 위하여 많은 보호계전알고리즘이 제안되었다. 특히 베어링에 고장이 발생한 경우, 고장을 사전에 발견하여 고장원인을 제거하고 베어링을 교체하는 경우보다 전동기 유지, 보수를 위해 훨씬 더 많은 비용과 시간이 소요된다. 이러한 고장들을 가장 민감하게 보여주는 부분이 입력 전류이고, 특히 베어링 고장의 경우, 입력전류의 주파수 해석을 통해 알 수 있다[1]. 그러나, 주파수 해석만으로 베어링 고장을 검출하려면 베어링의 기계적 구조와 부하특성에 관한 정보가 필요하고 이의 판단을 위해 전문가가 필요하다. 본 논문에서는 전동기의 단상 지락과 베어링 고장을 전문가의 도움없이 발견하기 위해 입력전류의 주파수 해석 결과를 Thomopoulos 등이 제안한 비교사 클러스터링 알고리즘인 Dignet을 이용하여, 그 결과로부터 고장을 검출하였다.

2. 유도전동기 고장유형

일반적으로 유도전동기에 발생할 수 있는 고장유형으로는 과부하로인한 열적 절연파괴, 단락, 상 불평형으로인한 역상전류, 회전자 구속, 그리고 베어링 고장 등을 들 수 있다. 이중 특히 베어링 고장의 경우 심각해질 경우 과부하 또는 회전자 구속의 요인이 될 수 있다. 본 논문에선 전동기의 단상지락과 베어링 고장에 대하여 고찰하고자 한다.

단상지락의 경우, 그림1에서 볼 수 있는 바와같이 사고가 발생한 A상의 경우 입력전류의 크기가 급격히 증가하며, 위상에도 변화가 있음을 알 수 있다. 나머지 두 상의 경우도 위상의 변화는 없으나 입력전류의 크기가 점차로 증가하는 것을 알 수 있다.

베어링 고장의 경우 정상적인 동작 조건에서부터 고장이 발생

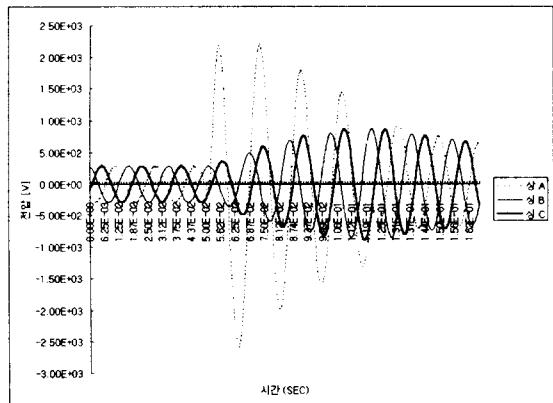


그림 1. 단상지락시 입력전류 파형.
Fig. 1. Wave form at one-phase ground fault.

하는 경우엔 보통 미세한 베어링 불이나 링 표면의 균열이나 흡집에서 시작된다. 일단 균열이 발생하면 흡집에 주기적으로 힘이 가해져서 급속히 확산, 진전되어 급기야 베어링 내에 파편조각이 발생하여 그 정도가 감지할 수 있는 정도가 된다. 반면, 전동기의 베어링 자체가 기울어져 조립되었거나, 베어링은 올바로 조립되었으나 부하에 연결된 죽이 기울어진 경우, 운전 초기에는 베어링이 한쪽 방향으로 지나치게 많은 힘을 받고 있음에도 거의 진동이 발생하지 않으나, 링의 힘을 받는 쪽이 결국엔 파이게 되어 전자의 경우와 마찬가지로 초기에는 감지할 수 없었던 주파수대에서 파형이 검출된다. 그러나, 이처럼 발생하는 고장 주파수는 베어링의 기계적 구조와 전동기의 회전속도에 의해 결정된다. 즉, 베어링의 기계적 치수가 아래의 그림2와 같을 때, 베어링의 바깥쪽 링에 고장이 발생한 경우와 안쪽 링에 고장이 발생한 경우, 그리고 베어링 불에 고장이 발생한 경우 나타나는 주파수는 식(5)로부터 각각 구할 수 있다[1].

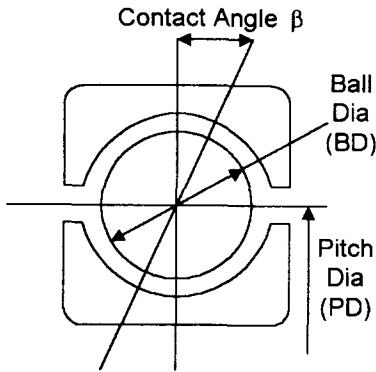


그림 2. 볼 베어링의 치수.
Fig. 2. Ball bearing dimensions.

바깥쪽 링 고장

$$f_o = f_e \pm k \left\{ \frac{n}{2} f_r \left[1 - \frac{BD}{PD} \cos \beta \right] \right\} \quad (1)$$

안쪽 링 고장

$$f_i = f_e \pm k \left\{ \frac{n}{2} f_r \left[1 + \frac{BD}{PD} \cos \beta \right] \right\} \quad (2)$$

베어링 볼 고장

$$f_b = f_e \pm k \left\{ \frac{PD}{BD} f_r \left[1 - \left(\frac{BD}{PD} \right)^2 \cos^2 \beta \right] \right\} \quad (3)$$

여기서 f_e 는 공급전원의 주파수, k 는 양의 정수, n 은 베어링 볼의 수이다. 대부분의 베어링은 6~12개의 볼을 가지며, 이 때, f_o 와 f_i 는 다음과 같이 근사화될 수 있다.

$$f_i = f_e \pm k (0.6 n f_r) \quad (4)$$

$$f_i = f_e \pm k (0.4 n f_r) \quad (5)$$

여기서 f_r 은 전동기의 회전속도이다.

3. 지능형 디지털 보호계전 알고리즘

3.1 비교사 학습에 의한 클러스터링 알고리즘

인공신경망에서의 클러스터링 알고리즘들은 각기 다른 데이터들의 유형들을 알고있어야 하는 경우가 대부분이다. 대표적인 예인 Hopfield Net[2]를 비롯하여 그의 변형 알고리즘과 많은 인공신경망 클러스터링 알고리즘들에서 인식되고 저장되는 패턴들이 서로 직교화되어 있음을 전제로 한다. 이는 네트워크 노이즈에 민감하게 한다. 이러한 의미에서 진정한 자기구성기능을 갖는 인공신경망으로 Carpenter와 Grossberg가 제안하였던 ART2[2]를 들 수 있다. 그러나, ART2의 클러스터링에 큰 비중을 차지하는 vigilance 파라미터는 같은 클러스터내의 두 데이터간에 존재할 수 있는 최대 차이를 규정하는 것으로서 데이터의 인식과정에서 기여하나 입력데이터의 신호대잡음비와의 관계를 명확히 규정해주지 못한다. 더욱이, 원하는 성능을 얻기위해 ART2를 미세조정하는 일은 많은 파라미터들을 연관시켜, 그 자체가 기술일만큼 데이터의 존성이 심하다.

Dignet[3]은 비교사 학습을 통해 노이즈가 포함된 입력을 저장, 분류할 수 있는 자기구성 인공신경망으로서, 경쟁에 의한 클러스터의 생성과 소멸에 근거한다. 새로운 클러스터는 클러스터들의 중심으로부터의 거리에 따라 새롭게 구분된 입력데이터들이 주변에 생성된다. 클러스터의 중심은 그 클러스터에 해당하는 입력데이터들의 최고 밀집지점으로 이동한다. 클러스터의 깊이는

학습의 강도를 나타내는 것으로서 데이터가 클러스터의 너비에 해당하는 경우 클러스터 중심이 갖는 관성에 영향을 준다. 즉, 클러스터의 깊이가 깊을수록 그것의 중심은 새로운 입력데이터쪽으로 멀 이동하게 된다. Dignet에서 입력데이터간의 유사성은 그들간에 이루는 각도에 의해 결정되며, 입력값의 크기에 영향을 받지 않도록 하기위해 입력은 정규화되어야 한다.

이미 여러개의 클러스터들이 생성되었다고 가정할 때, 새로운 입력데이터에 대한 Dignet은 다음과 같은 기능을 통해 클러스터링을 수행한다.

X_n 을 n 이라는 시점에서 Dignet에 입력된 데이터라고 하고 e_{n-1} 을 그때 존재하는 클러스터의 중심이라 하면, 그 중심은 다음과같이 변화한다.

$$e_n = \frac{c_n}{d_n} X_n + \frac{d_{n-1}}{d_n} e_{n-1}, \quad e_0 = 0 \quad (6)$$

여기서 d_{n-1} 은 시점 $(n-1)$ 에서의 깊이로서 다음과 같은 방법으로 계산된다.

$$d_n = d_{n-1} + c_n, \quad d_0 = 0 \quad (7)$$

그리고 c_n 은 아래와같은 값을 갖는 변수이다.

$c_n = 1$: 클러스터가 입력데이터를 획득하는 경우

0 : 입력데이터가 클러스터의 너비밖에 있는 경우 (8)

-1 : 입력데이터가 클러스터의 너비안에 있으나

획득하지 못하는 경우

입력데이터를 해당 클러스터의 중심(s)에 침가성 노이즈(n)가 침가된 것으로 생각한다면 $s+n = s+\Delta s$ 로서 클러스터 중심으로부터의 변위가 더해진 것으로 생각할 수 있다. 따라서, 클러스터 중심과 데이터간의 각도차를 유발하는 노이즈는 최악의 경우 클러스터중심과 직교하는 것으로 가정할 수 있다. 이러한 경우 피타고라스 정리에 의해, $\langle n, n \rangle + 1 = \lambda^2 = \langle s+n, s+n \rangle$ 이므로

$$\cos(\theta) = 1/\lambda = \frac{1}{\sqrt{1+\langle n, n \rangle}} \quad (9)$$

$\langle n, n \rangle = \sigma^2$ 라고 한다면,

$$\sigma^2 = 10^{-SNR/10} \quad (10)$$

따라서, 클러스터의 너비에관한 식은 다음과 같다.

$$\text{너비} = \sqrt{\frac{1}{1+10-SNR/10}} \quad (11)$$

일단 입력데이터가 Dignet에 입력되면, 클러스터들의 중심으로부터의 거리가 계산된다. 만약 가장 가까운 클러스터와의 거리가 클러스터 너비를 초과하면, 새로운 클러스터가 생성되고, 초과하지 않는다면 가장 가까운 클러스터의 깊이는 더 깊어진다. 만약 입력데이터가 두개 이상의 클러스터의 너비안에 속하게되면 가장 가까운 클러스터의 깊이는 깊어지고 새 데이터쪽으로 이동하며, 나머지 클러스터의 깊이는 알아지고 새 데이터로부터 멀어진다.

3.2 유도전동기 고장에 대한 적용

유도전동기의 입력전류는 주로 부하의 종류에따라 많은 변화가 있다. 그러나, 이러한 변화는 입력전류 형태의 주기적 반복으로 나타나는 것이 보통이다. 따라서, 정상운전의 경우 나타날 수 있는 입력전류의 주파수 스펙트럼 형태 또한 한정되어있다. 이를 연속적으로 전달되는 스펙트럼들을 클러스터링하여 살펴보면 정상상태에선 운전 및 부하특성에따라 한정된 클러스터가 생성된 후 더이상 새로운 클러스터는 생성되지 않는다. 그러나, 단상지락과같은 고장이 발생하면, 새롭게 발생하는 입력전류 파형으로 인해 기존의 정상상태에 속하지 않는 새로운 클러스터가 생성된다[4].

베어링 고장의 경우, 지락사고와는 달리 스펙트럼의 변화정도가 매우 작아, 스펙트럼의 형태가 거의 연속적으로 변화한다고 볼 수 있다. 클러스터들의 너비안에서 입력 데이터들이 연속적으로 변화하므로 클러스터의 중심또한 유입되는 데이터를 따라 이동하게되어 새로운 클러스터가 만들어 지기 힘들다. 이처럼 입력 데이터가 연속적으로 변화하는 경우를 검출하기 위해 Dignet의 SNR을 매우 작게하면 정상상태에서 나타날 수 있는 잡음, 또는 일시적 변동에 민감하여 과도한 클러스터가 생성될 수 있다. 이를 검출하기위해선 클러스터 중심의 이동을 살펴볼 필요가 있다. 즉, Dignet에 유입되는 주파수해석 결과를 다차원의 벡터라고 생각할 때, 베어링 고장은 특정 주파수를 중심으로 발견되는 것이 보통이므로 각 클러스터 중심을 가리키는 벡터들이 특정 차원쪽으로 연속적으로 이동해가는 것을 관찰하게된다.

4. 시뮬레이션 및 결과고찰

4.1 고장유형 시뮬레이션

유도전동기 고장유형 시뮬레이션에 사용된 유도전동기 모델은 다음과 같다.

최대 부하 전력 2.5388 MVA
 최대 부하 전압 4.2 kV
 최대 부하 슬립 0.015
 최대 부하 역률 0.85
 최대 부하 효율 90%
 회전자 관성 50 kg-m^2
 기계적 땀평 0.5 Nt-m/rad/sec
 동작 슬립 1%

유도전동기의 단상지락 모형을위한 시스템의 구성은 그림 3과 같다. 상A에 연결된 스위치는 4주기동안 접지와 단락된다. 이의 데이터는 28.8KHz의 주기로 EMTP 시뮬레이션에 의하였다. 이로부터 얻어진 데이터를 960Hz로 샘플링(60Hz 공급전원을 주기당 16번 샘플링)하였다.

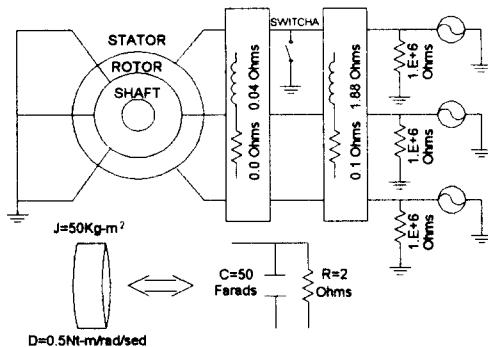


그림 3. 유도전동기 운전 모형.

Fig. 3. Model for induction motor operation.

베어링 고장의 경우 앞서 언급된 베어링의 고장유형중 f_0 에 대하여만 고려하였다. 고장 데이터를 얻기위해 EMTP 시뮬레이션에서 정상상태의 데이터에 시간에 따라 진폭이 점차 증가하는 주파수 f_0 의 파형을 추가하였다. 이에앞서, 베어링 고장으로 인한 f_0 주파수 주변에서의 변화는 초기엔 그 영향이 매우 작으므로, 정규화과정에서 공급전원의 파형에가려 검출하기가 어렵다. 정규화과정에서의 고장신호 소멸을 줄이기 위하여 노치(notch)필

터를 사용하여 공급전원 주파수 진폭을 감소시켰다.

위의 두 고장 유형의 시뮬레이션으로부터 상A의 입력전류값의 한 주기분(16개의 샘플)취하여 이를 FFT하여 그 결과를 Dignet의 입력으로 하였다.

4.2 결과

우선 단상지락시작의 경우, 그림4(a)에서 볼 수 있듯이 0.05초 지점에서 입력파형이 지락에 의해 급격히 변화하는 것을 알 수 있다. 이에따른 새로운 클러스터들의 생성을 그림4(b)에서 볼 수 있다.

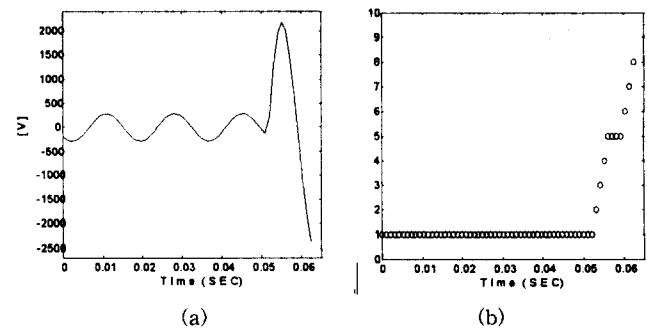


그림 4. One-phase ground fault and change of clusters

점진적으로 나타나는 베어링 고장현상을 보이기 위하여 그림5와같이 클러스터 중심의 각 차원의 변화로서 나타내었다. 클러스터 중심은 입력전류파형의 형태와 밀접한 관련이 있으므로, 행수가 클 수록 높은 주파수대에서 나타나는 현상을 대변하다고 볼 수 있다. 그림5(g)와 그 주변의 그림을 살펴보면, 클러스터의 중심을 나타내는 벡터의 7번째행에서 가장 높은 증가경향을 보이며 그 주변 주파수대에서도 증가추세를 보이는 것을 알 수 있다. 이는 공급전원보다 높은 주파수인 f_0 주변에서의 크기증가로 볼 수 있다. 그림5(a)와 (b)에서 반대로 크기가 감소하는 것은 f_0 주파수대의 진폭이 증가하였으므로 정규화과정에서 공급전원의 주파수대(그림(b))의 진폭이 상대적으로 감소하여 생긴 것으로 볼 수 있다.

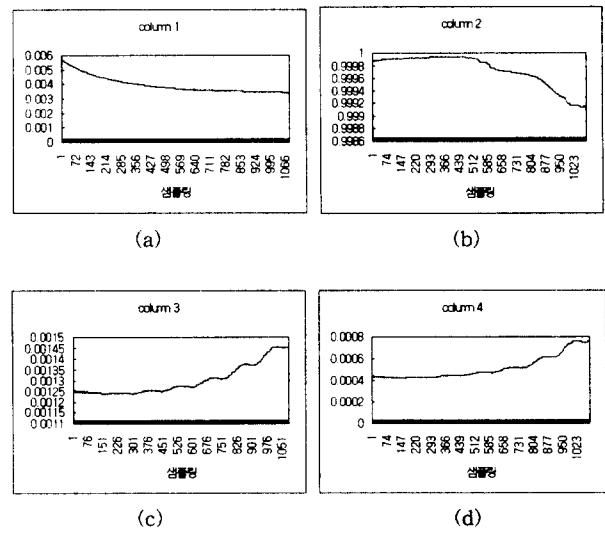


그림 5. 클러스터 중심의 이동(계속)

Fig. 5. Movement of center of a cluster(continued)

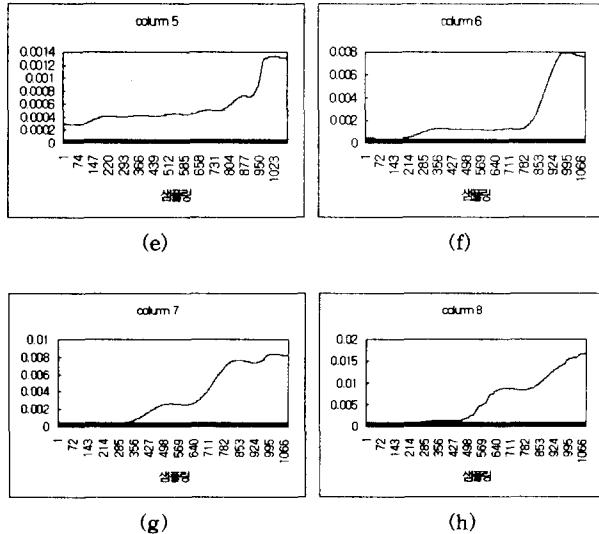


그림 5. 클러스터 중심의 이동
Fig. 5. Movement of center of a cluster

5. 결론

본 논문은 유도전동기의 고장에 가장 민감하게 반응하는 입력 전류 파형의 주파수 해석을 통해 이를 비교사 학습에 의한 클러스터링 알고리즘인 Dignet을 이용하여 클러스터링 한 후, 클러스터의 생성과 클러스터 중심의 이동으로써 고장을 검출하였다. 단상지락의 경우 급격한 입력전류의 변동으로 인한 새로운 클러스터의 발생을 통해 고장을 판정할 수 있었다. 베어링 고장의 경우 고장으로 인한 증상이 베어링의 기계적 구조와 부하특성에 의존하여 나타날 뿐 아니라 점진적이어서 새로운 클러스터의 생성보다는 클러스터링 중심의 편향적 이동으로부터 베어링 고장을 검출하였다. 이러한 알고리즘은 기계적 사양, 또는 운전경험에 의한 전문가를 필요로 하지 않는 점을 특징으로 하며, 앞으로 다른 고장유형들에 대한 적용이 필요하다.

참고문헌

- [1] Farrukh Kamran, Robert G. Bartheld, Randy R. Shoen, Thomas G. Gabetler, "Motor Bearing Damage Detection Using Stator Current Monitorin", IEEE Transc. Industry Applications, Vol. 31, No 6, November, 1995.
- [2] Laurene Fausett, "Fundamentals of neural networks architectures, algorithms, and applications", Prentice-Hall, Inc 1994.
- [3] Chin-Der Wann, Dimitrios K. Bougoulias, Stelios C. A. Thomopoulos, "Dignet: An Unsupervised-Learning Clustering Algorithm for Clustering and Data Fusion", IEEE Transc. Aerospace and Electronic Systems, Vol. 31, No. 1, January 1995.
- [4] Brian K. Lin, Jay H. Schlag, Randy R. Schoen, Thomas G. Gabetler, "An Unsupervised, On-Line System for Induction Motor Fault Detection Using Stator Current Monitoring", IEEE Trans. Industry Applications, Vol. 31, No. 6, November, 1995.