

İleri işaret işleme yöntemleri ile elektrik motorlarında rulman arıza tanısı

Emine AYZAZ*, Serhat ŞEKER

İTÜ Elektrik Elektronik Fakültesi, Elektrik Mühendisliği Bölümü, 80626, Maslak, İstanbul

Özet

Bu çalışmada asenkron motorlarda öngörülü bakım teknolojisine dayalı, rulman arıza gelişimi üzerine bir inceleme gerçekleştirilmiştir. Rulman arızası, hızlandırılmış eskitme süreçleri ile yapay olarak oluşturulmuştur. Motordan alınan titreşim ve akım işaretlerinin istatistiksel ve dalgacık analizi sonucu rulman arızasına ilişkin özellik çıkarımı yapılmıştır. Bu işaretlerin bir arada değerlendirilmesi ile koherens fonksiyonu tanımlanarak rotor eksenel bozukluğunu gösteren en baskın frekans değeri belirlenmiştir. Bu anlamda işaretler arasındaki ilişki, bir yapay sinir ağına öğretilerek (YSA), arıza frekanslarının YSA ile belirlenebildiği gösterilmiştir. Genetik algoritma yaklaşımı da YSA çıkışlarındaki maksimum hatayı bulmak için kullanılmıştır. Böylece YSA ve GA tabanlı hibrit bir yapay zeka izleme sistemi oluşturulmuştur.

Anahtar Kelimeler: Asenkron motor, dalgacık, titreşim, yapay sinir ağları, arıza tanısı, öngörülü bakım.

Bearing fault diagnosis in electric motors by advanced signal processing techniques

Abstract

This paper presents to detect the motor bearing failures for predictive maintenance purpose using the accelerated aging studies based on bearing flutings in electric motors. In terms of the bearing damage, feature extraction from vibration signals in electric motors was realized using the wavelet analysis. And an early detection criterion was developed by means of the statistical analysis of the motor vibration signals. Also, considering both of the motor current and vibration signals, correlation between these signals is shown by the coherence function, which is defined in frequency domain. Hence, most dominant frequencies related to rotor eccentricity caused by the bearing failures can be easily determined. These computed coherence functions defined for each aging cycle from initial case to final case are used as training and recall data set for an Artificial Neural Network (ANN). With this way, it is shown that ANN provides a very good performance in terms of the motor failure detection. Also, standard Genetic Algorithm (GA) approach is used to find the maximum amplitude, which indicates the faulty case of the bearings, by error signals at output nodes of the ANN. Hence, a hybrid Artificial Intelligence technique, which is based on ANN and GA methodologies, is implemented for motor condition monitoring studies.

Keywords: Induction motors, wavelet, vibration, artificial neural networks, fault detection, predictive maintenance.

*Yazışmaların yapılacağı yazar: Emine AYZAZ. ayaz@elk.itu.edu.tr; Tel: (212) 285 67 56.

Bu makale, birinci yazar tarafından İTÜ Elektrik Elektronik Fakültesi'nde tamamlanmış olan "Elektrik motorlarında dalgacık analizi yaklaşımı ile rulman arıza tanısı ve yapay zeka tabanlı bir durum izleme sistemi" adlı doktora tezinden hazırlanmıştır. Makale metni 04.02.2002 tarihinde dergiye ulaşmış, 22.07.2002 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 31.12.2002 tarihine kadar dergiye gönderilmelidir.

Giriş

Motor sistemleri modern toplumda önemli bir yere sahiptir. Örneğin bir çok endüstriyel tesiste her tip ve boyutta çok sayıda elektrik motoru kullanılır. Bu makinalar işletimleri sırasında elektriksel, mekaniksel, termal ve çevresel bir çok zorlanmalara maruz kalarak beklenmedik bir şekilde bozulurlar ve sistem arızasına yol açarlar (Bonnert ve Soukup, 1992). Sistemde ani kesilmelerin önlenmesi ve güvenilirliği arttırmak amacıyla ise işletmelerde bakım planlaması yapılır (O’Kane ve Sander, 2000). Bu planlamada arıza sonrası bakım ve periyodik bakımın yanı sıra bu makinaların durumu izlenmesi sonucunda referans duruma göre olabilecek değişiklikler gözlenir ve gerekli önlemler alınır. Bu amaçla son senelerde öngörülü bakım (predictive maintenance) programları geliştirilmiştir (King, 2000). Bir işletmede öngörülü bakım programının olması hiç olmamasına göre avantajlıdır, fakat her iki durumda da arızalı kısmı değiştirme ve problemin kaynağını düzeltme, muhtemelen erken arıza ile sonuçlanır. İlerideki bakım maliyeti ve kesintiyi azaltmak için öngörülü bakım teknolojilerini geliştirenler, son senelerde makina arızalarının ana nedenlerine (root cause) derinlemesine bakma yolunda ek bir çaba harcamaktadır. Bir makinanın herhangi bir yerindeki problemin nedeni tespit edildiğinde bu problemi ortadan kaldırmak ya da en aza indirmek için gerekli önlemler alınır ve dolayısıyla da makina ömrü uzar. Bu anlamda çeşitli modern teknikler geliştirilerek, bu alanda uygulanmaya başlanmıştır. Bu modern tekniklerin çoğu yapay zeka uygulamalarının yapıldığı akıllı sensör ve motor izleme sistemleridir. Asenkron motorlardaki üç ana kategorideki hatalar ve bunların oluşum sıklıkları şöyledir: stator hataları (%36), rotor hataları (%9), rulman hataları (%41), diğer hatalar (%14) (Smiley, 1992). Bu çalışmada ise asenkron motorların bilyalı rulmanlarındaki hataları erken teşhis etmek amacıyla yapay sinir ağları üzerine kurulmuş yeni bir arıza izleme sistemi geliştirilmiştir. Çalışmada kullanılan veriler *The University of Tennessee* (USA), Nükleer Mühendislik Bölümü’nde hazırlanan akıllı motor izleme sisteminde alınmıştır (Erbay ve Upadhyaya, 1999). Hızlandırılmış eskime süreçleri uygulanarak

asenكرون motorlar, çeşitli termal ve kimyasal etkiler altında laboratuvar ortamında yaşlandırılmıştır. Bu etkilerin yanı sıra her eskime sürecinden sonra motor miline dışardan akım ve gerilim vermek suretiyle mil akımı ve geriliminin oluşması sağlanmış ve bu akımın rulmanlar üzerinden geçmesi nedeniyle rulmanda meydana getireceği bozulmalar yapay olarak oluşturulmuştur (Costello, 1993; Kowal, 1999). Her eskime sürecinden sonra bir dinamometreye bağlı olan bu motordan çeşitli sensörler yardımıyla titreşim, akım, gerilim, sıcaklık, hız, moment gibi veriler bir veri toplama sistemine ve oradan da analiz için kişisel bilgisayara aktarılmıştır. Bu yolla motor performans testleri gerçekleştirilmiştir. Performans testleri sonucunda elde edilen titreşim işaretlerinin dalgacık analizi ile arıza özelliği çıkartılmış, istatistiksel analiz ile de erken arıza tanısı gerçekleştirilmiştir. Ayrıca motor akım ve titreşim işaretleri arasındaki ilişki irdelenerek, bu ilişki Yapay Sinir Ağı’na öğretilerek, Genetik Algoritma uygulaması da yapılarak, yapay zeka tabanlı bir motor durum izleme sistemi oluşturulmuştur.

Dalgacık dönüşümü ve çok çözünürlü analiz (ÇÇA)

$L^2(R)$ sonlu enerjili işaretler için bir vektör uzayını göstermek üzere, $x(t)$, $L^2(R)$ uzayında tanımlanan bir işaret olsun. Burada R gerçel sayılar kümesidir. Bu durumda sonlu enerjili işaretler:

$$\int_{-\infty}^{\infty} |x(t)|^2 dt < \infty \quad (1)$$

bağıntısını sağlarlar ve $x(t)$ nin sürekli dalgacık dönüşümü de:

$$CWT_{\psi} x(a,b) = W_x(a,b) = \int_{-\infty}^{\infty} x(t) \psi_{a,b}^*(t) dt \quad (2)$$

olarak tanımlanır. İntegral içindeki $\psi_{a,b}(t)$ fonksiyonu ise, normalize edilmiş olarak:

$$\psi_{a,b}(t) = |a|^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad (3)$$

şeklinde verilebilir. Burada $\psi(t)$ baz fonksiyonu ya da ana dalgacığı, (*) sembolü kompleks eşle-

niği ve a, b parametreleri ise $a, b \in R, a \neq 0$ olmak üzere sırasıyla genişleme ve öteleme parametrelerini gösterir. Sürekli genişleme ve öteleme parametreleri yerine, $a = a_0^m, b = nb_0 a_0^m$ şeklindeki ayrık parametreleri tanımlamak müm-kündür. Burada a_0, b_0 sabit sayılar olup, $a_0 > 1, b_0 > 0$ koşullarını sağlar. Ayrıca m, n sayıları da, Z tam sayılar kümesinin elemanlarını oluşturur. Bu durumda ayrıklaştırılmış ana dalgacık:

$$\psi_{m,n}(t) = a_0^{-m/2} \psi\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) \quad (4)$$

haline gelir ve ayrık parametrelili dalgacık dönüşümü:

$$DWT_{\psi} x(m, n) = \int_{-\infty}^{\infty} x(t) \psi_{m,n}^*(t) dt \quad (5)$$

ile verilir. a_0, b_0 'ın uygun seçimiyle ana dalgacık ailesi $L^2(R)$ 'nin ortonormal bazını oluşturur. a_0 ve b_0 'ın uygun seçimleri $a_0 = 2$ ve $b_0 = 1$ değerleri için dalgacık dönüşümü, diadik-ortonormal dalgacık dönüşümü adını alır. Bu durumdaki ortonormal bazın önemli özelliklerinden birisi ise a_0 ve b_0 'ın yukarıdaki gibi seçimiyle, işareti farklı zaman ve frekans çözünürlüklü ölçeklere ayrıştırmayı sağlayan ve *çok çözünürlü dalgacık analizi (ÇÇDA)* denilen algoritmanın kullanılabilmesidir.

Bu çalışmadaki uygulamanın ana konusunu oluşturan *çok çözünürlü işaret ayrıştırması* ise aşağıdaki gibi şu şekilde verilir: $c_0(n)$, fiziksel bir ölçme cihazından kaydedilen bir ayrık zaman işareti olsun. Bu işaret, yaklaşım ve detay gösterimi denilen iki ayrı frekans aralığına ayrıştırılabilir. Bu anlamda çok çözünürlü işaret ayrıştırma tekniği kullanılarak ölçek 1'de ayrıştırılmış işaretler $c_1(n)$ ve $d_1(n)$ olur. Bu durumda $c_1(n)$, orijinal işaretin yaklaşım versiyonunu ve $d_1(n)$ 'de, işaretin dalgacık dönüşümü formundaki detay gösterimini oluşturur. Bunlar sırasıyla:

$$c_1(n) = \sum_k h(k - 2n) c_0(k) \quad (6)$$


$$d_1(n) = \sum_k g(k - 2n) c_0(k) \quad (7)$$

olarak tanımlanırlar. Burada $h(n)$ ve $g(n)$, $c_0(n)$ 'i, $c_1(n)$ ve $d_1(n)$ 'e ayrıştıran birleşik filtre katsayılarıdır. Bir sonraki ölçek ayrıştırılmasında ise, yine $c_1(n)$ işareti temel alınır. Bu durumda ölçek 2'deki ayrıştırılmış işarete ilişkin yaklaşım ve detay katsayıları ise:

$$c_2(n) = \sum_k h(k - 2n) c_1(k) \quad (8)$$

$$d_2(n) = \sum_k g(k - 2n) c_1(k) \quad (9)$$

ile verilebilir. Böylece daha yüksek seviyelerdeki ölçek ayrıştırmaları da benzer yolla sürdürülebilir. Çok çözünürlü işaret ayrıştırma tekniğinin iki ölçeğe göre gerçekleştirilmesi Şekil 1'deki gibi gösterilebilir (Mallat, 1989).




Şekil 1. $c_0(n)$ 'nin 2 ölçeğe ayrıştırılması.

Motor rulmanlarında arıza oluşturma ve arıza tanısı

Bu çalışmada rulman arızasına sebep olan elektriksel boşalmanın benzetimi için aşağıdaki gibi bir deney düzeneği oluşturularak yapay rulman arızaları oluşturulmuştur.


Şekil 2'den de görüldüğü gibi şafta dışarıdan 27 A'lık bir akım uygulanmıştır. Bu şekildeki rulman eskitmesinin yanı sıra ayrıca yedi aşamada uygulanan termal ve kimyasal eskitme süreçleri de gerçekleştirilmiştir. Her süreçten sonra eskitme hızlanmış ve motor bir test platformu üzerinden başarımlı (performans) testinden geçi-



Toprak

Şekil 2. Rulman eskitmesi.

rilmiştir. % 0–115’lik yük altında gerçekleştirilen başarım testinde rulman arızasının analizinde kullanılacak olan titreşim işareti Şekil 3’deki A-A’ kesitine göre 2 numaralı konumdaki titreşim algılayıcısından alınmıştır.



Şekil 3. Motor başarım testi ve algılayıcı yerleri.

Motor eksenel bozukluğu için arıza frekanslarının tanımlanması

Elektrik makinalarında, rotor-stator arasındaki ilişki bu iki parça arasındaki hava aralığından geçen magnetik akı ile sağlanır. Eğer hava aralığı rotorun 360 derecelik çevresi boyunca simetrik olarak dağılmamışsa, o zaman motor içinde düzgün olmayan magnetik alanlar oluşur. Bu magnetik dengesizlikler stator sargılarının hareketine sebep olan kuvvetleri oluşturur ve sonuç olarak sargılarda tahribata sebebiyet verir ve titreşimler oluşturur. Rotor ve stator arasındaki bu tip bir arıza durumu çoğu zaman rotor eksenel kaçıklığı (bozukluğu) olarak nitelendirilir. Benzer şekilde, hava aralığı içindeki magnetik akı yoğunluğundaki bozulmaları üreten bu eksenel kaçıklıklar, rulman kaynaklı titreşimlerle stator akımları arasındaki spektral ilişki ile de belirlenebilir. Çünkü söz konusu bu eksenel bozukluk magnetik akıda değişimlere sebep olur ve motor endüktansları üzerindeki etkisi ile stator akımlarında harmonikler üretir. Bu olaya ilişkin ilgili frekanslar aşağıdaki eşitlik ile öngörülebilir (Schoen v. diğ., 1995):

$$f_{ecc} = f_e \left[1 \pm k \left(\frac{1-s}{p/2} \right) \right] = |f_e \pm kf_r| \quad (10)$$

Burada f_e şebekenin temel frekansı olup sırasıyla k -pozitif bir tam sayı, s -kayma, p -motor kutup sayısı ve f_{rm} 'de rotor dönme frekansdır.

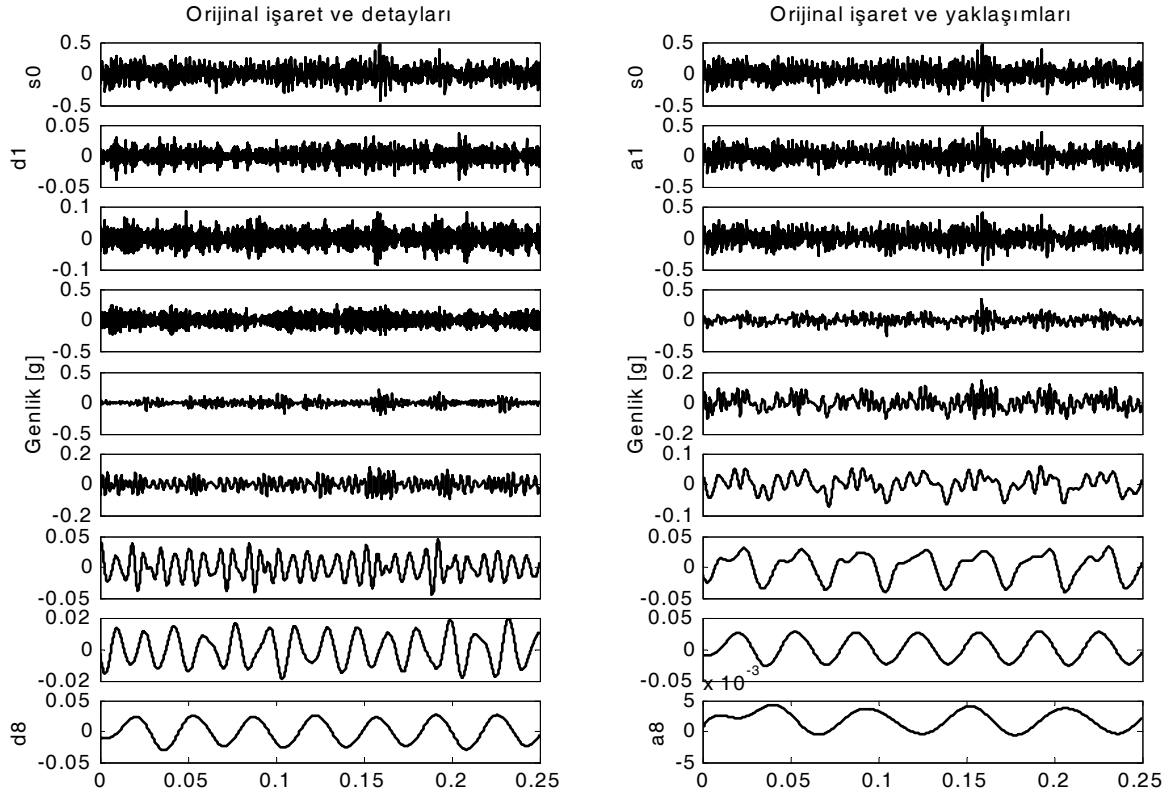
Dalgacık analizi ile titreşim işaretlerinden rulman arızasına ilişkin özelliğin çıkartılması

5 HP’lik 3 fazlı, 4 kutuplu asenkron makinanın yedi eskime süreci sonrasında motor performans testi yapılmıştır. Bunun sonucunda %100 yük altında her bir eskime süreci ile birlikte sağlam durumu da içerecek şekilde toplam 8 aşamadan oluşan, 12 kHz’lik örnekleme frekansına sahip titreşim işareti Şekil 3’teki 2 numaralı algılayıcıdan alınmıştır. Toplam 10 s’lik ölçme sonunda elde edilen bu titreşim işaretinin 0.25 s’lik kısmı bu çalışmanın dalgacık analizi kısmı için kullanılmıştır. Bu amaçla işaret, Tablo 1’de verildiği gibi 8 ayrı seviyede frekans alt bandlarına ayrıştırılmış ve bunlar Şekil 4 ve Şekil 5’te gösterilmiştir. Çok Çözünürlü Dalgacık (ÇÇD) Analizinin makinanın başlangıç (sağlam) ve son eskitme (arızalı) aşamasına ilişkin verilere uygulanması sonucunda aşağıda gösterildiği gibi, yaklaşım ve detay katsayılarının değişimleri elde edilmiştir.


Tablo 1. Titreşim işaretinin frekans alt bandları

Yaklaşımlar (a)	Alt bandlar (a) [Hz]	Detaylar (d)	Alt bandlar (d) [Hz]
a1	0 – 3000	d1	3000 – 6000
a2	0 – 1500	d2	1500 – 3000
a3	0 – 750	d3	750 – 1500
a4	0 – 375	d4	375 – 750
a5	0 – 187.5	d5	187.5 – 375
a6	0 – 93.75	d6	93.75 – 187.5
a7	0 – 46.88	d7	46.88 – 93.75
a8	0 – 23.44	d8	23.44 – 46.88

Analizde kullanılan dalgacık tipleri Shannon entropi fonksiyonu şeklinde tanımlanmış enerji fonksiyonunun minimize edilmesiyle saptanmış olup, sağlam durumda s0 verisi için Deubechies-20, yedinci eskitme aşaması sonucunda elde edilen s7 verisi için ise Deubechies-15 dalgacık tipleri kullanılmıştır. Buna göre 0-7 arasındaki tüm süreçlerin d1 detay değişimlerine ve işaretin kendisine ait RMS değerlerinin hesaplanması




Şekil 4. Başlangıç durumu için titreşim (s_0) verisinin ÇÇD analizi. a) Detaylar, b) Yaklaşımlar.



Şekil 5. Yedinci eskitme aşamasında titreşim (s_7) verisinin ÇÇD analizi. a) Detaylar, b) Yaklaşımlar

sonucunda, en iyi iki eğilimin 1.5-3 ve 3-6 kHz lik alt bandlarında olduğu gözlenmiştir. Bu durum Şekil 6'dan da görülebilmektedir. Böylece bu iki frekans aralığı rulman arızasına ilişkin özelliği de tanımlamış olur.




Şekil 6. Titreşim işaretinin kendisi ve d1, d2 detaylarının tüm süreçler için RMS değişimi.

Yapılan bu analize göre Şekil 6'dan da görüleceği gibi rulman arızasını en iyi karakterize eden frekans aralığı, bozukluğu gösteren bir özellik olarak, ÇÇD analizinin d1 detaylarından saptanmıştır. Bu durumda 3-6 kHz alt bandlarına ilişkin (d1) işaretlerinin Kısa-Zaman Fourier Dönüşümünün (KZFD) alınmasıyla da, söz konusu bu özelliğin şekil 7b'deki gibi 2-4 kHz arasında olduğu belirlenmiştir. Burada işaretin d1 detayı için frekans aralığının 3-6 kHz arasında tanımlı olmasına rağmen, 4 kHz'e kadar olan değişimin gözlenmesinin nedeni, bu frekans değeri sonrası için filtreleme yapılmış olmasıdır.


Titreşim işaretlerinin istatistiksel analizi ve erken arıza uyarı seviyesinin belirlenmesi

Rulman eskitme süreçleri sonrasında toplanan titreşim algılayıcı bilgisine ilişkin veri analizi gerçekleştirilerek, birinci momentten dördüncü momente kadar olan istatistiksel parametreler tüm eskitme (yaşlanma) süreçleri için Tablo 2'deki gibi hesaplanmıştır.

Hesaplanan bu büyüklükler vasıtasıyla makina durum farklılıklarının istatistiksel parametrelerden sadece standart sapma değerlerindeki değişiklik-



(a)




(b)


Şekil 7. d1 detaylarına ilişkin KZFD analizi
a) Sağlam durum, b) Bozuk durum.

Tablo 2. Eskitme süreçleri için hesaplanmış istatistiksel büyüklükler

Eskitme Aşamaları	Aritmetik Ortalama	Standard Sapma	Çarpıklık	Basıklık
0	1,23E-03	0,11	0,044	3,02
1	2,11E-03	0,15	-0,033	2,97
2	5,28E-04	0,21	-5,22E-02	3,00
3	2,51E-04	0,28	-2,28E-03	3,04
4	3,97E-04	0,34	-0,020	3,01
5	1,92E-03	0,35	-0,027	2,93
6	-3,18E-04	0,43	-0,0432	2,99
7	1,13E-02	0,63	-0,070	2,99



Şekil 8. Titreşim işaretleri. a) Sağlam, b) Bozuk durum



Şekil 9. Olasılık dağılım fonksiyonları. a) Sağlam durum, b) Bozuk durum

lere bağlı olduğu kolaylıkla gösterilebilir. Çünkü Tablo 2'ye göre her bir durum için ortalama değer yaklaşık olarak sıfırdır. Ayrıca, çarpıklık ve basıklık parametrelerinin bütün durumlar için sırasıyla $c = 0$ ve $k = 3$ yaklaşık değerlerini almasından dolayı olasılık yoğunluk fonksiyonlarının da normal dağılımlı kaldığı gözlemlenmiştir. Motor titreşim işaretlerinin sağlam ve yedinci eskitme aşaması sonundaki değişimleri ile bunların olasılıksal dağılım fonksiyonları ise Şekil 8 ve Şekil 9 ile gösterilmiştir.


Rulman bozulma modeli ve erken arıza tanısı

Rulman arızasının ortaya çıktığı süreç bir arıza belirleme seviyesi ile saptanmıştır. Buradaki arıza belirleme seviyesi özellikle normal dağılım-

lı işaretlerde genlik değerlerinin 3σ seviyesini aşma kriterine göre belirlenmiş olup, istatistiksel parametreler bakımından da en baskın parametrenin standart sapma değeri (veya varyans-2.moment) olduğu gösterilmiştir. Bu anlamda başlangıç durumundaki $3\sigma_0$ değeri temel alınarak $\pm 3\sigma_0$ aralığında %99.7 olasılıkla, gözlenen durumunun sağlam olduğu kabul edilebilir ve bunu aşan standart sapma değerleri ise bozuk duruma karşı gelen değerler olarak tanımlanabilir. Bu amaçla tanımlanan *Kritik Standart Sapma* (KSS) değeri ($KSS = \mu_0 + 3\sigma_0$) olarak verilebilir. Ayrıca standart sapmanın değişimi üzerine kurulan bir modelle de eskime sürecinin üstel bir modeli aşağıdaki gibi verilmiştir:

$$\sigma_n = \sigma_0 \exp\left[\frac{n}{4}\right] \quad (11)$$

Burada n , herhangi bir eskitme sürecini temsil eden tam sayı olup, σ_0 ve σ_n sırasıyla sağlam ve herhangi bir bozuk durum için standard sapma değerleridir.



Şekil 10. Standard sapmanın değişimi üzerine dayalı, üstel model ve arıza uyarı seviyesi

Bu modelden hareketle, her bir aşamada motor rulmanlarının sağlamlığına ilişkin bir güvenilirlik seviyesi aşağıdaki tanım yardımıyla verilebilir.

Tanım:


Gözönüne alınan normal dağılımlı, ardışık yaşlanma süreçleri arasında en baskın parametre standard sapma olarak saptanmışsa, yaşlanma süreci boyunca sağlam kalma derecesini veren büyüklük, sağlam ve herhangi bir bozulma seviyesindeki standard sapma değerleri arasındaki oran ile verilebilir:

$$r_n \triangleq \frac{\sigma_0}{\sigma_n} \quad (12)$$

Denklem (12) vasıtasıyla $n=0$ 'dan $n=7$ 'ye kadar olan bütün aşamalarda rulman sağlamlığının yüzde cinsinden derecesi kolayca gösterilebilir. Ayrıca bu oran, Denklem (11) yardımıyla güvenilirlik oranı olarak da yorumlanabilir.

Ayrıca, rulman arızasının gelişiminin, ortaya konulan kritik standard sapma (KSS) veya arıza

uyarı seviyesi yardımıyla, dördüncü süreçte başladığı saptanmıştır. Rulman yaşlanmasının üstel modeli de verilerek, Denklem (12) ile her bir aşamadaki sağlamlığın yüzde olarak ($\%R_n$) derecesi $R_n = r_n \times 100$ olarak tanımlanmış ve buna ilişkin değişim ise Şekil 11'de gösterilmiştir. Buna göre dördüncü aşama öncesinde sağlamlık oranı yaklaşık olarak %40 mertebesindedir.



Şekil 11. Motor rulmanının eskitme aşamalarına göre sağlamlık yüzdeleri

Motor akım ve titreşim işaretlerinin melez bir yapay zeka sistemi ile izlenmesi

Asenkron motor arızaları içerisinde daha sık görülen rulman arızalarının erken teşhisi amacıyla kullanılan standard yaklaşım, titreşim izleme tekniğidir. Rulman bozukluğunun rotor-stator arasındaki hava aralığının değişmesine neden olacağı ve buradaki magnetik akı değişiminin motorun çektiği akıma etkiyeceği düşüncesinden hareketle stator akımının izlenmesi, rulman bozukluğunu belirlemede kullanılabilir (Schoen v. diğ., 1995; Seker, 2000; Seker v. diğ., 2000). Bu anlamda farklı tip hataların, titreşim ve akım işaretlerinde farklı özellikler meydana getireceği gerçeğinden yola çıkarak bu işaretlerin zaman ve frekans tanım bölgesi analizleri yapılabilir.

Son yıllarda uzman sistem, yapay sinir ağları (YSA), bulanık mantık ve genetik algoritma gibi yapay zeka teknikleri asenkron motor durum izlemesinde uygulanmıştır (Filippetti v. diğ., 2000; Li v. diğ., 2000). Yapay sinir ağının

avantajı giriş ve çıkış arasındaki kompleks ilişkinin matematiksel model olmaksızın kurulabilmesidir. Bu çalışmada hızlandırılmış eskime süreçlerinden alınan titreşim ve akım işaretlerinin zaman ve frekans domenindeki özellikleri incelenerek arızaya neden olabilecek hatanın ayrıntılı tanımlanması amacıyla ve gerçek zaman uygulamalarında da kullanılabilir bir şekilde yapay sinir ağı modeli oluşturulmuştur. Kullanılan YSA modeli standart geriye yayılım (back-propagation) algoritmasıdır. Bu yapay sinir ağının eğitimi motor eskitme aşamalarından elde edilen veriler üzerinden 256 noktada hesaplanan koherens genlikleri ile yapıldıktan sonra başarımlı testi yapılmış ve motor durumunu izleme amacıyla uygulanabileceği görülmüştür. Bu amaçla kullanılan YSA modeli, giriş-çıkış büyüklükleri 0-6 kHz band genişliğinde 256 frekans noktasındaki genliklerle tanımlanmış olan ve 100 elemandan oluşan tek ara katmanlı oto-asosiyatif bir topolojiye sahiptir (256x100x256). Arıza belirleme ise YSA'nın üreteceği yanılğı (error) miktarının gözlemlenmesi ile gerçekleştirilmiştir. Bu anlamda yanılğının büyük genlik değerleri gösterdiği YSA çıkışları, aynı zamanda arızanın ortaya çıktığı frekans değerlerini de işaret edebilmektedir. Buna ilişkin olarak rulman arızasına dayalı motor eksenel bozukluk frekanslarının YSA tabanlı bir izleme sistemi ile belirlenmesi, uygulama bölümünde gösterilmiştir.

İşaretler arası ilişkinin matematiksel ifadesi

İki sürece ilişkin çapraz güç yoğunluğu spektrumu


bu iki süreç arasındaki benzerliğin bir ölçüsüdür. İki rastlantısal sürecin koherensi aşağıda tanımlandığı gibi çapraz-güç yoğunluğu spektrumunun normalize edilmiş şekli ile verilebilir:

$$C_{XY}(f) = \frac{P_{XY}(f)}{\sqrt{P_{XX}(f)P_{YY}(f)}} \quad (13)$$

Burada P_{xx} ve P_{yy} , sırasıyla $X(m)$ ve $Y(m)$ süreçlerinin öz-güç spektrumudur. Koherens fonksiyonu esas olarak verilen işaretler arasındaki benzerliğin bir ölçüsünü verir ve çapraz korelasyon fonksiyonu ile ilintilidir. Daha özel olarak, koherens bir işaretin diğer bir işaret üzerindeki lineer bağımlılığının bir ölçüsüdür.

YSA uygulaması

5 HP'lık 3 faz 4 kutuplu asenkron motorun yedi eskime süreci sonrasında motor performans testi yapılarak %100 yük altında her bir eskime süreci ile birlikte sağlam durumu da içerecek şekilde toplam 8 aşamadan oluşan, 12 kHz'lik örnekleme frekansına sahip motor titreşim ve akım işaretleri alınmıştır. 10 s'lik ölçme sonunda elde edilen bu verilerin 0.25 s'lik kısmı bu çalışmanın spektral analizi için kullanılarak akım ve titreşim işaretleri arasındaki koherens-ler hesaplanmıştır. Şekil 12'de, motor rulmanlarının sağlam ve yedinci eskitme aşamasına ilişkin olarak koherens değişimleri gösterilmektedir. Buradan görüleceği gibi son aşamadaki 234 ve bunun yaklaşık ikinci harmoniği olan 469 Hz, arızayı temsil eden en baskın frekanslardır. Bu anlamda Denklem (10)'da $f_e = 60$ Hz, $f_{rm} = 1742$ de-



Şekil 12. Akım ve titreşim arasındaki koherens değişimleri a) Sağlam durum b) Bozuk durum


vir/dak. = 29.03 Hz ve $k = 6$ alarak, motor eksenel bozukluğunu gösteren frekansın 234 Hz olduğu kolayca saptanabilir. 469 Hz’de bu frekansın ikinci harmoniği gibi yorumlanabilir.

YSA uygulaması bakımından ise yukarıda gösterilen koherenslerin tümü, sırasıyla motorun sağlam ve toplam yedi eskitme aşaması için ayrı ayrı hesaplanarak YSA giriş-çıkış çiftlerine Şekil 13’deki gibi uygulama verileri olarak kullanılmıştır.

Koherens hesaplamalarından elde edilen toplam sekiz veri setinin ilk beş tanesi $lr=0.1$ ’lik öğrenme oranı ile öğrenme süreci için kullanılırken son üç veri kümesi de geri çağırma sürecinde kullanılmıştır. $256 \times 100 \times 256$ ’lık YSA yapısının sağlam ve bozuk durumlara ilişkin başarımı ise Şekil 14’ten görüleceği gibi çıkışlarında ürettikleri yanılgi miktarları ile denemiştir. Bu durumda 5000 iterasyon sonucunda YSA’nın eriştiği toplam karesel hata miktarı $TKH=0.1197$ ’dir.

Bu durumda Şekil 14b’den görülebileceği gibi YSA, 234 ve 469 Hz’de oluşturduğu büyük yanılgiyla, motorda rulman bozukluğu nedeniyle ortaya çıkan rotor eksenel bozukluğunu kolayca belirleyebilmiştir.


Ayrıca standart Genetik Algoritma uygulamasının YSA çıkışlarına uygulanması ile de en büyük genliğin olduğu arıza frekansı otomatik olarak belirlenebilir.



Şekil 13. Koherenslerin YSA yapısına uygulanması


Genetik algoritma uygulaması

Her eskitme aşaması için, motor akımı ve titreşim işaretleri gibi ölçümlerden hesaplanan koherens fonksiyonları oto asosyatif nöral ağa uygulanması sonucu bu nöral yapısı rulman bozukluğunu tanımlamaya yardım eden bir hata işareti üretmiştir. Burada, hata işaretinin maksimum genlik veya tepe değeri ise standard GA yaklaşımını (Vonk ve diğ., 1997) kullanarak tespit edildi. Şekil 15’de hata değişiminin tepe değeri ve uygunluk fonksiyonu gösterilmiştir. Bu yüzden, GA, 469 Hz’deki maksimum noktayı kolaylıkla bulmuştur. Bu frekans motor rulmanlarındaki bilye hata frekansıdır. Şekil 15’te (*) sembolü ve (o) sembolü sırasıyla en iyi kromozomu ve başlangıç popülasyonundan seçilen kromozomları gösterir. Uygunluğun değişiminde, düz çizgi en iyi çözümü gösterirken kesikli çizgi popülasyonun ortalama uygunluğunu gösterir.



Şekil 14. YSA’nın koherens işaretlerine cevapları. a) Sağlam durum, b) Bozuk durum.


Ayrıca bu uygulamada, 200 kromozom kullanılarak 25 iterasyon sonunda bu çözüm bulunmuştur.



Şekil 15. GA uygulamasının sonuçları

Motor durum izleme sistemi olarak YSA ve GA tabanlı bir yapay zeka sisteminin kullanılması

Bilgi işleme ve yapay zeka tekniklerine dayalı akıllı durum izleme sistemi kurmak için koherens analizinden sonra hem YSA hem de GA birleştirilmiştir. Burada YSA, frekans tanım bölgesinde hatalı durumu işaret eden büyük genlikte hata üretir. GA'da, hatalı rulman (veya motor) nedeniyle YSA'nın ürettiği bu hata işaretindeki tepe değeri seçer ve bu özel frekans bir arıza modu olarak tanımlanabilir. Şekil 16'da tüm süreç gösterilmiştir.



Şekil 16. YSA ve GA tabanlı bir akıllı motor durum izleme sistemi.

Sonuçlar

Bu çalışmada ele alınan 5 HP'lik asenkron motorun rulmanları dış devreden beslenen harici bir akımla, toplam yedi aşamada yapay olarak

bozularak çeşitli elektriksel ve mekanik veriler toplanmıştır. Mekanik veri anlamında kullanılan motor titreşim işaretlerinin dalgacık analizi vasıtasıyla alt bandlara ayrılması ile rulman arızasını karakterize eden özelliğin 2-4 kHz'lik frekans aralığında yer aldığı saptanmıştır. Ayrıca yapılan istatistiksel analizler sonucunda arıza için kritik bir standard sapma değeri belirlenmiş ve buna göre rulman arızasının 4. aşamada belirgin hale geldiği görülmüştür. Yapılan yeni bir tanım ile de rulman sağlamlığı yüzde cinsinden bir büyüklükle ifade edilebilmiştir.

Yapay bozukluğun her aşamasında ayrı ayrı toplanan veriler ile motor akım ve titreşimleri arasındaki ilişki ise frekans tanım bölgesindeki koherens değişimleri ile gösterilerek YSA tabanlı bir durum izleme sisteminin giriş-çıkış verileri olarak kullanılmıştır. Koherens analizi sonucunda bulunan 234 ve 469 Hz gibi frekansların, rulman arızası sonucunda oluşan ve rotor eksenel bozukluğunu işaret eden baskın frekanslar olduğunun tanımlanması ile YSA çıktılarından üretilen yanığı değişimlerinden, bu özel frekansların kolayca belirlenebildiği gösterilmiştir. YSA yanığı değişimlerinin arıza frekanslarında gösterdiği en büyük genlik değerleri genetik algoritma yaklaşımı kullanılarak otomatik olarak saptanmıştır. Bu anlamda, bu çalışmada ele alınan YSA ve GA yaklaşımlarından oluşan melez bir yapay zeka uygulaması, gerçek-zaman uygulamalarında da kullanılacak şekilde bazı kritik sistemlerin durum izlemelerinde önemli bir rol oynayacağı gösterilmiştir.

Teşekkür

Yazarlar, bu çalışmada kullanılan deneysel verilerin sağlandığı, The University of Tennessee-Knoxville (UTK), Nükleer Mühendislik Bölümü ve UTK Maintenance & Reliability Center Yetkililerine teşekkürlerini sunarlar.

Kısaltmalar

- AC : Alternatif Akım
- ÇÇDA : Çok Çözünürlü Dalgacık Analizi
- g : Yerçekimi ivmesi
- GA : Genetik Algoritma
- HP : Beygir Gücü (Horse Power)
- Hz : Hertz

KSS	: Kritik Standard Sapma
KZFD	: Kısa Zaman Fourier Dönüşümü
RMS	: Root Mean Square
s	: Saniye
TKH	: Toplam Karesel Hata
YSA	: Yapay Sinir Ağı

Semboller

μ	: Ortalama değer
σ	: Standard sapma
$\psi(t)$: Ana dalgacık fonksiyonu
$\psi_{a,b}(t)$: Dalgacık ailesi
a	: Ölçek veya yayılma değişkeni
b	: Öteleme değişkeni
$c_{m,n}$: Ölçekleme katsayıları
CWT	: Sürekli dalgacık dönüşümü
$d_{m,n}$: Dalgacık katsayıları
DWT	: Ayrık parametrelili dalgacık dönüşümü
f_e	: Şebeke frekansı
f_{eec}	: Eksenel bozukluk frekansları
f_{rm}	: Dönme frekansı
$g(n)$: Yüksek geçiren filtrenin impuls cevabı
$h(n)$: Alçak geçiren filtrenin impuls cevabı
$L^2(R)$: Karesel integrale edilebilir fonksiyonlar kümesi
k, m, n	: Tamsayı
n	: Eskiştirme aşamaları
p	: Çift kutup sayısı
s	: Kayma
$x(t)$: Sonlu enerjili işaretler

Kaynaklar

- Bonnett, A., Soukup, G., (1992). Cause and Analysis of Stator and Rotor Failures in Three-Phase Squirrel-Cage Induction Motors, *IEEE Trans. on Industry App.*, **28**, 4, 921-937.
- Costello, M. J., (1993). Shaft Voltages and Rotating Machinery, *IEEE Trans. on Industry App.*, **29**, 2, 419-425.
- Erbay, A. S. ve Upadhyaya, B. R., (1999). Multi-Sensor Fusion for Induction Motor Aging

- Analysis and Fault Diagnosis, *Research Report, UTNE/BRU/99-01*, October.
- Filippetti, F., Franceschini, G., Tassoni, C. and Vas, P., (2000). Recent Developments of Induction Motor Drives Fault Diagnosis Using AI Techniques, *IEEE Trans. on Industrial Electronics*, **47**, 5, 994-1004.
- King, B., (2000). *Maintenance Planning, Management, and Evaluation*, System Reliability Institute.
- Kowal, D. (1999). Bearing Damage resulting from Shaft Voltages and Currents, *CSI*.
- Li, B., Chow, M. Y., Tipsuvan, Y. ve Hung, J. C., (2000). Neural-Network Based Motor Rolling Bearing Fault Diagnosis, *IEEE Transactions on Industrial Electronics*, **47**, 5.
- Mallat, S., (1989). A Theory for Multiresolution Signal Decomposition the Wavelet Representation, *IEEE Trans. Pattern Anal. And Machine Intelligence*, **11**, 7, 674-693.
- O'Kane, M. ve Sander, M. J., (2000). Intelligent Motors Move to the Forefront of Predictive Maintenance, *IEEE Industry Applications Magazine*, 47-51, September/October.
- Schoen, R., Habetler, T. G., Kamran, F., Bartheld, R. G., (1995). Motor Bearing Damage Detection Using Stator Current Monitoring, *IEEE Trans. on Industry App.*, **31**, 6, 1274-1279.
- Şeker, S., (2000). Determination of Air-Gap Eccentricity in Electric Motors Using Coherence Analysis, *IEEE Power Engineering Review*, **20**, 7, 48-50.
- Şeker, S., Ayaz, E., Upadhyaya, B. R., Erbay, A. S. (2000). Analysis of Motor Current and Vibration Signals for Detecting Bearing Damage in Electric Motors, *MARCON 2000, Maintenance And Reliability Conference*, Knoxville, May 8-10.
- Smiley, R. G., (1992). Using line current to diagnose faults in induction motors, *Iron and Steel Engineer*, 23-25, September.
- Vonk, E., Jain, L. C., Johnson, R. P., (1997). *Automatic Generation of Neural Network Architecture Using Evolutionary Computation*, World Scientific Publishing Co. Pte. Ltd.