

ASENKRON MOTORDA YAPAY SİNİR AĞLARI İLE DURUM KESTİRİMİ

Hıdır Selçuk NOĞAY¹

ÖZET

Asenkron motorun çalışması esnasında oluşabilecek arızaların anlık olarak tespit edilebilmesi, motorun görev yaptığı sistemin kusursuz çalışması açısından son derece önem arz etmektedir. Bu çalışmada, üç fazlı kafesli bir asenkron motorda arızaların tespit edilebilmesi için yapay sinir ağları (YSA) modeli kullanılmıştır. Belirli bir zaman aralığı için asenkron motorun titreşim verileri alınarak veri seti oluşturulmuştur. Oluşturulan veri setinin % 80 i ile model eğitilmiş, %10 u ile model test edilmiştir. Yapay sinir ağı modelinin test edilmesi sonucunda % 98,8 oranında bir tahmin oranı elde edilmiş ve ANN modelinin çıkışı ile hedefin birbirleri ile örtüştüğü görülmüştür.

Anahtar Kelimeler: Yapay Sinir Ağları (YSA), Arıza, Asenkron Motor, Titreşim.

PREDICTION OF STUATION IN AN INDUCTION MOTOR WITH ARTIFICIAL NEURAL NETWORK

ABSTRACT

Instantly detection of faults that may occur during the operation of induction motors is extremely important for the flawless operation of the system in that the motor running. In this study, artificial neural network (ANN) model was used in order to detect the faults of a three-phase squirrel cage induction motor. Data set has been created with vibration data on the induction motor for a specific time interval. The model trained with 80% of the generated data set and tested with 10% of the data set. As a result of testing the artificial neural network model; an estimated rate of 98.8% was obtained and in addition, the target and output of the ANN model found to be very close to each other.

Keywords: Artificial Neural Network (ANN), Fault, Induction Motor, Vibration

¹ Doç. Dr., Erciyes Üniversitesi, nogay@erciyes.edu.tr

Giriş

Endüstride hala en fazla kullanılan motor tiplerinden birisi asenkron motorlardır. Genellikle sürücü sistem ile birlikte çalışan asenkron motorlarda arıza tespiti hem sanayi açısından hem de tüketicinin ihtiyaçları açısından büyük bir öneme sahiptir. Asenkron motorun arızasının önceden bilinmesinin yanısıra sistemin ve sistemden kaynaklanan arızaların bilinmesi de son derece önemlidir. Asenkron motorlarda arızalar iki grupta incelenir. Birinci grup mekaniksel arızalardır. İkinci grup ise elektriksel arızalardır. Elektriksel arızalarda kendi içinde birçok çeşitte ifade edilebilir. Bu çalışmada bahsedilen arızalar basit elektriksel arızalardır (Hakan ve Kıyas , 2007).

Yapay sinir ağları yöntemi güncelliğini bugün bile devam ettiren ve birçok problemin çözümünde geniş bir kullanım alanı olan matematiksel bir yöntemdir. Yapay sinir ağları başlıca; sınıflandırma, modelleme ve tahmin uygulamaları olmak üzere, pek çok alanda kullanılmaktadır. Tahmin amaçlı kullanılacak bir yapay sinir ağı modelinde, başarılı bir tahmin için veri setininin doğruluğu ve çeşidi çok önemlidir (Ashwani ve Amar, 2016; Chine vd., 2016). Yapay sinir ağı modeli eğitilir ve öğrenir. Modelin öğrenmesi için veri setindeki giriş verilerinin sayısı ne kadar fazla olursa, modelin sistemi tanıma oranı da o kadar fazla olur (Çetin, 2003;Ercan, 2006; Vasif, 2005). Modelin sistemi çok iyi tanınması ile çok doğru tahminler elde etmek mümkün olmaktadır. Öte yandan veri setinin fazlalığı ve giriş sayısının fazla oluşu yapay sinir ağı modelinin hem eğitim sürecini uzatır hemde modelin yavaşlamasına neden olur (Cemalettin, 2012).

Bu çalışmada özellikle otomasyon sistemlerinde çok sık kullanılan asenkron motorda ve onu çalıştıran sürücüde olması muhtemel arızaların yapay sinir ağları yöntemi kullanılarak yüksek oranda tahmin edilmesi hedeflenmiştir.

Yöntem

Çalışmanın gerçekleştirilmesinde aşağıdaki yol izlenmiştir.

1. Veri setinin elde edilmesi
2. Yapay sinir ağı mimarisinin seçimi
3. Yapay sinir ağı modelinin eğitilmesi
4. Sonuçların elde edilmesi

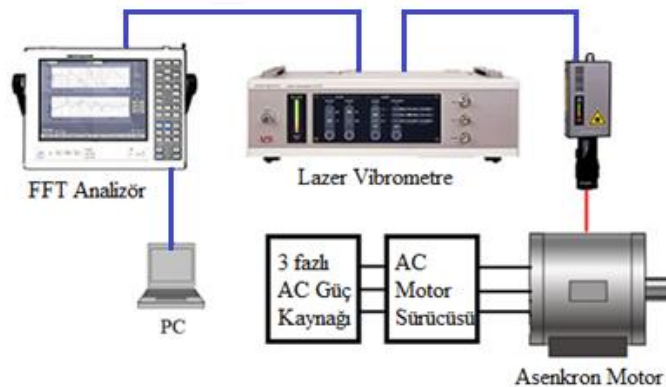
Veri setinin elde edilmesi

Çalışmada kullanılan veri setinin elde edilebilmesi için aşağıdaki adımlar takip edilmiştir.

1. Asenkron motorun genel çalışma ortamı kurulmuştur. Bu ortamda güç kaynağı, AC sürücü sistem, üç fazlı asenkron motor ve lazer titreşim ölçer bulunmaktadır. Düzenekte kullanılan üç fazlı kafesli asenkron motorun etiket değerleri aşağıda verilmektedir. Şekil 1 de deney ortamının şeması gösterilmektedir


Üç fazlı kafesli asenkron motorun etiket bilgileri:

3 Fazlı, Yıldız bağlı, 50 hz, 2800 d/d, $\cos\phi = 0,83$ $P = 0,37$ kW, $\Delta/Y = 220/380$, $I = \Delta 1,7$ A / Y 1 A



Şekil 1: Deney düzeneği

Asenkron motorun çalışma ortamında olabilecek üç adet arıza seçilmiş ve her arıza durumu için motor tekrar çok kısa süre çalıştırılmıştır. Burada dikkat edilecek husus motor çalışır durumda iken arızalı durumun oluşturulmasıdır. Motorun yüksüz durumdaki çalışması esnasında arızalı durum oluşturulduktan sonra motor çalıştırılmaya devam edilmiştir. Motorun çalışması esnasındaki motor titreşimleri ivme olarak ölçülüp 0.0000610352 saniyelik örnekleme zamanı ile PC ye aktarılmıştır. Şekil 2 de motorun 0,25 saniye çalışmasından ölçülen, arızalı durum (A9 arızası) ve sağlıklı çalışma durumları için titreşim grafikleri gösterilmektedir (Bimal, 2002).



Şekil 2: Asenkron motordan alınan titreşim verileri

2. Çalışmada kaydedilen titreşim verisi 4095 adettir. Bu titreşim verisi m/s² cinsinden ivmedir. Her bir titreşim verisinde, 3 tanesi arızalı durumlara ait ve bir tanesi de sağlıklı duruma ait 4 adet 80 veri (4x80 matrisi) kullanılmıştır. Veri seti oluşturulurken ki bu ilk kısım aşağıdaki Tablo 1 de gösterilmektedir.

Tablo 1: Veri seti oluşturulmadan önceki veri düzenlemesi

Data No	Arızalı			Sağlıklı
	A7	A8	A9	N
1	2,9419	4,2933	7,3041	1,6686
2	2,2047	4,859	6,7558	2,2789
3	3,1002	3,2749	8,5925	1,8252
.
.
.
77	3,1823	4,9612	8,9455	1,8235
78	3,3627	5,2473	8,4837	1,5306
79	2,7312	4,7834	6,9343	2,4832
80	3,6821	5,3292	8,4676	1,7920
Ortalama	3,1335	5,0725	7,3157	2,0082

3. Oluşturulan veri setinin ilk kısmında arızalı durumlar için kullanılan A7, A8, A9 ve sağlıklı durum için kullanılan N durumları için veri konfigürasyonu oluşturulmuştur. Tablo 3 de veri konfigürasyonu gösterilmektedir. Veri konfigürasyonu rastgele oluşturulmuş olup motorda olabilecek herhangi bir senaryodur. Bu senaryo aynı zamanda veri setinin giriş ve çıkışlarını hangi sıraya göre oluşturacağımızın da cevabıdır.

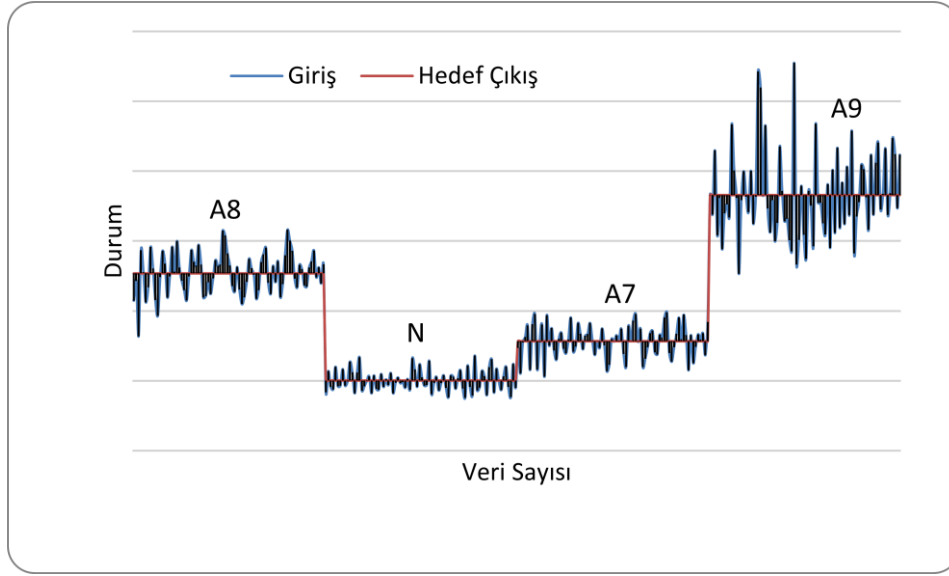
Tablo 2: Konfigürasyon ve numaralandırma

Konfigürasyon	Numaralandırma
A8	5,0725
N	2,0082
A7	3,1335
A9	7,3157

4. Motorun her durumu için Tablo 2 de gösterildiği gibi numaralandırma yapılmıştır. Bu numaralandırma her arıza durumuna ait olan 80 verinin ortalaması olarak belirlenmiştir. Verilen sayının Tablo 1 de belirtilen ortalamaları olarak belirlenmesinin herhangi bir nedeni yoktur. Burada önemli olan arızanın bir sayı ile temsil edilmesidir.
5. Konfigürasyon gereği arızalı duruma ait olan titreşim verileri birleştirilmek suretiyle YSA'nın giriş ve çıkış verilerinden oluşan son veri seti elde edilir. Tablo 3 de YSA modelinde kullanılan veri setinin özeti gösterilmektedir. YSA modelini eğitmek de kullanılacak olan veri seti bir giriş ve bir çıkıştan oluşan 1x320 matrislidir. Konfigürasyon gereği elde edilen, veri seti ve ulaşılmak istenen çıkış grafiksel olarak Şekil 3' de gösterilmiştir.

Tablo 3: Modelde kullanılan veri setinin özeti

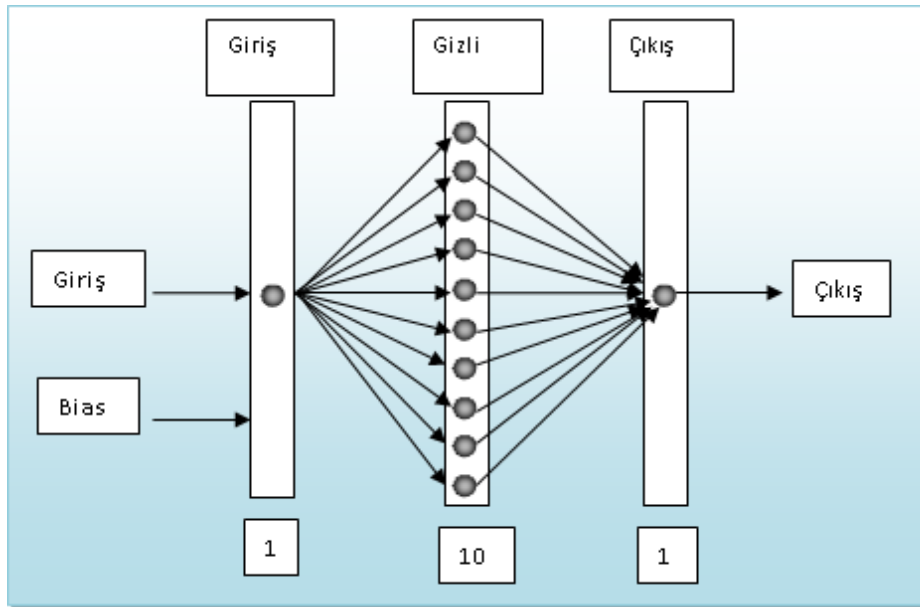
Veri No	Veri setinin ilk kısmı No	Giriş	Çıkış (Hedef)	Seneryo
1	1	4,2933	5,0725	A8
2	.	.	.	
3	80	5,3292	5,0725	
.	1	1,6686	2,0082	N
.	.	.	.	
.	80	1,7920	2,0082	
.	1	2,9419	3,1335	A7
.	.	.	.	
.	80	3,6821	3,1335	
.	1	7,3041	7,3157	A9
319	.	.	.	
320	80	8,4676	7,3157	



Şekil 3: Yapay sinir ağı modelinde kullanılan veri seti

Yapay sinir ağı modelinin mimarisinin seçimi

Çalışmada kullanılan YSA modeli çok katmanlı perceptrondur. Çalışma MATLAB NFTOOL kullanılarak gerçekleştirilmiştir. Tahmine dayalı problemlerin çözümünde bir çok akademik çalışmada da kullanılan çok katmanlı perceptron üç katmandan oluşmaktadır. Bu katmanlar; giriş katmanı, gizli katman ve çıkış katmanıdır. Modelde hiperbolik tanjant sigmoid transfer fonksiyonu kullanılmıştır. Şekil 4 den de anlaşılacağı üzere modelin bir girişi ve bir çıkışı bulunmaktadır. Gizli katmandaki nöron sayısı ise 10 olarak seçilmiştir. Gizli katmandaki nöron sayısını belirlemek için literatürde kesin bir bulgu bulunmamaktadır. Ancak eğitim sürecinin daha hızlı olması ve daha az yinleme (iterasyon) ile sonuca ulaşılması açısından gizli katmandaki nöron sayısının mümkün olduğunca az olması gerekir. Bu yüzden gizli katmandaki nöron sayısı 10 da sınırlı tutulmuştur (Bimal, 2002; Aktas, ve Okumus, 2010).



Şekil 4: Yapay sinir ağı modeli


Yapay sinir ağı modelinin eğitilmesi

Yapay sinir ağı modelinde toplam 320 adet veri kullanılmıştır. Bu verinin % 80 i (256 adeti) modelin eğitilmesi, % 10 u (32 adet) modelin test edilmesi ve % 10 u (32 adet) modelin test sürecinin doğrulanması için kullanılmıştır. Yapay sinir ağı modelinde eğitim için Levenberg Marquardt geri yayımlı öğrenme algoritması kullanılmıştır. Yapay sinir ağı modelinin eğitilmesi için ayrılan 256 adet veri ile sistem modele öğretilmiştir. Öğrenimin yüksek oranda gerçekleşmesi modelin çalışması açısından son derece önemlidir. Yapay sinir ağı modelinin eğitimi % 96,8 doğruluk oranıyla ve 17. iterasyonun sonunda gerçekleşmiştir. Eğitim süreci performans eğrisinde de görülebilir (Aktas, ve Okumus, 2010; Demetgül, 2008; Sina, Bathaie ve Khorasani, 2015).

Sonuçların elde edilmesi

Oluşturulan yapay sinir ağı modeli 256 veri ile eğitim sürecinden geçirildikten sonra 32 adet test verisi ve 32 adette doğrulama verisi ile test ve doğrulama süreçlerinden geçirilmiştir. Test sürecinin sonunda aşağıdaki grafiklere ve sayısal değerlere ulaşılmıştır.

1. Şekil 5 de ki test sürecine ait yaklaşım eğrisi elde edilmiştir.



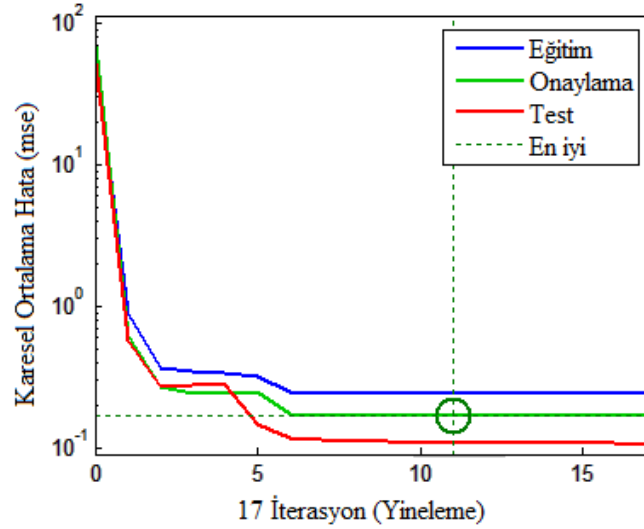
Şekil 5: Test için yaklaşım eğrisi

2. Yapay sinir ağının eğitim ve test süreçlerinin sonucunda karesel ortalama hata ve yaklaşım değerlerinin de verildiği Tablo 4 elde edilmiştir.

Tablo 4: Modelin sonuçları

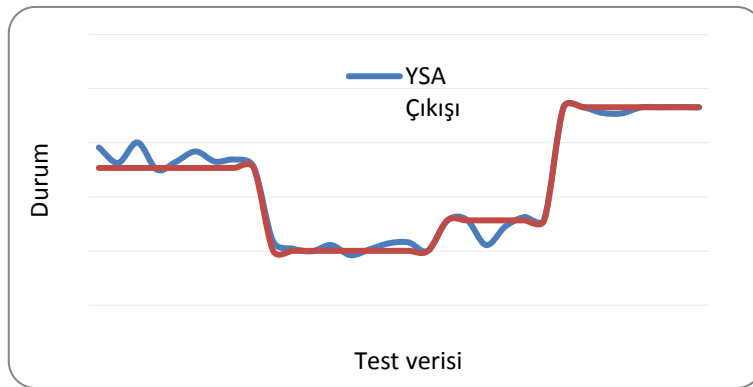
	Veri	Karesel Ortalama Hata (MSE)	R (Yaklaşım)
Eğitim	256	0,2428	0,9689
Onaylama	32	0,1662	0,9801
Test	32	0,1077	0,9882

3. Yapay sinir ağı modelinin eğitim, test ve doğrulama süreçlerine ait şekil 6 de verilen performans eğrisi çıkartılmıştır.



Şekil 6: Modelin performans eğrileri

4. Yapay sinir ağı modelinden elde edilen çıkış ile istenen çıkış (hedef), test verisi için kıyaslanmıştır. Sistemin başarısını daha net gösteren kıyaslama eğrisi sadece test için şekil 6 da gösterilmiştir.



Şekil 7: Modelin çıkışı ile hedefin karşılaştırılması

Sonuç ve Değerlendirme

Yapay sinir ağı modelinin test sürecinden geçirilmesi ile sistemden elde edilen sonuçlar ve sonuçların değerlendirilmesi aşağıda maddeler halinde verilmiştir.

1. Şekil 5 de test sonucundan elde edilen yaklaşım eğrisi görülmektedir. Yaklaşım eğrisinden kırmızı ile gösterilen uyum doğrusu ile kesikli çizgi ile gösterilen hedef doğrusunun örtüştüğü ve modelin yaptığı tahminin hedefe % 98 oranında yaklaştığı görülebilir.
2. Elde edilen Tablo 4 de ki sonuçlara göre, özellikle test süreci için karesel ortalama hata değeri 0,1077 ile hem endüşük değerdir ve hemde sıfıra çok yakındır. Karesel ortalama hata değeri sıfıra yaklaştıkça modelin çıkışıda hedefe yaklaşır ve modelin başarısı artar. Tablo 4 den test ve diğer süreçlerin yaklaşım değerleri de verilmektedir. Yaklaşım değerleri 1 e yaklaştıkça modelin tahmin oranı da yüze yaklaşır. Yaklaşım değerlerine bakıldığında 32 adet test verisinde 0,9882 değeri ile 1 e en yakın değere ulaşıldığı görülebilir.

3. Şekil 6 deki yapay sinir ağı modelinin her üç süreç için çıkartılan performans eğrilerine bakıldığında 10. yinelemeden sonra en düşük hata (mse) değerine ulaşıldığı görülebilir. Yeşil eğri ile gösterilen doğrulama sürecinde en düşük hatanın elde edildiği nokta yuvarlak içersine alınarak işaretlenmiştir. Performans eğrilerinden yapay sinir ağı modelinin çok yüksek oranda bir doğrulukla eğitildiği ve test sürecinin çok başarılı geçtiği gözlemlenebilir.
4. Şekil 7 deki kıyaslama eğrisinde, yapay sinir ağı modelinde kullanılan test verilerinin her veri için ayrı ayrı kıyaslaması yapılarak hedefe ne kadar yaklaşık bir tahminin elde edildiği görülebilir. Ayrıca asenkron motorun sadece arızalı durumunun değil başka çalışma durumlarının tahmini için de bu modelin son derece başarılı bir şekilde uygulanabileceği de görülmüştür.

Kaynakça

- Aktas, M., H. Okumus, I. (2010). Stator resistance estimation using ANN in DTC IM drives. Turk J Elec Eng & Comp Sci, Vol.18, No.2.
- Ashwani, K., Amar, P. (2016). Transistor level fault diagnosis in digital circuits using artificial neural network. *Measurement*, 82, 384–390.
- Bimal, K. (2002). Modern power electronics and AC drives, Prentice –Hall, USA Hakan, Ç., Kıyas K.(2007). Asenkron motor hata teşhisinde modern metodlar, *Makine Teknolojileri Elektronik Dergisi*. (4) 2, 49-57.
- Cemalettin, K. (2012). Matlab 7.11, Yapay zeka ve mühendislik uygulamaları, Sakarya Gelişim Ofset, Birinci Baskı, Sakarya.
- Chine, W., Mellit, A., Lughî, V., Malek, A., Sulligoi G., Massi P. (2016). A novel fault diagnosis technique for photovoltaic systems based on artificial neural Networks” *Renewable Energy*, 90, 501-512,
- Çetin, E. (2003). Yapay Sinir Ağları, Birinci Baskı, Seçkin, Ankara.
- Demetgül, M. (2008). Pömatik sistemde gerçek zamanlı LVQ yapay sinir ağı algoritması ile arıza tespiti. *Pamukkale University Engineering Faculty Journal of Engineering Sciences*, 14 , 1, 83-90.
- Ercan, Ö. (2006). Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.
- Sina T. S., Bathaie, Khorasani, K. (2015). Fault detection and isolation of gas turbine engines using a bank of neural Networks” *Journal of Process Control* 36, 22–41.
- Vasif, V. N. (2005). Yapay Zeka, İkinci Baskı, Seçkin, Ankara.