

**TEMEL BİLEŞENLER YARDIMIYLA
GERÇEK ZAMANLI MOTOR KORUMA
ALGORİTMASI**

TURGAY YALÇIN

YÜKSEK LİSANS TEZİ

**ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**

ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**TEMEL BİLEŞENLER YARDIMIYLA GERÇEK
ZAMANLI MOTOR KORUMA ALGORİTMASI**

TURGAY YALÇIN
YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI

DANIŞMAN
Doç. Dr. Okan ÖZGÖNENEL
SAMSUN - 2010

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bu çalışma jürimiz tarafından 08 /02/2010 tarihinde yapılan sınav ile Elektrik-Elektronik Müh. Anabilim Dalı'nda YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Başkan: Doç. Dr. Okan ÖZGÖNENEL

Üye: Yrd. Doç. Dr. Erdal KILIÇ

Üye: Yrd. Doç. Dr. İlyas EMİNOĞLU

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

..../..../2010

Prof. Dr. Hasan GÜMÜŞ

Fen Bilimleri Enstitü Müdürü

TEMEL BİLEŞENLER YARDIMIYLA GERÇEK ZAMANLI MOTOR KORUMA ALGORİTMASI

ÖZET

Asenkron motor, en genel elektromekanik enerji dönüşüm aygıtlarından biridir. Üretim sürecinin en önemli elemanıdır ve evlerde, ticari ve endüstriyel amaçlı denetim sistemlerinde yaygın bir şekilde kullanılır. Asenkron motor basit tasarımlı ve gürbüzlüğü sayesinde doğasında güvenilir bir aygıttır. Ancak çalışma anında çok farklı konularla karşı karşıya gelmektedir. Bu sorunlar çok farklı arıza tipine dönüşebilir. Bu yüzden durum izleme, bu tip arızalardan kaçınmak amacıyla gerekli hale gelmektedir.

Bu tez çalışmasında temel bileşenler analizi (TBA) ve yapay sinir ağı (YSA) tabanlı bir sayısal koruma algoritması önerilmiştir. Önerilen koruma algoritması iç sargı arızalarını, kırık rotor çubuk arızalarını ve rulman arızalarını ayırt edebilmektedir. Özel olarak tasarlanmış bir asenkron motor üzerinde birçok laboratuvar deneyleri önerilen algoritmanın başarımını sınamak için gerçekleştirilmiştir. Önerilen hibrit koruma algoritması motorun ani akımlarını kullanmaktadır. Bu akımlar ilk olarak TBA işlemine uygulanır ve kalıntılar diye adlandırılan ayırt edici özellikler elde edilir. Daha sonra bu kalıntı (özellik) vektörü ileri beslemeli-hatayı geri doğru yayan bir yapay sinir ağına giriş olarak uygulanmaktadır. Sonuç olarak, önerilen motor koruma algoritması normal çalışma koşullarını, stator arızalarını, rulman arızalarını, kırık rotor çubuğu arızalarını, rotor-stator arızalarını ve rulman-stator arızalarını ayırt edebilmektedir.

Anahtar Kelimeler: Motor arızaları, temel bileşenler analizi, yapay sinir ağı ve arıza tanılama

PRINCIPAL COMPONENT ANALYSIS (PCA) BASED REAL TIME MOTOR PROTECTION ALGORITHM

ABSTRACT

The induction motor is one of the single most common electromechanical energy conversion devices. It is the critical component of the production processes and is widely used in domestic, commercial, and industrial motion control devices and systems. An induction motor is considered inherently reliable due to its robustness, relatively simple design and construction. However, it faces various stresses during operation conditions. These stresses might lead to many modes of failures. Therefore the condition monitoring becomes necessary in order to avoid failures (breakdowns).

In this thesis, digital protection algorithm based on PCA and neural network methods is presented for induction motors. The proposed protection algorithm covers internal winding faults, broken rotor bar faults, and bearing faults. Many laboratory experiments have been performed on a specially designed induction motor to evaluate the performance of the suggested protection algorithm. The hybrid protection algorithm uses the instantaneous phase currents. These currents are first preprocessed by PCA to extract distinctive features called residuals. Then the residual (feature) vector is applied to a feed-forward back-propagation neural network as input vectors. Finally, the presented motor protection algorithm determines normal operating conditions, stator faults, bearing faults, rotor bar faults, rotor-stator faults and bearing-stator faults.

Keywords: Motor faults, principle component analysis, artificial neural network and fault diagnosis.

TEŞEKKÜR

Çalışmalarım esnasında desteğini ve yardımlarını esirgemeyen, bilgi ve deneyimlerinden yararlandığım Doç. Dr. Okan ÖZGÖNENEL' e teşekkürlerimi sunarım.

İÇİNDEKİLER

1.	GİRİŞ	1
2.	GENEL BİLGİLER	7
2.1.	Literatür Özeti: Motor Arıza Teşhisinin Tarihsel Gelişimi	7
3.	MATERYAL VE YÖNTEMLER	12
3.1.	Temel Bileşenler Analizi Ve Tekil Değerler Ayrışımı	13
3.1.1.	Temel Bileşenler Analizi (TBA)	13
3.1.2.	Çok Boyutlu Uzaydaki Bir Noktayı, Düşük Boyutlu Uzaya İndirmek	14
3.1.3.	TBA ile yeniden yapılandırma hatası en aza indirgenir	14
3.1.4.	Temel Bileşenler Analizinin Adımları	17
3.1.5.	TBA' nın Sınırlaması	19
3.1.6.	Temel Bileşenler Analizinin Geometrik Anlamı	19
3.2.	Tekil Değerler Ayrışımı (SVD)	20
3.3.	Temel Bileşenler Analizi ile Hata tespiti	22
3.4.	Çevrim Dışı Eğitim İşlevi	24
3.5.	Çevrim İçi Algılama	24
4.	YAPAY SİNİR AĞI (YSA) MODELİ	26
4.1.	Çok Katmanlı Algılayıcı (ÇKA)	26
4.2.	ÇKA Modelinin Yapısı	27
4.3.	ÇKA Ağının Öğrenme Kuralı	29
4.4.	ÇKA Ağının Çalışma Adımları	32
5.	BULGULAR: DENEYSEL ÇALIŞMALAR VE BİLGİSAYAR BENZEŞİMLERİ	35
5.1.	Motor Koruma Algoritmasının Aşamaları	36
5.2.	Deneysel Çalışmalar ve Senaryolar	37
5.3.	Motor Koruma Algoritmasının Sonuçları ve Bağlı Hatalar	51

5.4.	HFD ile Arıza Analizi	52
6.	SONUÇ VE ÖNERİLER	55
7.	KAYNAKLAR	56
8.	EKLER	61
	EK-A	61
	EK-B	64
	ÖZGEÇMİŞ	87

SİMGE VE KISALTMALAR

HFD: Hızlı Fourier Dönüşümü

TBA: Temel Bileşenler Analizi

TDA: Tekil Değerler Ayrışımı

ÇKA: Çok Katmanlı Algılayıcı

YSA: Yapay Sinir Ağı

ŞEKİLLERİN LİSTESİ

Sekil Numarası

Şekil 1.1.	Üç fazlı indüksiyon motoru	2
Şekil 1.2.	Motorun rotor ve stator parçaları	2
Şekil 1.3.	Elektrik motor arızaları	5
Şekil 2.1.	Hasarlı rulman titreşim sinyali	11
Şekil 3.1.	Temel bileşenler sırasıyla en büyük değişinti yönündedir.	14
Şekil 3.2.	Öz değerler ve temel bileşenler	18
Şekil 3.3.	Temel bileşenlerin varyans yüzdesine göre sıralanması	18
Şekil 3.4.	1.temel bileşen ve herhangi bir noktanın gösterimi	19
Şekil 3.5.	2. temel bileşen	19
Şekil 3.6.	Temel bileşenler düzlemi	20
Şekil 3.7.	Skorların gösterimi	21
Şekil 3.8.	X veri matrisi, skorlar ve yükler	21
Şekil 3.9.	a)Hata tespit yönteminin geleneksel model gösterimi b)Temel bileşenler yönteminin gösterimi	24
Şekil 4.1.	ÇKA modeli	26
Şekil 4.2.	Çok Katmanlı Ağ Hücresi	28
Şekil 4.3.	Çok Katmanlı çok nöronlu ağ yapısı	28
Şekil 4.4.	ÇKA' nın temel yapıları	33
Şekil 5.1.	Motor koruma algoritması şeması	35
Şekil 5.2.	Deneylerde Kullanılan Ağ Yapısı	37
Şekil 5.3.	Normal çalışma anındaki 3 faz akımları	38
Şekil 5.4.	Normal çalışma anındaki hata vektörü	38
Şekil 5.5.	Deneylerde kullanılan motorun statoru	39
Şekil 5.6.	Stator arızası durumunda 3 faz akımları	40
Şekil 5.7.	Stator arızası durumunda hata vektörü	40

Şekil 5.8.	Arızalı rulman	41
Şekil 5.9.	Rulman arızası durumunda 3 faz akımları	42
Şekil 5.10.	Rulman arızası durumunda hata vektörü	43
Şekil 5.11.	Kırık rotor çubuğu	44
Şekil 5.12.	Rotor arızası durumunda 3 faz akımları	45
Şekil 5.13.	Rotor arızası durumunda hata vektörü	46
Şekil 5.14.	Rotor + stator arızası durumunda 3 faz akımları	47
Şekil 5.15.	Rotor + Stator arızası durumunda hata vektörü	48
Şekil 5.16.	Rulman + stator arızası durumunda 3 faz akımları	49
Şekil 5.17.	Rulman + Stator arızası durumunda hata vektörü	50
Şekil 5.18.	Kırık rotor çubuğu arızası sırasında temel ve alt harmonikler	53
Şekil 5.19.	Rulman arızası sırasında temel ve alt harmonikler	54

ÇİZELGELERİN LİSTESİ

Çizelge 1.1.	Elektrik motor arızalarının dağılımı	4
Çizelge 4.1.	XOR problemi	26
Çizelge 5.1.	Arızasız durumda deney sonuçları	39
Çizelge 5.2.	Stator arızası durumunda deney sonuçları	41
Çizelge 5.3.	Rulman arızası durumunda deney sonuçları	43
Çizelge 5.4.	Rotor arızası durumunda deney sonuçları	46
Çizelge 5.5.	Rotor-Stator çoklu arızası durumunda deney sonuçları	48
Çizelge 5.6.	Rulman-Stator çoklu arızası durumunda deney sonuçları	50
Çizelge 5.7.	Deneyler sonunda oluşan bağıl hatalar	51

1.GİRİŞ

Birçok endüstriyel tesiste her tip ve boyutta çok sayıda elektrik motoru kullanılır. Bu makineler işletimleri sırasında elektriksel, mekaniksel, termal ve çevresel birçok zorlanmalara maruz kalarak beklenmedik bir şekilde bozulurlar ve sistem arızasına yol açarlar. Sistemde ani kesilmelerin önlenmesi ve güvenilirliği arttırmak amacıyla işletmelerde bakım planlaması yapılır. Bu planlamada arıza sonrası bakım ve dönemsel bakımın yanı sıra bu makinelerin durumunun izlenmesi sonucunda referans duruma göre olabilecek değişiklikler gözlenir ve gerekli önlemler alınır. Bu amaçla son senelerde öngörülü bakım programları geliştirilmiştir.


Endüstriyel süreçlerde uygulanan iyi bir bakım teknolojisinin getireceği en önemli avantajlardan birisi süreç güvenilirliğidir. Bu anlamda işletmeler üretimlerini kesintiye uğratmadan sürdürebilirler ve üretim ekonomisine de bu yolla önemli katkılar sağlayabilirler. Çünkü ürün rekabeti, güvenilirlik, güvenlik ve maliyet eniyileştirme gibi kavramlar endüstriyel oluşumları, bakım bölümlerini ve bakım eylemlerindeki mühendislik uygulamalarını yeniden gözden geçirme yönünde etkilemiştir. Endüstriyel bakım masrafları toplam üretim masrafının % 4-25' ini oluşturduğundan, büyük işletmelerde teknik bakım bölümleri önemli bir iş kolunu oluşturmaya başlamıştır. Ayrıca bakım teknolojilerinin diğer önemli bir uygulama alanı ise kritik sistem uygulamalarıdır. Bu sistemler daha çok askeri amaçlı, kesintiye uğramaması gereken sistemler olup uzay ve havacılık sektöründe de buna benzer alanlarda uygulamalar mevcuttur. Modern endüstriyel süreçler gittikçe karmaşık donanımlar içeren elektriksel sürücülere ihtiyaç duymaktadır. Bu süreçler içerisinde asenkron motorlar endüstrideki motorların %80'nini oluştururlar (Benbouzid ve ark. , 2003). Üç fazlı asenkron motorlar sağlamlık, düşük maliyet, güvenilirlik ve yüksek başarımlarından dolayı en çok tercih edilen motor tipleridir. Asenkron motorlar askeri ve nükleer fabrikalar gibi kritik uygulamalarda da sık sık kullanılır. Bu tür uygulamalarda güvenilirlik üst seviyededir. Önemli arızalar oluşmadan önce erken bir aşamada arıza teşhisi ve tespiti potansiyel başarımlarını düşüklüklerini engeller (Bellini ve ark. , 2008). Çalışma ilkesi bakımından asenkron motorlara indüksiyon motorları da denir.

Asenkron motorların DC motorlara göre üstünlükleri;


- a) Daha ucuzdurlar.
- b) Bakıma daha az ihtiyaç duyarlar.
- c) Asenkron motorlarda çalışma sırasında elektrik arkı meydana gelmez.
- d) Bir fazlı veya üç fazlı olarak üretilebilirler.
- e) Bir kaç wattan 3500 kW'a kadar üretilebilirler.
- f) Momentleri yüksektir.
- g) Asenkron motorlarda frekans değiştirilerek istenilen devir sayısı elde edilebilir.

Yukarıdaki nedenlerden dolayı asenkron motorlar endüstride en çok kullanılan elektrik makineleridir.

Asenkron motorlar genel olarak stator ve rotor olmak üzere iki kısımdan oluşmaktadır. Stator, asenkron motorun duran kısmıdır. Rotor ise motorun dönen kısmıdır. Şekil 1.1.'de üç fazlı indüksiyon motoru, Şekil 1.2.'de ise motorun rotor ve stator kısımları gösterilmektedir. Asenkron motorun rotoru, kısa devreli rotor (sincap kafesli rotor) ve sargılı rotor (bilezikli rotor) olmak üzere iki çeşittir. Asenkron motor, rotorun yapım biçimine göre de bilezikli ve kafesli asenkron motor olarak da tanımlanır.



Şekil 1.1. Üç fazlı indüksiyon motoru



Şekil 1.2. Motorun rotor ve stator parçaları

Çok yaygın olarak kullanılan asenkron motorların arızalanmaları hem üretim gücünü düşürür, hem de bakım ve maliyet masraflarını artırır. Üreticiler ve kullanıcılar ilk zamanlarda motorları korumanın yolunun aşırı akım ve gerilimden korumak olduğunu öngörmüşlerdi (Vas, 1993). Ancak ilerleyen yıllarda motor hatalarının oldukça çeşitli olduğu görülmüştür. Elektrik motorlarındaki anormal durumun erken tanısı ise endüstriyel süreçlerin ekonomik ve güvenli işletimi bakımından son derece önemlidir. Asenkron motorlarda meydana gelebilecek arızaların önceden teşhisi, endüstriyel sistemde olabilecek beklenmeyen durumları önler ve

dolayısıyla üretimin kesintiye uğraması engellenerek sistemin güvenilir ve ekonomik bir biçimde çalışması sağlanır.

Elektrik motorlarının izlenmesi ve hata teşhisi son yıllarda üreticilerin ve kullanıcıların önemli çalışma alanlarının başında gelmektedir. Bunun nedeni ise motorların çeşitli parçalarının arızalanması; motor tamiratlarının pahalı olmamasına karşın üretimi aksattığı için maliyetin artmasıdır (Nandi ve ark. , 2005).

Motor durumlarının izlenmesinin faydaları;

- o Yakında olabilecek arızalar hakkında bilgi sahibi olunur.
- o Mevcut bakım ihtiyaçlarını açığa çıkarır.
- o Gelecekte hangi parça üzerinde ne zaman bakım yapılması gerektiği anlaşılır.
- o Bakım esnasında minimum kesinti sağlanır.

Hata teşhisinin faydaları ise;

- o Teknik elemanlara fazla zaman kaybettirmeden hatanın neden kaynaklandığını ve nerede olduğu bilgisi aktarılır.
- o Belirli aralıklarla yapılan genel tamiratlar hata teşhisi sayesinde ortadan kalkarak zaman kaybına engel olunur (Vas, 1993).

Elektrik motorlarında meydana gelen hataların geçmişi, elektrik motorlarının geçmişi ile neredeyse aynıdır. Üreticiler ve kullanıcılar, başlangıçta meydana gelen hatalar karşısında basit çözümleri benimsemektedirler. Hatalar daha çok aşırı akım korumaları, gerilim regülatörleri, topraklama önlemleri alınarak çözülmekteydi. Ancak elektrik makinelerinin gelişimine paralel olarak, ortaya çıkan hata tiplerinin de artması ile hata teşhisi ve problemlerin çözülmesi de zorlaşmaya başlamıştır. Bu hataların sonucu oluşan arızalar karşısında işletmelerin finansal kayıpları da artmaktadır. İşte bu nedenle hızlı hata tespiti ve arızaya müdahale önem kazanmıştır.

Asenkron motorlarda elektriksel ve mekaniksel arızalar söz konusu olup bu arızaların % 50'den fazlası rulman bozukluğu ve mil dengesizliği gibi basit mekaniksel nedenlerden kaynaklanmaktadır. Arızaya neden olan hata mekanizmaları, aşırı ısınma, yalıtımda bozulmalar, mekanik arızalar ve motor devresi hatalarıdır. Bazı durumlarda motordaki normal dışı durumların nedeni güç kaynağındaki harmonikler de olabilir. Elektrik motorlarının arızalarının kaynağına bakıldığında 4 ana unsurun ön plana çıktığı görülmüştür.

Motor arıza tipleri :

- a) Rulman arızaları; dönme elemanları, iç ve dış bilezik, dönme elemanlarını tutan kafeste olabilecek arızalardır.

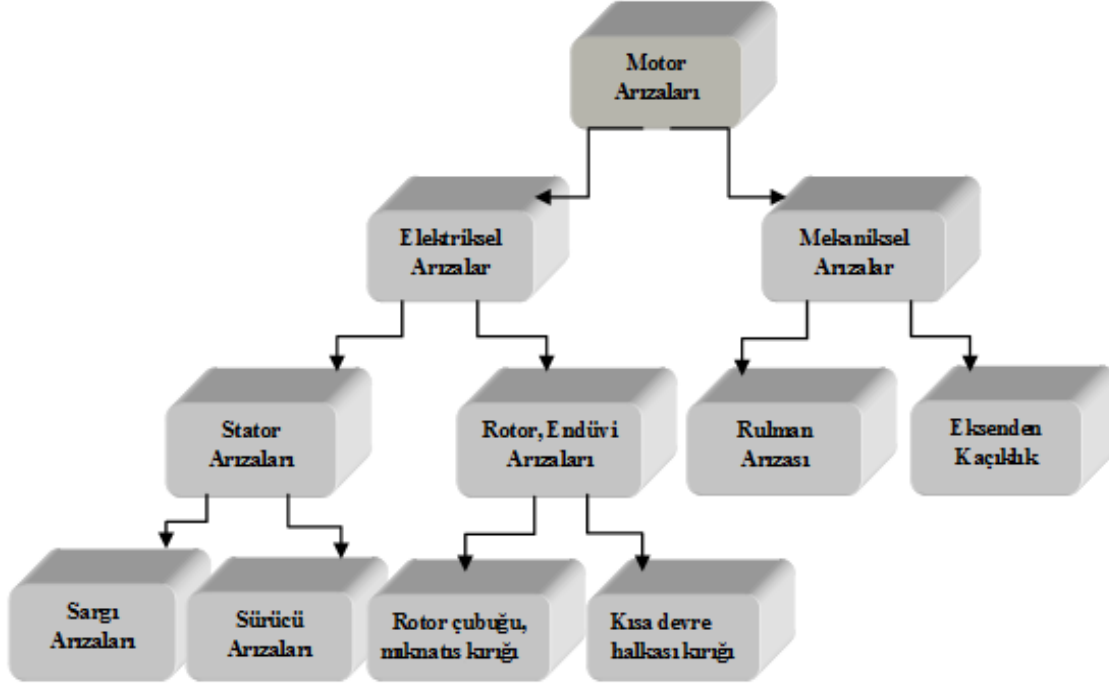
- b) Stator arızaları; stator gövdesi, stator çekirdeği ve stator sargılarında meydana gelebilecek arızalardır.
- c) Rotor arızaları; rotor çubukları, mil ve rotor gövdesinde olabilecek arızalardır.
- d) Diğer arızalar; faz empedanslarındaki dengesizlikler nedeniyle gerilim dengesizliğinin oluşması gibi elektriksel hatalar, aşırı yükleme, kötü kavramalar ve motorun iyi yataklanmaması gibi hatalardır.

Bu arızaların uluslararası ölçütlere göre dağılımı aşağıdaki Çizelge 1.1.' de görülmektedir.

Çizelge 1.1. Elektrik motor arızalarının dağılımı

	IEEE-IAS (%)	EPRI (%)
	Electrical Safety Workshop	Electric Power Research Institute
Rulman Arızaları	44	41
Sargı Arızaları	26	36
Rotor Arızaları	8	9
Diğer Arızalar	22	14

Elektrik motorlarında en sık görülen arıza tipi rulman arızası iken (yaklaşık % 42) en az sıklıkta görülen arıza tipi rotor arızalarıdır (yaklaşık % 9). Bu arızalar Şekil 1.3.' deki gibi sınıflandırılabilir.



Şekil 1.3. Elektrik motor arızaları

Oluşan bu arızaların teşhisinde motora ait akım, gerilim, hız, tork, sıcaklık ve titreşim gibi sinyaller izlenmektedir. İzlenen bu sinyaller birçok analiz yöntemi ile işlenerek motor durumu hakkında bilgi sahibi olunmaktadır. Asenkron motorun gözlenmesi ve hata teşhisinde en sık kullanılan analiz yöntemleri şunlardır (Yeh ve ark. , 2008):

- o Zaman ve frekans boyutunda analiz,
- o Elektromanyetik tork ve akımın zaman boyutunda analizi,
- o Sıcaklık ölçümü,
- o Motor akım sinyalleri analizi,
- o Titreşim ve gürültü izleme,
- o Motor tork ve hızının harmonik analizi,
- o Model, yapay zekâ ve yapay sinir ağları tabanlı yaklaşımlar.

Kullanılan tüm yaklaşımların içinde motor akım sinyallerini izleme ve analiz metodu elektrik motor arızalarında sıklıkla kullanılır. Akım sinyallerinin analizi; motor akımlarının spektral analizi yöntemini kullanır (Milimonfared ve ark. , 1999). Rotor çubuğu kırığı, eksenden kaçıklık arızası, stator sargılarında kısa devre arızası ve diğer mekaniksel arızaların tespitinde uzun yıllardır başarılı bir şekilde kullanılmaktadır (Cusidó, 2008). Diğer yandan, motorun bağlı olduğu sistemlerde genellikle akımı izleyen algılayıcıların olması veya evirici ile sürülen motorlarda sürücü kabiliyetleri sebebiyle ilave algılayıcı ihtiyacı duymaması,

yöntemin motor yükünden ve diğer asimetrisizliklerden etkilenmemesi sebebiyle kullanımının da ucuz ve kolay olması bu yöntemi diğerlerine göre bir adım daha öne çıkarmaktadır.

Son yıllarda geleneksel arıza teşhis yöntemlerinin yerini yapay sinir ağları, bulanık mantık, genetik algoritmalar, yapay bağışık sistemler ve veri madenciliği gibi akıllı arıza teşhis teknikleri almıştır (Filipetti ve ark. , 2000).

2. GENEL BİLGİLER

2.1. Literatür Özeti: Motor Arıza Teşhisinin Tarihsel Gelişimi

Asenkron motorlar birçok uygulamada kullanılır. Bu motorların büyük bir bölümünden petrokimyasal, madencilik ve ev aletleri ile ilgili endüstrilerde faydalanılmaktadır. Ayrıca güvenliğin üst düzeyde olduğu askeri ve uzay ile ilgili uygulamalarda tercih edilirler. Bu yaygın kullanımların en büyük nedenleri basit yapıları, güvenilirlikleri ve çok az dönemsel bakıma ihtiyaç duymalarından gelir (Chow, 1997). Asenkron motorların çalışma ortamları genellikle aşındırıcı ve nemlidir. Bu ortamlarda sürekli çalışan motorların belirli kısımlarında zamanla arızalar oluşur.

Arıza teşhisinin amacı motor tamamen bozulmadan önce motordaki başarımların düşüklüklerinin izlenmesi ile arızaları belirlemektir. Motorların izlenmesi için farklı algılayıcılar kullanılmaktadır. Arıza teşhisinde titreşim, hız, akı gibi pahalı motor parametreleri yerine maliyet açısından daha ucuz olan akım algılayıcıları tercih edilir. Asenkron motorlarda arıza teşhisi için model tabanlı teknikler ve uzman bilgisi gibi pahalı ve hassas ölçümler gerektiren geleneksel arıza teşhis yöntemleri kullanılmıştır. Son yıllarda geleneksel arıza teşhis yöntemlerinin yerini yapay sinir ağları, bulanık mantık, genetik algoritmalar, yapay bağışık sistemler ve veri madenciliği gibi akıllı arıza teşhis teknikleri almıştır (Filipetti ve ark. , 2000).

Asenkron motorlarda arızaların tanımlanması ve arıza teşhisi için en çok tercih edilen yöntem motor akım imza analizidir (Schoen ve ark. , 1995). Kırık rotor çubuğu arızaları, statik veya dinamik eksantriklik, mil yatağı ve stator arızaları bu metot kullanılarak tespit edilebilir. Bu yöntem genişletilerek stator, rotor, statik ve dinamik eksantriklik gibi arıza türleri de incelenmiştir (Benbouzid ve ark. , 1999). Kırık rotor çubuğu arızalarının tespiti için motor akım imza analizi ve diskriminant analizi tabanlı bir yöntem sunulmuştur (Ayhan ve ark. , 2005). Motor akım imza analizinin dezavantajlı yönü eğer yük çok düşük ise arıza ile ilgili frekans genlikleri oluşmaz. Geçiş durumlarında arızaları tespit etmek için dalgacık tabanlı ön işleme yöntemi önerilmiştir (Zarei ve ark. , 2007). Bu çalışmada Meyer dalgacığı arıza indeksi olarak her bir motor durumu için kullanılmıştır.

Diğer bir çalışmada kilitli rotor, tek faz, topraklama arızası, aşırı gerilim ve gerilim düşüşleri gibi arızaları tespit etmek amacıyla yapay bağışık sistem ve motor akım imza analizi temelli bir yöntem geliştirilmiştir (Branco ve ark., 2003). Önerilen yöntem üç modülden oluşmaktadır. T modülü öz/öz olamayan ayrımını sağlarken, B modülü sıklıkla oluşan tüm öz ve öz olmayan kodlar ile tepkimeye girer. D modülü ise T modülünün durum uzayını azaltmak için gereklidir. Bu çalışmada detektörlerin üretimi tüm öz olmayan uzayı kapsamayıp sadece yeni bir arıza oluştuğunda detektörlerin taşınması ve yeni durumun tespit edilmesine dayalıdır.

Farklı bir çalışmada negatif seçim algoritmasının detektörlerini üretmek için yapay sinir ağı tabanlı bir yöntem sunulmuştur (Gao ve ark. , 2008). Bu çalışmada öz verileri tanımayan detektörlerin yapay sinir ağı tarafından eğitimi sağlanmıştır. Negatif seçim algoritmasının başarımını artırmak için bulanık kümeleme ve genetik algoritmayı kullanan arıza tespit yöntemleri de mevcuttur (Aydın ve ark. , 2008). Bu yöntemlerde arıza teşhisi için özellik çıkarımı yapılarak asenkron motorlardaki kırık rotor ve sonlandırıcı halka arızaları tespit edilmiştir.

Akıllı hesaplama tabanlı teknikler sadece arızaları sınıflandırmakla kalmayıp, aynı zamanda arızanın şiddetinin belirlenmesi açısından da oldukça iyi sonuçlar verirler. Bu teknikler her bir motor çalışma durumu için özelliklerin çevrimdışı olarak öğrenilmesi ve izlenen bir motor durumunun çevrimiçi değerlendirilmesine dayalıdır. Bu süreç çok zaman alır ve elde edilen özellikler gürültü ve yük durumlarından etkilenir. Bu tür sorunları gidermek için asenkron motor arızalarının teşhisinde zaman serisi veri madenciliği yöntemi kullanılmıştır (Povinelli ve ark. , 2001; Povinelli ve ark. , 2002; Bangura ve ark. , 2003). Bu yöntemler veri madenciliği ve doğrusal olmayan zaman serileri analizine dayalıdır. Her bir motor durumu lineer olmayan zaman serisi analizi ile oluşturulan bir faz uzayında incelenir. Bu çalışmalarda sonlu elaman durum uzayı ile elde edilen moment sinyalleri arıza tespitinin özellik sinyallerini oluşturur. Kırık rotor ve eksantriklik arızaları başarılı bir şekilde teşhis edilmektedir.

Arıza teşhisi için zaman serisi veri madenciliğinin kullanımı iyi sonuçlar vermesine rağmen, Gaussian karışım modelinin oluşturulması oldukça karmaşıktır. Ayrıca zaman serisi veri madenciliğini kullanan birçok çalışmada akım sinyalleri yerine moment gibi elde edilmesi daha zor olan sinyaller kullanılmıştır.

Stator ve kırık rotor çubuğu arızalarının teşhisi için başka çalışmalarda üç faz akım sinyali üzerinden zaman serisi veri madenciliğini kullanan teşhis yöntemleri geliştirilmiştir (Yeh ve ark. , 2004; Da Silva, 2006). Her iki çalışmada da arıza teşhisi için faz uzayında Gaussian karışım modeli ile noktaların dağılımı modellenmekte ve Bayesian sınıflandırma ile arızaların sınıflandırılması sağlanmaktadır. Kırık rotor çubuğu arızalarını farklı çalışma durumları altında tespit etmek amacıyla zaman serisi veri madenciliği ve destek vektör makineleri kullanan yöntemler de literatürde vardır (Aydın ve ark. , 2008). Bu yöntemler üç faz motor akımı üzerinden park vektör dönüşümünü uygulamakta ve bu dönüşümden elde edilen yeni zaman serisinin faz uzaylarını sınıflandırmak için destek vektör makineleri kullanmaktadır.

Asenkron motor arızaları akıllı hesaplama teknikleri kullanılarak bir uzmana ihtiyaç duyulmadan teşhis edilebilir. Bangura ve arkadaşları (2003), kırık rotor, eksantriklik ve kırık sonlandırıcı halka arızalarını teşhis etmek için zaman serisi veri madenciliği yöntemini kullanmışlardır. Zaman serisi olarak sonlu elemanlar yöntemi ile elde edilen moment verisi alınmıştır. Arıza teşhisi için moment bilgisinin kullanımı pek tercih edilmemektedir. Çünkü moment verisini elde etmek maliyetli ve zordur. Yeh ve ark. (2004) arıza teşhisi için zaman serisi veri madenciliği yöntemini kullanan yeni bir yöntem önermişlerdir. Önerdikleri yöntem

stator sarımlarının kısa devre arızalarını teşhis etmişlerdir. Zaman serisi veri madenciliği yöntemi farklı çalışma durumları altında kırık rotor çubuğu arızalarının teşhisi için önerilmiştir (Aydın ve ark. , 2007). Yapılan çalışmada park vektör dönüşümü ile elde edilen yeni özellik vektörünün faz uzayı elde edilerek bulanık kümeleme algoritması ile arızalar teşhis edilmiştir. Bir diğer çalışmada ise farklı yük durumları altında kırık rotor çubuğu arızalarını teşhis etmek için üç fazlı bir asenkron motorun faz akımları ve gerilimlerinden 24 farklı özellik elde edilmiş ve arıza teşhisi için uygun olanlar seçilerek k-ortalama kümeleme algoritması ile arızalı ve sağlam motor durumları ayırt edilmiştir (Ondel ve ark. , 2006).


Kırık rotor çubuğu arızalarının farklı çalışma durumları altında tespiti için zaman serisi veri madenciliği ve destek vektör makineleri kullanan bir yöntem sunulmuştur. (Aydın ve ark. , 2008). Önerilen yöntemde her bir arıza durumu ve sağlam durumun faz uzayı zaman serisi veri madenciliği ile oluşturularak destek vektör makineler ile faz uzaylarının dolayısıyla arızaların sınıflandırılması sağlanmıştır. Ayhan ve ark. (2005) kırık rotor çubuğu arızalarının tespiti için motor akım imza analizi ve diskriminant analizi tabanlı bir yöntem sunmuştur. Bir kırık rotor çubuğunun dört farklı yük durumu için teşhisi gerçekleştirilmiştir. Park vektör dönüşümü ve motor akım imza analizine dayalı bir yöntem kırık rotor ve eksantriklik arızaları için önerilmiştir (Haji ve ark. , 2001). Bu iki özellik çıkarımı ile elde edilen özellikler Bayesian sınıflandırma yöntemi ile değerlendirilerek arıza türleri belirlenmektedir. Nejjari ve ark. (2000) park vektör dönüşümü ve yapay sinir ağı tabanlı bir yöntem ile asenkron motorlarda oluşan elektriksel arızaları belirlemişlerdir.

Rulmanlar dönen makinelerde yaygın olarak kullanılmaktadır. Makinelerin sorunsuz çalışması rulmanların sağlıklı çalışması ile doğrudan ilgilidir. Makine yataklarından titreşim ölçülerek makinenin iç yapısında gelişen olaylar hakkında bilgi edinilebilir. Rulmanlı yataklarda yağ filmi tabakası çok incedir ve temas noktalarında radyal doğrultuda bağıl hareket yoktur. Yatağın iç ve dış mobilitesi hemen hemen aynıdır. Bu nedenle yatağın dış yüzeyinde yapılan titreşim ölçümleri, iç yapıdaki gelişmeleri en doğru şekilde yansıtır (Belek, 1986). Dönen makinelerde arızadan kaynaklanan duruşların en önemli sebeplerinden birisi rulman arızalarıdır. Helikopter ve otomatik işleme makineleri gibi birçok sistemde beklenmedik rulman arızaları yıkıcı ve çok masraflı olabileceğinden rulman arızaları birçok araştırmanın konusu olmuştur (Li ve ark. , 2000). Aktürk ve ark. (1997) açısız temaslı iki rulman ile yataklanmış mil-rulman sisteminde aksel ve radyal titreşimleri incelemek için matematiksel model oluşturmuşlardır. Aktürk ve ark. (1998) iki açısız bilyeli rulman ile yataklanmış bir mil-rulman sisteminde bilye boyutundaki değişimin milin aksel ve radyal titreşimlerine olan etkisi incelemişlerdir. McFadden ve ark. (1984-1985) rulman iç bileziğindeki tek ve çoklu hasarların oluşturduğu titreşim modellenmiş, elde edilen sonuçların geçerliliğini deneysel sonuçlarla doğrulamışlardır. Taylor ve ark. (1993) rulman iç bileziğinde, dış bileziğinde ve yuvarlanma elemanlarında oluşan tek hasarın, rulmanın birden

fazla elemanında oluşan hasarın frekans analizi ile belirlenmesi arařtırmıřtır. Su ve ark. (1993) silindirik bilyeli rulmanlarda yzzey pürüzlülüęünün oluřturduęu titreřimi modellemiř ve deneysel sonularla modelin doęruluęunu ortaya koymuřlardır.

Diđer bir alıřmada AR-MA (Auto Regressive – Moving Average) ile rulman arızası teřhis edilmiřtir. Bu yzntemde, znceki alıřmalardan farklı olarak, hatalı motorlardan elde edilen stator akımı verilerinin frekans spektrumu bir AR-MA transfer fonksiyonu ile modellenmiřtir. Model, pay ve paydada z - polinomlarından oluřmaktadır. Bu transfer fonksiyonunun z – dzzlemindeki sıfır ve kutupları kullanılarak z boyutlu bir zznitelik vektzrü oluřturulmuřtur. Bu tdr verilerden genellikle daha az elemanlı zznitelik vektzrleri ıkarılmalıdır (Duda ve ark. , 2001). Bu alıřmada znerilen az elemanlı zznitelik vektzrlerinin, frekans spektrumundaki znemli bilgileri ayırt edici bir Őekilde tařıdıęı gzrmluř ve asenkron motorlarda rulman arızaları tespit edilmiřtir.

Rulmanlarda oluřan hasarlar bzlgesel ve daęınık olarak sınıflandırılabilir (Wowk, 1991; Aktürk, 1993; Tandon ve ark. , 1999). Bzlgesel hasarlar yuvarlanma yzzeylerindeki atlaklar, kzk delik Őeklinde korozyon ve kabarmalardır. Rulmanlarda sık rastlanan hasar tipi, yorulma atlaęının neden olduęu, bileziklerde ve yuvarlanma elemanlarındaki kabarmalardır. Daęınık hasarlar yzzey pürüzlülüęü, dalgalılık, eksenli kaık bilezikler, entik, korozyon ařınmaları, kir ve zlz dıřı yuvarlanma elemanlarıdır (Braun ve ark. , 1979). Rulman ařınması durumunda hasarlar ilk znce dıř bilezikte kabarma Őeklinde kendini gzsterir. Kabarma derinleřtike oluřan titreřimlerin genlięi artar. Arızanın son ařamasında yuvarlanma elemanları, kabarmayı i bilezięe tařırlar ve i bilezik geiř frekansındaki titreřimler artar. Bu sırada kısa sreli vuruntu sinyalleri daha byk genlikli ve ok sık olur (Orhan, 2002). Rulmanlarda, yuvarlanma elemanları hasar zzerinden geerken Őekil 2.1.' deki gibi kısa sreli, sznzml sinyaller zretirler (McFadden ve ark. , 1984). Hasarın rulmanın hangi elemanından kaynaklandıęını belirlemek iin titreřim frekanslarını incelemek gerekmektedir. İ bilezięi dznen, dıř bilezięi sabit bir rulmanın elemanlarının oluřturduęu titreřim frekansları, rulman geometrisi ve mil dznme devrine baęlı olarak hesaplanabilir. Elde edilen frekanslar ile zlzm sonucu elde edilen frekanslar karřılařtırılır. Hasarlı elemanlar hasar frekanslarında ve harmoniklerinde titreřime neden olurlar. Bazı durumlarda hasar titreřim frekansları mil dznme frekansı ve katlarında modlasyona uęrayarak yan bantlar oluřturabilir.



Şekil 2.1. Hasarlı rulman titreşim sinyali

3. MATERYAL VE YÖNTEMLER

Önerilen tez çalışmasında asenkron motora ait üç faz akımları akım trafoları (5/1A) tarafından uygun seviyeye düşürüldükten sonra NI-DAQ PCI MIO-E 16 veri kartı yardımıyla kaydedilmiştir. Örnekleme frekansı deneylerde 1000 Hz olarak seçilmiş ve peryot başına 20 örnek ile çalışma yapılmıştır.

TBA yöntemi kısaca çok boyutlu veri kümelerini çözümleme için küçük boyutlara düşüren vektör uzay dönüşümüdür. Aralarında yüksek ilinti bulunan birbiriyle ilişkili çok değişkenli verilerin, doğrusal dönüşüm sonucunda birbirleriyle ilişkisiz yeni bir koordinat sistemine dönüştürme işlemidir. Veri boyutu arttıkça, motor iç arızalarının algılanması ve motor koruma amacıyla kullanılan temel bileşenler analizinin başarımı sınırlanır. Bu sınırlamanın üstesinden gelmek için veri analizi için tekil değerler ayrışımı (TDA) ile temel bileşenler analizi birlikte kullanılır. Ayrıca TDA ile bilgisayar çözümleme zamanı kısalır. Diğer aşamada TBA sonucu oluşan kalıntılar özellik vektörü oluşturularak YSA' ya giriş olarak verilir.

Ayrıca önerilen tez çalışmasında motor koruma algoritmasının başarımı hızlı fourier dönüşümü (HFD) ile karşılaştırılmıştır.

Sonuç olarak bu tez çalışmasında TBA tabanlı YSA ile gerçek zamanlı veriler üzerinde arıza tespiti ve sınıflandırması için tam bir motor koruma algoritması gerçekleştirilmiştir. Önerilen koruma algoritması ile kırık rotor arızaları, rulman arızaları, stator arızaları, rotor-stator arızaları ve rulman-stator arızaları algılanabilmektedir. Algoritmanın başarımı ve doğruluğu birçok laboratuvar deneyi gerçekleştirilerek gözlenmiştir.

Sunulan yöntem arıza teşhisi için sadece üç faz motor akım işaretine ihtiyaç duyar, farklı algılayıcılara ihtiyaç duyulmaz. Böylece koruma algoritması arızaların tanınmasıyla üretim aşamasında sistemin düzenli çalışmasını sağlar, bakım esnasında en az kesinti sağlanır ve fazla maliyet yükünden kurtulmuş olunur.

3.1. Temel Bileşenler Analizi Ve Tekil Değerler Ayrışımı

Temel bileşenler analizi, çok boyutlu veri kümelerini analiz için küçük boyutlara düşüren vektör uzay dönüşümüdür. Diğer bir deyişle aralarında yüksek ilinti bulunan birbiriyle ilişkili çok değişkenli verilerin, doğrusal dönüşüm sonucunda birbirleriyle ilişkisiz yeni bir koordinat sistemine dönüştürme işlemidir.

3.1.1. Temel Bileşenler Analizi (TBA)

Çok boyutlu bir uzayda yüz tanıma, örüntü tanıma, arıza (hata) algılama veya sınıflandırma işlemi önemli bir sorundur. Bu sorunu aşmak için çok boyutlu uzaydaki bir giriş veri takımının daha düşük boyutlu bir uzaya haritalanması gerekmektedir. Günümüzde görüntü işleme tekniği olarak bilinen temel bileşenler analizi, motor iç arızalarının algılanması ve motor koruma amacıyla bu tez çalışmasında önerilmiştir.

Temel bileşenler analizinin temel fikri, çoklu boyutlu verinin ana özelliklerini az sayıda değişkenle temsil etmektir. Boyut azaltıldığında veri özelliklerinin bir bölümünün kaybolması engellenemez. Veri kümesinin ana özelliklerinin yok olmaması kaydıyla bu kaybedilmiş özelliklerin gürültü ve hatayla karşılaştırılacak kadar küçük olması beklenir.

Temel bileşenler analizinde temel amaçlar; bilgi kaybı olmaksızın veri boyutunun azaltılması, veriyi işlemek için kanonik gösteriminin elde edilmesi ve yüksek değişinti değerinin korunmasıdır. Boyuttaki azalma hesaplama zamanını düşürmekte ve gürültünün etkisini yok etmektedir.

TBA ile veri kümesinden en büyük değişintiye sahip bilgi alınarak işlenir. İşlenmemiş veri ile boyutu azaltılan veri arasındaki yapılandırma hatası en aza indirgenir. TBA' da veri değişinti değerini yüksek tutmak ve yeniden yapılandırma hatasını en küçüklemek için koordinat eksenlerini farklı bir düzleme dönüştürmek gerekir. TBA için tüm temel bileşenler koordinat sisteminin merkezinden (veri kümesinin ortalama değerinden) geçerler. İlk temel bileşen; orjinden en büyük değişinti yönündedir. Diğer temel bileşenler ise ilk temel bileşene diktir. Kalan en büyük değişinti değerini bu temel bileşenler tanımlar.

3.1.2. Çok Boyutlu Uzaydaki Bir Noktayı, Düşük Boyutlu Uzaya İndirmek

Bu bölümde hatanın özdeğer, özvektör ve kovaryans matrisiyle ilişkisi matematiksel olarak gösterilecektir.

1.noktalar: $x \in R, x = (x_1, x_2, \dots, x_n)$

2.taban (doğuray) seçimi: taban vektör kümesi $u = (u_1, u_2, \dots, u_k)$

birimlik doğuray (orthonormal basis) düşünüldüğünde;

$$u_i \cdot u_i = 1, \text{ ve } u_i \cdot u_j = 0 \text{ for } i \neq j$$


3.merkezi seç: \bar{x} uzayın görelî konumunu (offset) tanımlar.

4.en iyi koordinatlar düşük boyutlarda noktasal çarpımlarla tanımlanırsa: (z_1, z_2, \dots, z_k)

$$z_i = (x - \bar{x}) \cdot u_i \quad (3.1)$$

Değişintiyi en büyükleyen, ortalama karesel hatayı (mse) en küçükleyen z_i doğrultusunu bulmak gerekmektedir.

Veri dağılımını en büyük varyansa sahip 1.koordinat eksenine (1.temel bileşen); 2. koordinat eksenine (2. temel bileşen)...dönüştüren doğrusal dönüşüm sistemine TBA denir. Bu durum Şekil 3.1.' de gösterilmektedir.



Şekil 3.1. Temel bileşenler sırasıyla en büyük değişinti yönündedir

3.1.3. TBA İle Yeniden Yapılandırma Hatası En Aza İndirgenir.

- m veri noktaları verildiğinde:** $x_i = (x_1^i, x_2^i, \dots, x_n^i), i = 1 \dots m$
- her noktanın dönüşümü** eşitlik (3.2)' deki gibi gösterilir.

$$\tilde{x}^i = \bar{x} + \sum_{j=1}^k z_j^i \cdot u_j \quad (\text{i.veri noktası}) \quad (3.2)$$

$$\bar{x} = \frac{1}{m} \sum_{i=1}^m x^i \quad (\text{ortalama}) \quad (3.3)$$

$$z_j^i = (x^i - \bar{x}) \cdot u_j \quad (3.4)$$

Yeniden yapılandırma hatasını en aza indirmek için ($k \leq n$ olmak üzere):

$$hata_k = \sum_{i=1}^m (x^i - \tilde{x}^i)^2 \quad (3.5)$$

$$hata_k = \sum_{i=1}^m [\bar{x} + \sum_{j=1}^n z_j^i \cdot u_j - (\bar{x} + \sum_{j=1}^k z_j^i \cdot u_j)]^2 \quad (3.6)$$

$$hata_k = \sum_{i=1}^m (\sum_{j=k+1}^n z_j^i \cdot u_j)^2 = \sum_{i=1}^m [(\sum_{j=k+1}^n z_j^i \cdot u_j \cdot u_j \cdot z_j^i) + \sum_{j=k+1}^n \sum_{l=k+1}^n z_j^i \cdot u_j \cdot u_l \cdot z_l^i] \quad (3.7)$$

$$u_j \cdot u_j = 1, \text{ and } u_j \cdot u_l = 0 \text{ for } j \neq l$$

Eşitlik (3.5), (3.6), (3.7) yardımıyla yeniden yapılandırma hatası eşitlik (3.8)' de gösterilmektedir.

$$hata_k = \sum_{i=1}^m [(\sum_{j=k+1}^n (z_j^i)^2)] \quad (3.8)$$

Yeniden yapılandırma hatası ve kovaryans matrisi matematiksel ilişkisi eşitlik (3.9) denklemleri yardımıyla eşitlik (3.10)' da ifade edilmiştir.

$$\begin{aligned} (a \cdot b)^2 &= a^T \cdot b \cdot b^T \cdot a \\ a \cdot b &= a^T \cdot b = b^T \cdot a \end{aligned} \quad (3.9)$$

$$hata_k = \sum_{i=1}^m [(\sum_{j=k+1}^n (u_j \cdot (x^i - \bar{x}))^2)] \quad (3.10)$$

Kovaryans matrisi aşağıdaki eşitlik yardımıyla hesaplanır.

$$\Sigma = \frac{1}{m} \sum_{i=1}^m (x^i - \bar{x})(x^i - \bar{x})^T \quad (3.11)$$

Yeniden yapılandırma hatası; eşitlikler (3.12),(3.13),(3.14) yardımıyla ifade edilmektedir.

$$hata_k = \sum_{j=k+1}^n [(\sum_{i=1}^m (u_j \cdot (x^i - \bar{x}))^2] \quad (3.12)$$

$$hata_k = \sum_{j=k+1}^n \sum_{i=1}^m (u_j^T \cdot (x^i - \bar{x})(x^i - \bar{x})^T \cdot u_j) \quad (3.13)$$

$$hata_k = \sum_{j=k+1}^n u_j^T [\sum_{i=1}^m ((x^i - \bar{x})(x^i - \bar{x})^T)] \cdot u_j \quad (3.14)$$

Yeniden yapılandırma hatasını minimize etmek için taban vektörü (u_1, u_2, \dots, u_n) olarak seçilmektedir.

Eşitlik (3.13),(3.14) aracılığıyla yeniden yapılandırma hatası ve kovaryans matrisi arasındaki bağıntı eşitlik (3.15)'de gösterilmektedir.

$$hata_k = m \sum_{j=k+1}^n u_j^T \cdot \Sigma \cdot u_j \quad (3.15)$$

Öz vektörler ve öz değerler eşitlikleri:

$$\begin{aligned} A \cdot v &= \lambda \cdot v \\ v^T A v &= \lambda v^T v \\ v^T A v &= \lambda \end{aligned} \quad (3.16)$$

Eşitlik (3.16) dönüşümüyle eşitlik (3.15), eşitlik (3.17)'ye dönüştürülür.

$$hata_k = m \sum_{j=k+1}^n \lambda_j \quad (3.17)$$

Eşitlik (3.17)'de λ_j , j. en küçük öz değerdir.

Yeniden yapılandırma hatasını minimize etmek için seçilen taban vektörleri $(u_{k+1}, u_{k+2}, \dots, u_n)$ ise en küçük öz değerlere sahip öz vektörlerdir.

(u_1, u_2, \dots, u_k) , Σ (kovaryans matrisi) yüksek öz değerlere sahip öz vektörleri göstermektedir.

k değerinin nasıl seçileceği bölüm 3.1.4.'de 5. adımda anlatılmaktadır.

3.1.4. Temel Bileşenler Analizinin Adımları

m adet gözlem ve n adet değişkenden oluşan veri matrisi X , bu veri matrisi çok sayıda noktadan oluşan bir topluluktur. Değişkenler arasında tam bağımsızlık söz konusu olamayacağı için oluşan şeklin eksenleri birbirine dik olamayacak ve tanımlanamayacaktır. Diğer taraftan bu eksenlerin birbirine dik olması daha fazla bilgi verecektir. Bu amaçla, bir dönüştürme yaparak noktaların sahip oldukları toplam değişinti ilk eksen boyunca değişmemesi sağlanarak yeni eksenlerin birbirine dik olması sağlanmaktadır.

Adım 1. İşlenmemiş veri, X $m \times n$ boyutlu matris haline getirilir.

Adım 2. Veriler sıfır ortalamaya sahip sütunlar haline getirilir.

$$X_c = X - \bar{X} \quad (3.18)$$

Veri değişken ortalaması da X veri uzayında bir noktadır. Tüm temel bileşenler ortalama değerinden geçer. Bu ortalama değeri veri matrisinden çıkarılır. Bu durum eşitlik (3.18)'de ifade edilmektedir.

Adım 3. Kovaryans matrisi hesaplanır.

$$\Sigma = \frac{1}{m} \sum_{i=1}^m (X - \bar{X})(X - \bar{X})^T \quad (3.19)$$

Adım 4. Σ matrisinin öz değer ve öz vektörleri bulunur.

a) Öz değer ve öz vektör Kavramı

$T : V \rightarrow V$ doğrusal dönüşümü verilsin.

$v \in V$, olan sıfırdan farklı bir x vektörü için $T(v) = \lambda v$ eşitliğini sağlayan bir λ sayısı varsa, λ sayısına T dönüşümünün **öz değeri**, v vektörüne de λ öz değerine karşılık gelen **öz vektörü** denir (Lay, 2000). Eşitlik (3.20) öz değer, öz vektör arasındaki bağıntıları göstermektedir.

X kare matris olmak şartıyla;

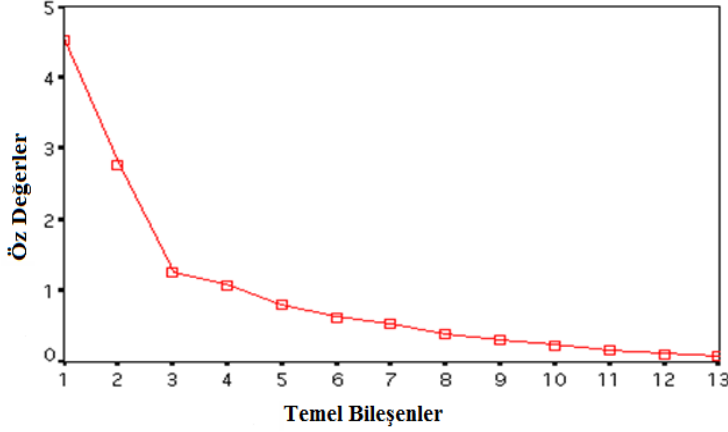
$$Xv = \lambda v \quad (3.20)$$

$$Xv - \lambda Iv = 0$$

$$(X - \lambda I)v = 0 \quad v \neq 0 \text{ olduğu için } X - \lambda I = 0 \text{ olur.}$$

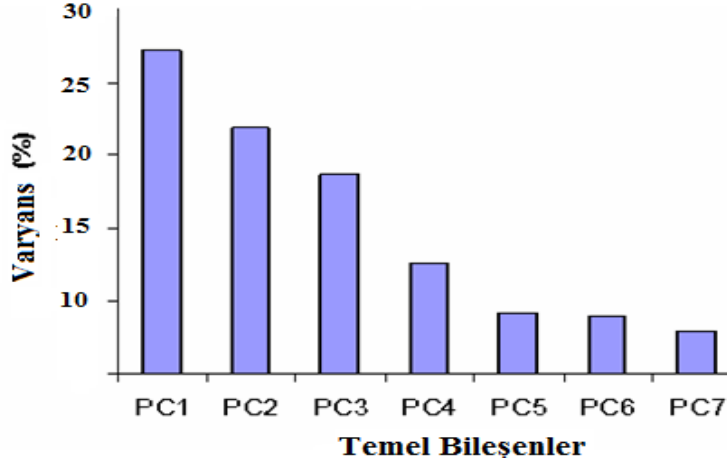
Adım 5. Temel Bileşenler belirlenir: Yüksek öz değerli öz vektörler temel bileşen olarak seçilir.

A) **1.yöntem:** Öz vektörler, öz değerlerinin genliklerine göre sıralanır. % 80-90 değişinti düzeyine sahip öz vektörler temel bileşen olarak seçilir. Temel bileşenlerin sayısı arttıkça, öz değerlerin genlikleri azalır. Bu durum Şekil 3.2.' de gösterilmektedir.



Şekil 3.2. Öz değerler ve temel bileşenler

Yüksek değişinti yüzdesi düzeyine sahip öz değerlere ait öz vektörler temel bileşen olarak belirlenir. Bu durum Şekil 3.3.' de gösterilmektedir.



Şekil 3.3. Temel bileşenlerin varyans yüzdesine göre sıralanması

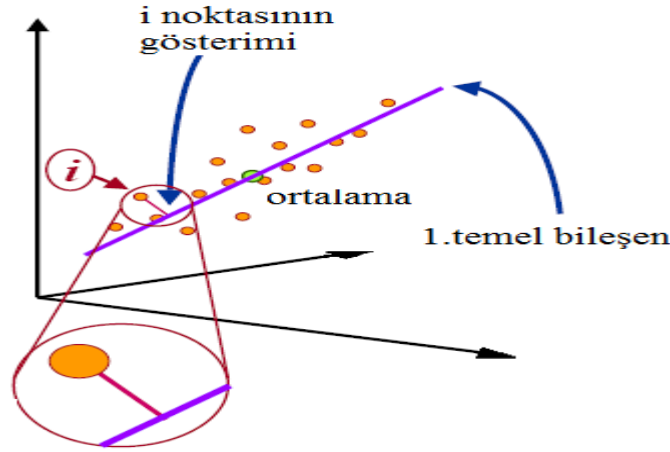
B) **2.yöntem:** Birden büyük öz değerlerin sayısı m ise; $\sum_{i=1}^m \frac{\lambda_i}{n} \geq \frac{2}{3}$ koşulunun sağlandığı en küçük m değeri önemli görülen temel bileşen sayısını belirlemektedir.(n değişken sayısıdır.)

3.1.5. TBA' nın Sınırlaması

Veri boyutu arttıkça (ör: Görüntü ($d \geq 10^4$)) temel bileşenler analizi yardımıyla motor koruma algoritma çözümlenmesi zorlaşır. Kovaryans Matrisi boyutu karesiyle doğru orantılı olarak artar. Boyut artmasıyla oluşan bu problemi çözmek için etkin veri çözümlenmesine sahip algoritma olan tekil değerler ayrışımı (SVD) ile temel bileşenler analizi birlikte kullanılır (Will, www.davidson.edu/academic/math/will/svd, 16.12.2008). Ayrıca tekil değerler ayrışım yöntemi kullanımıyla bilgisayar hesaplama zamanı kısalmıştır.


3.1.6. Temel Bileşenler Analizinin Geometrik Anlamı

1. temel bileşen yüksek değişimli veri dağılımına sahiptir. 1. temel bileşen eksenini boyunca veri değişimi maksimumdur. Bu eksen ortalama değerinden geçmektedir. Bu durum şekil 3.4.' de gösterilmektedir. Temel bileşen ekseninin yönü yük vektörü (p_1) ile belirlenir. Her noktanın konumunu ise skorlar (t_i) belirler.



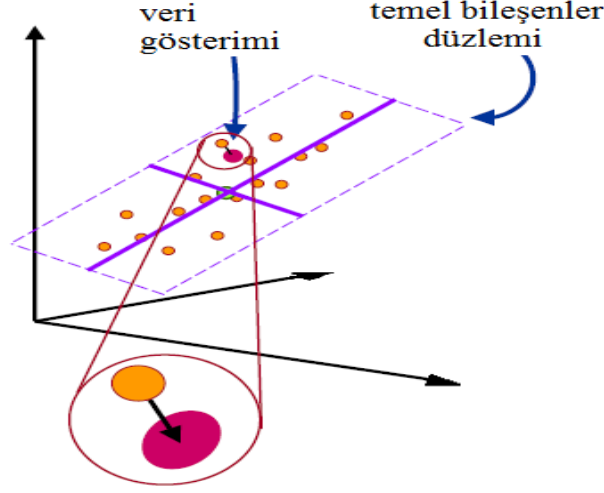
Şekil 3.4. 1. temel bileşen ve herhangi bir noktanın gösterimi

2. temel bileşen; 1. temel bileşene diktir. Bu durum şekil 3.5.' de gösterilmektedir. 2. temel bileşen de veri dağılımının merkezinden geçer. Temel bileşen eksenini boyunca veri değişimi 1.'ye göre daha azdır.



Şekil 3.5. 2. temel bileşen

Temel bileşenler düzlem oluştururlar. Bu durum şekil 3.6.' da gösterilmektedir.



Şekil 3.6. Temel bileşenler düzlemi

3.2. Tekil Değerler Ayrışımı (SVD)

Temel bileşenler analizindeki veri matrisi X aşağıdaki gibi ayrıştırılabilir:

$$X = WSV^T \quad (3.21)$$

(3.21) nolu eşitlikte W , XX^T ilişki matrisinin öz vektörlerinden oluşan $m \times m$ boyutlu bir matris, V ise $X^T X$ veri ilişki matrisinin öz vektörlerinden oluşan $n \times n$ boyutlu bir matristir.

S matrisinin köşegen elemanları $X^T X$ nin $\lambda_i = (i = 1, \dots, n)$ öz değerlerinin pozitif kareköküdür ve tekil değerler olarak adlandırılmaktadır. X matrisinin temel bileşenleri, değer matrisinin (T) sütunlarıdır ve aşağıdaki eşitlik yardımı ile hesaplanmaktadır.

$$T = XV = WS \quad (3.22)$$

$$t_i = Xv_i \quad (i = 1 \dots n) \quad (3.23)$$

t_i bileşenin varyansı (3.24) nolu eşitlikte hesaplanmıştır.

$$\text{var}(t_i) = v_i X^T X v_i = \lambda_i \quad (3.24)$$

(3.24) nolu eşitlikte λ_i , i .öz vektörle ilgili öz değeri göstermektedir.


Eşitlik (3.25)' de her elemanın temel bileşen ekseninde skorları belirlenmektedir.

$$t_i = \sum_{j=1}^k p_j x_{i,j} \quad (3.25)$$

P_j, X_j 'nin indirgenmiş yüküdür (loadings). Eşitlik (3.26)'da göstermektedir.

$$p_j = \cos(\theta_j) \quad (3.26)$$

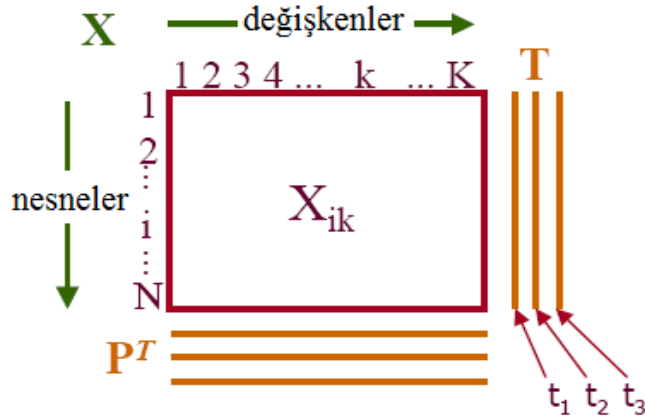
Şekil 3.7. 'de skorların geometrik yeri gösterilmektedir.



Şekil 3.7. Skorların gösterimi

Skorlar(t_i) her veri noktasının (observation) birbirine benzerliğini veya farklılığını belirler. Skorların varyansı öz değerleri (λ_i) verir. İndirgenmiş yükler (loadings(p_j)) skorları oluşturan değişkenlerin önemini belirtir. Yükler $X^T X$ matrisinin öz vektörlerinden oluşur.

Şekil 3.8. 'de skorlar ve yükler gösterilmektedir.



Şekil 3.8. X veri matrisi, skorlar ve yükler

İlişki matrisi simetrik olduğundan tüm öz değerleri sıfırdan büyük veya sıfıra eşittir. Tekil değerler ayrışım (SVD) yöntemi kullanılarak temel bileşenler aşağıdaki gibi elde edilebilir.

$$X = [W_1 \quad W_2] \begin{bmatrix} S_1 & 0 \\ 0 & S_2 \end{bmatrix} \begin{bmatrix} V_r^T \\ \hat{V}_r^T \end{bmatrix} \quad (3.27)$$

$$X = [W_1 S_1 \quad W_2 S_2] \begin{bmatrix} V_r^T \\ \hat{V}_r^T \end{bmatrix} = [T_r \quad \hat{T}_r] \begin{bmatrix} V_r^T \\ \hat{V}_r^T \end{bmatrix}$$

(3.27) nolu eşitlik yardımı ile V_r ve \hat{V}_r değerleri ve eşitlik (3.28) hesaplanmaktadır.

$$V_r = S_1 W_1 X \text{ ve } \hat{V}_r = S_2 W_2 X$$

$$X = T_r V_r^T + \hat{T}_r \hat{V}_r^T \quad (3.28)$$

$$X = X V_r V_r^T + X \hat{V}_r \hat{V}_r^T = \hat{X} + \overset{o}{X}$$

(3.28) nolu eşitlikte W_1 ve W_2 veri ve hata ile ilişkili indirgenmiş öz vektörler, V_r ve T_r ise İndirgenmiş yük ve skor matrisleri olarak adlandırılmaktadır.

Yukarıdaki denklemde indirgenmiş W_1 ve W_2 matrisleri kullanılarak veri:

$$X = W_1 W_1^T X + W_2 W_2^T X = \hat{X} + \overset{o}{X} \quad (3.29)$$

(3.29) nolu eşitlik şeklinde de ifade edilebilir. (3.28) ve (3.29) nolu eşitlikler yardımı ana bileşenler yöntemi aslında model \hat{X} ve hata $\overset{o}{X}$ ile ilgili iki parçaya böler.

3.3. Temel Bileşenler Analizi ile Hata tespiti

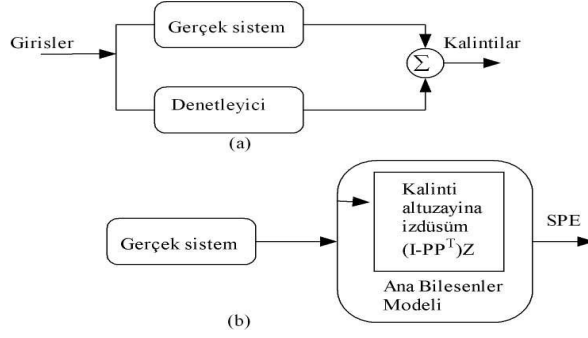
Doğrusal olmayan sistemlerdeki arızaları tespit etmek ve bu arızaları tanılamak çok önemlidir. Arıza tespit ve tanılama problemini çözmek için literatürde birçok yaklaşım vardır. Bunlardan, temel bileşenler analizi, faktör analizi ve veri analiz yöntemleri sistem başarımları hakkında faydalı bilgi sağlayabilmektedirler.

Temel bileşenler analizi, boyut azaltan çok değişkenli istatistiksel bir yöntemdir. İlk olarak 1901 yılında Karl Pearson tarafından tanıtılmıştır ve 1933 yılında Hotelling tarafından geliştirilmiştir. Edward tarafından sistemlerde arıza tanılama problemlerini çözmek için 1991 yılında kullanılmıştır. Literatürde, doğrusal temel bileşenler analizi ve bu yöntemeye dayanan farklı isimlerle adlandırılan yöntemler (çok ölçekli temel bileşenler analizi, sinir temel

bileşenler analizi, model veya çoklu yerel tabanlı temel bileşen analizi) sistem hatalarını tespit etmek için kullanılmış, ayrıca statik ve dinamik sistemlere uygulanmıştır (Vedam ve ark. , 1999; Zang ve ark. , 1999; Haiging ve ark. , 1999; Moya ve ark. , 2001).

Bazı araştırmacılar endüstriyel süreçten alınan verilerin daha etkili çözümlenmelerinin yapılabilmesi için temel bileşenler yönteminde değişiklikler önermektedir. Bunlardan ilki 1991 yılında Kramer tarafından tanıtılmıştır. Bu yöntemde hatanın geriye doğru yayılımı sağlanarak öğrenen bir sinir ağı yöntemi kullanmıştır. Bu yaklaşımın başarılı uygulamalarına rağmen, üretilen öz vektörlerin birbirlerine dik olma koşulu garanti edilememiştir (Zeng ve ark. , 2002). Başka bir grup araştırmacı da, yöntemin tanılama kapasitesini artırmak için destek vektör makineleri ve genetik programlama gibi farklı yöntemler kullanmışlardır. (Hiden ve ark. , 1997; Suykens ve ark. , 2003). Bununla birlikte, günümüzde bağımsız bileşen analizi olarak adlandırılan başka bir doğrusal dönüşüm yöntemi üzerinde de çalışılmaktadır (Hyvärinen ve ark. , 2001; Pöyhönen ve ark. , 2003). Bu yöntem, elde edilmiş verilerden bağımsız gizli faktörleri çıkarmak için kullanılmakta ve daha yüksek dereceden istatistiksel hesaplamalar içermektedir. Bu teknik, kovaryans matris içermeyen veri matrisinin dağılımındaki bilgiyi kullanmaktadır. Tüm Gauss değişken bilgisi kovaryans matris içinde bulunduğundan, veri matrisinin dağılımı Gauss biçimli olmamalıdır. Bu çalışmada, doğrusal olmayan dinamik sistem arızalarını algılamak amacı ile dinamik ana bileşenler analizi tanıtılmıştır. Buradaki dinamiklik kavramı veri oluşturma tekniğinden kaynaklanmaktadır. Veriler dinamik veya statik yollardan elde edilebilir. Statik veri kullanan doğrusal olmayan dinamik sistemlerde arızaları tespit ve tanılamamanın genellikle mümkün olmadığı gözlenmiştir. Bu yüzden; dinamik veri yapısı kullanılmış ve bu veriyi oluşturmak için kullanılan geçmiş örnek sayısı sistem derecesine eşit alınmıştır. Aksi takdirde, arıza algılama algoritması herhangi bir bozukluğun olmadığı durumlarda da arıza alarmı üretebilmektedir (Kilic ve ark. , 2007).

Arıza durumlarının ayırt edilmesi için kullanılan geleneksel model ve temel bileşenler yöntemi temeline dayalı modeller arasındaki fark şekil 3.9.' da görülmektedir. Hata tespiti için kullanılan temel bileşenler temeline dayalı yaklaşımda üç adım vardır, bunlar veri toplama, çevrim dışı eğitim ve çevrim içi tespittir. İlk adım veri toplama olarak bilinir. Bu işlem dinamik veya statik yolla yapılabilir. Statik veri matrisi sistemde arıza yokken sistemin ölçülmüş giriş çıkış büyüklükleri ya da sadece çıkış büyüklükleri kullanılarak oluşturulabilir.



Şekil 3.9. a) Hata tespit yönteminin geleneksel model gösterimi

b) Temel bileşenler yönteminin gösterimi

Dinamik veri matrisi eşitlik (3.30)' da tanımlanmıştır.

$$X = \begin{bmatrix} X_{k-L+1}^T & X_{k-L+2}^T & \dots & X_k^T \end{bmatrix}^T \quad (3.30)$$

X vektörü k uzunluğunda giriş-çıkış verisinden oluşmaktadır. Mühendislik sistemlerindeki farklı değişkenler genellikle farklı birimler kullandıklarından, veri matrisinin sütunları sıfır ortalamaya ve birim değışıntiye sahip olacak şekilde yeniden ölçeklendirilirler.

3.4. Çevrim Dışı Eğitim İşlevi

Çevrim dışı eğitiminde elde edilen veri matrisinin ortalama değeri, değışıntisi ve temel bileşenleri hesaplanmaktadır. Bu aşamada, ilişki matrisini oluşturmadan önce hesaplanmış değışınti ve ortalama değerler kullanılarak veri matrisi ölçeklendirilir (ortalama değer sıfır, birim değışınti). Ardından kovaryans matrisi bu otomatik ölçeklendirilmiş matris kullanarak aşağıdaki gibi hesaplanmaktadır:

$$Cov = \frac{X^T X}{n-1} \quad (3.31)$$

(3.31) nolu denklemde X, otomatik ölçeklendirilmiş veri matrisini göstermektedir. Kovaryans matrisinin ana bileşenleri ve öz değerleri hesaplanarak öz değerlerin büyüklükleri azalan sırada düzenlenir. Otomatik ölçeklenmiş kovaryans matrisinin öz vektörleri temel bileşenler olarak adlandırılmaktadır.

3.5. Çevrim İçi Algılama

Çevrim içi hata tespit sürecinde, çevrim dışı eğitim sürecinden elde edilen değışınti ve ortalamalar kullanılarak her yeni elde edilen veri vektörü otomatik olarak ölçeklendirilmektedir. Ardından sistemle ilgili indirgenmiş birkaç temel bileşen kullanarak kalıntılar (R) hesaplanır.

$$R = \| X - \hat{X} \|^2 = \| (I - W_1 W_1^T) X \|^2 \quad (3.32)$$

Yukarıdaki eşitlikte, R değerleri hata matrisi W_2 ile ilgili birkaç temel bileşen kullanılarak da hesaplanabilir:

$$R = \| W_2 W_2^T X \|^2 \quad (3.33)$$

Ölçeklendirme işleminden sonra R aşağıdaki hale dönüşür:

$$\bar{R} = \| W_2 S_2 W_2^T X \|^2 \quad (3.34)$$

Burada \hat{X} çevrim dışı işlevinden elde edilen öz vektörler kullanılarak çevrim içi algılamada tahmin edilen veri vektörünü göstermektedir (Kilic ve ark. , 2007).

4.YAPAY SİNİR AĞI (YSA) MODELİ

4.1. Çok Katmanlı Algılayıcı (ÇKA)

Bir yapay sinir ağının öğrenmesi istenen olayların girdi ve çıktıları arasındaki ilişkiler doğrusal olmayan ilişkiler olursa bu tür olayların öğrenilmesi için daha gelişmiş YSA modellerine ihtiyaç vardır. XOR probleminin özelliği doğrusal olmayan bir ilişkiyi göstermesidir. Yani çıktıların arasına bir doğru veya doğrular çizerek, onları iki veya daha fazla sınıfa ayırmak mümkün değildir. Bu problem Çizelge 4.1.' de gösterildiği gibidir. Basit algılayıcı ve ADALINE ile bu problem çözülememiştir.

Çizelge 4.1. XOR problemi

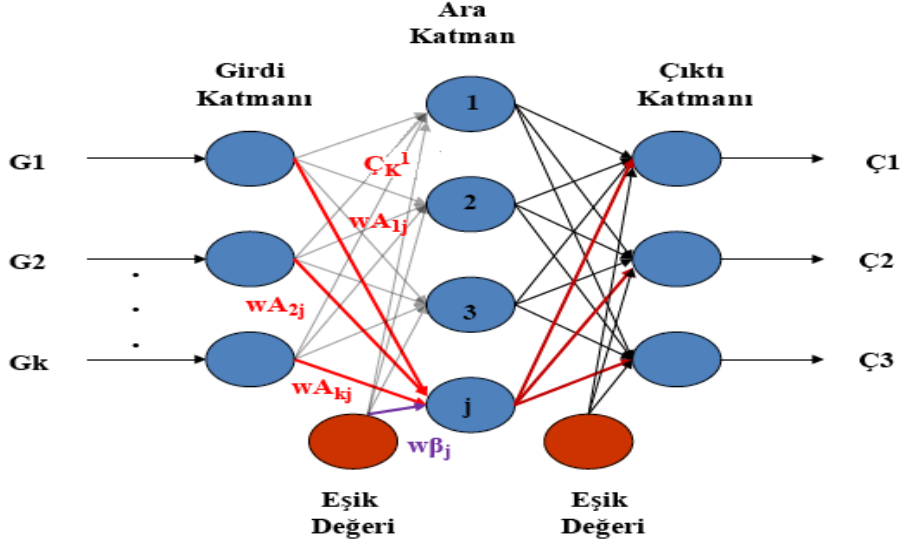
x_1	x_2	y
0	0	0
0	1	1
1	0	1
1	1	0

Bu problemin çok yaygın olarak kullanılmasının nedeni şöyle açıklanabilir. Minsky ve ark. (1969) özellikle perceptron modelinin bu probleme çözüm üretmediğini göstermiş ve yapay sinir ağlarının doğrusal olmayan problemlere çözüm üretmediğini iddia ederek bilimsel araştırmaların durmasına neden olmuştur. Çünkü günlük olayların hemen hemen hepsi doğrusal olmayan bir nitelik taşımaktadır. Bu örnekten sonra neredeyse bütün çalışmalar durmuş sadece birkaç araştırmacı çalışmalara devam etmiştir. Bu problemi çözerek yapay sinir ağlarına tekrar dikkatleri çekmeyi başarmışlardır. O nedenle bu problem yapay sinir ağı araştırmalarında bir kilometre taşı olarak görülebilir.

XOR problemini çözmek amacıyla yapılan çalışmalar sonucu *çok katmanlı algılayıcı modeli (ÇKA)* geliştirilmiştir. Rumelhart ve ark. (1986) tarafından geliştirilen bu modele *hata yayma modeli veya geriye yayım modeli (backpropagation network)* de denmektedir. ÇKA modeli yapay sinir ağlarına olan ilgiyi çok hızlı bir şekilde artırmış ve YSA tarihinde yeni bir dönemin başlamasına neden olmuştur. ÇKA özellikle sınıflandırma, tanıma ve genelleme yapmayı gerektiren problemler için çok önemli bir çözüm aracıdır. Bu model *Delta Öğrenme Kuralı* denilen bir öğrenme yöntemini kullanmaktadır. Temel amacı ağın beklenen çıktısı ile ürettiği çıktı arasındaki hatayı en aza indirmektir. Bunu hatayı ağa yayarak gerçekleştirdiği için bu ağa hata yayma ağı da denmektedir.

4.2. ÇKA Modelinin Yapısı

ÇKA ağlarının yapısı Şekil 4.1.' de gösterildiği gibidir. Şekilden de görüldüğü gibi ÇKA ileriye doğru bağlantılı ve 3 katmandan oluşan bir ağıdır:



Şekil 4.1. ÇKA modeli

4.2.1. Girdi Katmanı

Dış dünyadan gelen girdileri (G_1, G_2, \dots, G_N) olarak ara katmana gönderir. Bu katmanda bilgi işleme olmaz. Gelen her bilgi geldiği gibi bir sonraki katmana gider. Her proses elemanının sadece bir tane girdisi ve bir tane çıktısı vardır. Yani, girdi katmanındaki her proses elemanı bir sonraki katmanda bulunan proses elemanlarının hepsine bağlıdır.

4.2.2. Ara Katmanı

Ara katmanlar girdi katmanından gelen bilgileri işleyerek bir sonraki katmana gönderir. Çok katmanlı bir ağda birden fazla ara katman ve her katmanda birden fazla proses elemanı bulunabilir. Ara katmandaki her proses elemanı bir sonraki katmandaki bütün proses elemanlarına bağlıdır.


4.2.3. Çıkış Katmanı

Ara katmandan gelen bilgileri işleyerek ağa girdi katmanından verilen girdilere karşılık ağın ürettiği çıkışları ($\Ç_1, \Ç_2, \dots, \Ç_N$) belirleyerek dış dünyaya gönderir. Bir çıktı katmanında birden fazla proses elemanı olabilir. Her proses elemanı bir önceki katmanda bulunan bütün proses elemanların bağlıdır. Her proses elemanının sadece bir çıktısı vardır.

ÇKA ağında bilgiler girdi katmanından ağa sunulur ve ara katmanlardan geçerek çıktı katmanına gider ve ağa sunulan girdilere karşılık ağın cevabı dış dünyaya iletilir.

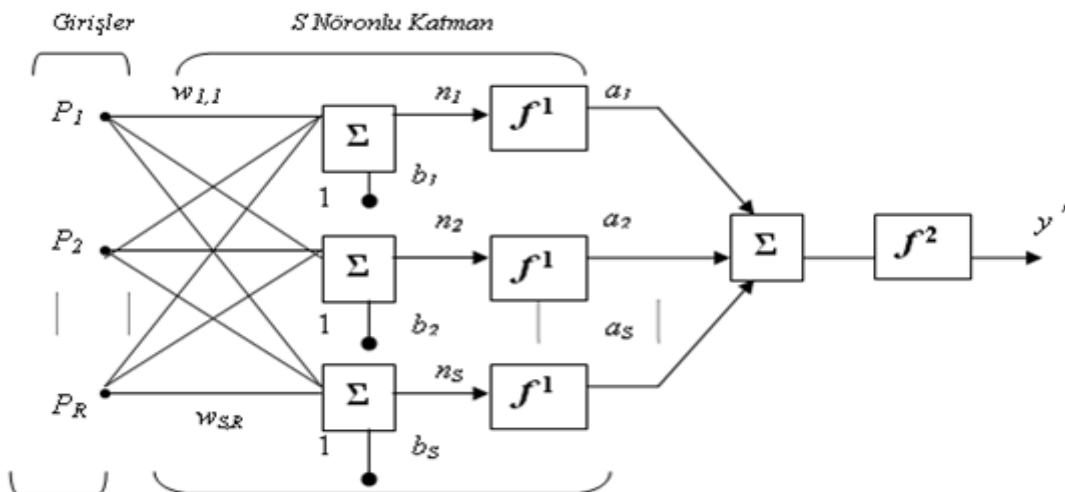
Çok katmanlı ağ öğretmenli öğrenme stratejisini kullanır. Ağ, hem örnekler hem de örneklerden elde edilmesi gereken çıktılar (beklenen çıktı) verilmektedir.

Sistem, kendisine gösterilen örneklerden genellemeler yaparak problem uzayını temsil eden bir çözüm uzayı üretmektedir. Daha sonra gösterilen benzer örnekler için bu çözüm uzayı sonuçlar ve çözümler üretebilmektedir. Şekil 4.2.'de Çok Katmanlı Ağ Hücresi gösterilmektedir



Şekil 4.2. Çok Katmanlı Ağ Hücresi

n : net giriş toplamı, a : çıkış, Σ : toplam fonksiyonu, f : aktivasyon fonksiyonu (sigmoid, tanh)



Şekil 4.3. Çok Katmanlı çok nöronlu ağ yapısı

Birçok giriş için genellikle bir nöron yeterli olmayabilir. Paralel işlem yapan birden fazla nörona ihtiyaç duyulduğunda katman kavramı devreye girmektedir. S tane nöronun tek bir katmanı Şekil 4.3.' te gösterilmiştir. Burada her giriş bir nörona bağlıdır.

4.3. ÇKA Ağının Öğrenme Kuralı

ÇKA ağları öğretmenli öğrenme stratejisine göre çalışırlar. Yani; bu ağlara eğitim sırasında ham girdiler hem de o girdilere karşılık üretilmesi gereken (beklenen) çıktılar gösterilir. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir. Çok katmanlı ağın öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralı'nın genelleştirilmiş halidir. Bu yüzden *Genelleştirilmiş Delta Kuralı* olarak da isimlendirilmektedir. Ağın öğrenbilmesi için eğitim seti adı verilen ve örneklerden oluşan bir sete ihtiyaç vardır. Bu set içinde her örnek için ağın hem girdiler hem de o girdiler için ağın üretmesi gereken çıktılar belirlenmiştir.

Genelleştirilmiş "Delta Kuralı" iki bölümden oluşur:

1-İleri Doğru Hesaplama(feedforward): Ağın çıktısını hesaplama safhasıdır.

2-Geriye doğru hesaplama(backpropagation): Ağırlıkları değiştirme safhasıdır.

4.3.1. İleri Doğru Hesaplama(feedforward)

Bu safhada bilgi işleme eğitim setindeki bir örneğin girdi katmanından ağa gösterilmesi ile başlar. Gelen girdiler hiçbir değişiklik olmadan ara katmana gönderilir.

Girdi katmanındaki k. proses elemanının çıktısı C_k^i şu şekilde belirlenir. Bu durum Şekil 4.1.' de gösterilmektedir.

$$C_k^i = G_k \quad (4.1)$$

Ara katmandaki her proses elemanı girdi katmanındaki bütün proses elemanlarından gelen bilgileri bağlantı ağırlıklarının (A_1, A_2, \dots) etkisi ile alır. Önce ara katmandaki proses elemanlarına gelen net girdi (NET_j^a) şu formül kullanılarak hesaplanır:

$$NET_j^a = \sum_{k=1}^n A_{kj} C_k^i \quad (4.2)$$

Burada A_{kj} k. girdi elemanını j. ara katman elemanına bağlayan bağlantının ağırlık değerini göstermektedir. Bu durum Şekil 4.1.' de j. ara katman elemanının çıktısı ise bu net girdinin aktivasyon fonksiyonundan (genellikle sigmoid fonksiyonundan) geçirilmesiyle hesaplanır. Önemli olan burada türevi alınabilir bir fonksiyon kullanmaktır.

Geriye doğru hesaplamada kullanılan fonksiyonun türevinin alınacağını unutmamak gerekir. Sigmoid fonksiyonu kullanılması halinde çıktı:

$$C_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad (4.3)$$

Burada β_j , ara katmanda bulunan j. elemana bağlanan eşik değer elemanının ağırlığını göstermektedir. Bu durum Şekil 4.1.'de gösterilmiştir. Bu eşik değer ünitesinin çıktısı sabit olup 1'e eşittir. Eğitim sırasında ağ bu değeri kendisi belirlemektedir.

Ara katmanın bütün proses elemanları ve çıktı katmanının proses elemanlarının çıktıları aynı şekilde kendilerine gelen NET girdinin hesaplanması ve sigmoid fonksiyonundan geçirilmesi sonucu belirlenirler. Çıktı katmanından çıkan değerler bulununca ağın ileri doğru hesaplama işlemi tamamlanmış olur.

4.3.2. Geriye doğru hesaplama (backpropagation):

Ağa sunulan girdi için ağın ürettiği çıktı ağın beklenen çıktıları ile karşılaştırılır. Bunların arasındaki fark hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Bu hata, ağın ağırlık değerlerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır. Çıktı katmanındaki m. proses elemanı için oluşan hata E_m ;

$$E_m = B_m - C_m \quad (4.4)$$

Eşitlik (4.4)'deki hata, bir proses elemanı için oluşan hatadır. Çıktı katmanı için oluşan toplam hatayı (TH) bulmak için bütün hataların toplanması gerekir.

$$TH = \frac{1}{2} \sum_m (E_m)^2 \quad (4.5)$$

Toplam hatayı enazlamak için bu hatanın kendisine neden olan proses elemanlarına dağıtılması gerekmektedir.

Ağın ağırlıklarının değiştirmek için 2 durum söz konusudur:

- 1) Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi
- 2) Ara katmanlar arası veya ara katman girdi katmanı arasındaki ağırlıkların değiştirilmesi

1) Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi:

Ara katmandaki j. proses elemanı çıktı katmanındaki m. proses elemanına bağlayan bağlantının ağırlığındaki değişim miktarına ΔA^a denirse; herhangi bir t zamanında ağırlığın değişim miktarı şöyle hesaplanır:

$$\Delta A_{jm}^a(t) = \lambda \delta_k C_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (4.6)$$

Eşitlik (4.6)'da λ öğrenme katsayısını, α momentum katsayısını göstermektedir.

Momentum katsayısı ağırlığın öğrenmesi esnasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlar. Eşitlik (4.7)'deki formül dikkate alındığında δ_m ise m. çıktı ünitesinin hatasını göstermektedir.

$$\delta_m = f'(NET) \cdot E_m \quad (4.7)$$

$f'(NET)$ aktivasyon fonksiyonunun türevidir. Sigmoid fonksiyonun kullanılması durumunda;

$$\delta_m = C_m(1 - C_m) \cdot E_m \quad (4.8)$$

Değişim miktarı hesaplandıktan sonra ağırlıkların t. iterasyondaki yeni değerleri:

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (4.9)$$

Benzer şekilde eşik değer ünitesinde ağırlıklarını değiştirmek gerekmektedir. Çıktı katmanında bulunan proses elemanlarının eşik değer ağırlıkları β_c ile gösterilirse; bu ünitenin çıktısı sabit ve 1 olması nedeni ile değişim miktarı:

$$\Delta \beta_m^c(t) = \lambda \delta_m + \alpha \Delta \beta_m^c(t-1) \quad (4.10)$$

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta \beta_m^c(t)$$

2) Ara katmanlar arası veya ara katman girdi katmanı arasındaki ağırlıkların değiştirilmesi:

Ara katman ile çıktı katman arasındaki ağırlıkların değişiminde her ağırlık için sadece çıktı katmanındaki bir proses elemanının hatası dikkate alınmıştır. Oysaki bu hataların oluşmasında girdi katmanı ve ara katman arasındaki ağırlıkların payı vardır.

Girdi katmanı ile ara katman arasındaki ağırlıkların değişimi ΔA^i ile gösterilirse değişim miktarı:

$$\Delta A_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta A_{kj}^i(t-1) \quad (4.11)$$

Hata terimi δ_a eşitlik (4.12)'de hesaplanmaktadır.

$$\delta_j^a = f'(NET) \cdot \sum_m \delta_m A_{jm}^a \quad (4.12)$$

Aktivasyon fonksiyonu olarak sigmoid fonksiyonun kullanılması durumunda;

$$\delta_j^a = \zeta_j^a (1 - \zeta_j^a) \cdot \sum_m \delta_m A_{jm}^a \quad (4.13)$$

Ağırlıkların yeni değerleri eşitlik (4.14)'de verilmiştir.

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (4.14)$$

Benzer şekilde eşik değer ünitesinde ağırlıklarını değiştirmek gerekmektedir. Ara katman eşik değer ağırlıkları β^a ile gösterilirse değişim miktarı;

$$\Delta \beta_j^a(t) = \lambda \delta_j^a + \alpha \Delta \beta_j^a(t-1) \quad (4.15)$$

Ağırlıkların yeni değerleri ise t. iterasyonda şöyle hesaplanacaktır.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t) \quad (4.16)$$

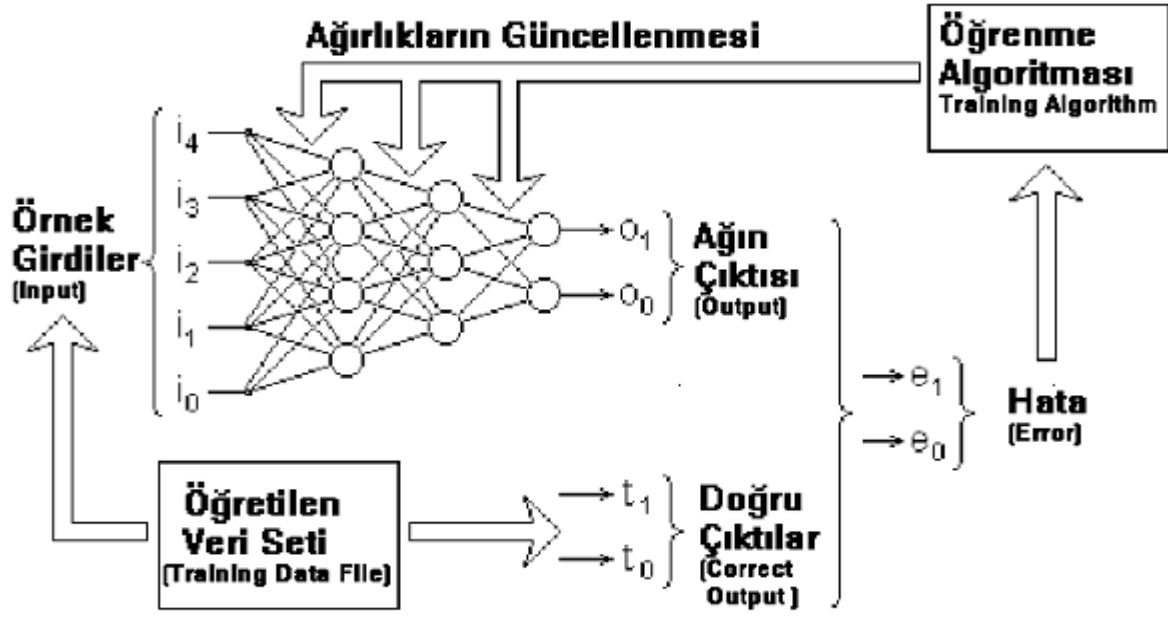
Böylece ağırlıklarının hepsi değiştirilmiş olacaktır. Bir iterasyon hem ileri hem de geriye doğru hesaplamaları yapılarak tamamlanmış olacaktır.

4.4. ÇKA Ağının Çalışma Adımları

- a) **Örneklerin toplanması:** Ağın çözmesi istenilen olay için daha önce gerçekleştirilmiş örneklerin bulunması adıımıdır. Ağın eğitilmesi için örnekler toplandığı gibi (eğitim seti) ağın test edilmesi için de örneklerin (test seti) toplanması gerekmektedir. Ağın eğitilmesi sırasında test seti ağa hiç gösterilmez. Eğitim setindeki örnekler tek tek gösterilerek ağın öğrenmesi sağlanır. Ağ olayı öğrendikten sonra test setindeki örnekler gösterilerek ağın performansı ölçülür. Hiç görmediği örnekler karşısındaki başarısı ağın iyi öğrenip öğrenmediğini ortaya koymaktadır.

- b) Ağın topolojik yapısının belirlenmesi:** Öğrenilmesi istenen olay için oluşturulacak olan ağın topolojik yapısı belirlenir. Kaç tane girdi ünitesi, kaç tane ara katman, her ara katmanda kaç tane proses elemanı ve kaç tane çıktı elemanı olması gerektiği bu adımda belirlenmektedir.
- c) Öğrenme parametrelerinin belirlenmesi:** Ağın öğrenme katsayısı, proses elemanlarının toplama ve aktivasyon fonksiyonları, momentum katsayısı gibi parametreler bu adımda belirlenmektedir.
- d) Ağırlıkların başlangıç değerlerinin atanması:** Proses elemanlarını birbirlerine bağlayan ağırlık değerlerinin ve eşik değer ünitesinin ağırlıklarının başlangıç değerlerinin atanması yapılır. Başlangıçta genellikle rastgele değerler atanır. Daha sonra ağ uygun değerleri öğrenme sırasında kendisi belirler.
- e) Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi:** Ağın öğrenmeye başlaması ve öğrenme kuralına uygun olarak ağırlıkları değiştirmesi için ağa örnekler (Girdi/Çıktı değerleri) belirli bir düzeneğe göre gösterilir.
- f) Öğrenme sırasında ileri hesaplamaların yapılması:** Sunulan girdi için ağın çıktı değerleri hesaplanır.
- g) Gerçekleşen çıktının beklenen çıktı ile karşılaştırılması:** Ağın ürettiği hata değerleri bu adımda hesaplanır.
- h) Ağırlıkların değiştirilmesi:** Geri hesaplama yöntemi uygulanarak üretilen hatanın azalması için ağırlıkların değiştirilmesi yapılır.


Yukarıdaki adımlar ÇKA ağının öğrenmesi tamamlanıncaya, yani gerçekleşen çıktılar ile beklenen çıktılar arasındaki hatalar kabul edilir düzeye ininceye kadar devam eder. Ağın öğrenmesi için bir durdurma kriterinin olması gerekmektedir. Bu ise genellikle üretilen hatanın belirli bir düzeyin altına düşmesi olarak alınmaktadır. Şekil 4.4.' de ÇKA' nın temel yapıları gösterilmektedir.



Şekil 4.4. ÇKA' nın temel yapıları

5. BULGULAR: DENEYSEL ÇALIŞMALAR VE BİLGİSAYAR BENZEŞİMLERİ

Şekil 5.1.'de motor koruma algoritması şekilsel olarak verilmiştir. Deneysel çalışmalarda üç fazlı 380V, 1kVA, 2.8A, 4 kutuplu bir asenkron motor kullanılmıştır. Farklı türde motor arıza türleri yapay olarak oluşturulmuş ve arıza sınıflandırmak için kullanılmıştır. Motordan NI-DAQ PCI 16MIO-E kart ile örneklenen akımlar normalize edilir ve TBA işleme giriş olarak verilir. TBA uygulaması sonucu elde edilen kalıntılar ile özellik vektörü oluşturularak YSA'ya giriş olarak verilir. YSA'nın sonucu olarak önerilen koruma algoritması ile kırık rotor arızaları, rulman arızaları, stator arızaları, rotor-stator arızaları ve rulman-stator arızaları algılanır.



Şekil 5.1. Motor koruma algoritması şeması

5.1. Motor Koruma Algoritmasının Aşamaları

1) Üç faz akımları I_{p1} , I_{p2} , I_{p3} 1000 Hz frekansıyla örneklenmiş ve dönem başına 20 örnek alınmıştır. 2 periyot boyunca 40 örnek alınarak elde edilen veriler matris biçiminde dizilerek veri matrisi oluşturulur.

2) TBA yöntemini uygulamak için gerekli olan zamanda geriye yayılma faktörü 5 olarak seçilmiştir. Faktörün 5 seçilmesinin nedeni, özellik vektörlerinin genliği bu sayede daha yüksek olmasıdır. (Asenkron motorun sistem derecesi 2 dir. Teorik olarak geriye yayılma faktörü sistemin derecesinin en az bir fazlası olarak alınır.). Dinamik veri matrisi elde edilir.

3) Elde edilen bu dinamik veri matrisinin temel bileşenler analizi için kovaryans matrisi hesaplanır.

4) Kovaryans matrisinin tekil değer ayrışımı yapılır. W (sol tekil vektör), S (tekil değerler matrisi), V (sağ tekil vektör) matrisleri hesaplanır. Bütün bu çalışmalar off-line kayıtlı veriler için yapılmıştır. Her üç faza ilişkin bir adet hata vektörü elde edilir.

5) Dinamik veri matrisinin her birinin satır vektörlerinden oluşan faz matrisleri (u) hesaplanır. Bu matrisin boyutu $[36 \times 15]$ ' tir.

6) $[W.W' \cdot (u)]$ işlemi sonucunda özellik vektörü çıkarılır ve bu vektör normalize edilir.

Elde edilen özellik vektörü YSA'ya giriş olarak verilir.

7) YSA' yı eğitmek için ağın çıkış vektörünü

[A] Normal çalışma,

[B] Stator arızası,

[C] Rulman arızası,

[D] Kırık rotor arızası,

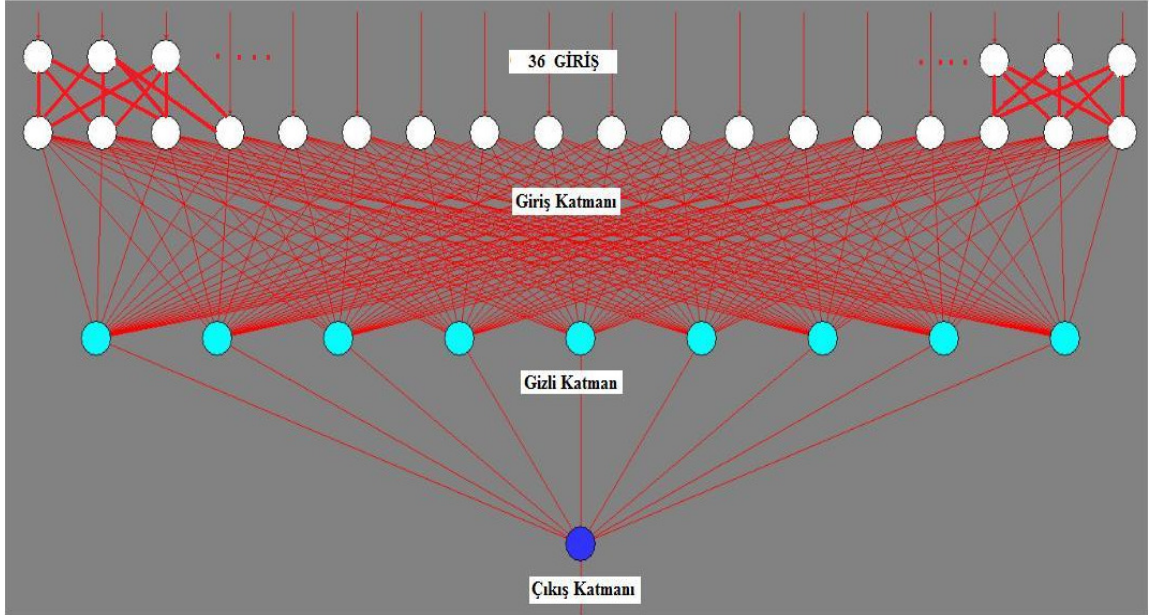
[E] Rotor ve stator çoklu arızası,

[F] Rulman ve stator arızalarını kapsayacak şekilde oluşturulur.

8) 5 ve 7 nolu adımları kullanarak 36×6 ' lık eğitim vektörü oluşturulur.

9) 18 giriş katmanı, 9 gizli katman ve 1 çıkış katmanına sahip oluşturulan yapay sinir ağı, 8 nolu adımdaki eğitim matrisini ve ağ parametrelerini (Aktivasyon fonksiyonu tanh öğrenme katsayısı λ : 0.2 , rms hata değeri: 1×10^{-10} , yineleme sayısı: 300) kullanarak eğitilir.

5.2. Deneysel Çalışmalar ve Senaryolar




Şekil 5.2. Deneyselerde Kullanılan Ağ Yapısı

Hata teşhis algoritmasında kullanılan ağın yapısı şekil 5.2' de gösterilmiştir. Bu ağın giriş katmanında 18, gizli katmanda 9, çıkış katmanında ise 1 nöron vardır.

Aşağıda verilen hata senaryoları laboratuvar ortamında gerçekleştirilen deney sonuçlarını göstermektedir.


Senaryo 1: Motorda herhangi bir hata yok.

Şekil 5.3 motorda hiçbir arıza yokken oluşan üç faz akımlarını göstermektedir.



Şekil 5.3. Normal çalışma anındaki 3 faz akımları

Şekil 5.4 ise bu durumda motor koruma algoritmasının 4 nolu adımı sonucu oluşan hata vektörünü göstermektedir. Şekilde de görüldüğü gibi geliştirilen motor koruma algoritması hata üretmemektedir.



Şekil 5.4. Normal çalışma anındaki hata vektörü


Bu hata senaryosunda YSA' dan beklenen 1 değerini üretmesidir. Çünkü YSA eğitilirken çıkıştaki ağın ürettiği 1 değeri motorun hatasız olduğunu göstermektedir. Çizelge 5.1.' de motor koruma algoritmasının arıza yokken YSA çıkış değerleri gösterilmektedir.

Çizelge 5.1. Arızasız durumda deney sonuçları

Deneyleer	Deney 1	Deney 2	Deney 3	Deney 4	Deney 5	Deney 6	Deney 7	Hedef Değerleri
Normal Çalışma	0.9706	0.9572	1	0.8073	0.9157	0.9595	0.934	1

En yüksek algoritma başarımı deney-3' te görülürken, en düşük başarıım ise deney-4' te elde edilmiştir.


Senaryo 2: Motorda stator hatası var. Stator arızası yaratmak için elektromekanik anahtarla stator sargılarının A fazının 20-40 sarım arası kısa devre edilmiştir. Şekil 5.5.' te laboratuvar deneylerinde kullanılan motorun statoru gösterilmektedir.



Şekil 5.5. Deneylerde kullanılan motorun statoru


Tüm stator arızaları kısa devre akımlarını sınırlamak amacıyla hata direnci kullanılmıştır. Sarım-sarım, sarım-toprak arızaları elektromekanik bir anahtar yardımıyla gerçekleştirilmiştir. Hata direnci olarak (FR), 0.5, 1, 2 ve 2.5 Ω olarak seçilmiştir.

Bu deney çalışmasında kısa devre A fazına uygulanmıştır. Elektromekanik anahtar yardımıyla kısa devre 0.29 ile 0.39 sn aralığında gerçekleşmiştir. Bu senaryoda asenkron motorun 3 faz akım değerleri şekil 5.6.' da gösterilmektedir.



Şekil 5.6. Stator arızası durumunda 3 faz akımları

Şekil 5.7 ise bu durumda motor koruma algoritmasının 4 nolu adımı sonucu oluşan hata vektörünü göstermektedir.



Şekil 5.7. Stator arızası durumunda hata vektörü


Bu hata senaryosunda YSA'dan sayısal 2 değerini üretmesi beklenir. Çünkü ağ eğitilirken 2 rakamı stator hatasıyla eşleştirilmiştir. Çizelge 5.2.' de motor koruma algoritmasının stator arızası olduğunda YSA çıkış değerleri gösterilmektedir.

Çizelge 5.2. Stator arızası durumunda deney sonuçları


Deneyler	Deney 1	Deney 2	Deney 3	Deney 4	Deney 5	Deney 6	Deney 7	Hedef Değerleri
Stator Arızası	2.0845	2.2966	1.9389	2.1281	2.2641	2.0391	1.9653	2

En yüksek algoritma başarımı deney-6' da görülürken, en düşük başarımlar ise deney-2' de elde edilmiştir.

Senaryo 3: Motorda rulman hatası var. Rulman arızası yaratmak için laboratuvar ortamında rulmana hasar verilmiştir. Şekil 5.8.' de deneylerde kullanılan arızalı rulman gösterilmektedir.




Şekil 5.8. Arızalı rulman



Şekil 5.9. Rulman arızası durumunda 3 faz akımları

Bu senaryoda asenkron motorun 3 faz akım değerleri şekil 5.9.' da gösterilmektedir. Rulman hatası oluşturulduktan sonra rulmanı eski arızasız hale getirmek mümkün olmadığı için belli bir zaman aralığında değil tüm simülasyon zamanı boyunca bu arıza devam etmektedir. Şekil 5.10.' da ise bu durumda motor koruma algoritmasının 4 nolu adımı sonucu oluşan hata vektörü gösterilmektedir.



Şekil 5.10. Rulman arızası durumunda hata vektörü


Bu hata senaryosunda YSA' dan sayısal 3 değerini üretmesi beklenir. Çünkü ağ eğitilirken 3 rakamı rulman hatasıyla eşleştirilmiştir. Çizelge 5.3.' de motor koruma algoritmasının rulman arızası sırasında YSA çıkış değerleri gösterilmektedir.

Çizelge 5.3. Rulman arızası durumunda deney sonuçları

Deneyler	Deney 1	Deney 2	Deney 3	Deney 4	Deney 5	Deney 6	Deney 7	Hedef Değerleri
Rulman Arızası	3.0051	3.2571	3.0288	3.0149	3.1167	3.1771	2.9926	3


En yüksek algoritma başarımı deney-7' de görülürken, en düşük başarımlar ise deney-2' de elde edilmiştir.

Senaryo 4: Motorda kırık rotor çubuğu arızası var. Rotor arızası yaratmak için laboratuvar ortamında rotor çubuğu kırılmıştır. Şekil 5.11.' de arızalı kırık rotor çubuğu gösterilmektedir.




Şekil 5.11. Kırık rotor çubuğu

Bu senaryoda asenkron motorun 3 faz akım değerleri şekil 5.12' de gösterilmektedir. Kırık rotor hatası oluşturulduktan sonra rotoru eski arızasız haline getirmek mümkün olmadığı için belli bir zaman aralığında değil tüm simülasyon zamanı boyunca bu arıza devam etmektedir.



Şekil 5.12. Rotor arızası durumunda 3 faz akımları

Şekil 5.13' te ise bu durumda motor koruma algoritmasının 4 nolu adımını sonucu oluşan hata vektörü gösterilmektedir.



Şekil 5.13. Rotor arızası durumunda hata vektörü


Bu hata senaryosunda YSA' dan sayısal 4 değerini üretmesi beklenir. Çünkü ağ eğitilirken 4 rakamı rotor hatasıyla eşleştirilmiştir. Çizelge 5.4.' de motor koruma algoritmasının kırık rotor arızası sırasında YSA çıkış değerleri gösterilmektedir.

Çizelge 5.4. Rotor arızası durumunda deney sonuçları

Deneyleer	Deney 1	Deney 2	Deney 3	Deney 4	Deney 5	Deney 6	Deney 7	Hedef Değerleri
Kırık Rotor Arızası	4.1291	3.8245	4.0881	3.9742	4.0579	4.2215	4.0274	4


En yüksek algoritma başarıımı deney-4' te görülürken, en düşük başarıım ise deney-6' da elde edilmiştir.

Senaryo 5: Motorda rotor-stator çoklu hatası var. Çoklu arızayı yaratmak için kırık rotorlu motor kullanılmıştır ve statorun A fazı (20-40 sarım arası) kısa devre edilmiştir. Bu senaryoda asenkron motorun 3 faz akım değerleri şekil 5.14.' te gösterilmektedir.



Şekil 5.14. Rotor + stator arızası durumunda 3 faz akımları

Şekil 5.15 de ise bu durumda motor koruma algoritmasının 4 nolu adımı sonucu oluşan hata vektörü gösterilmektedir. Bu senaryoda kısa devre 0.46-0.49 sn arasında gerçekleşmiştir.



Şekil 5.15. Rotor + Stator arızası durumunda hata vektörü


Bu hata senaryosunda YSA' dan sayısal 5 değerini üretmesi beklenir. Çünkü ağ eğitilirken 5 rakamı rotor-stator çoklu hatasıyla eşleştirilmiştir. Çizelge 5.5.' de motor koruma algoritmasının rotor-stator çoklu arızası durumunda YSA çıkış değerleri gösterilmektedir.

Çizelge 5.5. Rotor-Stator çoklu arızası durumunda deney sonuçları

Deneyler	Deney 1	Deney 2	Deney 3	Deney 4	Deney 5	Deney 6	Deney 7	Hedef Değerleri
Rotor+Stator Arızası	4.9089	4.9053	4.9519	4.9883	5.2912	5.1331	4.9463	5


En yüksek algoritma başarımı deney-4' te görülürken, en düşük başarıım ise deney-5' te elde edilmiştir.

Senaryo 6: Motorda rulman-stator çoklu hatası var. Çoklu arızayı yaratmak için rulmanı arızalı motor kullanılmıştır ve stator A fazı (20-40 sarım arası) kısa devre edilmiştir. Bu senaryoda asenkron motorun 3 faz akım değerleri şekil 5.16.' da gösterilmektedir.



Şekil 5.16. Rulman + stator arızası durumunda 3 faz akımları

Şekil 5.17 de ise bu durumda motor koruma algoritmasının 4 nolu adımı sonucu oluşan hata vektörü gösterilmektedir. Bu senaryoda kısa devre 0.73-0.86 sn arasında gerçekleşmiştir.



Şekil 5.17. Rulman + Stator arızası durumunda hata vektörü

Bu hata senaryosunda YSA' dan sayısal 6 değerini üretmesi beklenir. Çünkü ağ eğitilirken 6 rakamı rulman-stator çoklu hatasıyla eşleştirilmiştir. Çizelge 5.6.' da motor koruma algoritmasının rulman-stator çoklu arızası durumunda YSA çıkış değerleri gösterilmektedir.

Çizelge 5.6. Rulman-Stator çoklu arızası durumunda deney sonuçları

Deneyle	Deneyle 1	Deneyle 2	Deneyle 3	Deneyle 4	Deneyle 5	Deneyle 6	Deneyle 7	Hedef Değerleri
Rulman+Stator Arızası	6.1576	6.2469	5.7899	6.028	6.1629	6.0639	6.2513	6

En yüksek algoritma başarımı deney-4' te görülürken, en düşük başarıım ise deney-7' de elde edilmiştir.

5.3. Motor Koruma Algoritmasının Sonucunda Oluşan Bağlı Hatalar

Çizelge 5.7. Deneyler sonunda oluşan bağlı hatalar

Deneyler	Deney 1	Deney 2	Deney 3	Deney 4	Deney 5	Deney 6
Normal Çalışma	0.0294	0.0428	0	0.1927	0.0843	0.0405
Stator Arızası	0.0422	0.1483	0.0305	0.0640	0.1321	0.0195
Rulman Arızası	0.0017	0.0857	0.0096	0.0050	0.0389	0.0590
Kırık Rotor Arızası	0.0323	0.0439	0.0220	0.0064	0.0145	0.0554
Rotor+Stator Arızası	0.0182	0.0189	0.0096	0.0023	0.0582	0.0266
Rulman+Stator Arızası	0.0263	0.0412	0.0350	0.0047	0.0271	0.0107

Hata senaryoları sonucunda oluşan bağlı hatalar Çizelge 5.7.' de gösterilmektedir.

Normal çalışma uygulamasında deney-3 sonucunda hatasız çalışma halini % 100 doğrulukla algılamıştır. En büyük yanılığa ise deney-5 esnasında varmıştır. Bağlı hata % 8.43' tir.

Stator arızası uygulamasında en küçük hataya deney-6 esnasında ulaşılmıştır. Bağlı hata deney sonucunda % 1.95' dir. Bağlı hatanın en büyük olduğu değere , % 14.83, deney-2' de ulaşılmıştır.

Rulman arızası uygulamasında en küçük hataya deney-1 sonucunda ulaşılmıştır. Bağlı hata bu esnada % 8.57' dir. Bu hatanın en büyük olduğu değer % 0.17' dir. Bu değere deney-1 sonucunda ulaşılmıştır.

Kırık rotor arızası uygulaması sonucunda en küçük hataya deney-4' te ulaşılmıştır. Bağlı hata bu esnada % 0.64' tür. Bağlı hatanın en büyük olduğu değer % 5.54' tür. Bu hataya deney-6 sonucunda ulaşılmıştır.

Rulman-stator çoklu arızasında en küçük hataya deney-4' te ulaşılmıştır. Bu değer % 0.23' tür. Bağlı hatanın en büyük olduğu değer % 5.82' dir. Bu hataya deney-5 sonucunda ulaşılmıştır.

Rulman-stator çoklu arızasında ise en küçük hataya deney-6' da ulaşılmıştır. Bağlı hata % 1.07' dir. Bağlı hatanın en büyük olduğu değer % 4.12' dir. Bu hataya deney-2 sonucunda ulaşılmıştır.

Sonuç olarak önerilen koruma algoritması ile arıza tanılama sırasında en büyük bağlı hata % 14.83' tür.

5.4. Hızlı Fourier Dönüşümü (HFD) ile Arıza Analizi


Hızlı fourier dönüşümü birçok işaret işleme sisteminin vazgeçilmez bir uygulamasıdır. HFD bir zaman düzlem sinyalinin, eşdeğer frekans düzlem sinyaline dönüştürmekte kullanılan bir algoritmadır.

Asenkron motorlarda kırık rotor çubuğu arızası tanısı için stator akımlarının harmonik bileşenlerinin (HFD tabanlı) bazı araştırmalarda kullanıldığı görülmektedir. (Schoen ve ark. , 1995). Bu amaçla temel harmonik frekansının $\mp 2sf$ uzaklıktaki alt harmonikler arıza tanısı için kullanılmıştır. Burada s kaymayı ve f de kaynak frekansını simgelemektedir. Ancak hata tanılarda bu yöntemin birçok sakıncalı yönü vardır. Bu sakıncalı yönlerden bir tanesi ise yüke bağımlılıktır. Çünkü akım bileşenlerinin genliği yük bağlı motora ve bağlı yük sisteminin eylemsizliğine göre değişir. Bununla birlikte motor yüksüz ise bu yöntem kullanışsızdır çünkü s , kayma miktarı, yaklaşık sıfır olur ve kırık rotor çubuğu frekansı kaynak frekansıyla örtüşür. Bu metodun diğer bir sakıncalı yönü ise kırık rotor çubuğu arızasını algılamada kullanılan bu frekansları, küçük frekanslı yük torkları, voltaj dalgalanması ve rulman arızalarını oluşturabilmeleridir.

Bu bölümde tezde önerilen motor koruma algoritmasının başarımı akım analiz yöntemi olan HFD ile kıyaslanmıştır.

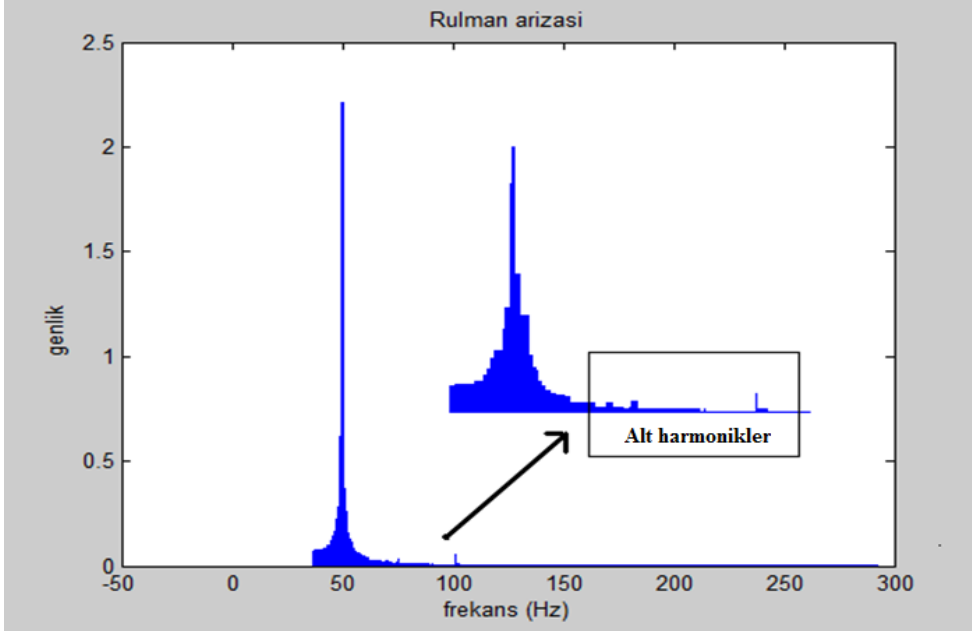
Stator akımı HFD (N=1024) algoritması uygulanarak frekans düzleminde oluşan alt harmonik bileşenlerinin genlikleri belirlenir. Genlik daha önceden belirlenen bir eşik seviyesinin üstündeyse motorda hata olduğuna, değilse motorda hata olmadığına karar verilir.

Senaryo 1: Motorda kırık rotor arızası var. Motor koruma algoritması test edilirken kullanılan kırık rotor çubuğu arıza senaryosu burada da kullanılmıştır. Şekil 5.18. kırık rotor çubuğu arızası sırasında HFD algoritması sonucu oluşan temel ve alt harmonikleri göstermektedir. Şekil 5.18. incelendiğinde alt harmonik genlik değerleri çok küçük olduğundan HFD algoritması hatayı algılayamamıştır. Fakat tezde önerilen motor koruma algoritmasında bu durum kırık rotor hatası olarak tespit edilmiştir.



Şekil 5.18. Kırık rotor çubuğu arızası sırasında temel ve alt harmonikler

Senaryo 2: Motorda rulman arızası var. Motor koruma algoritması test edilirken kullanılan rulman arıza senaryosu burada da kullanılmıştır. Şekil 5.19. rulman arızası sırasında HFD algoritması sonucu oluşan temel ve alt harmonikleri göstermektedir. Şekil 5.19. incelendiğinde alt harmonik genlik değerleri çok küçük olduğundan HFD algoritması hatayı algılayamamıştır. Fakat tezde önerilen motor koruma algoritmasında bu durum rulman hatası olarak tespit edilmiştir.



Şekil 5.19. Rulman arızası sırasında temel ve alt harmonikler

6. SONUÇ VE ÖNERİLER

Sonuç olarak sunulan tez çalışmasında TBA tabanlı YSA ile gerçek zamanlı veriler üzerinde arıza tespiti ve sınıflandırması için tam bir motor koruma algoritması gerçekleştirilmiştir. Önerilen koruma algoritması ile kırık rotor arızaları, rulman arızaları, stator arızaları, rotor-stator arızaları ve rulman-stator arızaları algılanır ve bu arızalar sınıflandırılmaktadırlar. Algoritmanın performansı ve doğruluğu birçok laboratuvar deneyi gerçekleştirilerek gözlenmiştir. Önerilen motor koruma algoritması giriş olarak ani faz akımlarını kullanır. Motor faz akımlarını örneklemede NI-DAQ PCI 16MIO-E kart kullanılmıştır. TBA tarafından kullanılan birincil akımlar işlenerek kalıntılar oluşturulur. Diğer aşamada TBA sonucu oluşan bu kalıntılar çok katmanlı algılayıcıya giriş olarak verilir. YSA' nın çıkışında sargı arızası, kırık rotor çubuğu arızası, rulman arızası ve normal çalışma, rotor-stator, rulman-stator arızalarından herhangi birini gösterir. Sunulan yöntem arıza teşhisi için sadece üç faz motor akım işaretine ihtiyaç duyduğundan farklı algılayıcılara gerek kalmaz. Böylece koruma algoritması arızaların tanınmasıyla üretim aşamasında sistemin düzenli çalışmasını sağlar ve fazla maliyet yükünden kurtulmuş olunur.

Tüm önerilen algoritmalar DSP tabanlı bir işlemci ile de işletilebilir. Daha hassas bir koruma algoritması için her üç faza ait hata vektörleri de elde edilebilir ve ağın giriş sayısı bu durumda 3' e çıkar. Böylece çok daha hassas bir koruma algoritması elde edilebilir. Bu tezde önerilen tek hata vektörlü koruma sisteminde arıza tanıları en az % 0.17 ve en fazla % 14.8 hata ile tespit edilmiştir.

Tezden Çıkan Ürünler

O. Ozgonenel, T. Yalcin, "Principal Component Analysis (PCA) Based Neural Network for Motor Protection" , DPSP 2010, The 10th International Conference on Developments in Power System Protection 29 March, 1April, 2010, Manchester, UK. Bildiri EK-B' de dir.

7. KAYNAKLAR

- Aktürk, N., Uneeb, M. and Gohar, R., 1997. The Effects of Number of Balls and Preload on Vibrations Associated with Ball Bearings, *Journal of Tribology*, 119, 747-753.
- Aktürk, N. and Gohar, R., 1998. The Effect of Ball Size Variation on Vibrations Associated with Ball-Bearings, *Proc. I.Mech.E.*, 212 Part J, 101-109.
- Aktürk, N., 1993. Rigid Shaft Supported by Angular Contact Ball Bearings, PhD.Thesis, Imperial College of Science, Technology and Medicine, University of London, pp 82-93.
- Aydın I., Karaköse M., Akin E., 2007. A Simple and Efficient Method for Fault Diagnosis Using Time Series Data Mining, *IEEE Electrical Machines & Drives Conference*, Antalya, 596-600.
- Aydın, İ., Karaköse, M., Akin, E., 2008. Zaman Serisi Veri Madenciliği ve Destek Vektör Makineler Kullanan Yeni Bir Akıllı Arıza Sınıflandırma Yöntemi, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, C. 23, Sayı 2, s. 431-440.
- Aydin, I., Karaköse, M., Akin, E., 2008. Artificial Immune Inspired Fault Detection Algorithm based on Fuzzy Clustering and Genetic Algorithm Methods, *İstanbul, IEEE Computational Intelligence for Measurement System and Applications (CIMSIA2008)*, C.1,s. 93-98.
- Ayhan, B., Chow, M. Y., Song, M. H., 2005. Multiple Signature Processing Based Fault Detection Schemes for Broken Rotor Bar in Induction Motors, *IEEE Trans. on Energy Conv.*, C. 20, No. 2, s. 336-343.
- Bangura, J. F., Povinelli, R. J., Demerdash, N. A. O., Brown, R. H., 2003. Diagnostics of Eccentricities and Bar/End-Ring Connector Breakages in Polyphase Induction Motors Through a Combination of Time-Series Data Mining and Time-Stepping Coupled FE–State-Space Techniques, *IEEE Trans. on Industry Applications*, C. 39, No. 4, s. 1005-1013.
- Belek, T., 1986. Makinelerde Titreşim Ölçümlerinin İzlenmesi Yolu İle Gerçekleştirilen Erken Uyarıcı Dinamik Bakım Yöntemleri, 2. Ulusal Makine Teorisi Sempozyumu, Gaziantep, 370-393.
- Bellini A., Filippetti F., Tassoni C., Capolino G.A., 2008. Advances in Diagnostic Techniques for Induction Machines, *IEEE Trans. On Industrial Electronics*, 15(2), 4109-4126.
- Benbouzid, M. E. H., Beguanane, R. Viera, M., 1999. Induction Motor Asymmetrical Faults Detection Using Advanced Signal Processing Techniques , *IEEE Trans. on Energy Conv.*, C. 14, No.2, s. 146-152.

- Benbouzid M.E., Kliman G.B., 2003. What Stator Current Processing based technique to use for induction motors rotor faults?, IEEE TRANSACTION ON ENERGY CONVERSION, Vol 18, No 2, pp 238-244.
- Branco, P. J. C., Dente, J. A., Mendes, R. V., 2003. Using Immunology Principles for Fault Detection, IEEE Trans. on Industrial Electronics, C. 50, No.2, s. 362-373.
- Braun, S. and Datner, B., 1979. Analysis of Roller/Ball Bearing Vibrations, Journal of Mechanical Design, 101, 119-125.
- Chow M. Y., 1997. Methodologies of Using Neural Network and Fuzzy Logic technologies for Motor Incipient Fault Detection, WORLD SCIENTIFIC. Pp 32-42.
- Cusidó, J.; Rosero, J.; Ortega, J.A.; Garcia, A.; Romeral, L.; 2008. Fault Detection in Induction Machines Using Power Spectral Density in Wavelet Decompositions ,IEEE Transactions on Industrial Electronics, Vol: 55 pp: 633-643.
- Da Silva, A. M., 2006. Induction Motor Fault Diagnostic and Monitoring Methods, Master Thesis, Marquette University, Milwaukee, WI, 159.
- Duda R.O., Hart P.E., Stork D.G., 2001. Pattern Classification, 2nd Ed.,654, John Wiley & Sons.
- Filipetti F., Franceschini G., Tassoni C., Vas P., 2000. Recent Developments of Induction Motor Drives Fault Diagnosis Using AI Techniques, IEEE TRANSACTION ON INDUSTRIAL ELECTRONICS, Vol 47, No 5, pp 994-1004.
- Gao, X. Z., Ovaska, S. J. Wang, X., Chow, M. Y., 2008. A Neural Network-based Negative Selection Algorithm in Fault Diagnosis, Neural Computing & Applications, C. 17, No. 1,s. 91-98.
- Haiging W., S. Zhihuan and L. Ping, 2000. Improved PCA with optimized sensor locations for process monitoring and fault diagnosis, Proceeding of teh 39th IEEE Conference on Decision and Control, pp 4353-4358, Sydney, Australia.
- Haji M., Toliyat H.A., 2001. Pattern Recognition- A Technique for Induction Machines Rotor Fault Detection Eccentricity and Broken Bar Fault, IEEE Trans. on Energy Conversion, 16 (4), 312-317.
- Hidden H. G., M. J. Willis, M.T. Tham, P. Turner and G., 1997. A. Montague. Non-linear principal components analysis using genetic programming, Genetic algorithms in engineering systems: Innovations and Applications, vol: 446, pp 302-307.
- Hyvärinen E. and J. Karhunen, E.Oja., 2001. Independent component analysis. Jhon Wiley and Sons.

- Kilic E., Ozgonenel O., Ozdemir A.E., "Fault Identification in Induction Motors with RBF Neural Network Based on Dynamical PCA", The IEEE International Electric Machines and Drives Conference (IEMDC 2007), 3-5 May, 2007, Antalya.
- Kliman G. B., Premerlani W. J., Koegl R. A., and Hoeweler D., 1996. A new approach to on-line fault detection in ac motors, in Proceedings of the IEEE Industry Application Society Annual Meeting Conference, pp. 687–693, San Diego, CA.
- Lay, David, 2000. Linear Algebra and It's Applications. Addison-Wesley, 588, Newyork
- Li, Y., Zhang, C., Kurfess, T.R., Danyluk, S. and Liang, S. Y., 2000. Diagnostics and Prognostics of a Single Surface Defect on Roller Bearings, Proc. Instn. Mech. Engrs., vol. 214 Part C, 1173-1185.
- Martins J.F., Pires V.F., Pires A.J., 2007. Unsupervised Neural-Network-Based Algorithm for an On-Line Diagnosis of Three-Phase Induction Motor Stator Fault", IEEE Trans. On Industrial Electronics, 54 (1), 259-264.
- McFadden, P. D. and Smith, J. D., 1984. Model for the Vibration Produced by a Single Point Defect in a Rolling Element Bearing, Journal of Sound and Vibration, 96(1a), 69-82.
- McFadden, P. D. and Smith, J. D., 1985. The Vibration Produced by a Multiple Point Defect in a Rolling Element Bearing, Journal of Sound and Vibration,98(2), 263-273.
- Milimonfared J., H. Kelk M., Nandi S., Minassians A. D., and Toliyat H. A., 1999. A novel approach for broken-rotor-bar detection in cage induction motors, IEEE Transactions on Industry Applications, Vol. 35, No. 5, pp. 1000–1006.
- Minsky M.ve Papert S., 1969. Perceptrons. The MIT Press, 323,Cambridge.
- Misra M. et al, 2002. Multivariate process monitoring and fault diagnosis by multi-scale PCA, Computer and chemical engineering, pp 1281-1293.
- Moya E., G. I. Sainz, B. Grande, M. J. Fuente and J. R. Peran, 2001. Neural PCA based fault diagnosis, Proceeding of the European Control Conference, pp 809-813.
- Nandi S., Toliyat H.A., and Li X., 2005. Condition Monitoring and Fault Diagnosis of Electrical Machines-A Review, IEEE Transactions on Energy Conversion, Vol. 20, No.4, pp.719-729.
- Nejjari H., Benbouzid M.E.H., 2000. Monitoring and Diagnosis of Induction Motors Using a Current Park's Vector Pattern Learning Approach, IEEE Trans. on Industry Applications, 36 (3), 730-735.
- Ondel O., Boutleux E., Clerc G., 2006. A Method to Detect Broken Rotor Bars in Induction Machine Using Pattern Recognition Techniques, IEEE Trans. on Industry Applications, 2(4), 916-923.

- Orhan, S., 2002. Rulmanlarla Yataklanmış Dinamik Sistemlerin Titreşim Analiziyle Kestirimci Bakımı, Doktora Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Makine Anabilim Dalı, Kırıkkale, 236 s.
- Povinelli, R. J., Bangura, J. F., Demerdash, N. A. O., Brown, R. H., 2001. Diagnostics of Faults in Induction Motor ASDs Using Time Stepping Coupled Finite Element State-Space and Time Series Data Mining Techniques, Philadelphia, Third Naval Symposium on Electric Machines, C. 1, s. 809,813.
- Povinelli, R. J., Bangura, J. F., Demerdash, N. A. O., Brown, R. H., 2002. Diagnostics of Bar and End-Ring Connector Breakage Faults in Polyphase Induction Motors Through a novel Dual Track of Time-Series Data Mining and Time-Stepping Coupled FE-State Space Modeling, IEEE Trans. on Energy Conversion, C. 17, No. 1, s. 39-46.
- Pöyhönen S., P Jover and H. Hyötyniemi, 2003. Independent component analysis of vibrations for fault diagnosis of an induction motor, Proceeding of the IASTED international conference, Circuits, Signals, and Systems. Pp 203-208. Cancun, Meksika.
- Rodriguez P.V.J., Antero A., 2008. Detection of Stator Winding Fault in Induction Motor Using Fuzzy Logic, Applied Soft Computing, 8, 1112-1120.
- Rumelhart D.E, Hinton G.E, Williams R.J, 1986. Learning representations by backpropagation errors, Nature, vol.323, pp 533-536.
- Schoen, R. R., Habetler, T. G., Kamran, F., Bartheld, R. G., 1995. Motor Bearing Damage Detection Using Stator Current Monitoring, IEEE Trans. on Industry App., C. 31, No. 6, s. 1274-1279.
- Su, Y.T., Lin, M.H. and Lee, M.S., 1993. The Effects of Surface Irregularities on Roller Bearing Vibrations, J. Sound and Vibration, 165(3), 455-466.
- Suykens J. A. K, Van Gestel T., Vandewalle J., and De Moor B., 2003. A support vector machine formulation to PCA analysis and its Kernel version, IEEE Transactions on neural networks. vol. 14, no. 2, pp 477-450.
- Tandon, N. and Choudhury, A., 1999. A Review of Vibration and Acoustics Measurement Methods for the Detection of Defects in Rolling Element Bearings, Tribology International, 32, 469-480.
- Taylor, J. I., 1980. Identification of Bearing Defects by Spectral Analysis, Journal of Mechanical Design, vol. 102, 199-205.
- Vas P., 1993. Parameter Estimation, Condition Monitoring, and Diagnosis of Electrical Machines, Oxford, U.K. Clarendon, pp 53-61.
- Vedam H. and V. Venkatasubramanian, 1999. PCA-SDG based process monitoring and fault diagnosis, Control engineering practice. vol.7. pp 903-917.

- Will, Todd, 1999, Introduction to the Singular Value Decomposition, Davidson College.
www.davidson.edu/academic/math/will/svd/index.html
- Yeh, C., Povinelli, R. J., Mirafzal, B., Demerdash, N. A. O. 2004. Diagnosing of Stator Winding Inter-Turn Shorts in Induction Motors Fed by PWM-Inverter Drive Systems Using a Time Series Data Mining, Singapore, IEEE International Conference on Power Systems, s. 891-896.
- Yeh C., Sayed-Ahmed A., Povinelli R., 2008. A Reconfigurable Motor for Experimental Emulation of Stator Winding Inter-Turn and Broken Bar Faults in Polyphase Induction Machines, IEEE Transactions on Energy Conversion, Vol. 23, No. 4, pp. 1005-1014.
- Zang H., A. K. Tangirala, S. Shah, 1999. Dynamic process monitoring using multiscale PCA, Proceeding of the 1999 IEEE Canadian conference on electrical and computer engineering, pp 1579-1584. Edmonton, Alberta, Canada.
- Zarei, J. Poshtan, J., 2007. Bearing Fault Detection Using Wavelet Packet Transform of Induction Motor Currents, Tribology, C. 40, s. 763-769.
- Zeng X., Y. Chen and Z. Nakao, 2002. Image feature representation by the subspace of nonlinear PCA , ,Icassp IEEE, pp 228-231.

8.EKLER

EK-A

```

%*****
% Matlab' da koruma algoritması için kullanılan kodlar
%*****

clear all,clc,close all
warning('off','MATLAB:dispatcher:InexactMatch')

load c:\exp\binhz\nc1

n=40;

Ip1=Ip1/3.2;Ip1=Ip1(1:n);
Ip2=Ip2/3.2;Ip2=Ip2(1:n);
Ip3=Ip3/3.2;Ip3=Ip3(1:n);

y1=[Ip1 Ip2 Ip3];

x=5;

z11 = regres([y1(:,1) y1(:,2)],x,x,1);
z12 = regres([y1(:,3) y1(:,3)],x,x,1);
z1=[z11 z12(:,1:5)];

R_d1=z1'*z1;
[U_d1,S_d1,V_d1] = svd(R_d1);

pe = 100*diag(S_d1)/sum(diag(S_d1));

%*****
% Hata hesabı
%*****

load c:\exp\binhz\nc1

Ip1=Ip1/3.2;
Ip2=Ip2/3.2;
Ip3=Ip3/3.2;
xx=1;yy=xx+39;
y2=[Ip1(xx:yy) Ip2(xx:yy) Ip3(xx:yy)];

u11 = regres([y2(:,1) y2(:,2)],x,x,1);
u12 = regres([y2(:,3) y2(:,3)],x,x,1);

```

```
u1=[u11 u12(:,1:5)];
```

```
y_1=0;
W = U_d1(:,3:end);
for i=1:n-x
    u=u1(i,:);
    r = (norm(W*sqrt(inv(S_d1(3:end,3:end)))*W'*u)')^2;
    y_1=[r;y_1];
end
```

```
diziters_a
```

```
figure,plot(t(1:length(xr1)),xr1),grid
break
sadeney3=xr1;
save c:\pca_tez1\sadeney3 sadeney3
load c:\pca_tez1\net
load c:\pca_tez1\sadeney3
an=sim(net,sadeney3');
an
break
```

```
%*****
% Eğitim verileri
%*****
```

```
load c:\PCA_tez1\nc
load c:\PCA_tez1\sa
load c:\PCA_tez1\ro
load c:\PCA_tez1\ru
load c:\PCA_tez1\rosa
load c:\PCA_tez1\rusa
```

```
egitim=[nc;sa; ro; ru; rosa ; rusa]';
```

```
hedef=[1 2 3 4 5 6];
```

```

%*****
% YSA'nin tasarimi, egitimi ve simulasyonu
%*****

net = newff(minmax(egitim),[18,9,1],{'tansig','tansig','purelin'},'trainrp');
net.trainParam.show =50;
net.trainParam.lr = 0.2;
net.trainParam.epochs =1000;
net.trainParam.goal = 1E-10;
net = train(net,egitim,hedef);

%*****
% Ağırlıkların ve biasların kaydedilmesi
%*****

netriw=net.iw{1};
nethd1=net.lw{2,1};
nethd2=net.lw{3,2};
netbias1=net.b{1};
netbias2=net.b{2};
netbias3=net.b{3};

save c:\pca_tez\netiw netiw
save c:\pca_tez\nethd1 nethd1
save c:\pca_tez\nethd2 nethd2
save c:\pca_tez\netbias1 netbias1
save c:\pca_tez\netbias2 netbias2
save c:\pca_tez\netbias3 netbias3

```

EK-B Tezden Çıkan Ürünler**Principal Component Analysis (PCA) Based Neural Network for Motor Protection:
A Real Time Study**¹O. Ozgonenel, ²T. Yalcin^{1,2}Ondokuz Mayıs University

Electrical & Electronic Engineering Department

55139 – Kurupelit – Samsun – TURKEY

e-mails: okanoz@omu.edu.tr, yalcnturgay@yahoo.com.tr**Abstract:**

In this work, a real time digital protection algorithm based on PCA and neural network methods is presented for induction motors. The proposed protection algorithm covers internal winding faults, broken rotor bar faults, and bearing faults. Many laboratory experiments have been performed on a specially designed induction motor to evaluate the performance of the suggested protection algorithm. The hybrid protection algorithm uses the instantaneous phase currents. These currents are first preprocessed by PCA to extract distinctive features called residuals. Then the calculated residuals are applied to a feed-forward back-propagation neural network as input vectors. The outputs of the network are winding fault, rotor bar fault, bearing fault, and normal operating. The proposed algorithm is implemented by using C++ with a NI-DAQ data acquisition board.

Index Terms: PCA, induction motor, faults, neural network

Introduction

The induction motor is one of the single most common electromechanical energy conversion devices. It is the critical component of the production processes and is widely used in domestic, commercial, and industrial motion control devices and systems. An induction motor is considered inherently reliable due to its robustness, relatively simple design and construction.

However, it faces various stresses during operation conditions. These stresses might lead to many modes of failures. Therefore the condition monitoring becomes necessary in order to avoid catastrophic failures (breakdowns) and ensures long life of electrical rotating machines. Furthermore, it reduces maintenance costs and prevents unscheduled downtimes. Therefore there has been a substantial amount of research to provide new condition monitoring techniques for AC induction motors.

Faults in induction are divided into three categories, such as stator winding faults, broken rotor bar problems, and bearing problems. Turn faults in stator winding of an induction motor leads to asymmetry between the three phases, causing undesirable motor behavior. This insulation breakdown in the stator winding corresponds to nearly 30-40% of the total motor failures. Stator faults can be classified into two different categories: laminations or frame faults and stator winding faults. [1]

The research in [2] conducted by the IEEE and Electrical Power Research Institute showed stator faults to be responsible for about 37% of total failures in induction motors. In common practice, these faults start as undetected turn to turn faults that finally grow and cumulate into major faults. Several interesting techniques have been introduced in the literature for purposes of diagnosis such type of fault at their early steps [3-7]. However, to these authors' knowledge, most of these techniques do not offer capability of identifying the specific faulty phase unless the neutral point is accessible or intrusive sensors are installed inside the machine. [8]

Bearing problems account for over 40% of all faults in induction motors. A successful bearing condition monitoring scheme must be able to detect location of faults and their severity levels. Bearing faults have been traditionally detected at incipient stage through vibration and stator current monitoring. Experimental results reveal the nature of vibration harmonic frequency bands which do not have any relationship to characteristic frequencies that have previously been used for bearing fault identification. [9]

The third fault in induction machines is broken rotor bar failure, although it is not very common type of fault. The classical approach used in the industrial environment for the detection of rotor bars in induction machines is based on the analysis of the stator current in the steady state, using two harmonic components placed around the main frequency component at distances $-2sf$ and $2sf$ (side band harmonics), where f is the main frequency and

s is the slip [11], [12]. This approach has been widely used due to its inherent advantages. However, it has some drawbacks for diagnosis purposes. One of them is load dependence because the amplitude of the current components depends on the load connected to the motor and on the inertia of the connected motor-load system. Furthermore, if the machine is unloaded, this approach is unsuitable because the slip will be approximately zero, and the frequencies associated with the broken rotor bars will overlap the supply frequency. Another problem of this method is that frequencies similar to those used for the rotor bar breakage detection can be generated by other causes such as low frequency oscillating torque loads, voltage fluctuations, or bearing faults [13]. Several interesting methods based on the steady state analysis can avoid some of these disadvantages [14-15], but most of them analyze other magnitudes [16-18].

As stated above, among the most important fault detection based on motor current is the motor current signature analysis (MCSA). This method relies on the interpretation of the frequency components in the stator current spectrum. Another successful fault detection method based on the analysis of the machine line currents is the Park's vector approach is based on the identification of a specified current pattern obtained from the transformation of the three phase stator currents to an equivalent two phase system. [19-20]

Among several soft computing techniques, artificial neural networks (ANNs) have verified their capability to perform induction motor fault detection. They present some advantages, such as flexibility to learn and do not need a precise mathematical model of the motor.

Methods proposed by other authors are focused on the analysis of the wavelet coefficients or use other mathematical techniques such as wavelet ridge. Other works convolute the start-up current signal with a Gaussian wavelet, which was centered on a particular frequency, to extract the evolution of the fault components. [18], [21-22].

This work is an extended study of referenced paper [23] and presents a complete real time induction motor protection algorithm based on dynamical principal component analysis (PCA). In this work, a combination of dynamical PCA approach and subsequently a feed forward back propagation neural network approach are used for MCSA to detect stator insulation failures (internal faults), broken rotor bar, and bearing faults. Dynamical PCA is used for feature vector extraction by using rms values of stator line currents and an RBF neural network used for fault identification purpose. The feature vectors extracted by using PCA have been used to train the neural network both off-line net training and on-line fault identification procedure. A specially designed four-pole, 1000 VA, 50Hz induction motor is used for laboratory experiments to validate the proposed techniques.

PCA Background

PCA is lower dimensional projection method that can use with multivariate data mining. The main idea behind the principal component analysis is to represent multidimensional data with fewer numbers of variables retaining main features of the data. It is inevitable that by

reducing dimensionality some features of the data will be lost. It is hoped that these lost features are comparable with the “noise-fault” and they do not tell much about underlying population. The method PCA tries to project multidimensional data to a lower dimensional space retaining as much as possible variability of the data. PCA is also a useful statistical technique having found application in fields such as face recognition and image compression, and is a common technique for finding patterns in data of high dimension.

Main ideas of PCA are reducing dimensionality without losing much information, finding a canonical representation of the data, and preserving variance of data.

The following examples **a** and **b** are useful for understanding the concept of PCA algorithm

a) Projecting a point (data vector) into a lower dimensional space with PCA:

1. Let data vector be x , and $x \in R$, $x = [x_1, x_2, \dots, x_n]$
2. Select a basis. Set of basis vectors are $u = [u_1, u_2, \dots, u_n]$. Orthonormal basis is considered with the following condition. $u_i \cdot u_i = 1$, and $u_i \cdot u_j = 0$ for $i \neq j$.
3. Select a center. \bar{x} defines offset of the space.
4. The best coordinates in lower dimensional space are defined by dot-products as

$$(z_1, z_2, \dots, z_k), z_i = (x - \bar{x}) \cdot u_i \quad (1)$$

5. It is required to find a direction of z_i that maximizes the variance and minimize the mean square error (mse).

PCA is a linear transformation that transforms the data to a new coordinate system such that the direction with the greatest variance lies on the first coordinate (called the first principal component (factor)) the second greatest variance on the second coordinate so on. (Figure 1)




Figure 1. Rotating the coordinate frame in order to maximize variance of projections

b) The basic PCA algorithm is defined in the following steps.

1. Read the data matrix of Y by $m \times n$.
2. Re-centering procedure by subtracting the mean value from each row of Y .

$$Y_c = Y - \bar{Y} \quad (2)$$

3. Computing covariance matrix.

$$\Sigma = \frac{1}{m} \sum_{i=1}^m (Y_c - \bar{Y})(Y_c - \bar{Y})^T \quad (3)$$

4. Finding eigen values and eigen vectors of Σ .

5. Selecting k^{th} eigen vectors with highest eigen values (principal components). Note that covariance matrix can be really big, therefore finding eigenvectors may take too much computer time. To overcome this problem singular value decomposition (SVD) is used to calculate k^{th} eigenvectors.

SVD Calculation

$$Y_{m,n} = \begin{bmatrix} W_{i,j} \\ \vdots \\ \vdots \\ \vdots \end{bmatrix}_{m,m} \begin{bmatrix} S_1 \\ \vdots \\ S_i \\ \vdots \\ S_n \end{bmatrix}_{n,n} \begin{bmatrix} V_{i,j} \\ \vdots \\ \vdots \\ \vdots \end{bmatrix}_{n,n}^T$$

The general SVD form is defined as in Eq. 4.

$$Y = WSV^T \quad (4)$$

In Eq. 4;

Y : data matrix, one row per data point

W : weight matrix, $m \times m$ matrix of eigenvectors of YY^T – coordinate of x^i in eigenspace

S : singular value matrix, diagonal matrix (in our setting each entry is eigenvalue λ_i), i.e, n diagonal elements contains of square root of the eigenvalues of Y^TY or YY^T , all other elements are zero.

V^T : singular vector matrix (in our setting each row is eigenvector v_j), i.e., rows of V contains the coefficients of the principal components.

The product of WS contains scores of the principal components that is amount of each observations contribution to the principal components.

The SVD is closely related to PCA and to eigenvalue computation. Recall from the eigenvalue equation 5:

$$Yx = \lambda x \quad (5)$$

The SVD is less restrictive in that it can be performed on any $m \times n$ matrix. The singular values of a matrix Y solve the equations 6 :

$$Yw = \lambda w, Y^T v = \lambda u \quad (6)$$

The vectors u and v are known as the right- and left-singular vectors respectively. We can show the relation

between SVD and eigenvalues through the following equations:

$$YY^T = (WSV^T)(WSV^T)^T = WSV^T V S U^T = US^2 U^T \quad (7)$$

$$Y^T Y = (WSV^T)^T (WSV^T) = VSW^T WSV = VS^2V^T$$

using the fact the W and V are orthogonal so $W^T=W^{-1}$. Equ. 7 shows that W and V can be calculated as the

eigenvectors of and respectively.

Residual Generation

The first stage is data manipulation. The data Y is constructed in a dynamic way under normal working conditions from the samples of the system inputs ($u(k)$) and/or outputs ($y(k)$) as:

$$Y = [y_{k-l+1}^T \ y_{k-l+2}^T \ \dots \ y_k^T]^T \quad (8)$$

where l denotes system order and y contains inputs and/or outputs data of length k . Since different variables in engineering systems usually use different units, the columns of Y usually need to be scaled; so they have zero mean and unity variance.

In the second stage, off-line stage, the covariance matrix is calculated by using auto scaled matrix as:

$$Cov = \frac{Y^T Y}{n - 1} \quad (9)$$

where Y shows auto scaled data matrix. To calculate principal components (PCs), the eigenvectors and eigenvalues of the covariance matrix have been computed and arranged in decreasing order of eigenvalues. The eigenvectors of the auto scaled covariance matrix are called PCs and they are used for residual generation purposes.

In the last stage, on-line residual generation stage, each new observation vector is auto scaled using the means and variances obtained in the off-line stage and projected on to the principal component subspace. Then a residual vector at discrete time k is calculated, using a few principal components (PCs) as.

$$e_k = \left\| Y_m - \hat{Y} \right\|^2 = \left\| (I - W_1 W_1^T) Y_m \right\|^2 \quad (10)$$

In a different way, the residual vector e at discrete time k is calculated by using a few PCs related to the error matrix W_2 as:

$$e_k = \left\| W_2 W_2^T Y_m \right\|^2 \quad (11)$$

where Y_m shows measurement vector and \hat{Y} is called prediction of the measurement vector. After detecting residual vectors, a fault isolation technique is needed. Threshold based fault isolation techniques may not work well in here. So, classification techniques or reasoning based fault isolation methods should be used.

The residual vector e_k is applied to the ANN network as an input. The ANN network produces decisions about the type and degree of fault such as “single fault” or “multiple faults”.

ANN Structure for Fault Identification and Classification

ANN is used for fault identification and classification purposes in the paper. A back propagation neural network is a multilayer network which consists of an input layer, a hidden layer and an output layer. Generally the network involved three stages of processes, namely the feed-forward of input training pattern, the back propagation of the calculated error and lastly the weight adjustment based on the error calculation. Activations flow from the input layer through the hidden layer, then to the output layer. A back propagation network typically starts out with a random set of weights. In feed-forward stage, the input neuron receives the input signal and fires it to every hidden neuron. Upon receiving the signal from the input neuron, the hidden neuron computes the activation and the result fires to the output layer.

In output layer, the output neuron computes the activation to obtain the net output. In the second stage, the back propagation of error stage computes the error by comparing the net output with the desired or target value. From the error, the error gradient at the hidden and the output neurons are calculated and the new weights are determined. The back propagation network updates its weights incrementally till it produce more accurate predictions and the network stabilizes. This is carried out in the last stage of the network, the weight updating stage.

Back-propagation Network Preparation

Back-propagation network preparations are the parameters or items considered during the training of the network.

Training Set

It is a collection of input and output set that are used in the network training. The input output set are the data obtained from the experiment stage and pre-processes. This stage has numerous set of data obtained from real world.

Testing Set

It is a collection of input and output set that are used to assess or test the network performance. Usually the training set is randomly select from the testing set. The testing set is the complete set of data and obtained from real time working conditions.

Learning Rate

Learning rate is a guideline, a scalar parameter to determine the analogous changes occurs in the weights each circle when the network undergone a training.

Momentum Factor

The momentum factor is added to enhance the speed of network training. By adding the momentum factor, the weight changes according to the direction of the current gradient descending.

Number of Input Neuron and Hidden Neuron

The number of input neuron and hidden neuron required is a critical factor for a good training. As there is no specific method on how to determine the number of input neuron and hidden neurons in a network training, therefore the rule of try and error is used as guidelines in determining the number of hidden neuron in this work.

The basic architecture of the fault identification unit with 3 inputs and 4 outputs is shown in Fig. 2.

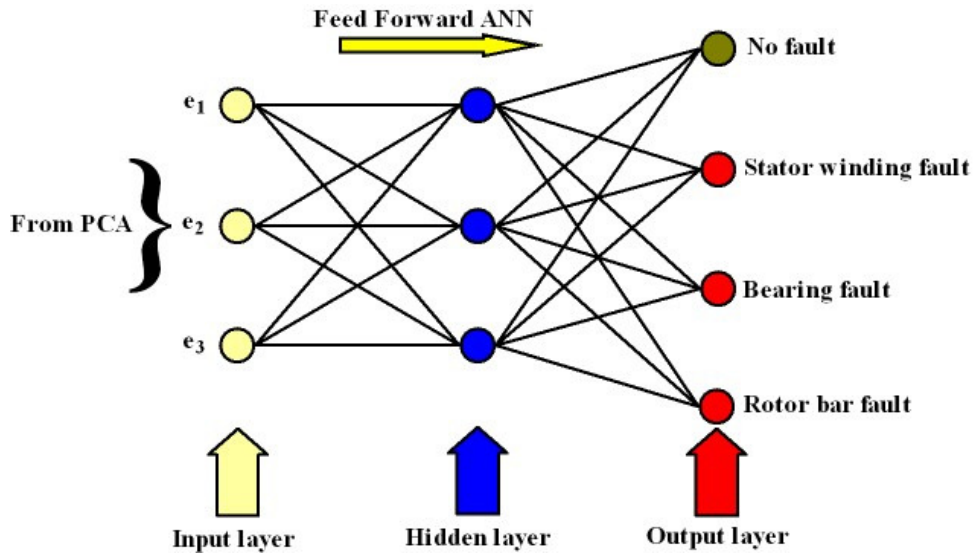


Figure 2. ANN structure for fault detection

As it is seen in Fig. 2, the suggested ANN network has 1 input layer with 3 neurons (i.e. fed by dynamical PCA algorithm), a hidden layer with 3 neurons and output layer with 4 neurons. The nodes in adjacent layers are fully connected. Fig. 3 shows the flowchart of the proposed fault detection and identification technique. The input vectors are defined as in Eq. 12.

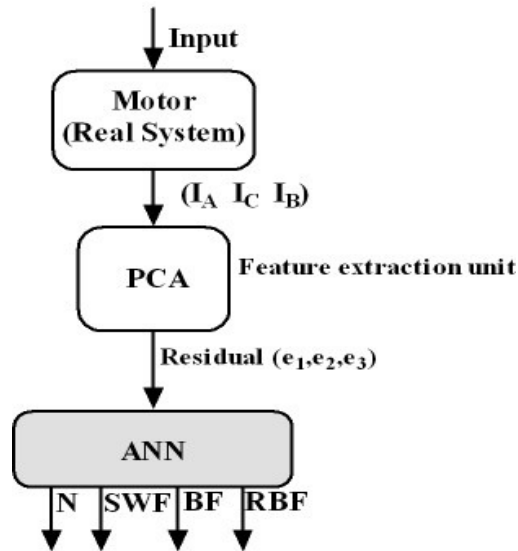


Figure 3. A complete fault identification and detection flowchart for motor protection, (N for normal operating, SWF for stator winding fault, BF for bearing fault, and RBF for rotor bar fault)

The overall ANN used in this paper is defined as follows.

$$X_i = [e_1 \ e_2 \ e_3]_{20 \times 3} \quad (12)$$

The input vector, X_i , has a 20x3 matrix and is output of the PCA algorithm. The hidden neuron is defined as in Eq. (13).

$$\begin{aligned} Z_{inj} &= v_{oj} + \sum X_i v_{ij} \\ Z_j &= f(Z_{inj}) \end{aligned} \quad (13)$$

Where Z_j is the output of the hidden unit and input of the output unit and $i, j = 3$.

Then, the output neuron is defined as in Eq. (14).

$$\begin{aligned} Y_{inj} &= w_{oj} + \sum Z_i w_{ij} \\ Y_j &= f(Y_{inj}) \end{aligned} \quad (14)$$

The network error is defined as in Eq. (15).

$$\begin{aligned} \delta_k &= (t_k - y_k) f'(Y_{inj}) \\ \Delta w_{jk} &= \alpha \delta_k Z_j \\ \Delta w_{0k} &= \alpha \delta_k \end{aligned} \quad (15)$$

In Eq. 15, t_k is the expected output, y_k is the output, $f'(Y_{inj})$ is the derivation of the output through activation function, and Δw_{0k} is the total error at the k instant.

The activation is computed on the hidden neuron based on the output error as in Eq. 16.

$$\begin{aligned}
\delta_{inj} &= \sum_{k=1}^m \delta_k w_{jk} \\
\delta_j &= \delta_{inj} f'(Z_{inj}) \\
\Delta v_{ij} &= \alpha \delta_k X_i \\
\Delta v_{0j} &= \alpha \delta_j
\end{aligned} \tag{16}$$

In Eq. 16, Δv_{0j} is the back-propagation variation of the threshold weights, δ_j is the back-propagation error at the j nth layer.

The updating the weights is defined as in Eq. 17.

$$\begin{aligned}
w_{jk}(new) &= w_{jk}(old) + \Delta w_{jk} \\
v_{ij}(new) &= v_{ij}(old) + \Delta v_{ij}
\end{aligned} \tag{17}$$

This procedure (Eq. 12 thru Eq. 17) is repeated until the desired rms error is reached.

Real Time Studies

A custom-built three-phase induction motor (1kVA, 380V, 2.8A, 4 poles) has been used for laboratory experiments to test the suggested fault protection algorithm. Different internal faults within the motor (i.e., insulation faults) are formed in the laboratory. Stator line currents are acquired with a sampling frequency of 1000Hz, which corresponds 20 samples in a cycle. True rms values of the line currents are calculated in each window interval and they are applied as inputs of the PCA algorithm to get the features (signatures) from the three-phase currents. The outputs of the PCA are the feature vectors representing normal working condition, abnormalities in the stator windings, rotor bar failures, and bearing faults. For all real time experiments the simulation time is set to 2 sec.

The following Figures show the result of real time experiments.

A) No Fault Condition

A number of experiments with different load conditions are performed in this section. The calculated rms values from instantaneous line currents are used as offline training procedure for PCA algorithm. Then the residuals (error vector) calculated by Eq. 11 are the inputs of the ANN for training procedure. In case of no fault condition, the magnitude of the error vector is very low as seen in Fig. 4.




Figure 4. Stator line currents and calculated error vectors (output of PCA) during no fault condition

In Fig. 4, the first row represents line currents of the motor and second row represents the calculated error vectors during no fault condition. The algorithm interprets the magnitudes of the error vectors as zero during no fault condition since the magnitudes have a value of 10^{-7} approximately. Then, these error vectors (e_A, e_B, e_C) are used as input functions of ANN. The output of ANN will produce 'no fault' with these inputs.

B) Stator Faults (Insulation Faults)

All stator faults are implemented by using a fault resistor to limit the short circuit current and to simulate the high impedance faults. Turn to turn or turn to earth faults are instantaneously formed by an electro-mechanical relay and a fault switch. The following Fig. 5 shows the fault inception scheme and 4 pole – winding layout.

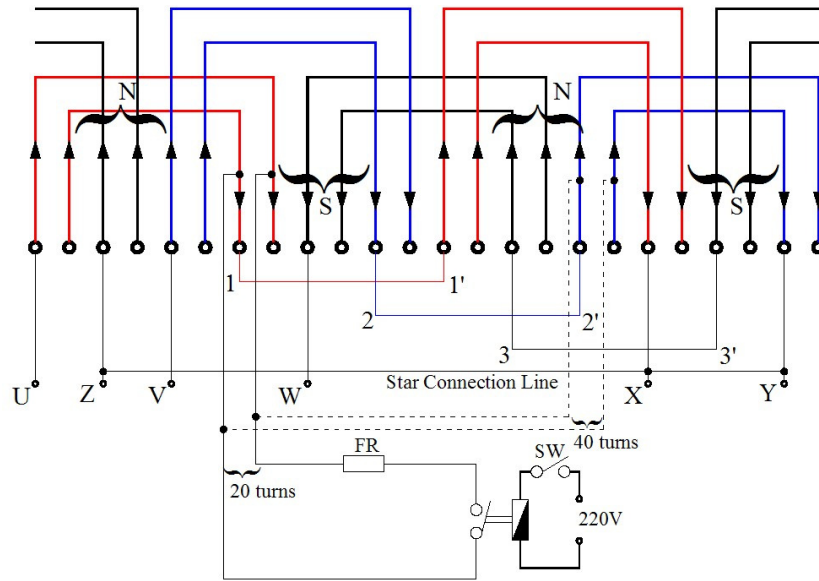


Figure 5. Winding layout of the custom built motor and fault inception scheme

A number of turn to turn or turn to earth faults are done in stator windings. In this research work, the faulty phase information (A Phase - red line) is used for training of PCA and ANN. Another C phase information (blue line) is used for testing for these algorithms. Fault resistance, FR , is chosen as 0.5Ω , 1Ω , 2Ω , and 2.5Ω to simulate possible insulation faults in phase windings. The following Fig. 5 shows the PCA outputs (ANN inputs) during 20 turns short circuited in phase A. As seen in Fig. 6 the magnitudes of error vectors are much higher during the internal fault than the magnitudes of error vectors during normal operating condition. Since the overall experimental set up is a three phase system, two phase currents are affected during the internal fault in only one phase.




Figure 6. Stator line currents and calculated error vectors (output of PCA) during internal fault in A Phase

Similarly, Fig. 7 shows the PCA outputs during 20 turns short circuited in phase C.




Figure 7. Stator line currents and calculated error vectors (output of PCA) during internal fault in C Phase

C) Start-up Condition

Since the start-up condition is not a fault, the proposed protection algorithm should stay remain during the start-up process. To aim this goal, PCA algorithm is trained for start-up condition and the related output of ANN interprets this situation as normal operating condition. Unlike the error vectors during internal faults, all error vectors have a spikes and higher magnitudes as seen in Fig. 8.




Figure 8. Stator line currents and calculated error vectors (output of PCA) during start-up process

D) Bearing Fault Condition

This condition is tested by using intentionally damaged bearing as seen in Fig. 9. In this case, it is observed that the phase currents (rms values) do not change significantly but the output of the PCA has distinctive features. Therefore the ANN algorithm interprets this situation as bearing fault.




Figure 9. Artificially created bearing fault

The following Fig. 10 shows the stator line currents and calculated error vectors during bearing fault condition.




Figure 10. Stator line currents and calculated error vectors during bearing fault condition

E) Broken Rotor Bar Fault

Two identical rotors are used for real time experiments, one for healthy conditions and the other one (having a broken bar) is used for testing rotor bar faults. The following Fig. 11 shows the rotor with a broken bar.




Figure 11. Broken rotor

The following Fig. 12 shows the stator line currents and calculated error vectors during rotor bar fault condition. Unlike the bearing fault condition, magnitudes of the error vectors are higher than the bearing rotor fault condition. Therefore the ANN algorithm interprets this situation as rotor bar fault condition.




Figure 12. Stator line currents and calculated error vectors during rotor bar fault condition

Broken rotor bar fault condition is tested while induction motor is unloaded. As stated in Introduction Section if the machine is unloaded, classical frequency based approaches fail to identify the fault due to the frequencies associated with the broken rotor bars will overlap the supply frequency. As seen in Fig. 12, even the machine is unloaded; the proposed protection algorithm is successfully able to identify the broken rotor bar fault.

The following Figures 13 and 14 show the fundamental and sub-harmonic frequencies during no-load condition, respectively without rotor bar fault and with rotor bar fault.




Figure 13. Fundamental and sub harmonics during no-load and healthy condition




Figure 14. Fundamental and sub harmonics during no-load and rotor bar fault condition

As seen in Fig. 14, frequency based techniques like FFT can detect the sub harmonics caused by rotor bar fault but since they have low magnitudes and can also be produced by oscillating load torques, they can not be used as distinctive features for future analysis.

Conclusion

This paper presents a novel application of PCA and neural network for a complete induction motor protection scheme. The protection algorithm covers stator winding faults, bearing faults, and rotor bar faults. These faults are tested on a specially designed induction motor in laboratory environment. The suggested protection algorithm is based on rms values of three phase stator currents. These currents are first preprocessed by PCA to distract distinctive features and then supplied as input variables to ANN for classifying the faults. The method is tested in different faulty and operating conditions, and its results are compared with those obtained from the classical Fourier analysis of the stator current in steady state.

The suggested protection algorithm doesn't require any additional hardware sensors to be installed in the machine, knowledge of machine design details or special wiring constrains.

The proposed technique has been verified using real time experimental test results. These authors believe that this technique presents a powerful tool which can be utilized in a future research to predict a faulty motor remaining life and provide fault mitigation strategy for this type of faults.

References

- [1] J. F. Martins, V. Fernão Pires, and A. J. Pires, "Unsupervised Neural-Network-Based Algorithm for an On-Line Diagnosis of Three-Phase Induction Motor Stator Fault", IEEE Trans. On Industrial Electronics, Vol. 54, No. 1, February 2007.
- [2] Motor Reliability Working Group, "Report of Large Motor Reliability Survey of Industrial and Commercial Installations: Part-I and Part-II", IEEE Trans. On Industry Applications, vol. IA-2 1, no. 4, Jul./Aug. 1985, pp. 853-872.
- [3] A. Stavrou, H. G. Sedding, and J. Penman "Current Monitoring for Detecting Inter-Turn Short Circuits in Induction Motors," IEEE Trans. On Energy Conversion, vol. 16, March 2001.
- [4] J. Penman, H. G. Sedding B. A. Lloyd, and W. T. Fink "Detection and location of interturn short circuits in the stator winding of operating motors," IEEE Trans. On Energy Conversion, vol. 9, pp. 652-658, Dec. 1994.
- [5] G. M. Joksimovic and J. Penman "The Detection of Interturn Short Circuits in the Stator Windings of Operating Motors," IEEE Trans. On Industrial Electronics, vol. 47, Oct. 2000.
- [6] S. Nandi and H. A. Toliyat "Novel Frequency –Domain-Based Technique to Detect Stator interturn Faults in Induction Machines Using stator–Induced Voltages After Switch Off," IEEE Trans. Industrial Applications, vol. 38, Jan/Feb. 2002.
- [7] S. Nandi, H. A. Toliyat, and X. Li "Condition Monitoring and Fault Diagnosis of Electrical Motors-A Review," IEEE Trans. On Energy Conversion, vol. 20, pp.719-729, Dec. 2005.
- [8] Ahmet Sayed, Chia-Chou Yeh, Nabeel A. O. Demerdash, Behrooz Mirafzal, "Analysis of Stator Winding Inter-Turn Short-Circuit Faults in Induction Machines for Identification of the Faulty Phase", IEEE 41st IAS Annual Meeting Conference, Volume 3, 8-12 Oct. 2006, pp:1579-1524
- [9] Rajesh Patel, S P Gupta, and Vinod Kumar, "Real-Time Identification of Distributed Bearing Faults in Induction Motor", PEDES '06. International Conference on Power Electronics, Drives and Energy Systems, 12-15 Dec. 2006, pp:1-5.

- [10] G. B. Kliman, J. Stein, and R. D. Endicott, "Noninvasive detection of broken rotor bars in operating induction motors," *IEEE Trans. Energy Convers.*, vol. 3, no. 4, pp. 873–879, Dec. 1988.
- [11] W. Deleroi, "Squirrel cage motor with broken bar in the rotor—Physical phenomena and their experimental assessment," in *Proc. ICEM*, Budapest, Hungary, 1982, pp. 767–770.
- [12] M. F. Cabanas, M. G. Melero, and G. A. Capolino, "A new methodology for applying the FFT to induction machine on-line diagnosis," in *Proc.Int. SDEMPED*, Gijon, Spain, Sep. 1999, pp. 537–543.
- [13] A. Bellini, F. Filippetti, G. Franceschini, C. Tassoni, and G. B. Kliman, "Quantitative evaluation of induction motor broken bars by means of electrical signature analysis," *IEEE Trans. Ind. Appl.*, vol. 37, no. 5, pp. 1248–1255, Sep./Oct. 2001.
- [14] F. Filippetti, G. Franceschini, C. Tassoni, and P. Vas, "AI techniques in induction machines diagnosis including the speed ripple effect," *IEEE Trans. Ind. Appl.*, vol. 34, no. 1, pp. 98–108, Jan./Feb. 1998.
- [15] R. R. Schoen and T. G. Habetler, "Evaluation and implementation of a system to eliminate arbitrary load effects in current-based monitoring of induction machines," *IEEE Trans. Ind. Appl.*, vol. 33, no. 6, pp. 1571–1577, Nov./Dec. 1997.
- [16] J. F. Watson, K. S. Gow, and W. T. Thomson, "Non-invasive instrumentation for on-line management and monitoring of electrical plant," in *Proc. Inst. Elect. Life Manage. Power Plants*, 1994, pp. 48–56.
- [17] M. Negrea, P. Jover, and A. Arkkio, "A comparative investigation on the reliability and accuracy of different diagnostic media when attempting to identify specific faults in an induction motor," in *Proc. SPEEDAM*, Capri, Italy, May 16–18, 2004, pp. 809–814.
- [18] Jose A. Antonino-Daviu, Martin Riera-Guasp, José Roger Folch, and M. Pilar Molina Palomares, "Validation of a New Method for the Diagnosis of Rotor Bar Failures via Wavelet Transform in Industrial Induction Machines", *IEEE Trans. On Industry Applications*, Vol. 42, No. 4, July/August 2006, pp:990-996.
- [19] A. J. M. Cardoso, S. M. A. Cruz, J. F. S. Carvalho, and E. S. Saraiva, "Rotor cage fault diagnosis in three-phase induction motors by Park's vector approach," in *Proc. IEEE Ind. Appl. Conf.*, 1995, vol. 1, pp. 642–646.
- [20] A. J. M. Cardoso, S. M. A. Cruz, and D. S. B. Fonseca, "Inter-turn stator winding fault diagnosis in three-phase induction motors, by Park's vector approach," *IEEE Trans. Energy Conv.*, vol. 14, pp. 595–598, Sep. 1999.

- [21] R. Burnett, J. F. Watson, and S. Elder, "The application of modern signal processing techniques to rotor fault detection and location within three phase induction motors," *Eur. Signal Process. J.*, vol. 49, no. 1, pp. 57-70, Feb. 1996.
- [22] J. F. Watson and N. C. Paterson, "Improved techniques for rotor fault detection in three-phase induction motors," in *Conf. Rec. IEEE-IAS Annu. Meeting*, Oct. 12–15, 1998, vol. 1, pp. 271–277.
- [23] E. Kilic, O. Ozgonenel, A.E. Ozdemir, "Fault Identification in Induction Motors with RBF Neural Network Based on Dynamical PCA", *The IEEE International Electric Machines and Drives Conference (IEMDC 2007)*, 3-5 May, 2007, Antalya.

ÖZGEÇMİŞ

ADI SOYADI: Turgay YALÇIN
DOĞUM TARİHİ: 16/ 12/ 1981
MEDENİ HALİ: Bekâr
BİLDİĞİ YABANCI DİLLER: İngilizce
EĞİTİM DURUMU
LİSE: Samsun Milli Piyango Anadolu Lisesi
2000
LİSANS: Erciyes Üniversitesi - 2006
YÜKSEK LİSANS: Ondokuz Mayıs Üniversitesi - 2007
ÇALIŞTIĞI KURUM/KURUMLAR: Ondokuz Mayıs Üniversitesi
İLETİŞİM BİLGİLERİ: yalcnturgay@yahoo.com.tr