

# ZAMAN SERİSİ VERİ MADENCİLİĞİ VE DESTEK VEKTÖR MAKİNALAR KULLANAN YENİ BİR AKILLI ARIZA SINIFLANDIRMA YÖNTEMİ

İlhan AYDIN, Mehmet KARAKÖSE\* ve Erhan AKIN\*

Bilgisayar Teknolojisi ve Prog. Eğt., Kemaliye H.A. Akın Meslek Yüksekokulu, Erzincan Üniversitesi 24600  
Kemaliye Erzincan

\*Bilgisayar Mühendisliği Bölümü, Fırat Üniversitesi, 23119, Elazığ  
[iaydin@firat.edu.tr](mailto:iaydin@firat.edu.tr), [mkarakose@firat.edu.tr](mailto:mkarakose@firat.edu.tr), [eakin@firat.edu.tr](mailto:eakin@firat.edu.tr)

(Geliş/Received: 17.07.2007; Kabul/Accepted: 06.12.2007)

## ÖZET

Asenkron motorlar endüstriyel uygulamalarda en çok kullanılan makinelerdir. Bu motorlar genellikle güvenilir olmalarına rağmen ortam ve eskimeye bağlı sebeplerden dolayı birçok arızaya maruz kalabilirler. Bu çalışmada, bir asenkron motorda oluşan kırık rotor çubuğu arızaları, destek vektör makineler ve zaman serisi veri madenciliği ile sınıflandırılmıştır. Arıza sınıflandırma için kullanılacak zaman serisi park vektör yaklaşımının iki bileşeni kullanılarak elde edilmektedir. Her bir arıza durumu için elde edilen yeni zaman serisi bir faz alanına dönüştürülmektedir. Sağlam ve arızalı faz alanlarını ayırt etmek için destek vektör makineler kullanılmaktadır. Destek vektör makinelerin eğitim hızını arttırmak için bulanık küme merkezleri eğitim verisi olarak alınmaktadır. Geliştirilen yöntem ile bir, iki, üç kırık rotor çubuğu arızaları ve sağlam durum, dört farklı çalışma hızında başarılı bir şekilde sınıflandırılmaktadır.

**Anahtar Kelimeler:** Zaman serisi veri madenciliği, destek vektör makineler, asenkron motor, kırık rotor çubuğu arızaları, arıza teşhisi.

## A NEW INTELLIGENT FAULT CLASSIFICATION METHOD USING TIME SERIES DATA MINING AND SUPPORT VECTOR MACHINES

### ABSTRACT

Induction motors are the most used machines in industrial applications. Although these motors are generally reliably, they can be exposed many faults due to environmental and wear reasons. In this study, broken rotor bar faults occurred in an induction motor are classified using support vector machines and time series data mining methods. Time series to be used for fault diagnosis is obtained by using two components of park's vector approach. The new time series which is obtained for each fault condition is transformed to a phase space. Support vector machines are used to separate healthy and faulty phase spaces. Fuzzy cluster centers are taken as training data to increase training speed of support vector machines. Healthy motor condition and one, two and three broken rotor bar faults are successfully classified at four different operation speeds with developing method.

**Keywords:** Time series data mining, support vector machines, induction motor, broken rotor bar faults, fault diagnosis.

### 1. GİRİŞ (INTRODUCTION)

Endüstride kullanılan motorların %80 gibi büyük bir kısmını asenkron motorlar oluşturmaktadır [1]. Asenkron motorlar birçok uygulamada kullanılır. Bu motorların büyük bir kısmından 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 sebepleri; basit yapıları, güvenilirlikleri ve çok az periyodik bakıma ihtiyaç duymalarından gelir [2]. Asenkron

motorların çalışma ortamları genellikle aşındırıcı ve nemli olduğundan motorların belirli bölümlerinde zamanla arızalar oluşur. Durum izleme ve arıza teşhis şemaları asenkron motorun mil yatağı, rotor ve stator gibi bileşenleri ile ilgili arızaları incelemektedir. Arızaların %10'a yakın bir kısmı motorun rotor bileşeni ile ilgilidir [3]. Arıza teşhisinde titreşim, hız, akı gibi pahallı motor parametreleri yerine maliyet açısından daha ucuz olan akım duyargaları tercih edilir [4]. Kırık rotor çubuğu arızalarını belirlemek için motor akım imza analiz en çok kullanılan yöntemlerden biridir. Motor akım imza analizinde stator akımının Hızlı Fourier Dönüşümü alınarak frekans spektrumu oluşturulur. Spektrumda frekansı 50 Hz hat frekansından küçük ilk spektral büyüklük sol, hat frekansından büyük ilk spektral büyüklük sağ yan banttır. Sol yan bantın genliği ölçülerek belli bir değer ile karşılaştırılır ve bu karşılaştırmanın sonucu bir arıza olup olmadığını belirler. Fakat yan bant bileşenleri motor yükü düşük olduğunda oluşmazlar [5]. Ayrıca, yan bantların hesaplanması için motor hızı gereklidir.

Son yıllarda geleneksel arıza teşhis yöntemlerinin yerini yapay sinir ağları, bulanık mantık, destek vektör makinalar, genetik algoritmalar, yapay bağışık sistemler ve veri madenciliği gibi akıllı arıza teşhis yöntemleri almıştır [6]. Akıllı hesaplama tabanlı teknikler hem arızaları sınıflandırma hem de arızanın büyüklüğünü belirleme özelliğine sahiptirler.

Motordan duyargalar ile alınan sinyaller üzerinden arıza teşhisi yapan birçok akıllı hesaplama tekniği vardır. Yapay sinir ağları ve bulanık mantık ile tek fazlı bir asenkron motorun mil yatağı ve stator arızaları akım ve hız bilgileri kullanılarak teşhis edilmiştir [2]. Kolla ve diğ. [7] üç fazlı bir asenkron motorda oluşan aşırı yük, tıkalı rotor, dengesiz besleme gerilimi, topraklama arızaları ve düşük gerilim gibi arızaları belirlemek için ileri beslemeli bir yapay sinir ağı önermiştir. Benbouzid ve diğ. [8] bulanık mantık tabanlı bir arıza teşhis algoritması ile üç fazlı bir asenkron motorun faz akımlarının değişimini inceleyerek gerilim dengesizliği ve açık faz arızalarını teşhis etmiştir. Ayhan ve diğ. [9] dört farklı yük durumu altında bir kırık rotor arızasını teşhis etmek için motor akım imza analizi ile elde edilen dört yan bantlı çoklu diskriminant analizi ve yapay sinir ağları ile sınıflandırmıştır. Arıza teşhis algoritmasının girişlerini motor akımı ve rotor hızı sinyalleri oluşturmaktadır. Bir diğer çalışmada 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 [10]. Destek vektör makinalar kullanılarak kırık rotor, kırık sonlandırıcı, mil yatağı ve stator arızaları teşhis edilmiştir [11, 12]. Bu iki çalışmada, titreşim analizi ve motor akım imza

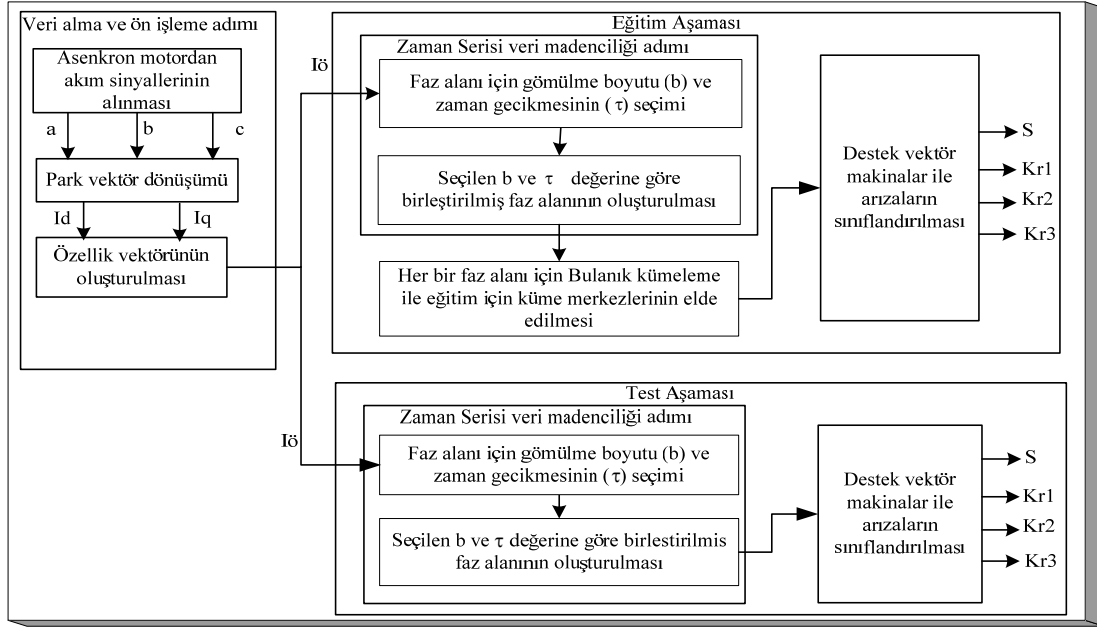
analizi gibi özellik çıkarımı yöntemleri kullanılmıştır. Motor akım imza analizi eğer motor bir şebekeden besleniyorsa iyi sonuçlar vermesine rağmen, PWM ile beslenen motorlar için uygun değildir. Çünkü bu tür motorlarda hız değişken olmaktadır [13]. Zaman serisi veri madenciliği ile kırık rotor, kırık sonlandırıcı ve eksantriklik arızaları teşhis edilmiştir [13]. Aydın ve diğ. [14] motorun dört farklı çalışma hızı için kırık rotor çubuğu arızalarını zaman serisi veri madenciliği ve bulanık kümeleme algoritması ile belirlemiştir. Yaptıkları çalışmada arıza teşhisi için motorun sadece üç faz akımı kullanmışlardır. Benbouzza ve diğ. [15] kırık rotor arızalarını belirlemek için park vektör yaklaşımı kullanmıştır. Aydın [16] iki farklı motordaki kırık rotor, eksantriklik, sarım ve mil yatağı arızalarını teşhis etmek için akıllı hesaplama teknikleri ve veri madenciliği kullanmıştır. Yapay bağışık sistemler ve motor akım imza analizi yöntemi ile arızalar teşhis edilmiştir [17].

Bu çalışmada bir, iki ve üç kırık rotor çubuğu arızalarını farklı çalışma hızlarında teşhis etmek amacıyla üç faz akımı kullanılmıştır. Motorun üç fazından elde edilen özellik vektörü zaman serisi veri madenciliği aracılığıyla bir faz alanına dönüştürülmektedir. Her bir motor durumunu sınıflandırmak için faz alanları destek vektör makinalar ile sınıflandırılmaktadır. Destek vektör makinaların sınıflandırma performansını arttırmak için faz alanındaki bütün noktaları eğitim için kullanmak yerine her bir faz alanı bulanık kümeleme ile kümeler ayrılarak bu küme merkezleri eğitim için kullanılmıştır. Kümeler doğru bir şekilde sınıflandırıldıktan sonra küme içinde kalan veriler de doğru sınıflandırılmış olacaktır. Bu çalışmada sadece üç faz akım bilgisi arıza teşhisi için kullanılmakta olup, elde edilen özellik sinyali faz alanında destek vektör makinalar ile başarılı bir şekilde sınıflandırılabilir biçimdedir.

## 2. ARIZA SINIFLANDIRMA İÇİN ÖNERİLEN YÖNTEM (THE PROPOSED METHOD FOR FAULT CLASSIFICATION)

Kırık rotor çubuğu arızalarının teşhisi için önerilen yöntem motorun üç faz akımına ihtiyaç duyar. Alınan üç faz akımı üzerinde gerekli ön işleme adımları ile özellik vektörleri elde edildikten sonra zaman serisi veri madenciliği yöntemi ile zaman serisinin faz alanı oluşturulur. Bulanık kümeleme algoritması ile faz alanındaki noktalar farklı kümeler ayrılır. Küme merkezleri destek vektör makinalara giriş olarak verilerek eğitilir. Sağlam ve arızalı motor verilerinin faz alanı dağılımları destek vektör makinalar ile sınıflandırılarak arızalar teşhis edilmektedir. Şekil 1'de önerilen arıza sınıflandırma yönteminin şeması verilmiştir.

Şekil 1'e göre a, b ve c asenkron motorun üç faz akımını göstermektedir. Bu üç faz akımı üzerinden park vektör dönüşümü ile park vektör bileşenleri  $I_d$  ve



Şekil 1. Arıza sınıflandırma şeması (Fault classification scheme)

$I_q$  elde edilmektedir. Bu iki bileşen ile özellik vektörü  $I_0$  elde edildikten sonra bu vektör faz alanına dönüştürülür. Faz alanındaki noktalar bulanık kümeleme ile kümeler ayrılır. Destek vektör makinaların eğitim örnekleri bu küme merkezlerinden oluşturulur. Böylece eğitim daha hızlı yapılabilen ve bir nokta yanlış sınıfta olsa bile ait olduğu küme doğru sınıfta ise doğru bir şekilde sınıflandırılmaktadır. Sistemin çıkışlarından S sağlam motor durumunu, Kr1 bir, Kr2 iki ve Kr3 üç kırık rotor çubuğu arızalarını göstermektedir. Önerilen yöntemin adımları aşağıda detaylı olarak verilmektedir.

### 2.1. Veri Ön İşleme Modülü- Özellik Vektörü Çıkarımı (Data Pre-processing Module- Extraction of Feature Vector)

Üç fazlı bir asenkron motorda stator akımlarının toplamı sıfırdır [8]. Park vektör yaklaşımı üç fazlı asenkron motorun hat akımlarının iki boyutlu gösterimini elde etmek için kullanılır. Park vektörünün genel biçimi denklem (1)'de verilmiştir.

$$\begin{aligned} I_d &= \sqrt{\frac{2}{3}}a - \frac{1}{\sqrt{6}}b - \frac{1}{\sqrt{6}}c \\ I_q &= \frac{1}{\sqrt{2}}b - \frac{1}{\sqrt{2}}c \end{aligned} \quad (1)$$

Park vektörü önemli performans düşüklüklerinin olduğu açık faz, gerilim dengesizliği gibi arızaları direkt olarak belirlemek için tek başına yeterlidir. Kırık rotor çubuğu arızalarının teşhisi için bu dönüşümün tek başına kullanılması uygun değildir. Çünkü eğer örüntüler farklı arızalar için aynı ise bu dönüşüm yanlış sonuçlar verir. İkinci bir dezavantaj ise gürültü olduğunda sınıflandırma işlemi zor

olacaktır [18]. Fakat park vektör dönüşümünün akımdaki bütün bilgileri tutması ve arıza teşhisinde kullanılabilecek değişken sayısını azaltması gibi özelliklerinden dolayı bu dönüşüm üzerinden özellik vektörünün elde edilmesi amaçlanmıştır. Bu amaçla şekil 2'de yeni bir özellik vektörü olan  $I_0$  serisini elde etmek için algoritmanın bir bölümü verilmiştir. Şekil 3'te yöntemin uygulandığı bir örnek verilmiştir.

```

s=0;
While(i<boyut(Id))
  if (Id(i)>Id(i-1))&(Id(i)>0)&(Id(i)<Id(i+1))
    continue;
  if(Id(i)>0)&(Id(i)>Id(i-1))&(Id(i)>Id(i+1))
    Io1(s)=Id(i);
    s=s+1;
end

```


Şekil 2. Özellik vektörünün elde edilmesi (Constituting of feature vector)

Şekil 2'deki algoritma ile sadece  $I_d$  park vektör bileşeninin tepe noktasına yakın bölgelerdeki değişimlerden oluşan  $I_{01}$  vektörü elde edilmiştir. Bu işlem,  $I_q$  vektörü için de tekrarlanarak  $I_{02}$  elde edilir ve iki vektör birleştirilerek  $I_0$  vektörü elde edilir. Elde edilen özellik vektörü zaman serisi veri madenciliği yöntemine giriş olarak verilmeden önce [0,1] aralığında normalize edilir.

### 2.2. Zaman Serisi Veri Madenciliği Modülü (Time Series Data Mining Module)

Bir zaman serisi, belirli zaman aralıklarında bir sistemden alınan verilerdir. Denklem (2)'de bir zaman serisi örneği verilmiştir.

$$X = \{x_t, t = 1..n\} \quad (2)$$



Şekil 3. Elde edilen özellik vektörü (Obtained feature vector)

Burada  $t$  zamanı ve  $n$  örnek sayısını gösterir. Zaman serisi veri madenciliği yöntemi bir zaman serisinden ilginç örüntülerin çıkarılması amacıyla serinin bir faz alanında incelenmesini gerektirir. Zaman serisinden çıkarılması gereken ilginç örüntüler olay olarak ifade edilir [13]. Farklı amaçlar için kullanılan zaman serilerinde olay kavramı farklı anlamlar ifade eder. Örneğin sismik bir zaman serisinde depremler önemli olaylar olarak alınırken, günlük stok fiyatlarını tutan bir zaman serisinde ani fiyat düşüşü veya yükselişi ve bir asenkron motorda oluşan arızalar zaman serisi veri madenciliği için bir olaydır [19].

Zaman serisi veri madenciliği yöntemi, veri madenciliği ve lineer olmayan zaman serisi analizinin birleşiminden oluşmaktadır. Zaman serisinin amacına göre herhangi bir optimizasyon algoritması veya sınıflandırma algoritması kullanılır. Bu çalışmadaki amaç, farklı çalışma durumlarını ayırt etmek olduğundan bir sınıflandırma işlemi yapılacaktır. Zaman serisi veri madenciliği yönteminde bir zaman serisi faz alanında incelenir. Denklem (2)'deki zaman serisi için oluşturulan faz alanı matrisinin bir satırı denklem (3)'teki gibidir.

$$X_t = (x_{t-(b-1)\tau}, x_{t-(b-2)\tau}, \dots, x_t) \quad (3)$$

Yukarıdaki denklemde  $b$  gömülme boyutunu ve  $\tau$  ise zaman gecikmesini gösterir. Faz alanı matrisinde dikkat edilmesi gereken nokta, matrisin her satırının faz alanında bir noktaya karşılık gelmesidir. Örneğin gömülme boyutu  $b=3$  ve zaman gecikmesi  $\tau=2$  olarak seçildiğinde faz alanında bir nokta

$X_t = (x_{t-4}, x_{t-2}, x_t)$  ile ifade edilir. Dolayısıyla üç boyutlu bir faz alanı oluşturulur. Zaman gecikmesinin belirlenmesi için karşılıklı bilgi yöntemi ve gömülme boyutunun belirlenmesi için yanlış en yakın komşu algoritması kullanılır [19].

### 2.2.1. Faz alanı için zaman gecikmesinin seçimi (Selecting time lag for phase space)


Faz alanına dönüştürülen bir zaman serisinin iki farklı zamanda alınmış örnekleri arasındaki değişimleri belirlemek veya birbirine benzer iki zaman serisi arasındaki farklılıkları ortaya çıkarmak için uygun bir zaman gecikmesi seçilmelidir. Zaman gecikmesi küçük olduğunda faz alanındaki noktalar birbirine çok yakın olduklarından zaman serilerinin ayırt edilmesi zorlaşır. Karşılıklı bilgi yöntemi denklem (4)'te verilmiştir.

$$M(X_t, X_{t+\tau}) = \sum_{i,j} p_{ij}(\tau) \ln p_{ij}(\tau) - 2 \sum_{i,j} p_i \ln p_i \quad (4)$$

Burada  $p_i$ ,  $X_t$ 'nin histogramda  $i$ . kutuda kalma olasılığı ve  $p_{ij}$   $X_t$ 'nin  $i$ . kutuda kalma ve  $X_{t+\tau}$ 'nin  $j$ . kutuda kalma olasılığıdır. Bu yöntemde de karşılıklı bilgi fonksiyonunun ilk minimuma ulaştığı gecikme zaman gecikmesi olarak alınır [5]. Faz alanı matrisinin aynı satırındaki her bir matris elemanı, orijinal zaman serisinden bir zaman gecikmesi ve gömülme boyutuna göre oluşturulan yeni zaman serilerinin bir elemanıdır. Dolayısıyla yukarıdaki denklemde matrisin bir satırındaki  $X_t$  biliniyorsa faz alanında ona karşılık gelen aynı satırdaki  $X_{t+\tau}$  değeri de tahmin edilebilir.

### 2.2.2. Faz alanı için gömülme boyutunun belirlenmesi (Determining embedding dimension for phase space)

Faz alanı için minimum bir gömülme boyutunun belirlenmesi faz alanında benzersizlik için önemlidir. Bu özelliğin belirlenmesi için yanlış en yakın komşu algoritması kullanılır [5]. Aşağıda denklem (5)'te bu yöntem verilmiştir.



Şekil 4. Zaman gecikmesi ve gömülme boyutunun belirlenmesi (Determining of time lag and embedding dimension)

$$r_i = \sqrt{\frac{\|X_i^{b+m} - X_j^{b+m}\|^2 - \|X_i^b - X_j^b\|^2}{\|X_i^b - X_j^b\|^2}} \quad (5)$$

Burada  $\|X_i^b - X_j^b\|$  iki nokta arasındaki öklid mesafesidir.  $R^{b^c}$  de her nokta  $X_i^b$  ile tanımlanır [19].  $X_i^b$ 'nin en yakın komşusu  $X_j^b$ 'dir.  $r_i$  verilen bir  $v$  eşik değerini aştığında  $X_i^b$  yanlış bir en yakın komşuya sahip olarak işaretlenir. Bu algoritma  $r_i > v$  için veri noktalarının sayısı  $R^b$ 'da sıfır olduğunda  $b$  gömülme boyutu olarak tanımlanır. Bu çalışmada zaman serisi olarak  $I_0$  özellik vektörünün faz alanı oluşturulmuştur. Faz alanı için zaman gecikmesi karşılıklı bilgi yöntemine göre 4 ve gömülme boyutu yanlış en yakın komşu algoritmasına göre 2 seçilmiştir. İki yöntemin  $I_0$  üzerindeki sonuçları ve oluşturulan bir faz alanı örneği Şekil 4'te verilmiştir.

### 2.3. Bulanık Kümeleme Modülü (Fuzzy Clustering Module)

Bulanık kümeleme algoritması, bulanık üyelik derecesi kullanarak bir verideki noktaları kümelere ayıran bir yöntemdir [20]. Bu algoritmada her bir nokta 0 ile 1 arasında üyelik derecesi ile bütün kümelere ait olabilirler. Bulanık kümelemenin amacı benzersizlik fonksiyonunu minimum eden küme merkezlerini bulmaktır. Üyelik matrisi (U) denklem (6)'da verilmiştir. Bulanık kümelemede kullanılan benzersizlik fonksiyonu ise denklem (7)'de verilmiştir.

$$\sum_{i=1}^c u_{ij} = 1, \forall j = 1, \dots, n \quad (6)$$

$$J(U, c_1, c_2, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (7)$$

Burada  $u_{ij}$  0 ile 1 arasında bir değerdir. Bir  $i$  kümesinin merkezi  $c_i$  ile ifade edilir. İki küme merkezi arasındaki mesafe  $d_{ij}$  ve  $m$  ise  $[1, \infty]$  arasında değer alan ağırlıklandırma üssüdür. Bu çalışmada amaç, arızaları sınıflandırmak olduğundan bulanık kümeleme faz alanındaki noktaları temsil etmek için kullanılmaktadır. Zaman serisi veri madenciliği ile elde edilen faz alanındaki noktaların hepsini destek vektör makinaların girişleri olarak kullanmak algoritmanın eğitim zamanını artırır. Fakat bu noktaları temsil edecek küme merkezlerini kullanmak hem eğitim hızını artırır hem de küme merkez noktaları doğru sınıflandırıldıklarında kümeye ait olan veriler de doğru sınıflandırılacağından doğruluk oranı yüksek sonuçlar alınır.

### 2.4. Destek Vektör Makinalar Modülü (Support Vector Machines Module)

Destek vektör makineler, 1960'ların sonunda V. Vapnik tarafından geliştirilen bir istatistiksel öğrenme metodu olup, iki sınıflı bir sınıflandırma yöntemidir [21]. Destek vektör makinaların en basit modeli lineer olarak ayrılabilen girişler için uygulanan modeldir. Burada iki sınıf mevcut olup bir sınıfın etiketi -1 diğer sınıfın etiketi +1 ile ifade edilir. İki sınıflı bir problem için  $m$ -boyutlu  $x$  girişleri eğer lineer bir şekilde ayrılabilirse denklem (8)'deki ifade bu sınıfları ayırmak için kullanılır.


$$f(X) = w^T x + b \quad (8)$$

İki sınıf arasındaki destek vektörlerin maksimum olması için denklem (9)'daki ilk ifadedin minimum yapılması ve bütün örneklerin doğru sınıflandırılması için her eğitim örneği ikinci eşitsizliği sağlanmalıdır.

$$\frac{1}{2} \|w\|^2 \quad \text{minimum} \quad (9)$$

$$y_i(w^T x_i + b) \geq 1 \quad \forall \text{ eğitim örneği için}$$

İki sınıflı lineer bir aşırı düzlem ile ayrılabilen bir örnek gösterim Şekil 5'te verilmiştir. Sınıflandırma için birden fazla aşırı düzlem elde edilebilir. Fakat önemli olan destek vektör olarak isimlendirilen ve aşırı düzleme en yakın noktaların arasındaki mesafenin maksimum olmasıdır [22].



Şekil 5. Lineer şekilde ayrılabilen örnekler için optimal aşırı düzlem (Optimal hyper plane for linearly separable samples)

Eğer eğitim örnekleri sayısı fazla ise denklem (12)'deki optimizasyon problemini çözmek için Lagrangian fonksiyonunu kullanmak gerekir.

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j x_i^T x_j$$

$$\sum_{i=1}^l y_i \alpha_i = 0 \quad (10)$$

$$\alpha_i \geq 0$$

Burada  $\alpha = (\alpha_1, \dots, \alpha_l)$  lagrangian çarpanlarıdır. Eğer optimal çözümler  $\alpha^*$  ve  $b^*$  ise denklem

(12)'deki eşitsizlik sadece sıfıra eşit olmayan  $\alpha^*$ 'lar için sağlanır. Linear şekilde ayrılabilen verilerde hatalı sınıflandırma varsa denklem (10)'daki ifadeye pozitif  $\xi$  serbestlik değerlerinin toplamı C penaltı parametresi ile çarpılarak eklenmelidir. Eğer sınıflar birbirinden linear bir şekilde ayrılmıyorsa verilerin daha yüksek boyutlu yeni bir özellik alanına dönüştürülmesi gereklidir. Bu amaçla giriş örnekleri üzerinde denklem (11)'deki dönüşüm uygulanır.

$$z(x) = [a_1\phi_1(x), a_2\phi_2(x), \dots, a_n\phi_n(x)]^T \quad (11)$$

Bu özellik dönüşümünden sonra linear karar fonksiyonu aşağıdaki biçime dönüşür.

$$f(x) = \sum_{i=1}^l \alpha_i y_i z^T(x) z(x_i) + b \quad (12)$$


Linear olmayan sınıflandırmada, giriş verileri çekirdek fonksiyonları adı verilen fonksiyonlardan geçirilip özellik uzayına düşürülürler ve burada sınıflandırma yapılır. En çok kullanılan çekirdek fonksiyonları denklem (13), (14) ve (15)'te verilmiştir [23].

$$K(x, y) = (x \cdot y)^d \quad (13)$$

$$K(x, y) = \exp(-\|x - y\|^2 / (2\sigma^2)) \quad (14)$$

$$K(x, y) = \tanh(\kappa(x \cdot y) + \phi) \quad (15)$$

Destek vektör makinaları iki sınıflı bir sınıflandırma yöntemi olmasına rağmen bazı yöntemler kullanılarak çok sınıflı sınıflandırma problemlerinde kullanılabilir. Kullanılan yöntemlere birine karşı bir, birine karşı diğerleri ve yönlendirilmiş çevrimsiz çizge örnekleri verilebilir [21]. Birine karşı biri yönteminde ikili sınıflar alınır ve birbirinden ayrılır. Bu yöntem Şekil 6'da verilmiştir.



Şekil 6. Çok sınıflı sınıflandırıcı (Multi-class classifier)

### 3. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)


Önerilen arıza sınıflandırma algoritmasını uygulamak için MATLAB programı kullanılmıştır. Arıza sınıflandırma için üç fazlı gerçek bir asenkron motordan akım sinyalleri alınmıştır. Kullanılan motor ile ilgili parametreler Tablo 1'de gösterilmiştir. Kırık

rotor arızalarını oluşturmak amacıyla üç adet rotor çubuğu delinmiştir. Asenkron motordan verileri elde etmek amacıyla Advantech'in 16 bitlik bir veri toplama kartı kullanılmıştır. Akım verileri 3000 örnek/saniye ile 3 saniye boyunca alınıp kaydedilmiştir

Tablo 1. Deneyde kullanılan asenkron motorun özellikleri (Features of induction motor used in the experiment)

Özellik	Değer
Güç	0.37 Kw
Giriş gerilimi	380 V
Tam yük akımı	1.2 A
Frekans	50 Hz
Kutup sayısı	4
Rotor slot sayısı	22
Tam yükte çalışma hızı	1390 Rpm

Asenkron motordan veriler dört farklı hızda alınmıştır. Motora verilen besleme gerilimleri 260, 300, 340 ve 380 V olarak seçilmiştir. Üç faz akımından elde edilen akım sinyalleri arıza sınıflandırma için kullanılmıştır. Üç faz akımı denklem (1)'de verilen dönüşüm kullanılarak park vektörüne dönüştürülmüştür. Her bir sağlam ve arızalı motor için elde edilen park vektör bileşenlerinden yeni özellik vektörü Şekil 2'deki algoritma kullanılarak elde edilmiştir. Şekil 7'de kullanılan motorun faz akımları, elde edilen park vektörü ve özellik vektörü görülmektedir.




a) Faz akımları b) Park ve özellik vektörleri  
(a) Feature vectors (b) Park and feature vectors)

Şekil 7. Bir kırık rotor çubuğuna sahip motorun faz akımları ve özellik vektörleri (Phase currents and feature vector having one broken rotor bar fault)


Özellik vektörünü direkt olarak arızayı belirlemek için kullanmak yeterli değildir. Şekil 8'de 260 V ile beslenen bir motor için sağlam ve bir kırık rotor için elde edilen özellik vektörleri verilmiştir. Şekil 9'da K1260 260V ile beslenen bir kırık rotor çubuğu için özellik vektörünü gösterirken, S260 ise aynı besleme gerilimi için sağlam motor için özellik vektörünü gösterir.

Elde edilen özellik vektörlerine göre kırık rotor çubuğu arızalarını sınıflandırmak için özellik vektörü zaman serisi veri madenciliği yönteminin bir ön işleme adımı olarak faz alanına dönüştürülür. Her bir

arıza durumu ve sağlam motor durumu için ayrı ayrı faz alanları oluşturulmuştur. Faz alanı için zaman gecikmesi denklem (5)'teki yöntemle göre dört, gömülme boyutu ise denklem (6)'daki yöntemle göre iki ve olarak seçilmiştir. Şekil 9'da ayrı ayrı oluşturulan faz alanlarının birleştirilmiş hali görülmektedir.




**Şekil 8.** Sağlam ve bir kırık rotor çubuğu için özellik vektörleri (Features vectors for healthy motor and one broken rotor bar fault)



**Şekil 9.** Farklı durumların birleştirilmiş faz alanı (Combined phase space of different conditions)

Faz alanında çok fazla veri olduğundan bu verilerin hepsini destek vektör makinalarının eğitimi için kullanmak çok fazla hesaplama zamanı almaktadır. Bunun yerine sadece verileri temsil edecek bulanık küme merkezlerinin kullanılması yöntemin performansını arttıracaktır. Faz alanındaki verilerin kaç kümeye ayrıldığı da önemlidir. Çünkü az sayıda bulanık küme kullanıldığında bütün veriler temsil edilmeyebilir ve yanlış sınıflandırma işlemi yapılmış olur. Çok sayıda küme kullanıldığında ise bir veriyi temsil eden birden fazla küme merkezi olacaktır. Sağlam motor için özellik vektörünün faz alanı ve bulanık kümeleme ile bu durumu temsil eden küme

merkezleri Şekil 10'da gösterilmiştir.



**Şekil 10.** Faz alanı ve bulanık kümeleme ile elde edilen küme merkezleri (Cluster centers obtained via phase space and fuzzy clustering)

Şekilde BKM değeri bulanık küme merkezlerini ve SMBFA ise sağlam motor için birleştirilmiş faz alanını ifade etmektedir. Destek vektör makinalar normalde iki sınıflı istatistiksel bir sınıflandırıcı yöntemidir. Burada sağlam, bir kırık, iki kırık ve üç kırık rotor çubuğu şeklinde dört ayrı sınıf mevcuttur. Çok sınıflı bir sınıflandırma işlemi için önceki bölümde anlatılan bire karşı bir yöntemi kullanılmıştır. Faz alandaki verilerin dağılımı lineer olmadığından veriler yeni bir özellik alanına dönüştürülmüştür. Yeni özellik alanı vektörü denklem (16)'da verilmiştir.

$$z = [1 \quad I_{i1}^2 \quad \sqrt{2} * I_{i1} * I_{i2} \quad I_{i2}^2 \quad \sqrt{2} * I_{i1} \quad \sqrt{2} * I_{i2}] \quad (16)$$

Bu denklemde  $I_{i1}$  ve  $I_{i2}$  anlık giriş ve bir sonraki örnek değeri temsil etmektedir. Algoritmanın performansını değerlendirmek için iki farklı radyal tabanlı çekirdek fonksiyonu (rtçf) kullanılmıştır. Lineer ve polinom çekirdek fonksiyonlarının performansı daha düşük olduğundan sonuçları gösterilmemiştir. Daha önce denklem (14)'te verilen radyal tabanlı çekirdek fonksiyonun değiştirilmiş biçimi (Drtçf) de kullanılmıştır. Bu fonksiyon denklem (17)'de verilmiştir.

$$K(x, y) = \exp(-\sqrt{\|x - y\|^2} / (2\sigma^2)) \quad (17)$$


**Tablo 2.** İki farklı Rtçf fonksiyonu için destek vektör makinalar için eğitim ve test sonuçları (Training and test results of support vector machines for two different radial based kernel functions)

Eğitim Zamanı (sn)	$\sigma$	Doğruluk Yüzdeleri (%)		Eğitimde kullanılan Bulanık küme sayısı	Rtçf
		Eğitim	Test		
0.26	1.00	100	94.83	30	Drtçf
0.20	1.50	98.33	58.63	30	Drtçf
0.20	0.50	100	98.58	30	Drtçf
0.43	0.25	100	99.49	30	Drtçf
0.43	1.00	100	97.40	30	Rtçf
0.43	1.50	99.4	95.53	30	Rtçf
0.40	0.50	100	99.03	30	Rtçf
0.30	0.25	100	99.46	30	Rtçf

**Tablo 3.** İki farklı Rtcf fonksiyonu için destek vektör makinalar için eğitim ve test sonuçları (Effects of fuzzy cluster's number on performance of support vector machines)

Eğitim Zamanı (sn)	$\sigma$	Doğruluk Yüzdesi (%)		Eğitimde kullanılan bulanık küme sayısı	Rtcf
		Eğitim	Test		
0.10	1.0	100	90.33	15	Drtcf
<b>0.10</b>	<b>0.5</b>	<b>100</b>	<b>92.57</b>	<b>15</b>	<b>Drtcf</b>
<b>0.13</b>	<b>0.25</b>	<b>100</b>	<b>95.03</b>	<b>15</b>	<b>Drtcf</b>
0.10	1.5	100	75.04	15	Drtcf
0.10	1.0	100	91.59	15	Rtcf
<b>0.10</b>	<b>0.50</b>	<b>100</b>	<b>94.75</b>	<b>15</b>	<b>Rtcf</b>
<b>0.10</b>	<b>0.25</b>	<b>100</b>	<b>97.59</b>	<b>15</b>	<b>Rtcf</b>
0.10	1.5	100	89.03	15	Rtcf

Destek vektör makinalar ile sağlam ve bir kırık rotor çubuğu arızalarının iki ayrı sınıfa ayrılması görülmektedir. Eğitim için sadece bu iki durum için elde edilen bulanık küme merkezleri kullanılmıştır. Bu örnek için  $\sigma = 0.5$  olarak alınmış ve denklem (14)'teki çekirdek fonksiyonu kullanılmıştır. Eğitim örneklerinin %100 başarı oranı ile sınıflandırıldığı Şekil 11'den de görülmektedir.

**Şekil 11.** Destek vektör makinalar ile sağlam ve bir kırık rotor çubuğu faz alanlarının sınıflandırılması (Classification of healthy and one broken rotor bar phase spaces by support vector machines)

Destek vektör makinaların çekirdek parametreleri uygun bir şekilde ayarlandığında birçok doğrusal olmayan problemi başarılı bir şekilde sınıflandırabilir. Bu çalışmada radyal tabanlı çekirdek fonksiyonun  $\sigma$  parametresi ve kullanılan bulanık küme sayısına göre yöntemin performansı değerlendirilmiştir. Penaltı parametresi C 100 olarak alınmıştır. Yöntemin arıza teşhisi için gösterdiği performans Tablo 2'de farklı parametre seçimlerine göre verilmiştir. Tablo 3'te kullanılan bulanık küme sayısı 15'e düşürüldüğünde test performansının yine %97.59 olduğu görülmektedir.

Aynı zamanda eğitim zamanı da ortalama 0.1 sn çıkmaktadır. Bu çalışmada bulanık kümeleme sadece eğitim verisi için kullanılmıştır. Normalde eğer eğitim

için kullanılan küme sayısı en uygun olursa faz alanındaki noktalar üyelik derecelerine göre herhangi bir kümeye ait olacağından veriler eğitimdeki doğruluk yüzdeleri kadar yani %100 sınıflandırılacaktır. Fakat burada test için direkt olarak eğitim kümesi kullanılmayıp motor durumlarını gösteren faz alanındaki bütün noktalar ve farklı zamanlarda alınmış akım sinyalleri kullanılmıştır. Dolayısıyla eğitim ile test veri kümesi farklı verilerden oluşmaktadır.

Bu çalışmanın en önemli avantajlarından biri, arıza sınıflandırma amacıyla sadece üç faz akım bilgisine ihtiyaç duymasındır. Daha önce zaman serisi veri madenciliği yöntemini kullanan birçok çalışma kırık rotor arızalarının teşhisi için genellikle moment bilgisine ihtiyaç duymaktaydılar. Moment bilgisi hassas ölçümler gerektirdiğinden pahalı bir tekniktir. Zaman serisi veri madenciliği kullanarak kırık rotor çubuğu arızasının bulunması için Silva [5] tarafından yapılan çalışmada üç faz akımının yanında motor hız bilgisine de ihtiyaç duyulmaktadır. Hız bilgisi slot harmoniklerinden ve rotor sayısı hesaplanarak elde edilmektedir. Fakat bu çalışmada, sadece üç faz akımı kullanılmakta ve bu faz akımından elde edilen dönüşüm ile yeni özellik vektörü elde edilmektedir. Önerilen yöntem ile Silva [5] tarafından önerilen yöntemin performans karşılaştırması Tablo 4'te gösterilmiştir.

Literatürde kırık rotor çubuğu arızalarını sınıflandırmak için önerilen yaklaşımların çoğu motor akım imza analizine dayalıdır. Bu yöntemin en önemli dezavantajı kırık rotor arızalarının teşhisi için kullanılan yan bant genliklerinin motor yükünden etkilenmesi ve motor hızının ölçülmesini gerektirmesidir. Günümüzde artık asenkron motorların çoğu PWM cihazlar ile beslendiğinden hız ölçümü de değişken olmaktadır. Önerilen yöntemin

**Tablo 4.** Literatürdeki bir çalışmanın uygulanması ve elde edilen sonuçların performansının karşılaştırması (Applying of one study in literature and performance comparison of obtained results)

Makale No	Kullanılan Küme Sayısı	En düşük Doğruluk	En yüksek Doğruluk	Ölçülen Motor Parametreleri	Matematiksel Karmaşıklık
<b>Önerilen yöntem</b>	<b>15</b>	<b>95.03</b>	<b>97.59</b>	<b>Üç faz motor akımı</b>	<b>Orta</b>
	<b>30</b>	<b>99.03</b>	<b>99.49</b>		
[5] nolu makaledeki yöntemin uygulanması	16	93.00	96.00	Üç faz motor akımı ve hız bilgisinin çıkarımı	Yüksek

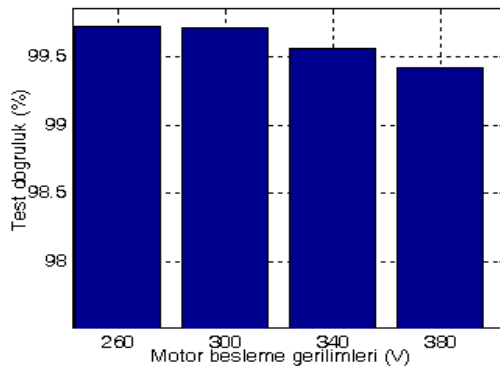


**Tablo 5.** Literatürde kullanılan yöntemler ile performans ve matematiksel karmaşıklık karşılaştırması  
(Performance and mathematical complexity comparison with used methods in literature)

Makale No	Ölçülen motor sinyali	Kullanılan metotlar	Matematiksel karmaşıklık	Tespit edilen arızalar	Ortalama doğruluk (%)
<i>Önerilen yöntem</i>	<i>Üç faz akımı</i>	<i>Zaman serisi veri madenciliği ve destek vektör makinalar</i>	<i>Orta</i>	<i>Bir, iki ve ikiden fazla kırık rotor çubuğu arızaları</i>	<i>%99.49</i>
[4]	Üç faz akımı ve slot harmoniklerinden hız tahmini	Motor akım imza analizi ve park vektör dönüşümü	Orta	Dört kırık rotor çubuğu arızası	%97.9
[8]	Üç faz akımı ve hız bilgisi	Motor akım imza analizi ve park vektör dönüşümü	Orta	Bir, iki, üç ve dört kırık rotor çubuğu arızası	%95.0
[9]	Üç faz akımı ve hız bilgisi	Motor akım imza analizi	Yüksek	Dört farklı yük altında bir kırık rotor çubuğu arızası	%93.75
[13]	Motor torku	Zaman serisi veri madenciliği	Orta	Üç, altı ve dokuz kırık rotor ve kırık konektör arızası	%98.0

motor akım imza analizi kullanılan yöntemler ile performans ve doğruluk karşılaştırması Tablo 5'te verilmiştir.

Önerilen arıza sınıflandırma yöntemi normalde her bir motor durumu için özellik vektörlerinden faz alanları oluşturulduktan sonra uygun bir normalleştirme işlemi ile faz alanlarını birleştirmektedir. Bulanık küme merkezleri bu birleştirilmiş faz alanlarından elde edilip, destek vektör makinaların eğitimi bu kümeler kullanılarak yapılmaktadır. Algoritma her bir motor besleme gerilimi için sağlam ve arızalı motor durumunun faz alanları için de test edilmiştir. Destek vektör makinalar için rtçf fonksiyonu kullanılmış ve çekirdek parametresi  $\sigma = 0.25$  olarak alınmıştır. Buna göre test sonuçları Şekil 12'de görülmektedir.



**Şekil 12.** Motorun her bir besleme gerilimi için ayrı ayrı oluşturulan faz alanlarının test sonuçları (Test results of separately constructed phase spaces for each feed voltages of motor)

Bütün test sonuçları %99'un üzerinde olmasına rağmen düşük besleme gerilimlerinde daha iyi sonuçlar alınmaktadır.

Asenkron motorun besleme gerilimi düşürüldüğünde faz akımları sinyalleri bu değişime bağlı olarak bozulur. Fakat algoritma bu hassasiyete rağmen iyi sonuçlar vermektedir. Bu durum yöntemin besleme geriliminden bağımsız olduğunu göstermektedir.

#### 4. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, asenkron motorlarda oluşan kırık rotor çubuğu arızalarının sınıflandırılması için zaman serisi veri madenciliği ve destek vektör makinalar kullanılmıştır. Arıza sınıflandırma için sadece faz akımları yeterlidir. Burada park vektöründen elde edilen yeni özellik vektörü sadece kırık rotor ile ilgili özellikler elde edilmiştir. Bu özellik vektörü zaman serisi veri madenciliği yöntemi ile bir faz alanında incelenmektedir. Her bir arıza ve sağlam durumu için birleştirilmiş faz alanları oluşturulur. Bulanık kümeleme ile bu faz alanında destek vektör makinaların eğitimi için küme merkezleri elde edilmektedir. Böylece, faz alanındaki bütün noktaları eğitim için kullanmak yerine bu noktaları temsil eden küme merkezleri kullanılmaktadır. Test aşaması faz alanındaki bütün noktaları kapsamaktadır ve %99.49 gibi bir başarı oranı elde edilmektedir. Daha önce zaman serisi veri madenciliği yöntemini kullanan arıza teşhis şemaları moment ve hız bilgisi gibi elde edilmesi zor ve pahalı olan duyarılardan gelen bilgileri kullanmıştır. Literatürde kırık rotor çubuğu arızaları için en çok kullanılan yöntem olan motor akım imza analizi de hız bilgisi gerektirmektedir.

#### KAYNAKLAR (REFERENCES)

1. Benbouzid M.E., Kliman G.B., "What Stator Current Processing based technique to use for induction motors rotor faults?", **IEEE Trans. on Energy Conversion**, Cilt 18, No 2, 238-244, 2003.
2. Chow M. Y., **Methodologies of Using Neural Network and Fuzzy Logic Technologies for Motor Incipient Fault Detection**, World Scientific, 1997.
3. Czeslaw, T. K., T. O. Kowalska, "Neural Network Application for Induction Motor Fault Diagnosis", **Mathematics and Computers in Simulation**, Cilt 63, 435-448, 2003.

4. Kim K., Parlos A.G., Bharadwaj R. M., "Sensorless Fault Diagnosis of Induction Motors", **IEEE Trans. on Industrial Electronics**, Cilt 50, No 5, 1038-1051, 2003.
5. Aderiano M. da Silva, **Induction Motor Fault Diagnostic and Monitoring Methods**, Master Thesis, Marquette University, Milwaukee, WI, 2006.
6. Filipetti F., Franceschini G., Tassoni C., Vas P., "Recent Developments of Induction Motor Drives Fault Diagnosis Using AI Techniques", **IEEE Trans. on Industrial Electronics**, Cilt 47, No 5, 994-1004, 2000.
7. Kolla S., Varatharasa L., "Identifying Three-phase Induction Motor Faults using Artificial Neural Networks", **ISA Transactions**, Cilt 39, No 4, 433-439, 2000.
8. Benbouzid M.E.H., Nejari H., "A Simple Fuzzy Logic Approach for Induction Motors Stator Condition Monitoring", **IEEE Electrical Machines and Drives Conference (IEMDC)**, Cambridge, MA, June 17-20, 2001.
9. Ayhan B., Chow M.Y., Song M.H., "Multiple Discriminant Analysis and Neural-Network-Based Monolith and Partition Fault-Detection Schemes for Broken Rotor Bar in Induction Motors", **IEEE Trans. on Industrial Electronics**, Cilt 53 , No 4, 1298-1308, August 2006.
10. Ondel O., Boutleux E., Clerc G., "A method to Detect Broken Rotor Bars in Induction Machine Using Pattern Recognition Techniques", **IEEE Trans. on Industry Applications**, Cilt 2, No 4, 916-923, 2006.
11. Pöyhönen, S., **Support Vector Machine Based Classification in Condition Monitoring of Induction Motors**, Doktora Tezi, Helsinki University of Technology Control Engineering Laboratory, 2004.
12. Shin H. J., Eom D. H., Kim S. S., "One-class Support Vector Machines—An Application in Machine Fault Detection and Classification", **Computer & Industrial Engineering**, Cilt 48, No 2, 396-408, 2005.
13. Bangura J. F., Povinelli R. J., Demerdash, N.A.O., Brown R. H., "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**, Cilt 39, No 4, 1005-1013, 2003.
14. Aydın İ., KARAKÖSE M., AKIN E., "A Simple and Efficient Method for Fault Diagnosis Using Time Series Data Mining", **IEEE Electrical Machines and Drives Conference (IEMDC07)**, 597-600, 2007.
15. Benbouzza N., Benyettou A., Bendiabdellah A., "An Advanced Park's Vectors Approach for Rotor Cage Diagnosis", **IEEE First International Symposium On Control, Communications and Signal Processing**, 461-464, 2004.
16. Aydın İ., **Arıza Teşhisinde Veri Madenciliği ve Yumuşak Hesaplama Tekniklerinin Kullanımı**, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 2006.
17. Aydın İ., Karaköse M., Akın E., "Yapay Bağışıklık Sistemi Tabanlı Arıza Teşhis Algoritması", **IEEE 14. Sinyal İşleme Ve İletişim Uygulamaları Kurultayı (SIU'2006)**, 17-19 Nisan, Antalya, 2006.
18. Haji M., Toliyat H.A., "Pattern Recognition-A Technique for Induction Machines Rotor Fault Detection-Eccentricity and Broken Bar Fault", **IEEE Industry Applications Conference (IAS)**, 1572-1578, 2001.
19. Feng X., Huang H., "A Fuzzy Set Based Reconstructed Phase Method for Identification of Temporal Patterns in Complex Time Series", **IEEE Trans. On Knowledge and Data Engineering**, Cilt 17, No 5, 601-613, 2005.
20. Bezdek J. C., **Pattern Recognition with Fuzzy Objective Function Algorithms**, Plenum Press, New York, 1981
21. Cristianini N., Shawe Taylor J., **An Introduction to Support Vector Machines and Other Kernel-based Learning Methods**, Cambridge University Press, 2001.
22. Kecman V., **Learning and Soft Computing: Support Vector Machines, neural Networks and Fuzzy Logic**, The MIT Press., 2001.
23. Burges, C., "A Tutorial on Support Vector Machines for Pattern Recognition", **Journal of Data Mining and Knowledge Discovery**, Cilt 2, No 2, 121-167, 1998