

PAPER DETAILS

TITLE: Elektrik Motorlarının Arıza Tespitinin Otomatik Olarak Yapılmasında Kullanılan Yapay Öğrenme Yöntemleri

AUTHORS: Ferhat ÇIRA

PAGES: 95-103

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/991923>



Elektrik motorlarının arıza tespiti otomatik olarak yapılmasında kullanılan yapay öğrenme yöntemleri



Artificial learning methods for automatic fault detection in electric motors

Ferhat Çıra

Dicle Üniversitesi Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Diyarbakır, Türkiye

MAKALE BİLGİSİ

Geliş Tarihi: 8 Temmuz 2017
Revizyon Tarihi: 10 Temmuz 2017
Kabul Tarihi: 11 Temmuz 2017
Elektronik Yayın Tarihi: 19 Ekim 2017
Basım: 1 Kasım 2017

ÖZET

Elektrik motorlarının arıza tespiti ve arıza tespitinde kullanılan özelliklerin bir sınıflandırıcıda eğitilerek arıza tespitinin otomatik olarak yapılması üzerine yapılan çalışmalar gittikçe popüler hale gelmektedir. Bu çalışmada elektrik motorlarının arızalarının tespiti ve arıza şiddetinin belirlenmesinde etkin olan sinyal özellikleri kullanılarak motorun farklı yük ve hız durumlarında karakteristik özelliklerinin arıza şiddetine göre değişim miktarı sınıflandırıcı ağlarda eğitim ve test verileri olarak kullanılması, sınıflandırmanın başarısında etkili olmaktadır. Bu çalışmada arıza tespitinin otomatik olarak belirlenmesi amacıyla kullanılan çok katmanlı yapay sinir ağı (MLP), destek vektör makinesi (SVM), k-en yakın komşuluk yöntemi (kNN), karar ağacı (DT) ve Random Forest (RF) gibi örüntü tanıma (ÖT) yöntem ve algoritmaları anlatılmaktadır.

Keywords: Otomatik motor arıza tespiti, Yapay öğrenme, Sınıflandırma

ABSTRACT

Studies on the automatic detection of faults and diagnostics of electrical motors by training them in a classifier are becoming increasingly popular. In this study, using the signal characteristics which are effective in determining the faults of the electric motors and determining the fault severity, the effect of changing the characteristics of the motor in different load and speed conditions according to the severity of the fault is used as training and test data in the classification networks. Pattern recognition methods such as multi-layer artificial neural networks (MLP), support vector machine (SVM), k-nearest neighbors method (kNN), decision tree (DT) and random forest (RF) methods and algorithms are explained in this study as well.

Anahtar sözcükler: Automatic motor fault detection, Artificial learning, Classification

Giriş


Bir elektrik motorunun arızasının tespiti ve arıza şiddetinin otomatik olarak belirlenmesi için birbirinden farklı sınıflandırıcılar kullanılabilmektedir. Örüntü Tanıma ile sınıflandırma genellikle biyomedikal uygulamalarda yaygın olarak kullanılsa da, son yıllarda motor arızalarının tespit uygulamalarında kullanılmaya başlanmıştır. Örüntü tanımayı anlamak için örüntünün ne olduğunu bilmek gerekmektedir. Örüntü, varlıklar hakkında gözlemlenebilir veya ölçülebilir bilgiler şeklinde tanımlanabilmektedir. Ses sinyali, uzaktan algılama verisi,

insan yüz şekli, retina, parmak izi, bir metin içerisindeki karakterler veya motordan elde edilen işaretler (akım, gerilim, titreşim v.b), örüntüye dair bazı örneklerdir. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir (1). Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamaları insan yaşantısında da görülebilmektedir: Hava değişimin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz

ve ses tanıma gibi bulanık sınırlara sahip birçok etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanıması, geçmiş tecrübelerle dayalı öğrenme esaslıdır. Daha önce karşılaşılan örüntü tanıma olaylarını yaşanan tecrübeler ışığında değerlendirebilme olanağı sağlayabilmektedir. Örneğin belirli bir sesi tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin birçoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinaların yapmasını arzularlar. Örüntü tanıma, akıllı ve öğrenebilen makinaları gerçekleyebilmek amacıyla ortaya çıkan çok disiplinli bir mühendislik yöntemidir (1).

Örüntü tanıma olayı şu şekilde tanımlanabilir: Aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesneleri bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırmadır. Bu bağlamda, örüntü tanımının en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir (1). Örüntü tanıma olarak bilinen uygulamalar, makina öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır.

Genel bir örüntü tanıma sistemi, Şekil 1’de gösterildiği gibi 2 temel aşamadan oluşmaktadır. Bunlar sırasıyla özellik belirleme ve sınıflandırma aşamalarıdır. Özellik belirleme aşaması, elektronik algılayıcılarla toplanmış olan ham örüntüyü karakterize eden, özelliklerinin elde edilebilmesi için çeşitli dönüşüm tekniklerinin gerçekleştirildiği süreçtir. Sınıflandırma aşaması ise özellik belirleme süreci sonucunda örüntüden elde edilen özellikleri kullanarak, bir karar verme mekanizması (sınıflandırıcı) yardımıyla örüntünün ait olduğu sınıfın belirlendiği süreçtir.



Şekil 1: Bir örüntü tanıma sistemi blok diyagramı.

Özellik belirleme aşamasında amaç, çevreden algılanan yüksek boyutlu ham örüntüyü karakterize edebilen, kararlı, ölçülebilir ve mümkün olduğunca daha küçük boyutlu bir bilgi ile temsil edebilmektir. Bu süreç sonucunda ham örüntüden elde edilen bu nitelikteki bilgiye özellik vektörü adı verilir. Özellik belirleme

sürecinde, ham veriyi temsil eden bu özellik kümesi elde edilirken aslında birbiriyle ilişkili üç aşamalı bir yol izlenir. Bunlar:

• Ön İşleme

Özellik belirleme sürecinin ilk aşamasını oluşturur. Bu aşamada gerektiğinde örüntü filtrelenir, bölütlere ayrılır, çeşitli gösterim teknikleri kullanılarak işlenir, bileşenlere ayrılır veya modellenir (1).

• Özellik Çıkarma

Özellik çıkarmı, en basit ifadeyle ön işleme aşaması sonucunda yeniden düzenlenen örüntünün boyut indirgeme işlemlerinin gerçekleştiği aşamadır. Sınıflandırılacak bir örüntü genellikle çok fazla miktarda ve gereksiz bilgi içerir. Bu durum, sınıflandırma hassasiyetini düşürürken işlem süresini de yükseltir. Bu olumsuzluğu gidermek için, örüntü bilgisi daha az miktardaki başka bir veriye dönüştürülür. Örüntüye ait fazla ve gereksiz verinin elenip, sadece örüntüyü temsil eden ve toplam veriden çok daha az sayıdaki karakteristik bilginin elde edildiği bu dönüşüme özellik çıkarma adı verilir. Karakteristik özelliklerin çıkarmı, örüntü tanıma sistemlerinin kritik tasarım aşamalarından biridir. Çıkarılan özelliklerin ayırt edici ve mümkün olduğunca az sayıda olması, tanıma işleminin daha basit sınıflandırıcılarla, daha yüksek hassasiyetle ve daha kısa sürede gerçekleştirilmesini sağlar (2).

• Özellik Seçme

Özellik çıkarma işlemleri sonucu örüntüden elde edilen özellik kümesi ile örüntünün boyutu büyük oranda küçültülür. Ancak elde edilen bu özellik kümesi içerisindeki bazı özellikler örüntü ile ilişkisiz olabileceği gibi bazı özellikler de örüntüyü temsil etmede fazlalık teşkil edebilir (3). Gereksiz olan ve fazlalık teşkil eden bu özellikler kullanılacak sınıflandırıcının genelleme ve ayırıştırma yeteneğini olumsuz yönde etkiler. Özellik seçme aşaması ile özellik kümesinden bu tür istenmeyen özelliklerin çeşitli yöntemler kullanılarak arındırılıp daha iyi bir özellik alt kümesi bulunması amaçlanır.

Bilinmeyen bir örüntüyü tanıyabilmek için özellik belirleme aşamasından sonra sınıflandırma işlemi yürütülür. Sınıflandırma, bilinmeyen bir örüntünün hangi sınıfa dâhil olduğunu, o örüntüye ait özellikleri giriş olarak kullanan bir sınıflandırıcı yardımıyla belirleme işlemidir. Sınıflandırma işlemi temel olarak iki aşamadan oluşmaktadır. Birinci aşamada, ilgilenilen örüntü sınıflarından elde edilen özellik verileri ile sınıflandırıcı

eğitilerek bir karar mekanizması oluşturulur. İkinci aşamada ise herhangi bir örüntü sınıfından elde edilen özellik verisi eğitilen sınıflandırıcı girişine verilerek bunun hangi sınıfa dâhil olduğuna karar verilir.


Sınıflandırma yöntemleri kullanılan öğrenme stratejisine göre genel olarak iki grupta incelenir: GÜDÜMLÜ ve GÜDÜMSÜZ öğrenme. GÜDÜMLÜ öğrenmede, ilgilenilen örüntüler ve bu örüntülerin ait olduğu sınıflar arasında bir model oluştururken eğitme işlemi sırasında ilgilenilen örüntü sınıflarının belirlenmiş özellikleri ile birlikte bu örüntülerin ait olduğu sınıflarda (etiketlerde) sınıflandırıcıya gösterilir. GÜDÜMSÜZ öğrenmede ise sınıflandırıcıya eğitim esnasında sadece ilgilenilen örüntülerin belirlenmiş özellikleri gösterilerek bunlar arasındaki benzerlik, uzaklık gibi fonksiyonlar kullanılarak bir model oluşturulur.

1. Çok Katmanlı Yapay Sinir Ağı (MLP) ile Sınıflandırma

Elektrik motorlarının akım ve gerilimlerinden elde edilen sağlıklı ve arızalı motorları birbirinden ayırmak ve arızalı motorun arıza şiddetini belirlemek için tespit edilen arıza imaları ile eğitilen çok katmanlı yapay sinir ağı (MLP) yöntemi kullanılmaktadır. Vektör kontrol ile sürülen motorlarda hız kontrolü için inverterli sürücüler kullanılmaktadır. Motorların çalışma performansında inverter çıkışının dengeli bir yapıya sahip olması oldukça önemlidir ancak uygulamada hiçbir motor sürücüsü tam dengeli ve kusursuz değildir. Bu kusurlar inverterin doğrusal olmayışı, motorun doğal asimetrisi ve akım veya hız ölçüm hataları gibi nedenlerden kaynaklanmaktadır. Sürücü kusurları, sarım arıza yönteminin hassasiyetini etkileyen bir unsurdur. Çünkü sürücü kusurlarının fiziksel sonuçları sarım arızasının yarattığı asimetriklikle karıştırılmaktadır. Daha güvenilir bir sarım arıza tespiti için bu kusurlardan kaynaklı etkilerin giderilmesi kritik önemdedir. Fakat bu etkileri gidermek biraz zordur çünkü bu kusurlar motorun doğrusal olmayan çalışma koşullarına bağlı olarak değişmektedir. Bu sorunu çözmek için çok sayıda yapay sinir ağı tabanlı örüntü tanıma algoritması uygulanmıştır.

İdeal olmayan bir motor sürücü sisteminin sarım kısa devre arızasının tespiti zordur. Bu zorluğu aşmak için geniş bir uzaydaki girişleri birbirinden bağımsız veri kümesindeki belirgin örüntüleri etkin şekilde tespit edebilecek yöntemler geliştirilmiştir (4). Bu yöntemler yapay zekâ, bulanık mantık ve yapay sinir ağları gibi uzman sistemleri kapsamaktadır. Bunlardan yapay sinir ağları (ANN) doğrusal olmayan tahminlerinden ötürü

makina arızalarının tespitinde kullanılmaktadır. Temel olarak, bu tahminler, uygun ağırlık katsayıları ile birbirine bağlı yapay nöronların uygun bir ağ oluşturulması ile elde edilmektedir



Şekil 2: MLP'nin şematik gösterilişi.

Şekil 2'de MLP ağı yapısına ait örnek model gösterilmiştir. Bu yapıda giriş ve çıkışlar; x_i ve y_i ile gösterilmiştir. Girişler $x_i = [x_1, x_2, \dots, x_N]^T \in R^N$ vektörü, çıkışlar $y_i = [y_1, y_2, \dots, y_N]^T \in R^N$ vektörü ile gösterilmiştir. Gizli katmanda N tane sinir hücresi bulunduran ve aktivasyon fonksiyonu $g(x)$ ile tanımlanan en temel MLP sinir ağı yapısı, matematiksel gösterim olarak denklem (1)'deki gibi ifade edilebilir (5).

$$\sum_{i=1}^M \beta_i g(w_i \cdot x_j + b_i) = o_j, j = 1 \dots N \quad (1)$$

$\beta_i = [\beta_1, \beta_2, \dots, \beta_M]^T$ i'nci gizli sinir hücresine ve çıkış sinir hücrelerine bağlı olan çıkış ağırlık dizisidir. b_i ise i'nci gizli sinir hücresine eklenen eşik değeri olarak tanımlanabilir. $o_j = [o_1, o_2, \dots, o_N]^T$ ise MLP ağının beklenen ya da olması istenen çıkışıdır. $w_i \cdot x_j$ ise w_i ve x_j 'nin içsel çarpımını yani ağırlıklandırılmış girişlerini ifade eder. En temel haliyle oluşturulan bu MLP ağı yapısının ortalama olarak "sıfır" hata değerine yaklaşabildiği kabul edilmektedir. Yani, olması istenen çıkış ve verilen çıkış ilişkisi $\sum_{j=1}^N \|o_j - y_j\| = 0$ şeklinde ifade edilebilir. Bu durumda (1) numaralı denklem yeniden yazılırsa (2) numaralı denklem elde edilmektedir.

$$\sum_{i=1}^M \beta_i g(w_i \cdot x_j + b_i) = y_j, j = 1 \dots N \quad (2)$$

Sinir ağları, kabul edilebilir bir tahminin elde edilmesinden önce, giriş değerleri çok farklı


kombinasyonlar ile eğitilmelidir. Bir sinir ağı tabanlı çevrimdışı eğitim mümkün olabilecek tüm çalışma koşullarından elde edilen giriş verileri ile eğitilmesi gerekir. Fakat pratikte gerçekleştirilecek tüm çalışma koşullarında veri elde etmek mümkün olamayabilir. Bu nedenle mümkün olan en geniş çalışma koşullarında ve çok sayıda birbirine yakın giriş verileri alınarak en yakın tahmin elde edilebilir. Ağın eğitimi sırasında çıkış ile istenilen sonuç arasındaki farkın azaltılması için ağırlıklar eğitim algoritmasına bağlı olarak değişir. Ortalama karesel hata eğrisi, eğitim iterasyonları boyunca, ağın çıkışı ile istenilen sonuç arasındaki farkın karesini gösterir. Ağın fazla eğitilmesi durumunda ağın genelleştirme yapması zorlaşır. Ağın eğitimi durdurmak için geçerlilik kriteri kullanılır.

Sarım arızasının tespitinde belirli bir hız ve yük durumu gibi dar bir çalışma koşulunda giriş verisi alınarak sinir ağı eğitildiğinde, doğru olmayan bir sonuç verebilecektir. (6)'da bir asenkron motordaki sarım kısa devre arızasının tespitine yönelik ileri beslemeli sinir ağları kullanılması önerilmektedir. Buna göre farklı yük koşulları altında çalışan asenkron motordan alınan negatif akım bileşenleri ve pozitif gerilim bileşenleri ile negatif gerilim bileşenini tahmin edebilmek için bir yapay sinir ağı eğitilmiştir. Daha sonra izleme aşamasında sarım arızasından kaynaklanan asimetrikliği tespit edebilmek için ölçülen ve tahmin edilen negatif gerilim bileşenleri karşılaştırılmıştır. Eğitimde kullanılan giriş verilerinin alındığı çalışma koşullarının dışındaki veri kümesinden, test verisi alındığında, arıza tespiti tahmin başarımının çok düştüğü gözlenmektedir. Ancak önerilen yöntemin geliştirilmesi ile akım kontrollü gerilim kaynaklı inverter (CCVSI) ile sürülen motorların sarım arızasının tespitinde güvenilir sonuçlar verebildiği gözlenmektedir.

2. Destek Vektör Makinası ile Sınıflandırma

Motor fazlarından ölçülen akım ve gerilimlerinden elde edilen arıza imzaları ile arıza tespiti ve arıza şiddetinin belirlenmesinde kullanılan bir diğer sınıflandırma yöntemi destek vektör makinası (SVM) yöntemidir. Optimizasyona dayalı sınıflandırma teknikleri arasında yer alan Destek Vektör Makinası (SVM), genellikle veri madenciliği sınıflandırma problemlerinde kullanılan bir yöntemdir. Bu yöntem sınıflandırmayı doğrusal veya doğrusal olmayan bir fonksiyon yardımıyla yerine getirir. Destek vektör makinası yöntemi, veriyi birbirinden ayırmak için en uygun fonksiyonun tahmin edilmesi esasına dayanmaktadır. Daha çok makina öğrenmesi yöntemleri arasında yer alan bu yöntem günümüzde veri madenciliği alanında da tercih edilmeye

başlanmıştır. Destek Vektör Makinaları öğrenme, sınıflandırma, kümeleme, yoğunluk tahmini ve son olarak da verilerden regresyon kuralları üretmek için kullanılan bir eğitim algoritmasıdır. SVM'nin teorik temelleri ilk olarak V. Vapnik tarafından 1960'lı yıllarda atıldıktan sonra ilk olarak 1995 yılında sınıflandırmada kullanılmıştır. Vapnik'in teorisi eğitim kümelerindeki hata ile VC (Vapnik-Chervonenkis) boyutuna göre ifade edilen hipotez uzayının karmaşıklığının her ikisini de küçükleyen çözümün bulunduğunu göstermektedir (7). Bu sınıflar arasında birçok doğrunun çizilebilme ihtimali vardır. Hata toleransını en düşük hale getirmek için çizilebilecek doğrular arasında her iki sınıfa en uzak olacak şekilde çizilen doğru bulunmalıdır.




Şekil 3: Doğrusal Olarak ayrılabilen (örtüşmeyen) veri kümesi.

Şekil 3'te doğrusal olarak ayrılabilen (örtüşmeyen) veri kümesi birbirinden doğrusal olarak ayrılabilir. Kesikli çizgi, ayırıcı çoklu düzlemi, düz çizgiler ise ayırıcı düzlemden belli bir uzaklıktaki sınırları göstermektedirler. Sınır çizgileri üzerinde kalan kırmızı daire içerisine alınan veriler destek vektörleri göstermektedir. $x, w \in R^n$ dir. w ayırıcı çoklu düzleme olan dikey (normal) ağırlık vektörüdür, b ise ön değerdir (bias). $\|w\|$, w 'nin Euclidian normudur, $\frac{|b|}{\|w\|}$ çoklu düzlemden orijine dikey mesafedir.

Destek Vektör Makinaları ile sınıflandırma mantığının temeli her iki sınıfın uç noktalarında bulunan ve eğitim örneklerinin arasından seçilen destek vektörlerdir. Ayrıca düzlemin optimum olmasıyla genelleme yeteneği de maksimum düzeyde olacaktır. Fakat bu verileri iki sınıfa ayıracak çok fazla sayıda ayırıcı düzlem bulunmaktadır. Öncelikle bu ayırıcı düzlem sayısı sınıflar arası mesafe ölçüsüyle sınıf genişliği çarpımı 1 alınarak

sınıflandırılmıştır. Daha sonra bu ayırıcı düzlemler arasında optimum olanının bulunması gerekmektedir. Optimum ayırıcı düzlem ise her iki sınıfın en uç verileri arasındaki mesafenin (iki sınıfın destek vektörleri arasındaki mesafe) maksimum olduğu durumu sağlayan ayırıcı düzlemdir. Bu ayırıcı düzlem bahsettiğimiz aralığın tam ortasından geçmelidir (8). SVM, optimum ayırıcı düzlemi bulunurken önce optimizasyon problemini formüleştirebilir sonra ikinci dereceli programlama adı verilen metotları kullanarak çözmektedir. SVM öğrenme metodu teorik olarak VC boyutu ve yapısal risk minimizasyonu (SRM) prensiplerine uygun olarak tasarlanmıştır.

Şekil 4, tüm makina öğrenme metotları için geçerli olan bir mimaridir. Sınıflandırma işlemi yapılırken eldeki verilerin bir kısmı eğitim için, kalan kısmı ise test için ayrılır. Çünkü eğitime verilerinin, sınıflandırıcının doğruluk tahmininde de kullanılması iyimser (gerçek uygulamalara göre daha yüksek olan) sonuçlar elde etmemize sebep olur. Bu verilerin birbirine oranı sınıflandırma işleminin doğruluk oranını (aynı zamanda hata oranını) doğrudan etkilemektedir. Doğruluk oranını etkileyen bir diğer faktör de verilerin sahip olduğu dağılımdır. Matematiksel olarak SVM, dağılımından bağımsız formül yapısı üzerine kurulmuştur. SVM tekniğinde de önce eğitim verileri alınıp, SVM eğitilerek sınıflandırıcı model oluşturulur. Daha sonra çıkış değerini önceden bildiğimiz test verileri için sistemin hesaplayacağı çıkış değeri gözlemlenir. Sonra bu iki değer arasındaki farklılık oranına göre SVM'nin sınıflandırma performansı değerlendirilir (8).



Şekil 4: SVM ile sınıflandırma mimarisi.

Destek Vektör Makinalarında karşılaşılabilecek iki durum, sınıflandırma yapılırken verilerin lineer olarak ayrılacakları bir yapıda olması veya lineer olarak ayrılacakları yapıda olmasıdır. Ancak, gerçek yaşam problemlerinin büyük çoğunluğu birçok farklı bileşenden oluşan problemlerdir ve lineer olarak ayrılmış bir yapı halinde karşımıza çıkmazlar. Lineer olarak ayrılmış olan veriler arasında direkt olarak maksimum sınırın bulunması oldukça kolaydır, ancak

lineer olarak ayrılacakları veriler öncelikle lineer olarak ayrılacakları farklı bir uzaya aktarılmalıdır (9).

3. k-En Yakın Komşuluk Yöntemi ile Sınıflandırma

Sınıflandırma teknikleri içerisinde yaygın olarak kullanılan algoritmalarından olan k-en yakın komşu yöntemi (kNN), aradaki mesafeye dayalı olarak sınıflandırma yapan bir algoritmadır. Parametrik olmayan bu yöntem en basit ve yorumlanması kolay denetimli makina öğrenme algoritmalarından biridir (10). k-en yakın komşuluk yöntemi, n boyutlu özellik uzayında nesneleri sınıflandırmak ya da tahmin etmek için mesafe olarak kendisine en yakın komşu örneklerini kullanır. k-en yakın komşu yönteminde sınıflandırma yapabilmek için kaç adet en yakın komşu sayısının katılacağı, k gibi bir pozitif tam sayı ile belirtilir. Eğer k=1 ise sınıflandırmaya çalıştığımız örnek, en yakın komşusunun bulunduğu sınıfa dahil olacaktır.

Bu yöntem kestirim için de kullanılmaktadır. En yakın komşuların belirlenmesinde seçilen örnek ile eğitim kümesindeki örnekler arasındaki uzaklık ölçümü yapılır. Bu ölçümler Euclidean, Manhattan ve Cheyshev gibi ölçüm fonksiyonları kullanılarak yapılmaktadır. Bunlardan en çok kullanılan fonksiyon olan Euclidean uzaklık fonksiyonu denklem (3)'te gösterildiği gibidir.

$$d_{ab} = \|a - b\| = \sqrt{\sum_{i=1}^n (a_i - b_i)^2} \quad (3)$$

Burada a ve b, n-boyutlu uzaydaki iki nokta ise aralarındaki mesafe Euclidean fonksiyonu ile bu şekilde hesaplanabilmektedir. Bu algoritma test verisi ile eğitimi yapılmış tüm veriler arasındaki mesafelerin hesaplanmasını gerekli kılar. Uzaklık mesafeleri en kısıdan en uzağa doğru sıralanır, bu sıralama aynı zamanda seçilen örneğe en yakın komşudan en uzak komşuya olan sıralamayı da gösterir. Yöntemde, sınıflandırma yapılacak verilerin öğrenme kümesindeki normal davranış verilerine benzerlikleri hesaplanarak; en yakın olduğu düşünülen k adet verinin ortalamasıyla, belirlenen eşik değere göre sınıflara atamaları yapılır. Yani sınıflandırmada kullanılan bu algoritmaya göre sınıflandırma sırasında çıkarılan özelliklerden sınıflandırılmak istenen yeni bireyin daha önceki bireylerden k tanesine yakınlığına bakılmaktadır. Önemli olan, her bir sınıfın özelliklerinin önceden net bir şekilde belirlenmiş olmasıdır. Yöntemin performansını;

- K en yakın komşu sayısı,
- Eşik değeri,
- Benzerlik ölçütü etkilemektedir (11).

Buradaki k , 1'den büyük ve genelde tek sayı olarak seçilen bir tam sayıdır. K en yakın komşuluk yönteminde sadece bir tane en büyük benzeme değerine değil, k tane en büyük benzeme değerine bakılarak sonuca ulaşılır. Seçilmiş olan k değerinin küçük olması durumunda birbirine benzerlikleri yüksek olan kayıtlar bir sınıfa sokulurken, k değerinin büyük seçilmesi birbirine benzemeyen kayıtların aynı sınıfa sokulması hatasını ortaya çıkarabilir.


Bu yöntemin avantajları arasında;

- K -en yakın komşunun ortalaması alındığı için gürültülü veriden az etkilenmesi,
- Uygulaması ve anlaşılmasının kolay olması,

Dezavantajları olarak;

- En yakın komşuların sayısı olan k parametresinden,
- Seçilen uzaklık ölçütünden oldukça etkilenmesi,
- Eğitim verisinin büyük olduğu durumlarda verimli olması sayılabilir.

Örneğin, ω_1 , ω_2 ve ω_3 olmak üzere üç adet sınıf olduğu varsayılın ve bilinmeyen bir x_u örneği sınıflandırılmaya çalışılın. $k=5$ değeri için 5 en yakın komşu incelendiğinde 4 adet komşunun w_3 sınıfında olduğu, 1 adet komşunun ise w_2 sınıfında olduğu görülmektedir. Baskın olan taraf w_3 olduğu için x_u örneği ω_3 sınıfına dâhil olur (Şekil 5).



Şekil 5: K-en yakın komşuluk sınıflandırma yöntemi.


4. Karar Ağacı Yöntemi ile Sınıflandırma

Karar ağacı yöntemi (DT), yorumlanmasının kolay olması, veri tabanı sistemlerine entegre edilebilirliği, yüksek güvenilirliği gibi nedenlerle sınıflama yöntemleri içerisinde yaygın kullanıma sahip yöntemlerden biridir.

Bu yöntem kestirimci ve tanımlayıcı özelliklere sahiptir. Karar ağacı düğüm, dal ve yaprak olarak adlandırılan üç kısımdan oluşan, anlaşılması kolay bir yöntemdir (12). Bu ağaç yapısında her bir değişken bir düğüm tarafından temsil edilir. Dallar ve yapraklar ağaç yapısının diğer elemanlarıdır. Ağaçta en son kısım yaprak en üst kısım ise kök olarak adlandırılır. Kök ve yapraklar arasında kalan kısımlar ise dal olarak ifade edilir. Başka bir ifadeyle bir ağaç yapısı; verileri içeren bir kök düğümü, iç düğümler (dallar) ve uç düğümlerden (yapraklar) oluşur. Eğitim verilerine ait değişken bilgilerinden yararlanılarak bir karar ağacı yapısı oluşturulmasında temel prensip verilere ilişkin bir dizi sorular sorulması ve elde edilen cevaplar doğrultusunda hareket edilerek en kısa sürede sonuca gidilmesi olarak ifade edilebilir. Bu şekilde karar ağacı, sorulara aldığı cevapları toplayarak, karar kuralları oluşturur. Ağacın ilk düğümü olan kök düğümünde verilerin sınıflandırılması ve ağaç yapısının oluşturulması için sorular sorulmaya başlanır ve dalları olmayan düğümler ya da yapraklar bulunana kadar bu işlem devam eder.

Karar ağaçlarının oluşturulmasındaki en önemli adım ağaçtaki dallanmanın hangi kritere veya kıstasa göre yapılacağı ya da hangi değişken değerlerine göre ağaç yapısının oluşturulacağıdır. Literatürde bu problemin çözümü için geliştirilmiş çeşitli yaklaşımlar vardır. Bunlardan en önemlileri bilgi kazancı ve bilgi kazanç oranı, Gini indeksi, Twoing kuralı ve Ki-Kare olasılık tablo istatistiği yaklaşımlarıdır. Karar ağacında bulunan her bir dalın belirli bir olasılığı mevcuttur. Bu sayede son dallardan köke veya istenilen yere ulaşana dek olasılıkların hesaplanması mümkündür. Karar düğümü, gerçekleştirilecek testi belirtir. Bu testin sonucu ağacın veri kaybetmeden dallara ayrılmasına neden olur. Her düğümde test ve dallara ayrılma işlemleri ardışık olarak gerçekleşir ve bu ayrılma işlemi üst seviyedeki ayrımlara bağlıdır. Ağacın her bir dalı sınıflama işlemini tamamlamaya adaydır. Eğer bir dalın ucunda sınıflama işlemi gerçekleşmiyorsa, o dalın sonucunda bir karar düğümü oluşur. Ancak dalın sonunda belirli bir sınıf oluşuyorsa, o dalın sonunda yaprak vardır. Bu yaprak, veri üzerinde belirlenmek istenen sınıflardan biridir. Karar ağacı işlemi kök düğümünden başlar ve yukarıdan aşağıya doğru yaprağa ulaşana dek ardışık düğümleri takip ederek gerçekleşir (13). Karar ağacı tekniğini kullanarak verinin sınıflanması iki basamaklı bir işlemdir (12). İlk basamak öğrenme basamağıdır. Öğrenme basamağında önceden bilinen bir eğitim verisi, model oluşturmak amacıyla sınıflama algoritması tarafından analiz edilir.

Öğrenilen model, sınıflama kuralları veya karar ağacı olarak gösterilir. İkinci basamak ise sınıflama basamağıdır. Sınıflama basamağında test verisi, sınıflama kurallarının veya karar ağacının doğruluğunu belirlemek amacıyla kullanılır. Eğer doğruluk kabul edilebilir oranda ise kurallar yeni verilerin sınıflanması amacıyla kullanılır (13). Karar ağaçları geçmiş veriye dayanarak yeni verilerin hangi sınıfa ait olduğuna, kurallar çıkartarak karar vermektedir. Karar ağacı, sorulan sorular ve alınan cevaplar doğrultusunda hareket eder ve sorulan sorulara alınan cevapları birleştirerek kurallar oluşturur. Oluşan ağaç birçok “eğer-ise”(if-then)’den oluşan kurallar bütünüdür de diyebiliriz. Soru sormaya verideki hangi değişkenden başlanacağına karar verildiğinde ilgili değişken ağacın kök düğümünü oluşturmuş olur. Kök düğümden başlayarak, cevabı veri tabanında bulunan sorular sorulup alınan cevaplara göre yeni düğümler oluşturulmaktadır. Her düğüm kendinden sonra iki veya ikiden fazla dala ayrılmaktadır. Oluşan düğümden sonra yeni soru sorulamıyorsa dallanma bitmiştir ve bir sınıfa temsil eden yaprağa ulaşılmıştır (14). Şekil 6’da karar ağacını oluşturan kök düğüm, iç düğüm ve terminal düğümler gösterilmiştir.



Şekil 6: Karar Ağacı Diyagramı.


5. Rastgele Orman Algoritması ile Sınıflandırma

Elektrik motorlarının stator sarımlar arası kısa devre arızasının tespitinin otomatik olarak yapılmasında bir tür optimize edilmiş karar ağacı algoritması olan Rastgele Orman (RF) metodu kullanılmıştır. L. Breiman tarafından (15), tek bir karar ağacı üretmek yerine her biri birbirinden farklı eğitim veri kümesiyle eğitilen birden fazla, çok değişkenli ağacın kararlarının birleştirilmesini öngören “Torbalama” yöntemi geliştirilerek RF algoritması elde edilmiştir. Bu yöntem, birbirinden farklı

alt eğitim veri kümelerinin oluşturulmasında önyükleme tekniğini, ağaçların gelişimi aşamasında da rastgele özellik seçimini kullanır. Torbalama yönteminden farklı olarak, ağaçların gelişimi aşamasında veri kümesindeki tüm değişkenleri kullanmak yerine her bir düğümden rastgele seçilen değişkenler arasından en iyisini kullanarak her bir düğümü dallara ayırmasıdır. Burada ağaçlar rastgele seçilen değişkenlere göre oluşturulur. Oluşturulan yeni veri kümelerinden ağaç gelişimi işlemi de CART algoritmasına göre yapılır. Ancak RF algoritmasında CART algoritmasındaki gibi ağaç budama işlemi yapılmaz (15, 16) often the goals are both to produce an accurate classifier and to uncover the predictive structure of the problem. Most machine learning methods, such as k-nearest neighbors, support vector machines, and neural networks, are useful for classification. However, these methods provide no insight regarding the covariates that best contribute to the predictive structure. Other methods, such as linear discriminant analysis, require the predictor space be substantially reduced prior to deriving the classifier. A recently developed method, random forests (RF). Ağaç budama metodu, ağaç tabanlı sınıflandırıcıların performansını olumsuz etkilemektedir (17) training time and user defined parameters. Landsat Enhanced Thematic Mapper Plus (ETM+). RF algoritmasında budamanın yapılmaması bu yöntemi diğer karar ağacı yöntemlerinden daha avantajlı ve tercih edilir hale getirmektedir. Ayrıca RF algoritmasının diğer karar ağacı algoritmalarından daha hızlı, aşırı uyuma karşı dayanıklı ve ne kadar istenirse o kadar ağaçla çalışabilir olması tercih edilmesindeki diğer faktörlerdir. Bu üstün özelliklerinden ötürü RF algoritması şu anki algoritmalar arasında doğruluğu eşsiz bir algoritma olarak tanımlanmaktadır (18). Şekil 7’de RF algoritmasının daha iyi ifade edilebilmesi için anlaşılması kolay bir örnek verilmiştir. Burada, $I=\{i_1, i_2, i_3\}$ giriş özellik vektörü, $Th=\{th_1, th_2, th_3, th_4, th_5\}$ eşik değerleri vektörü ve $P=\{p_1, p_2, p_3, p_4, p_5, p_6\}$ ise tahmin edilen değerler vektörü olsun. RF tahmin algoritması şu üç adımdan oluşur.

- Tahmin ölçütünün doğru seçilmesi
- Veri seti bölütlendirilirken ihtiyaç duyulan kadar bölüte ayrılması
- Uygun alt ağaç algoritmasının seçimi

Bu adımların doğru uygulanması sonucu verilerin sınıflandırmasının güvenilirliği artmaktadır. Bu çalışmada uygulanan RF algoritması bu ölçütlere tamamen uyulmuştur.



Şekil 7: Rastgele Orman (RF) Algoritması Örneği.

6. Sonuç

Belirli bir arıza durumu için en iyi yöntemin seçimine karar vermek için, makina durum izlemenin avantaj ve dezavantajlarının göz önüne alınması gerekir. Makina durum izleme yöntemleri, makinanın kullanılabilirliğini, verimliliğini ve güvenilirliğini arttırmak, ayrıca güvenli çalışma imkânını geliştirmek gibi, avantajları sağlayabileceği gibi, durum izleme için kullanılacak ekipmanların ek maliyeti ve durum izleme sistemi eğitimi için ek maliyet gibi dezavantajları ortaya çıkabilmektedir.

Bu çalışmada elektrik motorlarında meydana gelen arızaların tespiti için kullanılan örüntü tanıma ve makine öğrenme yöntemleri tanıtılmıştır.

Kaynaklar

1. C. Ortega, A. Arias, C. Caruana, J. Balcells, and G. M. Asher, "Improved waveform quality in the direct torque control of matrix-converter-fed PMSM drives," *IEEE Trans. Ind. Electron.*, vol. 57, no. 6, pp. 2101–2110, 2010.
2. J. Beerten, J. Verveckken, and J. Driesen, "Predictive Direct Torque Control for Flux and Torque Ripple Reduction," *IEEE Trans. Ind. Electron.*, vol. 57, no. 1, pp. 404–412, 2010.
3. R. Errouissi, M. . Ouhrouche, W.-H. . Chen, and A. M. Trzynadlowski, "Robust cascaded nonlinear predictive control of a permanent magnet synchronous motor with antiwindup compensator," *IEEE Trans. Ind. Electron.*, vol. 59, no. 8, pp. 3078–3088, 2012.
4. K. Raggl, B. Warberger, T. Nussbaumer, S. Burger, and J. W. Kolar, "Robust angle-sensorless control of a PMSM bearingless pump," *IEEE Trans. Ind. Electron.*, vol. 56, no. 6, pp. 2076–2085, 2009.
5. J. R. Riba Ruiz, J. A. Rosero, A. Garcia Espinosa, and L. Romeral, "Detection of demagnetization faults in permanent-Magnet synchronous motors under nonstationary conditions," *IEEE Trans. Magn.*, vol. 45, no. 7, pp. 2961–2969, 2009.
6. S. Rajagopalan, W. le Roux, T. G. Habetler, and R. G. Harley, "Dynamic Eccentricity and Demagnetized Rotor Magnet Detection in Trapezoidal Flux (Brushless DC) Motors Operating Under Different Load Conditions," *IEEE Trans. Power Electron.*, vol. 22, no. 5, pp. 2061–2069, Sep. 2007.
7. Y. Zhang and J. Jiang, "Bibliographical review on reconfigurable fault-tolerant control systems," *Annu. Rev. Control*, vol. 32, no. 2, pp. 229–252, Dec. 2008.
8. P. Poure, P. Weber, D. Theilliol, and S. Saadate, "Fault tolerant control of a three-phase three-wire shunt active filter system based on reliability analysis," *Electr. Power Syst. Res.*, vol. 79, no. 2, pp. 325–334, Feb. 2009.
9. W. T. Thomson and M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Ind. Appl. Mag.*, vol. 7, no. 4, pp. 26–34, 2001.
10. L. Frosini and E. Bassi, "Stator Current and Motor Efficiency as Indicators for Different Types of Bearing Faults in Induction Motors," *IEEE Trans. Ind. Electron.*, vol. 57, no. 1, pp. 244–251, Jan. 2010.
11. R. N. Andriamalala, H. Razik, L. Baghli, and F.-M. Sargos, "Eccentricity Fault Diagnosis of a Dual-Stator Winding Induction Machine Drive Considering the Slotting Effects," *IEEE Trans. Ind. Electron.*, vol. 55, no. 12, pp. 4238–4251, Dec. 2008.
12. B. M. Ebrahimi, J. Faiz, and M. J. Roshtkhari, "Static-, Dynamic-, and Mixed-Eccentricity Fault Diagnoses in Permanent-Magnet Synchronous Motors," *IEEE Trans. Ind. Electron.*, vol. 56, no. 11, 2009.
13. S. Grubic, J. M. Aller, and T. G. Habetler, "A Survey on Testing and Monitoring Methods for Stator Insulation Systems of Low-Voltage Induction Machines Focusing on Turn Insulation Problems," *IEEE Trans. Ind. Electron.*, vol. 55, no. 12, pp. 4127–4136, Dec. 2008.
14. R. M. Tallam, T. G. Habetler, and R. G. Harley, "Transient model for induction machines with stator winding turn faults," *IEEE Trans. Ind. Appl.*, vol. 38, no. 3, pp. 632–637, 2002.
15. K.-H. Kim, B.-G. Gu, and I.-S. Jung, "Online fault-detecting scheme of an inverter-fed permanent magnet synchronous motor under stator winding shorted turn and inverter switch open," *IET Electr. POWER Appl.*, vol. 5, no. 6, pp. 529–539, 2011.
16. K. C. Kim, S. B. Lim, D. H. Koo, and J. Lee, "The shape design of permanent magnet for permanent magnet synchronous motor considering partial demagnetization," *IEEE Trans. Magn.*, vol. 42, no. 10, pp. 3485–3487, 2006.
17. R. M. Tallam, T. G. Habetler, and R. G. Harley, "Transient model for induction machines with stator winding turn faults," *IEEE Trans. Ind. Appl.*, vol. 38, no. 3, pp. 632–637, 2002.
18. J. Bockstette, E. Stolz, and E. Wiedenbrug, "Upstream Impedance Diagnostic for Three-Phase Induction Motors," in *2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, 2007, pp. 411–414.
19. J. Yun, J. Cho, S. Bin Lee, and J. Y. Yoo, "Online detection of high-resistance connections in the incoming electrical circuit for induction motors," *IEEE Trans. Ind. Appl.*, vol. 45, no. 2, pp. 694–702, 2009.

20. A. von Jouanne and B. Banerjee, "Assessment of voltage unbalance," *IEEE Trans. Power Deliv.*, vol. 16, no. 4, pp. 782–790, 2001.
21. S. Yu and R. Tang, "Electromagnetic and mechanical characterizations of noise and vibration in permanent magnet synchronous machines," in *IEEE Transactions on Magnetics*, 2006, vol. 42, no. 4, pp. 1335–1338.
22. S. Ruoho, J. Kolehmainen, J. Ikaheimo, and A. Arkkio, "Interdependence of Demagnetization, Loading, and Temperature Rise in a Permanent-Magnet Synchronous Motor," *IEEE Trans. Magn.*, vol. 46, no. 3, pp. 949–953, Mar. 2010.
23. P. Zheng, J. Zhao, R. Liu, C. Tong, and Q. Wu, "Magnetic characteristics investigation of an axial-axial flux compound-structure PMSM used for HEVs," in *IEEE Transactions on Magnetics*, 2010, vol. 46, no. 6, pp. 2191–2194.
24. Z. Guoxin, T. Lijian, S. Qiping, and T. Renyuan, "Demagnetization Analysis of Permanent Magnet Synchronous Machines under Short Circuit Fault," *Power Energy Eng. Conf. (APPEEC)*, 2010 Asia-Pacific, pp. 1–4, 2010.
25. G. H. Kang, J. Hur, H. Nam, J. P. Hong, and G. T. Kim, "Analysis of irreversible magnet demagnetization in line-start motors based on the finite-element method," *IEEE Trans. Magn.*, vol. 39, no. 3 I, pp. 1488–1491, 2003.
26. S. Nandi, H. A. Toliyat, and X. Li, "Condition Monitoring and Fault Diagnosis of Electrical Motors—A Review," *IEEE Trans. ENERGY Convers.*, vol. 20, no. 4, 2005.
27. B. M. Ebrahimi and J. Faiz, "Diagnosis and performance analysis of three-phase permanent magnet synchronous motors with static, dynamic and mixed eccentricity," *IET Electr. Power Appl.*, vol. 4, no. 1, pp. 53–65, 2010.
28. J. Hong, S. Bin Lee, C. Kral, and A. Haumer, "Detection of airgap eccentricity for permanent magnet synchronous motors based on the d-axis inductance," *IEEE Trans. Power Electron.*, vol. 27, no. 5, pp. 2605–2612, 2012.
29. J. Rosero, L. Romeral, E. Rosero, and J. Urresty, "Fault Detection in dynamic conditions by means of Discrete Wavelet Decomposition for PMSM running under Bearing Damage," in *2009 Twenty-Fourth Annual IEEE Applied Power Electronics Conference and Exposition*, 2009, pp. 951–956.
30. J. R. Stack, T. G. Habetler, and R. G. Harley, "Fault classification and fault signature production for rolling element bearings in electric machines," in *IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, SDEMPED 2003 - Proceedings*, 2003, pp. 172–176.
31. J. R. Stack, R. G. Harley, and T. G. Habetler, "An amplitude Modulation detector for fault diagnosis in rolling element bearings," *IEEE Trans. Ind. Electron.*, vol. 51, no. 5, pp. 1097–1102, 2004.
32. J. C. Urresty Betancourt, "Electrical and magnetic faults diagnosis in permanent magnet synchronous motors." *Universitat Politècnica de Catalunya*.
33. M. Arkan, H. Çalış, and M. E. Tağluk, "Bearing and misalignment fault detection in induction motors by using the space vector angular fluctuation signal," *Electr. Eng.*, vol. 87, no. 4, pp. 197–206, 2005.