



FIRÇALI DA MOTORLARDA AÇIK VERİ SETİ İLE MAKİNE ÖĞRENMESİ TABANLI KESTİRİMCİ BAKIM VE ARIZA TEŞHİSİ

Erdoğan ÖZEL*

¹Van Yüzüncü Yıl University, Faculty of Engineering, Department of Electrical and Electronics Engineering, 65080, Van, Türkiye

Özet: Fırçalı Doğru Akım (FDA) motorları, endüstriyel otomasyon sistemlerinde ve tahrik mekanizmalarında yaygın olarak kullanılmakta olup, fırça aşınması ve sargı deformasyonları beklenmedik duruşlara ve yüksek bakım maliyetlerine neden olabilmektedir. Bu çalışmada, fırçalı DA motorların durum teşhisi ve Kalan Faydalı Ömür (Remaining Useful Life, RUL) tahmini için veri odaklı, ağaç tabanlı toplu öğrenme yöntemleri önerilmiştir. F.A.I.R veri setinden çoklu sensörlerden elde edilen akım, gerilim, devir, motor-ortam sıcaklık farkı ve spektral titreşim öznitelikleri kullanılarak motor ömrü; Evre I (Sağlıklı), Evre II (Hafif Aşınma), Evre III (Orta Aşınma) ve Evre IV (Kritik/Arıza) olmak üzere dört sağlık evresine ayrılmıştır. Durum teşhisinde Random Forest algoritması %98,7 test doğruluğu ve %95,70 10 katlı çapraz doğrulama başarısı ile Extra Trees algoritmasına göre daha yüksek performans göstermiştir. Öznitelik önem analizi, motor sağlığını en güçlü şekilde temsil eden değişkenlerin net sıcaklık artışı, yüksek frekanslı titreşim bileşenleri (16–26 kHz) ve motor devri olduğunu ortaya koymuştur. RUL tahmininde ise Extra Trees Regressor modeli 0,9666 belirlenme katsayısı (R^2) ve 21,49 zaman adımı RMSE değeri ile en başarılı sonucu elde ederken, Random Forest Regressor modeli 0,9603 R^2 ve 23,43 zaman adımı RMSE değerleriyle benzer düzeyde yüksek performans sergilemiştir. Elde edilen sonuçlar, önerilen yaklaşımın FDA motorlarda durum izleme ve öngörücü bakım uygulamaları için güvenilir ve etkili bir karar destek sistemi olarak kullanılabileceğini göstermektedir.

Anahtar kelimeler: Fırçalı DA motor, Kalan faydalı ömür (RUL), Durum teşhisi, Makine öğrenmesi, Random forest, Extra trees

Predictive Maintenance and Fault Diagnosis Based on Machine Learning with Open Data Set in Brushed DC Motors

Abstract: Brushed DC motors are widely used in industrial automation systems and drive mechanisms, but brush wear and winding deformations can lead to unexpected shutdowns and high maintenance costs. This study proposes data-driven, tree-based ensemble learning methods for condition diagnosis and Remaining Useful Life (RUL) estimation of brushed DC motors. Using current, voltage, speed, motor-ambient temperature difference, and spectral vibration features obtained from multiple sensors in the F.A.I.R dataset, motor life was divided into four health stages: Stage I (Healthy), Stage II (Slight Wear), Stage III (Moderate Wear), and Stage IV (Critical/Failure). In condition diagnosis, the Random Forest algorithm showed higher performance than the Extra Trees algorithm with 98.7% test accuracy and 95.70% 10-fold cross-validation success. Feature significance analysis revealed that the variables most strongly representing motor health were net temperature rise, high-frequency vibration components (16–26 kHz), and motor speed. In RUL prediction, the Extra Trees Regressor model achieved the most successful result with a coefficient of determination (R^2) of 0.9666 and a time-step RMSE value of 21.49, while the Random Forest Regressor model showed similarly high performance with an R^2 of 0.9603 and a time-step RMSE value of 23.43. The results indicate that the proposed approach can be used as a reliable and effective decision support system for condition monitoring and predictive maintenance applications in brushed DC motors.

Keywords: Brushed DC motor, Remaining useful life (RUL), Condition diagnosis, Machine learning, Random forest, Extra trees

*Sorumlu yazar (Corresponding author): Van Yüzüncü Yıl University, Faculty of Engineering, Department of Electrical and Electronics Engineering, 65080, Van, Türkiye
E mail: erdoganozel@yyu.edu.tr (E.ÖZEL)

Erdoğan ÖZEL  <https://orcid.org/0000-0002-4366-7257>

Gönderi: 09 Temmuz 2026

Kabul: 12 Ağustos 2026

Yayınlanma: 15 Eylül 2026

Received: July 09, 2026

Accepted: August 12, 2026

Published: September 15, 2026

Cite as: Özel, E. (2026). Predictive maintenance and fault diagnosis based on machine learning with open data set in brushed DC motors. *Black Sea Journal of Engineering and Science*, 9(5), 2453-2461.

1. Giriş

Doğru akım (DA) motorları, hassas hız ve tork kontrolü gerektiren uygulamalarda vazgeçilmez güç dönüştürücüleri olmuştur. Fırçasız motor teknolojilerindeki hızlı gelişmelere rağmen, fırçalı DA motorlar maliyet etkinlikleri, yüksek başlangıç torku ve basit kontrol yapıları sayesinde otomotiv, endüstriyel otomasyon, madencilik ve enerji sektörlerinde geniş bir uygulama alanını korumaktadır. Bu motorların temel yapısal bileşeni olan fırça-komütatör düzeneği, dönen

rotor sargılarına sabit referans çerçevesinden elektrik iletimini sağlamakla birlikte, sürekli mekanik sürtünme ve elektriksel yük altında çalışması nedeniyle en kritik aşınma noktasını oluşturmaktadır (Barkas vd., 2020; Filina vd., 2023). FDA motorlar, yapıları gereği sürekli dönen bir komütatör (kollektör) yüzeyine mekanik olarak temas eden karbon-grafit fırçalara bağlıdır. Fırça-komütatör arayüzünde meydana gelen sürekli sürtünme, yüksek akım yoğunlukları ve elektriksel arklar, zamanla bu bileşenlerin hızla aşınmasına ve



motorun işlevini yitirmesine yol açmaktadır (Pham vd., 2023; Teel-Jongebloed, 2020). Literatür incelendiğinde, FDA motorlardaki arızaların büyük bir kısmının komütatör ve fırça aşınmalarından kaynaklandığı görülmektedir. Bu tür beklenmedik bileşen arızaları, üretim hatlarında plansız duruşlara, iş gücü kayıplarına ve yüksek bakım maliyetlerine neden olmaktadır.

Geleneksel bakım stratejileri, fırçaların belirli çalışma saatlerinden sonra periyodik olarak değiştirilmesine dayanır. Ancak fırça aşınma hızı, yük profili, ortam sıcaklığı, nem ve komütatör yüzey kalitesi gibi çok sayıda faktöre bağlı olduğundan, sabit aralıklı bakım planları hem erken değiştirme (gereksiz maliyet) hem de geç değiştirme (beklenmedik arıza) riskini beraberinde getirir (Filina ve Tsvetkov, 2019). Bu bağlamda, Durum Tabanlı Kestirimci Bakım yaklaşımları, fırça sağlığını gerçek zamanlı olarak izleyerek bakım müdahalelerini optimize etme imkânı sunmaktadır. Bu bağlamda, fırça-komütatör sisteminden elde edilen titreşim, sıcaklık, akım, gerilim ve akustik sinyallerinin sürekli izlenmesi, fırça aşınmasının erken tespiti ile kestirimci bakım uygulamalarının gerçekleştirilmesine olanak sağlamaktadır (Reñones, 2020).

Son yıllarda durum temelli bakım ve makine sağlığı öngörüsü alanında, sensörlerden elde edilen çok değişkenli zaman serisi verilerinin analizine dayalı veri odaklı yaklaşımlar önemli ölçüde gelişmiştir. Bu süreçte yapay zekâ ve makine öğrenmesi algoritmaları; sağlık göstergelerinin oluşturulması, makinenin sağlık evrelerinin belirlenmesi ve kalan faydalı ömrünün tahmin edilmesi amacıyla yaygın olarak kullanılmakta ve kestirimci bakım uygulamalarının temel bileşenleri arasında yer almaktadır (Lei ve vd., 2018). Özellikle üretken yapay zekâ tabanlı modeller, ekipman davranışlarını öğrenerek olası arızaları önceden tahmin edebilmekte ve bakım planlarının optimize edilmesine olanak sağlamaktadır (Mohapatra, 2024; Rajabioun vd., 2025). Ancak, kestirimci bakım alanında akademik ve pratik çalışmalar yürüten araştırmacıların karşılaştığı en büyük zorluklardan biri, bir motorun normal çalışma durumundan tamamen arıza durumuna kadar geçen tüm aşınma sürecini içeren, güvenilir ve zengin içerikli açık veri setlerine erişimin kısıtlı olmasıdır. Endüstriyel ölçekteki ekipmanların arızalanana kadar çalıştırılması hem maliyetli hem de operasyonel olarak risklidir (Reñones, 2020).

Bu çalışmada, söz konusu literatür boşluğunu doldurmak ve veri odaklı arıza teşhis yöntemlerini test etmek amacıyla paylaşılan açık veri seti kullanılmıştır. Deneyler sırasında nominal çalışma koşullarının dışına çıkarılarak hızlandırılmış aşınma sürecine maruz bırakılan FDA motor üzerinden; yüksek frekanslı titreşim, akım, besleme gerilimi ve sıcaklık verileri toplanmıştır. Çalışma kapsamında, bu veriler üzerinde gerçekleştirilen özellik mühendisliği ve frekans analizi tabanlı sinyal işleme çıktılarından yararlanılmıştır. Toplanan çoklu sensör öznitelikleri, Random Forest ve Extra Tree makine öğrenmesi algoritmaları eğitilmiş; motorun komütatör

aşınma aşamaları sınıflandırılmış ve arıza kararlılığı analiz edilmiştir.

2. Materyal ve Yöntem

Bu çalışmada, Reñones (2020) tarafından geliştirilen F.A.I.R. (Findable, Accessible, Interoperable and Reusable) açık erişimli FDA motor arıza veri seti kullanılmıştır (Reñones, 2020). F.A.I.R. açık veri seti çalışmasında kullanılan FDA motorunda hızlandırılmış komütatör-fırça aşınması esnasında toplanan çoklu sensör verileri kullanılarak motorun sağlık durumunun anlık olarak teşhis edilmesi hedeflenmiştir. Önerilen kestirimci bakım metodolojisi; veri setinin yapısı, öznitelik mühendisliği, veri kümesi bölümlendirme ve makine öğrenmesi tabanlı sınıflandırma olmak üzere beş ana aşamadan oluşmaktadır.

2.1. Fırçalı Doğru Akım Motorları

Fırçalı doğru akım motorları, oyuncak sistemleri, otomotiv uygulamaları, elektrikli el aletleri gibi çok çeşitli alanlarda yaygın olarak kullanılan elektromekanik enerji dönüştürücüleridir. Bu motorların alternatif akım motorlarına göre temel üstünlüklerinden biri, ek güç dönüştürücü gereksinimi olmaksızın doğrudan batarya kaynaklarından beslenebilmesi ve yaklaşık 20.000 dev/dak'a ulaşabilen yüksek dönme hızlarında çalışabilmesidir. Bunun yanı sıra, düşük üretim maliyetleri, basit kontrol yapıları, kompakt tasarım imkânı ve farklı boyut ile geometrilerde üretilebilmeleri, FDA motorlarının endüstriyel, ticari ve taşınabilir sistemlerde yaygın olarak tercih edilmesini sağlamaktadır (Cros vd., 2009). F.A.I.R. veri seti çalışmasında kullanılan FDA motorunun temel bileşenleri şekil 1'de verilmiştir.




Şekil 1. F.A.I.R. veri seti çalışmasında kullanılan FDA motorunun temel bileşenleri: Armatür, sargılar, fırçalar, komütatör ve stator mıknatısları (Reñones, 2020).

2.2. Deneysel Veri Seti ve Sistem Altyapısı

Bu çalışmada kullanılan veri seti, Reñones (2020) tarafından geliştirilen F.A.I.R. (Findable, Accessible, Interoperable and Reusable) açık erişimli FDA motor arıza veri setinden elde edilmiştir. F.A.I.R. çalışmasında kullanılan deneysel veri seti, açık kaynaklı bir FDA motorun hızlandırılmış ömür testinden elde edilmiştir. Toplam 377 satır gözlem ve 50 farklı sensör özniteliklerinden oluşan bu veri tabanı, motorun sağlıklı ilk çalışma anından katastrofik arıza (durma/bozulma)

anına kadar geçen yaklaşık 35 dakikalık kesintisiz bir aşınma sürecini kronolojik olarak kaydetmektedir. Veri toplama sistemi kapsamında; motor hızı, besleme gerilimi, çekilen toplam akım, motor gövde sıcaklığı ve ortam sıcaklığı anlık olarak ölçülmüştür. Bunlara ek olarak, arıza teşhisinde en kritik rolü oynayan titreşim ve akım sinyalleri, frekans alanına (FFT) dönüştürülerek

1x'ten 10x'e kadar olan harmonik bileşenleri ve belirli geniş frekans bantları (0-4kHz, 16-26kHz vb.) bazında yüksek hassasiyetle kaydedilmiştir (Reñones, 2020). Şekil 2'de F.A.I.R. veri setinden alınan fırçalı DA motorun yaklaşık 35 dakikalık hızlandırılmış ömür testi boyunca kritik sensör sinyallerinin zamana bağlı değişim trendleri sunulmuştur.



Şekil 2. F.A.I.R. veri seti FDA hızlandırılmış aşınma süreci ve sinyal değişim trendleri (Reñones, 2020).

2.3. Öznitelik Mühendisliği

FDA motorlarda fırça-komütatör temas yüzeyinde meydana gelen aşınma, temas direncinin artmasına, mekanik sürtünmenin yükselmesine ve elektriksel ark oluşumunun sıklaşmasına neden olmaktadır. Bu süreçler motor içerisinde ek enerji kayıpları oluşturarak sıcaklık artışına yol açmaktadır. Bu nedenle sıcaklık değişimi, motorun çalışma sağlığını değerlendirmede yaygın olarak kullanılan durum izleme parametrelerinden biridir (Jardine vd., 2005; Mohapatra, 2024) Motor dış gövde sıcaklığı (temp_mot), ortam sıcaklığındaki (temp_ort) mevsimsel veya çevresel değişimlerden etkilenebileceğinden tek başına yanıltıcı olabilmektedir. Bu doğrultuda, çevresel gürültüleri elimine etmek ve arızanın termal karakteristiğini daha kararlı hale getirmek amacıyla eşitlik 1 kullanılarak net sıcaklık artışı (ΔT) parametresi türetilmiştir:

$$\Delta T = temp_mot - temp_ort \quad (1)$$

Bu diferansiyel öznitelik sayesinde model, ortam sıcaklığındaki değişimlerden büyük ölçüde bağımsız hâle getirilmiş ve yalnızca motor içerisinde sürtünme, temas direnci ve elektriksel ark oluşumu sonucu meydana gelen sıcaklık artışına odaklanmıştır. Literatürde, ham sensör verilerinden fiziksel anlam taşıyan yeni özniteliklerin türetilmesi, makine öğrenmesi modellerinin ayırt ediciliğini artıran ve genelleme performansını iyileştiren önemli bir veri ön işleme yöntemi olarak kabul edilmektedir (Guyon ve Elisseeff, 2003; Zheng ve Casari, 2018).

2.4. Zaman Serisi Etiketleme ve Sağlık Evreleri

Motorun sürekli aşınma sürecini doğrusal bir yaklaşımla temsil edebilmek ve makine öğrenmesi modeli için gözetimli öğrenmeye uygun hedef değişken oluşturabilmek amacıyla zaman serisi verileri kronolojik sıraya göre eşit uzunlukta dört evreye ayrılmıştır. Bu yaklaşım, gerçek zamanlı aşınma miktarının doğrudan ölçülemediği durumlarda ekipmanın yaşam döngüsünün belirli sağlık evrelerine ayrılması esasına dayanmaktadır. Kestirimci bakım ve kalan faydalı ömür (RUL) çalışmalarında, fiziksel bozunma miktarını doğrudan temsil eden etiketlerin bulunmadığı veri kümelerinde, zaman eksenli veya sağlık göstergelerine dayalı etiketleme yöntemleri yaygın olarak kullanılmaktadır (Lei vd., 2018; Karakılıç vd., 2025). Bu nedenle veri seti kronolojik sıraya göre dört eşit bölüme ayrılmış ve her bölüm artan bozunma seviyesini temsil eden bir sağlık evresi olarak tanımlanmıştır. Gerçek aşınma miktarını gösteren fiziksel referans ölçümlerinin bulunmadığı durumlarda, zamana dayalı eşit aralıklı etiketleme yaklaşımı, bozunmanın monoton olarak arttığı varsayımı altında makine öğrenmesi modellerinin eğitimi için literatürde kabul gören pragmatik veri hazırlama yöntemlerinden biridir (Ellefsen vd., 2019). Toplam satır sayısının (N=377) çeyrek periyotları (N/4) referans alınarak yapılan matematiksel etiketleme mantığı şu şekildedir:

- Evre I (Normal Çalışma): $0 \leq indeks < \frac{N}{4}$ Motorun mekanik ve termal olarak tamamen sağlıklı olduğu başlangıç dönemi.

- Evre II (Başlangıç Aşınması): $\frac{N}{4} \leq indeks < \frac{2N}{4}$
Mikroskobik fırça aşınmalarının başladığı, sinyallerde hafif pürüzlerin olduğu dönem.
- Evre III (İleri Düzey Aşınma): $\frac{2N}{4} \leq indeks < \frac{3N}{4}$
Komütatör yüzey kalitesinin bozulmaya başladığı ve termal artışın hızlandığı kararsızlık dönemi.
- Evre IV (Kritik / Arıza Durumu): $\frac{3N}{4} \leq indeks \leq N$
Fırçaların yüzeyden sıçrama yaptığı, ark seviyesinin

ve titreşimin pik noktaya ulaştığı katastrofik süreç. Dört evre seçimi, sınıf dengesini korumak, her evrede yeterli örnek sayısı sağlamak ve bozunma sürecini normal, erken aşınma, orta aşınma ve kritik aşınma olmak üzere yorumlanabilir sağlık durumlarına ayırmak amacıyla tercih edilmiştir. Belirlenen sağlık evrelerine göre sensör sinyallerinin tanımlayıcı istatistiksel ortalamaları Tablo 1’de verilmiştir.

Tablo 1. Belirlenen sağlık evrelerine göre sensör sinyallerinin tanımlayıcı istatistiksel ortalamaları

Motor Durumu	Ortalama Akım (A)	Temel Titreşim Genliği (g RMS)	Ortalama Motor Sıcaklığı (°C)	Ortalama Ortam Sıcaklığı (°C)
Evre I (Sağlıklı)	1,83	2,50	38,30	22,09
Evre II (Hafif Aşınma)	1,94	2,61	49,33	22,18
Evre III (Orta Aşınma)	2,05	2,76	58,74	22,25
Evre IV (Kritik Aşınma)	2,45	3,52	64,39	22,29

Tablo 1 incelendiğinde, kronolojik etiketleme sonucunda oluşturulan sağlık evrelerinin motorun fiziksel davranışıyla tutarlı eğilimler sergilediği görülmektedir. Ortalama akım değeri Evre I’de 1,83 A iken Evre IV’te 2,45 A’a yükselmiştir. Benzer şekilde motor gövde sıcaklığı 38,30 °C’den 64,39 °C’ye, temel titreşim genliği ise 2,50 ‘den 3,52’ye artmıştır. Buna karşın ortam sıcaklığının deney süresince sabit seviyede kalması, motor sıcaklığındaki artışın büyük ölçüde motor içerisindeki sürtünme, temas direnci ve elektriksel kayıplarla ilişkili olduğunu göstermektedir.

Bu bulgular, kronolojik olarak oluşturulan sağlık evrelerinin sensör verilerindeki bozunma eğilimleriyle uyumlu olduğunu ve oluşturulan etiketlerin makine öğrenmesi modellerinin eğitimi için ayırt edici bir hedef değişken sağladığını göstermektedir. Bununla birlikte, sağlık evreleri veri setinde fırça aşınma miktarı, temas direnci veya komütatör aşınmasını temsil eden doğrudan fiziksel eşik değerleri bulunmadığından, zaman eksenini boyunca eşit uzunlukta dört bölüme ayrılarak oluşturulmuştur. Dolayısıyla Evre II ile Evre III arasındaki sınır fiziksel aşınma geçişini değil, veri temelli kronolojik bir etiketlemeyi temsil etmektedir. Bu durum çalışmanın önemli sınırlılıklarından biri olup, gelecekte fiziksel aşınma ölçümleriyle desteklenen veri setleri kullanılarak sağlık evrelerinin fiziksel kriterlere dayalı olarak tanımlanması önerilmektedir.

2.5. Öznitelik Seçimi

F.A.I.R. Veri seti; titreşim, sıcaklık, motor akımı, gerilim, devir sayısı ve farklı frekans bantlarına ait spektral bileşenler olmak üzere motorun mekanik, elektriksel ve termal durumunu temsil eden toplam 50 değişken içermektedir. Veri setindeki tüm özniteliklerin doğrudan

modele aktarılması, yüksek boyutlu veri uzayında bilgi içeriği düşük veya yüksek korelasyonlu değişkenlerin model karmaşıklığını artırmasına ve genelleme performansının azalmasına neden olabilmektedir. Bu durum makine öğrenmesi literatüründe boyutluluk laneti olarak tanımlanmakta olup, uygun öznitelik seçiminin aşırı öğrenmeyi azaltarak model doğruluğunu artırdığı bilinmektedir (Guyon ve Elisseeff, 2003; Hastie vd., 2009). Bu nedenle çalışmada, veri setinde bulunan değişkenler arasından fırçalı DA motor fırça aşınmasının mekanik, elektriksel ve termal etkilerini en iyi temsil eden öznitelikler seçilmiştir. Bu yaklaşım, titreşim tabanlı durum izleme ve kestirimci bakım literatüründe önerilen özellik seçimi stratejileriyle uyumlu olduğu görülmektedir (Jardine vd., 2005; Randall, 2021) Seçim sürecinde yalnızca değişken sayısını azaltmak değil, aynı zamanda arıza mekanizmasını fiziksel olarak temsil eden parametrelerin korunması hedeflenmiştir. Bu kapsamda sıcaklık artışı (ΔT), düşük frekanslı titreşim harmonikleri (1X, 2X ve 3X), 16–26 kHz aralığındaki yüksek frekanslı titreşim bileşenleri, motor akımı, motor gerilimi, akım harmonikleri ve motor devir sayısı model girdileri olarak kullanılması tercih edilmiştir.

Düşük frekanslı titreşim harmonikleri rotor dengesizliği, mekanik gevşeklik ve komütatör-fırça etkileşimlerinden kaynaklanan temel dinamik davranışı temsil ederken, yüksek frekanslı (16–26 kHz) titreşim bileşenleri fırça sıçraması, ark oluşumu ve darbe karakterli temas bozukluklarının belirlenmesinde önemli bilgiler sağlamaktadır. Buna karşılık, 4X–10X arasındaki yüksek harmonik bileşenlerin deneysel veri setinde düşük genlikli ve yüksek gürültü içerdiği gözlemlendiğinden bu harmonikler modele dâhil edilmemiştir. Yüksek frekans

bölgesindeki bilgi kaybını önlemek amacıyla bu harmonikler yerine 16–26 kHz geniş bant enerji bileşeni kullanılmıştır. Ayrıca motor akımı ve gerilim değişkenleri yük değişimlerini ve elektriksel çalışma koşullarını temsil ederken, akım harmonikleri komütasyon bozuklukları ile ark oluşumuna bağlı dalga şekli değişimlerinin belirlenmesinde kullanılmıştır. Motor devir sayısı ise artan sürtünme torkunun neden olduğu mekanik performans değişimlerini temsil eden tamamlayıcı bir öznetelik olarak modele dâhil edilmiştir.

2.6. Makine Öğrenme Algoritmaları

Bu çalışmada, fırçalı DA motorların sağlık evrelerinin sınıflandırılması amacıyla karar ağacı tabanlı iki denetimli makine öğrenmesi algoritması olan Random Forest (RF) ve Extra Trees (ET) kullanılmıştır. Her iki algoritma da topluluk öğrenmesi yaklaşımına dayanmakta olup, çok sayıda karar ağacının birlikte çalışması prensibi ile sınıflandırma gerçekleştirmektedir. Topluluk öğrenmesi yöntemleri, tek bir karar ağacına göre daha yüksek doğruluk, daha düşük varyans ve daha güçlü genelleme performansı sağlamaları nedeniyle arıza teşhisi ve kestirimci bakım uygulamalarında yaygın olarak kullanılmaktadır (Breiman, 2001; Geurts vd., 2006).

Makine öğrenmesi modellerinde hiperparametre optimizasyonu, modelin genelleme yeteneğini ve tahmin doğruluğunu artırdığı için kritik öneme sahiptir. Tahmin modelleri geliştirilirken, grid search gibi sistematik hiperparametre arama teknikleri sıklıkla

kullanılmaktadır. Bu yöntem, belirlenen hiperparametre değerlerinin farklı kombinasyonlarını *GridSearchCV* çerçevesinde değerlendirmekte ve en yüksek performansı veren kombinasyonu seçmektedir. Literatürde de, Ensemble modellerde (Random Forest, Extreme Randomized Trees vb.) hiperparametre arama stratejileri ile farklı kombinasyonlar değerlendirilmiş ve performansı artıran parametre kümeleri seçilmiştir (Bergstra ve Bengio, 2011; Ippolito, 2022).

Bu çalışmada RF ve ET modellerinin hiperparametre optimizasyonu *GridSearchCV* yöntemi kullanılarak gerçekleştirilmiştir. Hiperparametre arama sürecinde ağaç sayısı (*n_estimators*), maksimum ağaç derinliği (*max_depth*), düğüm bölünmesi için gerekli minimum örnek sayısı (*min_samples_split*), yaprak düğümde bulunması gereken minimum örnek sayısı (*min_samples_leaf*), her düğümde değerlendirilecek özellik sayısı (*max_features*) ve Random Forest modeli için ayrıca *bootstrap* parametresi değerlendirilmiştir. Her parametre kombinasyonu 10 katlı çapraz doğrulama (10-fold cross-validation) (Mahlich vd., 2025) ile test edilmiş ve doğruluk (*accuracy*) ölçütüne göre en yüksek performansı sağlayan kombinasyon nihai model olarak seçilmiştir. Tablo 2’de Random Forest ve Extra Trees modellerinde kullanılan hiperparametre arama uzayı ve elde edilen optimum hiperparametreler verilmiştir.

Tablo 2. Random Forest ve Extra Trees modellerinde kullanılan hiperparametre arama uzayı ve elde edilen optimum hiperparametreler

Hiperparametre	Açıklama	Aranan Değerler	RF	ET
<i>n_estimators</i>	Karar ağacı sayısı	100, 200, 300, 400, 500	100	100
<i>max_depth</i>	Maksimum ağaç derinliği	10, 15, 20, 25, None	20	20
<i>min_samples_split</i>	Bir düğümün bölünebilmesi için gerekli minimum örnek sayısı	2, 5, 10	2	5
<i>min_samples_leaf</i>	Yaprak düğümde bulunması gereken minimum örnek sayısı	1, 2, 4	1	1
<i>max_features</i>	Her düğümde değerlendirilecek maksimum özellik sayısı	sqrt, log2	sqrt	sqrt
<i>bootstrap</i> *	Bootstrap örnekleme yöntemi	True	True	–

*Yalnızca Random Forest algoritmasında kullanılmıştır.

Model geliştirme sürecinde veri kümesi eğitim ve test alt kümelerine %80-%20 oranında ayrılmıştır. Veri bölme işlemi, sağlık evrelerinin her iki alt kümede dengeli biçimde temsil edilmesini sağlamak amacıyla *train_test_split* fonksiyonu ve stratify parametresi kullanılarak gerçekleştirilmiştir. Böylece her sağlık evresi eğitim ve test kümelerinde benzer dağılım oranlarıyla korunmuştur. Model performansı yalnızca eğitim verisi kullanılarak geliştirilen modeller üzerinde


değerlendirilmiş ve test kümesi eğitim sürecine dâhil edilmemiştir. Bu yaklaşım, eğitim ve test verileri arasında veri sızıntısı (data leakage) oluşmasını önlemeyi amaçlamaktadır.

3. Bulgular ve Tartışma

Fırçalı DA motora ait akım, voltaj, devir sayısı, sıcaklık ve spektral titreşim öznitelikleri kullanılarak gerçekleştirilen durum teşhisi (sınıflandırma) ve kalan faydalı ömür (RUL) tahmini (regresyon) sonuçları analiz edilmiştir. Önerilen ağaç tabanlı toplu öğrenme mimarileri olan RF ve ET algoritmalarının performansları ampirik bulgularla ortaya konulmuştur.

3.1. Sağlık Evresi Sınıflandırma ve Durum Teşhis Performansı

FDA motorun operasyonel ömrü boyunca sergilediği 4 farklı aşınma evresini (Evre I: Sağlıklı, Evre II: Hafif Aşınma, Evre III: Orta Aşınma, Evre IV: Kritik/Arıza) ayırt etmek amacıyla geliştirilen sınıflandırma modellerinin hata dağılımlarını ve evreler arasındaki geçiş hassasiyetlerini detaylı incelemek için üretilen hata matrisleri Şekil 3'te verilmiştir.




Şekil 3. Modellerin hata dağılımlarını ve evre geçiş hassasiyetlerini gösteren hata matrisleri.

Her iki hata matrisi de bağımsız test kümesinde yer alan toplam 76 örnek üzerinden oluşturulmuştur. Matrislerde diyagonal elemanlar doğru sınıflandırılan, diyagonal dışındaki elemanlar ise yanlış sınıflandırılan örnekleri göstermektedir. Hata matrisleri incelendiğinde her iki modelin de sınıflar arasında yüksek ayırma başarısı gösterdiği görülmektedir. Yanlış sınıflandırmalar yalnızca ardışık aşınma evreleri (özellikle Evre II ve Evre III) arasında gerçekleşmiş, uzak evreler arasında herhangi bir karışıklık gözlenmemiştir. RF modeli Evre IV örneklerinin tamamını doğru sınıflandırırken, ET modeli yalnızca bir Evre IV örneğini Evre III olarak sınıflandırmıştır. Bu sonuçlar, modellerin özellikle kritik arıza evresinin belirlenmesinde yüksek güvenilirliğe sahip olduğunu göstermektedir.


3.2. Öznitelik Önem Dereceleri ve Fiziksel Karakterizasyon

Random Forest modeli tarafından hesaplanan bilgi kazancı tabanlı öznitelik önem dereceleri Şekil 4'te hiyerarşik olarak sunulmuştur.

Öznitelik önem analizi, hem sağlık evrelerinin sınıflandırılması hem de kalan faydalı ömür (RUL) tahmini açısından yüksek frekanslı titreşim bileşenleri, sıcaklık farkı (ΔT) ve elektriksel büyüklüklerin belirleyici olduğunu göstermektedir. Özellikle yüksek frekanslı titreşim bileşenleri, fırça-komütatör temas yüzeyindeki aşınmaya bağlı olarak gelişen mekanik düzensizlikleri yansıtırken, sıcaklık farkı (ΔT) motorun termal davranışındaki değişimleri ortaya koymaktadır. Benzer şekilde akım ve elektriksel harmonik bileşenleri de fırça aşınmasının elektriksel etkilerini temsil ederek modellerin ayırt ediciliğini artırmıştır. Bu bulgular, seçilen özniteliklerin motorun fiziksel bozunma mekanizmasını başarılı bir şekilde temsil ettiğini ve geliştirilen modellerin karar verme sürecinin fiziksel olarak anlamlı değişkenlere dayandığını göstermektedir. Seçilen bu kritik özniteliklerin oluşturduğu öznitelik uzayındaki anlamsal dağılım Şekil 5'teki saçılım grafiğinde görselleştirilmiştir.



Şekil 4. Random Forest modeli tarafından hesaplanan bilgi kazancı tabanlı öznitelik önem dereceleri hiyerarşik sıralaması.



Şekil 5. Kritik özniteliklerin oluşturduğu öznitelik uzayındaki anlamsal dağılım.

Grafikte, net sıcaklık artışı ile yüksek frekans spektral titreşim bileşenlerinin eş zamanlı olarak motorun aşınma evrelerini belirgin kümeler halinde ayırabildiği fiziksel olarak göstermektedir. Motor kararlı durumdan arıza durumuna geçtikçe, sargı ve fırça sürtünmesinden kaynaklanan termal yük yükselmiş, mikro ark gürültüleri ise yüksek frekans titreşim genliklerini artırdığı görülmektedir.

3.3. Kalan Faydalı Ömür (RUL) Tahmin Sonuçları

Çalışmada, motor sağlığını sadece kesikli evrelerle sınıflandırmakla yetinilmeyip, sürekli bir bozunum eğrisi üzerinden Kalan Faydalı Ömür (RUL) kestirimi de gerçekleştirilmiştir. Ağaç tabanlı regresyon modellerinin test seti üzerindeki tahmin başarıları Tablo 3'te verilmiştir.


Tablo 3. RF ve ET modellerinin sınıflandırma ve RUL tahmin performanslarının karşılaştırılması

Algoritma	10-Fold CV (%)	Test Doğruluğu (%)	F1-Skoru (%)	R ²	RMSE (Zaman Adımı)
RF	95,70	98,70	98,70	-	-
ET	95,38	93,40	93,50	-	-
RFR	-	-	-	0,9603	23,43
ETR	-	-	-	0,9666	21,49

Tabloda sınıflandırma ve regresyon modellerinin performansları karşılaştırılmıştır. Sınıflandırmada Random Forest modeli, %95,70 çapraz doğrulama başarısı, %98,70 test doğruluğu ve %98,70 F1-skoru ile en yüksek performansı göstermiştir. Extra Trees modeli ise %95,38 çapraz doğrulama başarısı, %93,40 test doğruluğu ve %93,50 F1-skoru elde etmiştir. Regresyon sonuçlarında ise Extra Trees Regressor modeli $0,9666 R^2$ ve 21,49 RMSE ile Random Forest Regressor modelinden ($R^2 = 0,9603$, RMSE = 23,43) daha başarılı sonuçlar vermiştir. Genel olarak, Random Forest sınıflandırmada, Extra Trees Regressor ise RUL tahmininde daha yüksek performans sergilemiştir. RUL tahmin performans grafiklerinin zamana bağlı iz düşümü Şekil 6'da verilmiştir.

Grafikte, RFR ve ETR modelleri için bağımsız test kümesinde elde edilen gerçek ve tahmin edilen Kalan Faydalı Ömür (RUL) değerlerinin karşılaştırılması

sunulmaktadır. X eksenini kronolojik zaman sırasını değil, bağımsız test kümesinde yer alan örneklerin indekslerini; Y eksenini ise bu örneklerle ait Kalan Faydalı Ömür (RUL) değerlerini göstermektedir. Her iki model de motorun kalan ömründeki azalma eğilimini başarılı bir şekilde takip etmiş ve tahmin eğrileri genel olarak gerçek RUL eğrisi ile yüksek uyum göstermiştir. Özellikle ömrün ilk ve orta evrelerinde her iki modelin tahminleri gerçek değerlere oldukça yakın gerçekleşmiştir. Motor ömrünün son evrelerinde ise sinyaldeki ani değişimler nedeniyle tahmin hatalarında kısmi artışlar gözlenmesine rağmen, her iki model de genel bozulma eğilimini korumuştur. Performans ölçütleri incelendiğinde, ETR modeli $R^2 = 0,9666$ ve RMSE = 21,49 zaman adımı ile RFR modeline ($R^2 = 0,9603$, RMSE = 23,43 zaman adımı) göre daha başarılı sonuçlar elde etmiş, bu da ET algoritmasının doğrusal olmayan bozulma davranışını modellemede daha yüksek tahmin doğruluğu sağladığını göstermiştir.



Şekil 6. RUL tahmin performans grafiklerinin zamana bağlı iz düşümü.

4. Sonuç

Bu çalışmada; F.A.I.R. veri setinden alınan akım, gerilim, hız, sıcaklık ve titreşim sinyallerini içeren çoklu sensör ölçüm verileri kullanılarak FDA motorların hem durum tespiti hem de RUL tahmini için veri odaklı, ağaç tabanlı toplu öğrenme modelleri geliştirilmiş ve değerlendirilmiştir. Deneysel sonuçlar, önerilen Random Forest ve Extra Trees sınıflandırıcılarının sırasıyla %98,7 ve %93,4 gibi yüksek sınıflandırma doğruluklarına ulaştığını; ayrıca sırasıyla %95,70 ve %95,38'lik 10 katlı çapraz doğrulama (10-fold cross-validation) başarılarıyla güçlü bir sınıflandırma performansı ve iyi bir genelleme yeteneği sergilediğini ortaya koymuştur. Karışıklık matrisi analizi, az sayıdaki hatalı sınıflandırmanın yalnızca birbirine yakın evreler arasında gerçekleştiğini ve kritik arıza aşamasının (Evre IV) yüksek güvenilirlikle tespit edildiğini göstermiştir. Bu durum, önerilen çerçevenin kestirimci bakım uygulamalarındaki kullanılabilirliğini vurgulamaktadır. Öznitelik önemi analizi, seçilen özniteliklerin fiziksel

anlamlılığını doğrulamış; net sıcaklık artışının aşınma sürecindeki en etkili gösterge olduğunu, bunu yüksek frekanslı titreşim bileşenlerinin ve dönüş hızının takip ettiğini açığa çıkarmıştır. Kalan faydalı ömür (RUL) tahmini için ise Extra Trees Regressor, Random Forest Regressor modeline göre biraz daha iyi bir performans sergileyerek 0,9666'lık bir R^2 skoru ve 21,49 zaman adımı RMSE değeri elde etmiştir. Random Forest Regressor ise 0,9603'lük bir R^2 skoru ve 23,43 zaman adımı RMSE değerine ulaşmıştır.

Bu sonuçlar, ağaç tabanlı toplu öğrenme yöntemlerinin fırçalı DA motorların hem bozulma aşamalarını hem de kalan ömürlerini doğru bir şekilde modelleyebildiğini ve güçlü bir kestirim performansı sunabildiğini kanıtlamaktadır. Genel olarak önerilen çerçeve, FDA motorların akıllı durum izlemesi ve kestirimci bakımı için verimli ve pratik bir karar destek aracı sağladığı görülmüştür.

Gelecekteki çalışmalar; önerilen modellerin farklı güçteki FDA motor verileri ile değerlendirilerek motor güç değişimindeki farklılıkların tespitine yönelik olacaktır.

Katkı Oranı Beyanı

Yazarın katkı yüzdeleri aşağıda verilmiştir. Yazar makaleyi incelemiş ve onaylamıştır.

	E.Ö.
K	100
T	100
Y	100
VTI	100
VAY	100
KT	100
YZ	100
KI	100
GR	100
PY	100
FA	100

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi, FA= fon alımı.

Çalışma Beyanı

Yazar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Etik Onay Beyanı

Bu çalışmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

Kaynaklar

- Barkas, D. A., Ioannidis, G. Ch., Psomopoulos, C. S., Kaminaris, D., & Vokas, G. A. (2020). Brushed DC Motor Drives for Industrial and Automobile Applications with Emphasis on Control Techniques: A Comprehensive Review. *Electronics*, 9(6), 887-887. <https://doi.org/10.3390/electronics9060887>
- Bergstra, J., & Bengio, Y. (2011). Algorithms for hyper-parameter optimization. *HAL (Le Centre pour la Communication Scientifique Directe)*. Centre National de la Recherche Scientifique. <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.47.6.5930>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/a:1010933404324>
- Cros, J., Sincero, G. C. R., & Viarouge, P. (2009). Design method for brush permanent magnet DA motors. *2009 IEEE International Electric Machines and Drives Conference*, 1625-1632.
- Ellefsen, A. L., Ushakov, S., Æsøy, V., & Zhang, H. (2019). Validation of Data-Driven Labeling Approaches Using a Novel Deep Network Structure for Remaining Useful Life Predictions. *IEEE Access*, 7, 71563-71575. <https://doi.org/10.1109/access.2019.2920297>
- Filina, O., & Tsvetkov, A. N. (2019). Evaluation of the operational life of direct current motors. *IOP Conference Series Materials Science and Engineering*, 489, 12-16. <https://doi.org/10.1088/1757-899x/489/1/012016>
- Filina, O., Martyushev, N. V., Malozyomov, B. V., Tynchenko, V. S., Kukartsev, V. A., Bashmur, K. A., Pavlov, P. P., & Panfilova, T.

- (2023). Increasing the efficiency of diagnostics in the brush-commutator assembly of a direct current electric motor. *Energies*, 17(1), 17-17. <https://doi.org/10.3390/en17010017>
- Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63(1), 3-42. <https://doi.org/10.1007/s10994-006-6226-1>
- Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of machine learning research*, 3(Mar), 1157-1182.
- Hastie, T., Tibshirani, R., & Friedman, J. H. (2009). The Elements of Statistical Learning. İçinde *Springer series in statistics*. Springer Science+Business Media. <https://doi.org/10.1007/978-0-387-84858-7>
- Ippolito, P. P. (2022). Hyperparameter tuning: the art of fine-tuning machine and deep learning models to improve metric results. İçinde *Applied data science in tourism: Interdisciplinary approaches, methodologies, and applications* (ss. 231-251). Springer International Publishing.
- Jardine, A., Lin, D., & Banjević, D. (2005). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483-1510. <https://doi.org/10.1016/j.ymssp.2005.09.012>
- Karakılıç, M., Hataş, H., & Pacal, İ. (2025, May). Open-Circuit Fault Detection in T-Type MLI Using XGBoost: A Machine Learning-Based Approach. In *2025 7th International Congress on Human-Computer Interaction, Optimization and Robotic Applications (ICHORA)* (pp. 1-6). IEEE.
- Lei, Y., Li, N., Guo, L., Li, N., Yan, T., & Lin, J. (2018). Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*, 104, 799-834. <https://doi.org/10.1016/j.ymssp.2017.11.016>
- Mahlich, C., Vente, T., & Beel, J. (2025). From theory to practice: Implementing and evaluating e-fold cross-validation. In J. Liu, A. Ghosh, C. W. Tan, & H. Zhao (Eds.), *International Conference on Artificial Intelligence and Machine Learning Research (CAIMLR 2024)* (Vol. 13635, Article 1363505). SPIE. <https://doi.org/10.1117/12.3058568>
- Mohapatra, A. (2024). Generative AI for Predictive Maintenance: Predicting Equipment Failures and Optimizing Maintenance Schedules Using AI. *International Journal of Scientific Research and Management (IJSRM)*, 12(11), 1648-1672. <https://doi.org/10.18535/ijrm/v12i11.ec03>
- Pham, V.-H., Le, D. B., & Nguyen, P. D. (2023). A Method of Assessing the Service Life and Reliability of Motor Brushes Based on Wear Under Variable Current and Environmental Conditions. *Tribology in Industry*, 45(1), 302-312. <https://doi.org/10.24874/ti.1443.02.23.06>
- Rajabioun, R., Hataş, H., Afshar, M., Atan, Ö., & Akin, B. (2025). Optimal feature selection for distributed bearing fault detection using cost-effective, high-performance machine learning algorithms. *IEEE Journal of Emerging and Selected Topics in Industrial Electronics*, 7(1), 46-57.
- Randall, R. B. (2021). *Vibration-based condition monitoring: industrial, automotive and aerospace applications*. John Wiley & Sons.
- Reñones, A. (2020). F.A.I.R. open dataset of brushed DC motor faults for testing of AI algorithms (Version 1.0) [Data set]. Zenodo. <https://doi.org/10.5281/zenodo.4314249>
- Teel-Jongbloed, C. C. (2020). Detection of permanent magnet DC motor failure due to brush wear using parameter estimation and statistical analysis. *OakTrust (Texas A&M University Libraries)*. <https://hdl.handle.net/1969.1/192653>
- Zheng, A., & Casari, A. (2018). *Feature engineering for machine learning: principles and techniques for data scientists*. O'Reilly Media, Inc