



Özgür Aydın

Bingöl University, oaydin@bingol.edu.tr, Bingöl-Türkiye

Erhan Akın

Fırat University, eakin@firat.edu.tr, Elazığ-Türkiye

DOI	http://dx.doi.org/10.12739/NWSA.2024.19.4.2A0200	
ORCID ID	0000-0001-8130-277X	0000-0001-6476-9255
Corresponding Author	Özgür Aydın	

ASENKRON MOTORLARDA KIRIK ROTOR ÇUBUKLARININ ERKEN TEŞHİSİ: TRANSFER ÖĞRENME YAKLAŞIMLARININ DEĞERLENDİRİLMESİ

ÖZ

Asenkron motorlar, basit tasarımları, düşük bakım gereksinimleri ve uzun ömürleri nedeniyle hem günlük hayatta hem de endüstriyel uygulamalarda geniş bir kullanım alanına sahiptir. Bu motorlarda meydana gelen rotor arızalarının hızlı ve güvenilir bir şekilde tespit edilmesi, işletmelerin verimliliği ve sürekliliği açısından kritik öneme sahiptir. Bununla birlikte, transfer öğrenme yöntemi, motor arızalarının teşhisinde hala yeterince araştırılmamış bir alan olarak dikkat çekmektedir. Transfer öğrenme, mevcut veri setlerinden elde edilen bilgi birikimini yeni problemlere uyarlayarak, asenkron motorlarda rotor çubuğu arızalarının daha güvenilir bir şekilde teşhis edilmesini sağlayabilir. Bu çalışma, kırık rotor çubuklarının erken tespiti için transfer öğrenme modellerinin etkinliğini incelemektedir. Araştırmada, hazır bir veri setinden elde edilen beş farklı zaman-frekans görüntüsü kullanılmıştır. Bu görüntüler üzerinde beş farklı transfer öğrenme modeli değerlendirilmiş ve performansları karşılaştırılmıştır. Sonuçlar, transfer öğrenme yaklaşımlarının asenkron motor arızalarının teşhisinde %99,5'in üzerinde doğruluk oranlarına ulaştığını göstermektedir. Bu bulgular, yöntemin motor arıza teşhisi için etkili ve umut verici bir çözüm sunduğunu ortaya koymaktadır.

Anahtar Kelimeler: Asenkron Motor, Arıza Teşhisi, Kırık Rotor Çubuğu, Transfer Öğrenme, Görüntü İşleme

EARLY DETECTION OF BROKEN ROTOR BARS IN INDUCTION MOTORS: EVALUATION OF TRANSFER LEARNING APPROACHES

ABSTRACT

Induction motors are widely used in both daily life and industrial applications due to their simple design, low maintenance requirements, and long service life. The rapid and reliable detection of rotor faults in these motors is critically important for ensuring operational efficiency and continuity in businesses. However, transfer learning remains an underexplored area in the diagnosis of motor faults. Transfer learning enables the application of knowledge gained from existing datasets to new problems, providing a more reliable approach for detecting rotor bar faults in induction motors. This study investigates the effectiveness of transfer learning models for the early detection of broken rotor bars. The research utilizes five different time-frequency images obtained from a pre-existing dataset. These images are analyzed using five distinct transfer learning models, and their performances are compared. The results demonstrate that transfer learning approaches achieve an accuracy rate exceeding 99.5% in diagnosing induction motor faults. These findings highlight the potential of this method as an effective and promising solution for motor fault diagnosis.

Keywords: Induction Motor, Fault Diagnosis, Broken Rotor Bar, Transfer Learning, Image Processing

How to Cite:

Aydın, Ö. ve Akın, E., (2024). Asenkron motorlarda kırık rotor çubuklarının erken teşhisi: transfer öğrenme yaklaşımlarının değerlendirilmesi. 19(4):42-52, DOI: 10.12739/NWSA.2024.19.4.2A0200.



1. GİRİŞ (INTRODUCTION)

Asenkron motorlar, elektrik motorları arasında endüstriyel ve evsel alanlarda yaygın olarak kullanılan önemli bir türdür. Endüstriyel sektörde, pompa sistemleri, fanlar, konveyörler, kompresörler gibi çeşitli makinelerin tahrikinde kullanılırken; evsel kullanımlarda, çamaşır makineleri, bulaşık makineleri, vantilatörler ve klimalar gibi cihazlarda sıkça karşımıza çıkmaktadırlar [1]. Bununla birlikte, asenkron motorlar kullanım sırasında çeşitli arızalarla karşılaşabilirler. Bu arızaların temel sebepleri, çevresel etkiler (aşırı yüklenme, yüksek sıcaklık, nem, toz), elektriksel sorunlar (voltaaj dalgalanmaları, faz dengesizlikleri), mekanik problemler (rulman hasarı, rotor dengesizliği) ve yalıtım eksiklikleri [2].

Arıza teşhis yöntemleri, genellikle akustik analiz, titreşim analizi, izolasyon direnci ölçümleri, termal görüntüleme ve görsel inceleme gibi prosedürleri içerir [3]. Ayrıca spektral analiz, yapay zekâ teknikleri ve makine öğrenimi gibi modern teşhis yöntemleri de kullanılmaktadır [4]. Bu teşhis yöntemleri, asenkron motorların arızalarını hızlı ve etkili bir şekilde tanımlamaya yardımcı olur ve bakım süreçlerini iyileştirir [5]. Bu nedenlerden dolayı asenkron motorların güvenilirliğini artırmak ve verimliliğini sağlamak için düzenli bakım ve arıza teşhis prosedürlerinin uygulanması önemlidir.

Transfer öğrenme, yapay zekâ alanında son yıllarda önemli bir araştırma konusu olmuştur. Yapılan çalışmalar, transfer öğrenme tekniklerinin çeşitli alanlarda etkileyici sonuçlar verdiğini göstermektedir. Önceden eğitilmiş derin öğrenme modellerinin kullanımı, sınırlı veriye sahip görevlerde bile yüksek başarı sağlamaktadır [6]. Bu modeller, genel bir görüntü tanıma görevinden elde ettikleri bilgileri, daha spesifik görevlere transfer ederek performanslarını artırabilmektedirler [7]. Metin verisi için yapılan çalışmalar da benzer başarıları göstermektedir; transfer öğrenme teknikleri, duyu analizi, metin sınıflandırma gibi doğal dil işleme görevlerinde önemli iyileştirmeler sağlamıştır [8]. Ayrıca ses ve video gibi multimodal veri türlerinde de transfer öğrenme yaklaşımlarının etkili olduğu gözlemlenmiştir [9]. Bu başarılar, transfer öğrenme tekniklerinin genellikle daha az etiketli veriyle yüksek başarı elde etme potansiyeline sahip olduğunu ortaya koymaktadır. Dolayısıyla, transfer öğrenme, yapay zekâ uygulamalarında verimliliği artırmak ve daha genel, genelleştirilebilir modeller geliştirmek için önemli bir araç olarak kabul edilmektedir.

Asenkron motorlarda arıza teşhisi, sınırlı etiketli veri setleri, çeşitli çalışma koşulları ve potansiyel overfitting gibi zorluklarla karşılaşır. Bu zorlukların üstesinden gelmek için transfer öğrenimi yaklaşımları önemli bir araç sağlar. Transfer öğrenimi, daha büyük ve genel veri setlerinden öğrenilen bilgilerin, asenkron motorlardaki arıza tespiti gibi belirli bir göreve aktarılmasına olanak tanır. Bu sayede, sınırlı veri kümeleriyle daha etkili modeller oluşturulabilir. Ayrıca farklı koşullar altında elde edilen veriler arasındaki farklılıkları dengeleyerek daha genel ve adaptif modellerin oluşturulmasına yardımcı olur. Bununla birlikte, küçük veri kümeleriyle çalışırken ortaya çıkan overfitting problemini azaltmaya ve model eğitim süresini kısaltmaya yardımcı olur. Bu nedenlerle, transfer öğrenimi yaklaşımlarının asenkron motorlardaki arıza tespiti gibi görevlerde kullanılması önemlidir [10, 11 ve 12].

Transfer öğrenimi kullanılarak resimlerin sınıflandırılması üzerine birçok çalışma yürütülmüştür. Jain ve ark., çeşitli cilt kanseri türlerini sınıflandırmak için transfer öğrenimi tabanlı derin öğrenme yöntemlerinin uygulanmasını incelemiştir. Araştırma özellikle Xception ağının cilt kanseri tespitinde %90.48 gibi yüksek bir doğruluk oranına ulaştığını belirtmektedir. Çalışmada genel olarak VGG19,



ResNet50, InceptionResNetV2, InceptionV3 ve MobileNet gibi çeşitli derin öğrenme modelleri kullanılmış ve her biri farklı başarı oranları gösterilmiştir. Araştırmada dermatologlar tarafından etiketlenmiş HAM10000 gibi kamuoyuna açık cilt kanseri veri setleri kullanılmıştır [13].

Fan ve ark., histopatoloji görüntülerinin sınıflandırılması için transfer öğrenme ve destek vektör makinesi (SVM) kullanımını incelemiştir. Çalışma, özellikle iki farklı kanser türünü içeren veri setleri üzerinde gerçekleştirilmiştir: biri ikili meme kanseri veri seti ve diğeri çok sınıflı akciğer ve kolon kanseri veri setinden oluşmaktadır. Çalışmanın sonuçlarına göre, geleneksel softmax sınıflandırıcıya ek olarak bir SVM sınıflandırıcı eklenmesiyle oluşturulan sentetik mimari, diğeri modellere göre daha yüksek sınıflandırma başarısı göstermiştir. Bu hibrit mimari, özellikle karmaşık tıbbi görüntü veri setlerinde yüksek doğruluklu sonuçlar için etkili bir yol sunmaktadır [14].

Shaha ve ark., evrişimli sinir ağlarının (CNN) nesne tanıma gibi uygulamalarda kullanımını incelemiştir. Özellikle, AlexNet, VGG16 ve VGG19 gibi ünlü CNN mimarileri üzerinde durmuşlardır. Önceden eğitilmiş VGG19 ağının parametrelerini ince ayarlayarak transfer öğrenimini kullanarak görüntü sınıflandırma görevini gerçekleştirmeyi amaçlamışlardır ve ayarlanmış VGG19 mimarisinin en iyi performansı sergilediğini göstermişlerdir [15].

Transfer öğrenme yöntemleri kullanılarak asenkron motorlar üzerindeki arıza teşhislerinin tespiti için çok etkili ve başarılı çalışmalar yürütülmüştür. Bu modeller ile yapılan çalışmalarda %80 üzerinde başarı elde edilmiştir. Örneğin, Misra ve ark., üç fazlı bir endüksiyon motorunun rotorunda kırık çubuklar bulunan bir veri seti üzerinde çalışmışlardır. Zaman, frekans ve zaman-frekans alanlarında özellik çıkarılarak, sağlıklı ve arızalı rotorlar arasında sınıflandırma yapmışlardır. Zaman ve frekans alanından çıkarılan özellikler, Random-Forest (RF) modeli ile %87.52 ve %88.58 doğrulukla sınıflandırılmıştır. Zaman-frekans alanında ise, Short Time Fourier Dönüşümü (STFT) tabanlı spektrogramlar kullanılarak %97.67 civarında yüksek doğruluk elde etmişlerdir [16].

Yapılan araştırmalarda transfer öğrenme modellerinin genel olarak bir karşılaştırılmasına rastlanılmamıştır. Bu çalışmada farklı transfer öğrenimi yöntemlerinin (EfficientNetB7, EfficientNetV2L, EfficientNetV2M, EfficientNetV2S, InceptionResNetv2) asenkron motorlardaki arıza teşhisi için başarıyla kullanılabileceği ve %99.5 üzerinde başarı oranları elde edilebildiği gösterilmiştir.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Asenkron motorlar, modern endüstriyel uygulamalarda en sık kullanılan elektrik motorları arasında yer almakta ve güvenilir bir şekilde çalışması üretim süreçlerinin sürdürülebilirliği açısından hayati önem taşımaktadır. Ancak bu motorlarda meydana gelebilecek rotor arızalarının erken teşhisi, yalnızca motorların ömrünü uzatmakla kalmayıp aynı zamanda bakım maliyetlerini düşürmekte ve iş sürekliliğini sağlamaktadır. Transfer öğrenme yaklaşımları, geleneksel yöntemlerin yetersiz kaldığı durumlarda, yüksek doğruluk oranlarıyla arızaların hızlı teşhis edilmesine olanak tanımaktadır.

Bu çalışmanın hedefi, transfer öğrenme yöntemleri kullanılarak kırık rotor çubuklarının erken teşhisi için yenilikçi bir yaklaşımla sektöre katkı sağlamaktır. Çalışmada, transfer öğrenme modellerinin farklı yük ve arıza koşullarındaki performansları detaylı olarak incelenmiş, böylece hem akademik literatüre hem de endüstriyel uygulamalara yönelik önemli çıkarımlar elde edilmiştir. Bu çıkarımlar neticesinde çalışmanın sektöre sağlayabileceği katkılar şunlardır:



- **Üretim Sürekliliği:** Erken teşhis ile üretim süreçlerinde olası duraksamalar önlenebilir.
- **Maliyet Verimliliği:** Planlı bakım süreçlerinin optimize edilmesiyle bakım maliyetleri düşürülür.
- **Teknolojik Gelişim:** Transfer öğrenme modellerinin endüstriyel uygulamalarda benimsenmesiyle dijital dönüşüm hızlandırılır.

Önemli Noktalar (Highlights):

- Transfer öğrenme yaklaşımları kullanılarak %99.5 üzerinde doğrulukla kırık rotor çubuklarının erken teşhisi gerçekleştirildi.
- Yük ve arıza koşulları altında transfer öğrenme modellerinin performansları detaylı şekilde değerlendirilerek, aynı veri seti üzerinde yapılan çalışmalara oranla daha iyi bir performans elde edildi.
- Çalışma, endüstriyel motor arıza teşhisinde transfer öğrenme uygulamalarının etkinliğini vurgulayan önemli bir referans oluşturdu.

3. MATERYAL VE METHOD (MATERIALS AND METHODS)

3.1. Veri Seti (Dataset)

Araştırmamızda kullandığımız veri seti, genellikle herkese açık olarak bulunabilen bir kırık rotor çubuğuna ait verileri içermektedir. Üç fazlı indüksiyon motorları üzerinde yapılan denemeler sırasında toplanan elektriksel ve mekanik sinyaller bu veri setinin bir parçasıdır. İndüksiyon motorunun ekseninde farklı mekanik yükler ve motor rotorundaki çeşitli kırık çubuk kusur dereceleri test edilmiştir. Ayrıca kusursuz bir rotorun verileri de mevcuttur. Çalışmada kullanılan asenkron motorun özellikleri şu şekildedir: 3 fazlı, 1 beygir gücünde (hp), 220/380V, 4 kutuplu ve nominal hızı 1785 devir/dakikadır. Veri seti, üç fazlı asenkron motor üzerinde yapılan deneylerden elde edilen elektriksel ve mekanik sinyalleri içermektedir. Veri seti, dört farklı kusur sınıfı ve bir sağlıklı sınıf içermektedir. Veri seti 0.5, 1.0, 1.5, 2.0, 2.5, 3.0, 3.5 ve 4.0 Nm torklarla oluşturulmuştur. Her sağlıklı ve yük koşulu kombinasyonu için veri seti oluşturulması için on deney yapılmıştır. Deneyler, sürücü tarafındaki mekanik titreşim hızları (Vib_acpi) ve yük koşulu kombinasyonu için birinci faz akım sinyali (Ia) için gerçekleştirilmiştir. Titreşim sinyallerinin örnekleme frekansı 7600Hz iken, elektriksel sinyallerin örnekleme frekansı 50kHz olarak belirlenmiştir [17].

3.2. Transfer Öğrenme (Transfer Learning)

3.2.1. EfficientNet

EfficientNetB7, EfficientNetV2L, EfficientNetV2M ve EfficientNetV2S modelleri, Google tarafından geliştirilen, derin öğrenme alanında önemli bir yer edinen modellerdir ve özellikle bilgisayarlı görüde kullanılmaktadır. Bu modeller, EfficientNet ailesinin en büyük ve karmaşık olanlarıdır ve hesaplama gücü açısından optimize edilmiş mimariye sahiptir. Araştırmacılar, modelin derinlik, genişlik ve çözünürlük gibi faktörleri dengelerken bir ölçek katsayısını dikkate almışlardır. EfficientNet ailesi, büyük ölçekli görevlerde yüksek performans sergilerken, aynı zamanda hesaplama kaynaklarını ve bellek kullanımını minimize etme yeteneğine sahiptir. Bu özellikleri sayesinde, geniş bir uygulama yelpazesinde mobil cihazlardan bulut sunucularına kadar kullanılabilir [18 ve 19].

3.2.2. InceptionResNetv2

InceptionResNetV2 derin öğrenme modeli Google aracılığı ile geliştirilmiştir ve bilgisayarlı görüş alanında kullanılmak üzere



tasarlanmıştır. Inception ve ResNet'in özelliklerini birleştiren bu model, karmaşık özelliklerin çıkarılması için Inception bloklarını kullanırken, aynı zamanda derin ağlarda oluşabilecek gradyan kaybını önlemek için ResNet'in bağlantılarını kullanır. InceptionResNetV2, genellikle yüksek doğruluk sağlayan karmaşık görsel tanıma görevlerinde tercih edilir ve görüntü sınıflandırma, nesne tanıma ve yüz tanıma gibi alanlarda kullanılır [20].

3.3. Performans Metrikleri (Performance Metrics)

Derin öğrenme performans metrikleri, derin öğrenme modellerinin sınıflandırma veya regresyon gibi görevlerdeki performansını ölçmek için kullanılan temel ölçütlerdir. Doğruluk (accuracy), modelin doğru tahmin ettiği örneklerin toplam örnekler içindeki oranını ifade eder. Hassasiyet (precision), belirli bir sınıf olarak tahmin edilen örneklerin gerçekte bu sınıfa ait olanların oranını ölçerken, duyarlılık (recall) gerçek pozitiflerin doğru bir şekilde tahmin edilme oranını ifade eder. F1 skoru (F1 score), hassasiyet ve duyarlılığın harmonik ortalamasıdır ve dengeli bir performans ölçüsüdür. ROC eğrisi ve ROC AUC değeri (Receiver Operating Characteristic Area Under Curve), sınıflandırıcının doğruluğunu değerlendiren bir diğer önemli metriktir. Bu metrikler, derin öğrenme modellerinin performansını çeşitli açılardan değerlendirmek için kullanılır ve modelin doğruluğu, güvenilirliği ve genel performansını anlamak için önemlidir. Bu çalışmada yöntemlerin sınıflandırma performanslarını değerlendirmek için; accuracy, precision, recall, F1 score ve ROC AUC metrikleri kullanılmıştır.

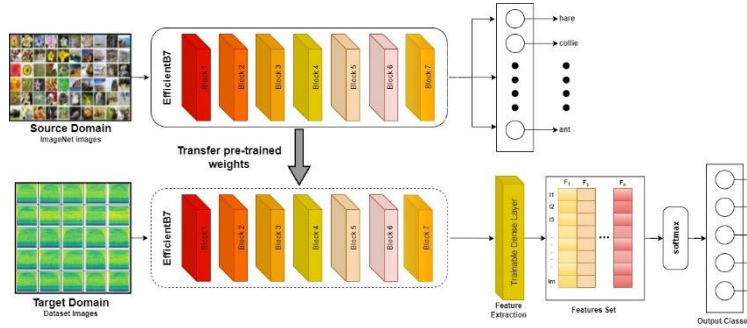
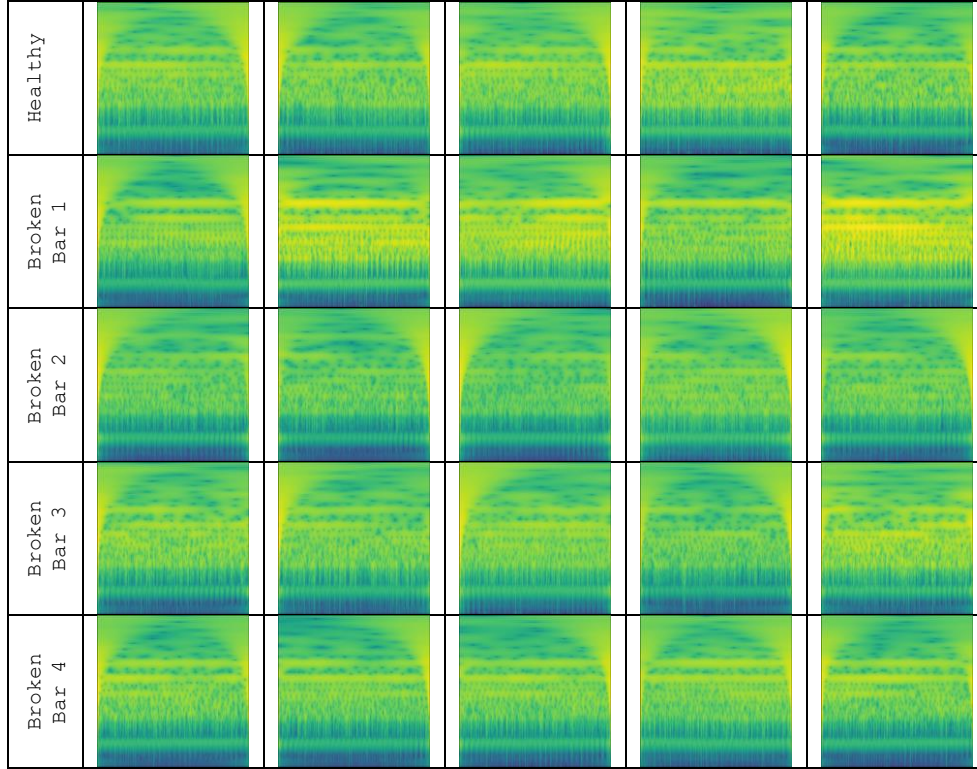
4. DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

Deneysel çalışmaların yürütülmesi esnasında, 64 GB RAM'e sahip Intel Xeon E5-2630 v3 işlemcili bir bilgisayar kullanılmıştır. Ayrıca derin öğrenme uygulamaları için 45 GB RAM'li bir NVIDIA RTX A5000 GPU kullanılmıştır. Veri setinden dataların okunması ve görüntülerin oluşturulması sürecinde kodlamalar MATLAB ile gerçekleştirilmiştir. Transfer öğrenme modellerinin uygulanması ve sonuçlarının alınması sürecinde Python programlama dili ve kütüphanelerinden faydalanılmıştır.

Görüntüler veri setinde yer alan Vib_acpi titreşim sinyali ile oluşturulmuştur. Vib_acpi titreşim sinyallerin uzunluğu 18 saniyedir ve her sinyal zarfı 11-15 zaman aralığında, 1 saniye uzunluğunda örtüşmeyen bir pencere kullanılmıştır. Böylece Vib_acpi sinyali için Tablo 1. de gösterilmekte olan ve 5 farklı gruptan oluşan toplam 2000 adet zaman-frekans gösterimi oluşturulmuş ve deneysel çalışmalarda kullanılmıştır. Görüntüler oluşturulurken Dişli ve arkadaşlarının deneysel çalışmalarında yer alan işlem adımları örnek alınmış ve adım adım uygulanmıştır [21].

Çalışmamızda ağırlıklı olarak EfficientNet transfer öğrenme modelleri kullanılmıştır. Kullanılan modelin çalışma hattı EfficientB7 modeli baz alınarak Şekil 1'de gösterilmektedir. Diğer karşılaştırmalı modeller ise bu çatı üzerine inşa edilmiştir.

Tablo 1. Vib_acpi sinyallerinin 0.5 Nm yük altında tüm sınıflar için zaman-frekans gösterimi
 (Table 1. Time-frequency representation of Vib_acpi signals for all classes under 0.5 Nm Load)



Şekil 1. Transfer öğrenme modelleri hattının gösterimi
 (Figure 1. Representation of the transfer learning models pipeline)

Çalışmamızda EfficientNetB7, EfficientNetV2L, EfficientNetV2M, EfficientNetV2S ve InceptionResNetV2 modellemeleri üzerinde performans karşılaştırmaları gerçekleştirilmiştir. Bu bağlamda geliştirilen her bir model için kullanılan hiper parametreler Tablo 2’de gösterilmiştir.

Tablo 2. Geliştirilen model için kullanılan hiper parametreler
 (Table 2. Hyperparameters used for the developed model)

Layer (type)	Output Shape	Param
input 1 (InputLayer)	[(None, 224, 224, 3)]	0
lambda (Lambda)	(None, 224, 224, 3)	0
efficientnetb7 (Functional)	(None, None, None, 2560)	64097687
global average pooling2d (GlobalAveragePooling2D)	(None, 2560)	0
dropout (Dropout)	(None, 2560)	0
dense (Dense)	(None, 5)	12805

Transfer öğrenme yöntemleri genellikle daha az epoch ile çalışır çünkü önceden eğitilmiş modellerin öğrendiği genel özellikler ve temsiller, yeni görevde hızlı bir şekilde kullanılabilir. Bu, önceden eğitilmiş ağırlıkların yeni görev için başlangıç ağırlıkları olarak kullanıldığında, modelin daha hızlı bir şekilde uyum sağlamasına olanak tanır. Ayrıca transfer öğrenme genellikle az miktarda etiketlenmiş veri ile başarılı olabilir, çünkü önceden eğitilmiş modelin temel özellikleri yeni görevde daha az veri ile öğrenilmesine olanak tanır. Bununla birlikte, ideal epoch sayısı, önceden eğitilmiş modelin uygunluğuna, yeni görevin karmaşıklığına ve kullanılan veri miktarına bağlı olarak değişebilir [7].

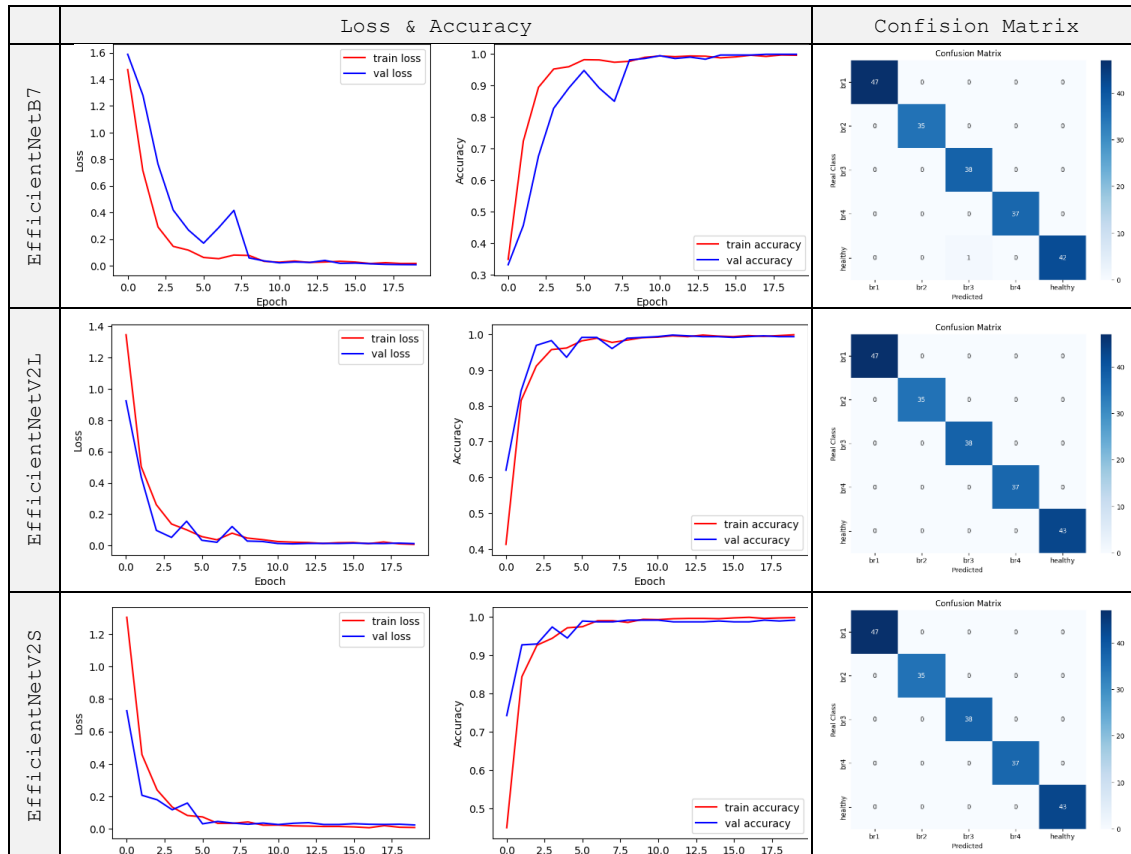
4. BULGULAR (FINDINGS)

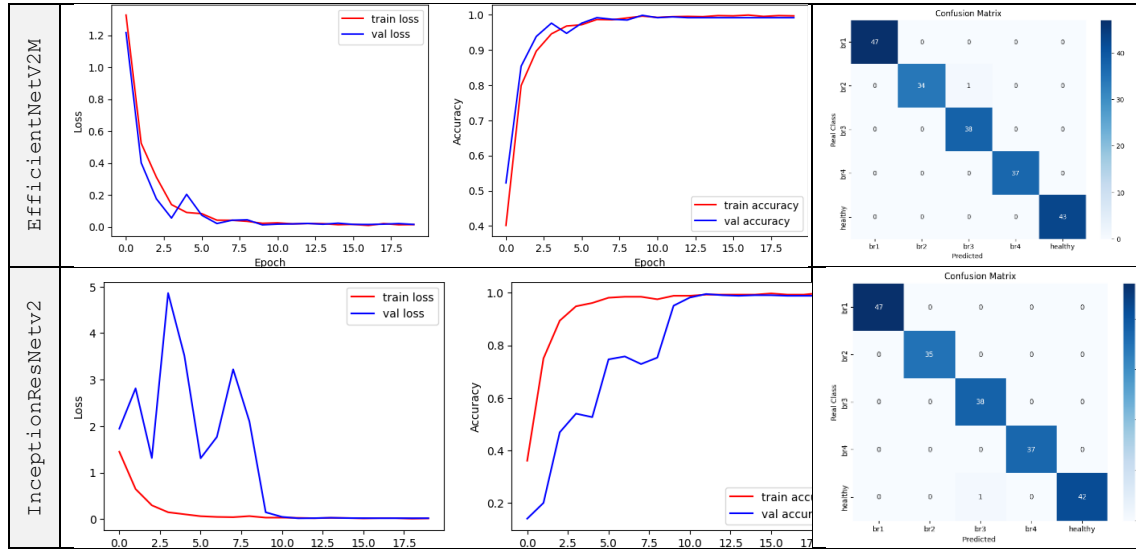
Çalışmamızda modellerin eğitilmesi için farklı epoch sayıları ile çalışılmıştır ve en ideal öğrenme için 20 epoch seçilmiştir. Tüm modeller için alınan sonuçlar %99 üzerinde doğruluk ile Tablo 3’de listelenmiştir.

Tablo 3. Transfer öğrenme modellerinin performans sonuçları
 (Table 3. Performance results of transfer learning models)

Model	Accuracy	precision	recall	F1 score	ROC AUC
EfficientNetV2L	1	1	1	1	1
EfficientNetV2S	1	1	1	1	1
EfficientNetB7	%99.87	0.998	0.992	0.990	0.998
EfficientNetV2M	%99.65	0.997	0.995	0.991	0.995
InceptionResNetv2	%99.58	0.993	0.997	0.995	0.997

Tablo 4. Transfer öğrenme modellerinin loss, accuracy ve confussion matrix sonuçları
 (Table 4. Loss, accuracy, and confusion matrix results of transfer learning models)





Tablo 4'de görüldüğü üzere EfficientNetB7 ve InceptionResNetv2 modelleri için br3 haricindeki tüm sınıflar doğru bir şekilde sınıflandırılmıştır. Yalnızca healthy sınıfında yer alması gereken 1 örnek br3 olarak sınıflandırılmıştır. EfficientNetV2M modelinde ise br2 sınıfında yer alan 1 örneklem, br3 sınıfında tahmin edilmiştir. EfficientNetV2S ve EfficientNetV2L modellemelerinde ise hatalı bir tahminde bulunulmamıştır.

Tablo 5. Transfer öğrenme modelleri performans karşılaştırması
(Table 5. Performance comparison of transfer learning models)

	Model	Epoch	Doğruluk Oranı
1.	EfficientNetV2M	7.	%99.11
2.	EfficientNetV2S	9.	%99.11
3.	EfficientNetB7	11.	%99.33
4.	EfficientNetV2L	12.	%99.78
5.	InceptionResNetv2	12.	%99.56

Tablo 5'de görüldüğü üzere %99 üzerindeki doğruluk oranına yaklaşımda en iyi performans EfficientNetV2M modeli ile gerçekleştirilmiştir. Tüm modellerde yer alan doğruluk oranları 20. epoch sonuna kadar istikrarlıydı ve ani bir düşüş yaşanmamıştır. InceptionResNetv2 modeli öğrenmesinde kısa süreli dengesizlik meydana gelmesine rağmen 12. epoch sonunda stabil bir şekilde %99.56 oranında öğrenmesini tamamlamıştır.

Elde edilen bu sonuçlar, transfer öğrenme yaklaşımlarının asenkron motor arıza teşhisindeki üstün performansını açıkça ortaya koymaktadır. Literatürde yer alan diğer çalışmalarla karşılaştırıldığında, bu yöntemlerin doğruluk ve kesinlik açısından mevcut yaklaşımlara kıyasla daha iyi sonuçlar verdiği görülmektedir. Örneğin; Aydın ve ark., tarafından gerçekleştirilen çalışmada MobileNetV2 modeli kullanılarak %97.2 doğruluk ve kesinlik oranları elde edilmiştir [22]. Çalışmamızda kullanılan EfficientNetV2L ve EfficientNetV2S modelleri, %99.5'in üzerinde doğruluk sağlayarak bu oranı önemli ölçüde aşmıştır. Benzer şekilde, Misra ve ark., tarafından yapılan çalışmada STFT tabanlı girişler ve VGG16, InceptionNet gibi modellerle %97.67 doğruluk oranına ulaşılmıştır [23]. Ancak çalışmamızda yer alan EfficientNetB7 modeli %99.87 doğruluk oranıyla bu çalışmayı geride bırakmıştır. Bu sonuçlar, EfficientNet modellerinin transfer öğrenme tabanlı sınıflandırma görevlerinde yüksek performans sunduğunu ve literatürdeki diğer çalışmalara göre üstünlük sağladığını göstermektedir. Fırat Dişli ve ark., tarafından yapılan çalışmada ise SVM, KNN ve DT gibi geleneksel



yöntemler kullanılarak %93.9 doğruluk ve kesinlik oranlarına ulaşılmıştır [24]. Bu oranlar, transfer öğrenme modellerinin karmaşık veri yapısını daha iyi yakalayabildiğini ve bu nedenle daha yüksek başarı sağladığını açıkça göstermektedir. Ayrıca Misra ve ark., çalışmasında %99 kesinlik oranı rapor edilmiş olsa da, çalışmamızda kullanılan EfficientNet modellerinin tüm metriklerde daha üstün performans sunduğu gözlemlenmiştir.

5. SONUÇ VE ÖNERİLER (CONCLUSION AND RECOMMENDATIONS)

Asenkron motorlarında arıza teşhisi, işletmelerin verimliliği, güvenliği ve maliyetlerini etkileyen kritik bir faktördür. Erken arıza tespiti, üretim süreçlerinin kesintisiz devam etmesini sağlar, maliyetli onarımların önüne geçer ve enerji verimliliğini artırır. Ayrıca işyeri güvenliği sağlar, motorların ömrünü uzatır ve çevresel etkileri azaltır. Bu nedenle, elektrik motorlarında arıza teşhisi süreçleri etkin bir şekilde yürütülmelidir. Transfer öğrenme yöntemleri, elektrik motorlarında arıza teşhisi süreçlerinin geliştirilmesinde önemli bir rol oynayabilir. Bu yöntemler, önceden eğitilmiş derin öğrenme modellerinden elde edilen bilgiyi yeni bir arıza teşhisi görevine aktararak, sınırlı veriye ve etiketlenmiş örneklere sahip olduğumuz durumlarda bile etkili sonuçlar elde etmemizi sağlar.

Bu çalışmada, transfer öğrenme yöntemlerinin asenkron motorlarda kırık rotor çubuklarının erken teşhisi üzerindeki etkisi incelenmiştir. Kullanılan EfficientNetV2L, EfficientNetV2S ve EfficientNetB7 modelleri, literatürdeki diğer yöntemlere kıyasla %99.5'in üzerinde doğruluk oranları ile üstün performans sergilemiştir. Tablo 5'te gösterildiği üzere, EfficientNetV2L modeli %99.78 doğruluk oranıyla en yüksek performansı göstermiştir. Bunun yanı sıra, Şekil 1'de görülen transfer öğrenme model mimarileri, kullanılan modellerin başarısında etkili olan optimizasyon yapısını detaylandırmaktadır.

Bu çalışma transfer öğrenme tabanlı modellerin sınırlı veri setleriyle bile yüksek performans sunduğunu ve endüstriyel motor arıza teşhisinde uygulanabilir bir çözüm sunduğunu göstermektedir. Bunun yanı sıra, Tablo 3'te sunulan performans metrikleri (doğruluk, kesinlik, geri çağırma, F1 skoru), transfer öğrenme modellerinin yüksek doğruluk ve güvenilirlik sunduğunu ortaya koymaktadır. Bunun yanı sıra Tablo 4'de, EfficientNetV2L ve EfficientNetV2S modelleri, hatasız sınıflandırma yaparak dikkat çekmiştir.

Çalışmamız, Tablo 5'de belirtilen literatür çalışmaları ile karşılaştırılarak, Fırat Dişli ve ark., tarafından geliştirilen geleneksel yöntemlerin (%93.9 doğruluk) ötesine geçmiş, Misra ve ark., tarafından kullanılan STFT tabanlı modellerin (%97.67 doğruluk) sonuçlarını aşmıştır. Bu durum, transfer öğrenme tabanlı modellerin, karmaşık veri ilişkilerini daha iyi yakalayıp endüstriyel uygulamalarda önemli bir potansiyele sahip olduğunu göstermektedir.

Gelecekte, titreşim ve akım sinyalleri birleştirilerek çok modelli girişler tasarlanabilir ve farklı endüstriyel uygulamalara yönelik genel modeller geliştirilebilir. Ayrıca transfer öğrenme yaklaşımının gerçek zamanlı uygulamalarda entegrasyonu, üretim süreçlerinde daha etkin çözümler sunabilir.

NOT (NOTICE)

Bu çalışma, Özgür Aydın tarafından Erhan Akın'ın akademik danışmanlığında yürütülen "Sanal Sensör ve Dijital İkiz Yöntemleri Kullanılarak Gerçek Zamanlı Arıza Teşhisi" başlıklı Doktora Tezinden türetilmiştir.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Yazarlar çıkar çatışması bildirmemişlerdir.



FİNANSAL AÇIKLAMA (FINANCIAL DISCLOSURE)

Yazarlar bu çalışma için herhangi bir mali destek almadığını beyan etmiştir.

ETİK STANDARTLAR BEYANI (DECLARATION OF ETHICAL STANDARDS)

Makalenin yazarları bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel izin gerektirmediğini beyan eder.

KAYNAKLAR (REFERENCES)

- [1] Hughes, A. and Drury, B., (2019). *Electric motors and drives: fundamentals, types and applications*. Newnes.
- [2] Nandi, S., Toliyat, H.A., and Li, X., (2005). Condition monitoring and fault diagnosis of electrical motors—A review. *IEEE transactions on energy conversion*, 20(4):719-729.
- [3] Mohan, N., Undeland, T.M., and Robbins, W.P., (2003). *Power electronics: converters, applications, and design*. John wiley and sons.
- [4] Jain, P.H. and Bhosle, S.P., (2021). A review on vibration signal analysis techniques used for detection of rolling element bearing defects. *SSRG Int. J. Mech. Eng*, 8:14-29.
- [5] Gangsar, P. and Tiwari, R., (2018). Multifault diagnosis of induction motor at intermediate operating conditions using wavelet packet transform and support vector machine. *Journal of Dynamic Systems, Measurement, and Control*, 140(8):081014.
- [6] Rawat, W. and Wang, Z., (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, 29(9):2352-2449.
- [7] Pan, S.J., and Yang, Q., (2009). A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10):1345-1359.
- [8] Howard, J. and Ruder, S., (2018). Universal language model fine-tuning for text classification. *arXiv preprint arXiv:1801.06146*.
- [9] Aytar, Y. and Zisserman, A., (2011, November). Tabula rasa: Model transfer for object category detection. In 2011 international conference on computer vision (pp:2252-2259). IEEE.
- [10] Li, X. and Zhang, W., (2020). Deep learning-based partial domain adaptation method on intelligent machinery fault diagnostics. *IEEE Transactions on Industrial Electronics*, 68(5):4351-4361.
- [11] Tong, Z., Li, W., Zhang, B., Jiang, F., and Zhou, G., (2018). Bearing fault diagnosis under variable working conditions based on domain adaptation using feature transfer learning. *IEEE access*, 6:76187-76197.
- [12] Razavi-Far, R., Farajzadeh-Zanjani, M., Zare, S., Saif, M., and Zarei, J., (2017, April). One-class classifiers for detecting faults in induction motors. In 2017 IEEE 30th Canadian Conference on Electrical and Computer Engineering (CCECE) (pp:1-5). IEEE.
- [13] Jain, S., Singhanian, U., Tripathy, B., Nasr, E.A., Aboudaif, M.K., and Kamrani, A.K., (2021). Deep learning-based transfer learning for classification of skin cancer. *Sensors*, 21(23):8142.
- [14] Fan, J., Lee, J., and Lee, Y., (2021). A transfer learning architecture based on a support vector machine for histopathology image classification. *Applied Sciences*, 11(14):6380.



- [15] Shaha, M. and Pawar, M., (2018, March). Transfer learning for image classification. In 2018 second international conference on electronics, communication and aerospace technology (ICECA) (pp:656-660). IEEE.
- [16] Misra, S., Kumar, S., Sayyad, S., Bongale, A., Jadhav, P., Kotecha, K., ... and Gabralla, L.A., (2022). Fault detection in induction motor using time domain and spectral imaging-based transfer learning approach on vibration data. *Sensors*, 22(21):8210.
- [17] Treml, A.E., Flauzino, R.A., Suetake, M., Maciejewski, N.R., and Afonso, N., (2020). Experimental database for detecting and diagnosing rotor broken bar in a three-phase induction motor. *IEEE DataPort*.
- [18] Tan, M. and Le, Q., (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning (pp:6105-6114). PMLR.
- [19] Tan, M. and Le, Q., (2021, July). Efficientnetv2: Smaller models and faster training. In International conference on machine learning (pp:10096-10106). PMLR.
- [20] Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A., (2017, February). Inception-v4, inception-resnet and the impact of residual connections on learning. In Proceedings of the AAAI conference on artificial intelligence, 31:1.
- [21] Dişli, F., Gedikpınar, M., and Sengur, A., (2023). Deep transfer learning-based broken rotor fault diagnosis for Induction Motors. *Turkish Journal of Science and Technology*, 18(1):275-290.
- [22] Aydın, I. and Akin, E., (2024, July). Multi-sensory Fault Diagnosis of Broken Rotor Bars Using Transfer Learning. In International Conference on Intelligent and Fuzzy Systems (pp:349-356). Cham: Springer Nature Switzerland.
- [23] Misra, S., Kumar, S., Sayyad, S., Bongale, A., Jadhav, P., Kotecha, K., ... and Gabralla, L.A., (2022). Fault detection in induction motor using time domain and spectral imaging-based transfer learning approach on vibration data. *Sensors*, 22(21):8210.
- [24] Dişli, F., Gedikpınar, M., and Sengur, A., (2023). Deep transfer learning-based broken rotor fault diagnosis for Induction Motors. *Turkish Journal of Science and Technology*, 18(1):275-290.