



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.2025.20.1.1A0493	
ORCID ID	0000-0001-8130-277X	0000-0001-6476-9255
Corresponding Author	Özgür Aydın	

ASENKRON MOTORLARDA KIRIK ROTOR ÇUBUĞU ARIZA TEŞHİSİ İÇİN ÇOKLU SİNYAL FÜZYONU: SANAL SENSÖR TABANLI TOPLULUK ÖĞRENME YAKLAŞIMI

Öz

Bu çalışma asenkron motorların arıza teşhisinde sanal sensör tabanlı ensemble learning yaklaşımının etkinliğini araştırmaktadır. Çalışmada özellikle kırık rotor çubuğu arızasının tespiti üzerine odaklanılmıştır. Akım (Ia, Ib, Ic) ve titreşim (Vib_acpe, Vib_acpi) sinyallerinden Fourier Dönüşümü (FFT) ve bant gücü analizi ile anlamlı özellikler çıkarılmıştır. Elde edilen özellikler, RNN, GRU ve LSTM gibi derin öğrenme modelleriyle bireysel olarak değerlendirilmiş ve ardından daha güçlü bir sınıflandırma performansı elde etmek amacıyla ensemble learning yaklaşımı uygulanmıştır. Sonuçlar, ensemble modelin %94.44 doğruluk ve %95.25 kesinlik oranı ile bireysel modelleri geride bıraktığını göstermektedir. Bu çalışma aynı veri setini kullanan literatürdeki diğer çalışmalara kıyasla önemli bir üstünlük sağlamaktadır. Literatürde, genellikle yalnızca tek bir akım (Ia) veya tek bir titreşim (Vib_acpi) sinyali ile sınıflandırma yapılırken, bu çalışmada çoklu akım ve titreşim sinyalleri birlikte kullanılarak daha kapsamlı bir veri temsili sağlanmıştır. Bu strateji yanlış pozitif ve yanlış negatif oranlarını düşürerek daha kararlı bir sınıflandırma performansı elde edilmesini sağlamıştır. Ayrıca ensemble yapısının, bireysel RNN, GRU ve LSTM modellerine göre daha stabil ve genellenebilir bir sonuç verdiği gözlemlenmiştir.

Anahtar Kelimeler: Asenkron Motor Arıza Teşhisi, Sanal Sensör, Rotor Çubuğu Arızası, Topluluk Öğrenmesi, Çoklu Model Sınıflandırma

MULTI-SIGNAL FUSION FOR FAULT DIAGNOSIS OF BROKEN ROTOR BARS IN INDUCTION MOTORS: A VIRTUAL SENSOR-BASED ENSEMBLE LEARNING APPROACH

ABSTRACT

This study investigates the effectiveness of a virtual sensor-based ensemble learning approach for fault diagnosis in asynchronous motors. The study specifically focuses on the detection of broken rotor bar faults. Significant features were extracted from current (Ia, Ib, Ic) and vibration (Vib_acpe, Vib_acpi) signals using Fourier Transform (FFT) and band power analysis. The extracted features were individually evaluated using deep learning models such as RNN, GRU, and LSTM, and then the ensemble learning approach was applied to achieve stronger classification performance. The results demonstrate that the ensemble model outperforms individual models with an accuracy of 94.44% and a precision of 95.25%. This study provides a significant advantage compared to other studies in the literature that use the same dataset. In the literature, classification is typically performed using only a single current (Ia) or a single vibration (Vib_acpi) signal. However, in this study, all current and vibration signals were used together to achieve a more comprehensive data representation. This strategy enabled a more robust classification performance by reducing false positive and false negative rates. Additionally, it was observed that the ensemble structure provides a more stable and generalizable result compared to individual RNN, GRU, and LSTM models.

Keywords: Asynchronous Motor Fault Diagnosis, Virtual Sensor, Rotor Bar Fault, Ensemble Learning, Multi-Model Classification

How to Cite:

Aydın, Ö. ve Akın, E., (2025). Asenkron motorlarda kırık rotor çubuğu arıza teşhisi için çoklu sinyal füzyonu: sanal sensör tabanlı topluluk öğrenme yaklaşımı, 20(1):1-20, DOI: 10.12739/NWSA.2025.20.1.1A0493.


1. GİRİŞ (INTRODUCTION)

Günümüz endüstriyel üretim sistemlerinde, kesintisiz üretim süreçlerinin sürdürülmesi ve maliyetlerin kontrol altında tutulması, işletmelerin rekabet gücünü belirleyen temel faktörler arasındadır. Bu hedeflere ulaşmak, yalnızca üretim kapasitesini artırmakla değil, aynı zamanda sistem bileşenlerinin performansının sürekli izlenmesi ve arızaların meydana gelmeden öngörülmesiyle mümkündür. Özellikle karmaşık otomasyon sistemlerinin temel unsurlarından biri olan asenkron motorlar, üretim süreçlerinin sürekliliği ve güvenilirliği açısından kritik bir öneme sahiptir. Bu motorların performansındaki herhangi bir bozulma, tüm üretim hattını etkileyerek ciddi kesintilere ve maliyet artışlarına neden olabilir. Bu nedenle, asenkron motorlarda arıza teşhisinin hızlı, doğru ve proaktif bir yaklaşımla gerçekleştirilmesi, plansız duruşların önlenmesi ve genel sistem verimliliğinin artırılması açısından büyük bir gerekliliktir [1, 2 ve 3].

Asenkron motor arızaları, elektriksel ve mekaniksel olmak üzere iki ana gruba ayrılır. Elektriksel arızalar arasında stator sargı arızaları, dengesiz voltaj ve rotor sargı arızaları; mekaniksel arızalar arasında ise kırık rotor çubuğu, hava boşluğu düzensizlikleri, mil arızaları ve rulman arızaları yer alır. Bu arızalar motorun verimliliğini düşürerek enerji kayıplarına, aşırı ısınmaya ve dengesizliklere yol açar. Her bir arıza türünün doğru teşhisi, motorların güvenilir ve uzun ömürlü çalışması açısından hayati bir rol oynar. Literatürde, bu arızaların tespiti için geliştirilen yöntemlerin başarılı sonuçlar verdiği ve endüstriyel süreçlere önemli katkılar sağladığı görülmektedir. Arıza tespiti ve izleme amacıyla kullanılan yöntemler arasında titreşim analizi, akustik emisyon, motor akım imzası analizi (MCSA), kızılötesi termografi ve elektromanyetik alan izleme teknikleri dikkat çekmektedir. Bu yöntemler, farklı arıza türlerini belirli avantajlarla tespit ederek endüstriyel otomasyon sistemlerinin daha güvenilir ve verimli bir şekilde işletilmesine katkıda bulunur [4 ve 5]. Artan endüstriyel gereksinimler ve karmaşık arıza senaryoları, geleneksel arıza teşhis yöntemlerinin ötesine geçilmesini zorunlu kılmıştır. Geleneksel yöntemler, genellikle akım ve titreşim sinyallerinin analizi üzerine odaklanırken, yenilikçi veri odaklı yaklaşımlar, yapay zeka ve makine öğrenmesi tabanlı tekniklerle birleşerek arıza teşhis süreçlerinde önemli ilerlemeler sağlamıştır [6]. Özellikle makine öğrenmesi, derin öğrenme ve sanal sensör teknolojileri, arıza teşhisinde geleneksel yöntemlerin sınırlamalarını aşarak daha hassas ve güvenilir çözümler sunmaktadır. Proaktif yaklaşımlar, arızaların meydana gelmeden öngörülmesine olanak tanıyarak, plansız duruşları ve bakım maliyetlerini azaltmakta; bu durum, asenkron motorlar gibi kritik bileşenlerde üretim sürekliliği ve sistem güvenilirliği açısından stratejik bir önem taşımaktadır [7, 8 ve 9]. Bu doğrultuda, arızaların erken tespiti ve bakım faaliyetlerinin etkin şekilde planlanabilmesi için geleneksel reaktif bakım yaklaşımlarının ötesine geçilerek, kestirimci bakım stratejilerinin benimsenmesi gerekmektedir. Bu bağlamda, derin öğrenme ve makine öğrenmesi modellerinin yanı sıra, Sanal Sensör (Virtual Sensors) gibi yenilikçi yaklaşımlar, arıza teşhis süreçlerinde hız, hassasiyet ve verimlilik sağlamaktadır [3, 10, 11, 12, 13 ve 14].


Sanal sensörler, literatürde sıklıkla soft sensörler olarak da adlandırılmaktadır ve son yıllarda, süreç endüstrisinde bu sensörlerin kullanımı giderek yaygınlaşmıştır [15 ve 16]. Soft sensörler, birincil sensörlere destek sağlama, olası arızaları işaret etme ve donanım tabanlı sensörlerin yerine geçme potansiyeline sahip şekilde tasarlanmaktadır [17]. Bu sebeple sanal sensörler, stator akımı, titreşim ve akustik gibi ortak sinyalleri ölçen donanım sensörlerinin çıktılarından yararlanarak motor arızalarının tespit edilmesinde etkili bir şekilde

kullanılabilmektedir. Öte yandan sanal sensörler, fiziksel sensörlerin maliyet, bakım ve kurulum zorluklarını azaltmak amacıyla geliştirilmiş, fiziksel olarak ölçülmesi zor veya imkânsız olan büyüklükleri tahmin eden yazılım tabanlı araçlardır [10, 13 ve 14]. Bu sensörler, ilgilenilen miktarı tahmin etmek için mevcut diğer ölçümleri veya verileri kullanarak fiziksel bir sensörün davranışını taklit ederler. Özellikle gerçek zamanlı izleme ve kontrolün gerekli olduğu, fiziksel sensörlerin kullanımının pratik olmadığı veya maliyetli olduğu durumlarda sanal sensörler tercih edilmektedir. Şekil 1'de sanal sensörlerin (SS) çeşitli takımı yıldızları gösterilmektedir: (a) yalnızca fiziksel sensörlere (FS) dayalı bir sanal sensör, (b) başka bir sanal sensöre dayalı bir sanal sensör, (c) fiziksel ve sanal sensörlerin her ikisine de dayalı bir sanal sensör.



Şekil 1. Farklı türdeki sanal sensör takımı yıldızları [12]
(Figure 1. Different types of virtual sensor constellations)

Sanal sensör kavramını açıkça açıklamak ve ana özelliklerini tanımlamak için, Şekil 2'de yapının bileşenleri ve aralarındaki bağlantılar gösterilmiştir.



Şekil 2. Sanal sensörlerin örnek yapısı [12]
(Figure 2. Sample structure of virtual sensors)

Bu yeni yaklaşım ile yapılan çalışmalardan biri, Ahmed ve ark., tarafından gerçekleştirilmiştir. Çalışma otomotiv motorlarında manifold basıncı ve krank mili sensörlerinin arıza teşhisinde kullanılmak üzere ikinci dereceden kayma modu gözlemcileri (SOSM) tabanlı sanal sensörler geliştirmiştir. Çalışmada manifold basıncı ve motorun açısal hızını izleyen sanal sensörler, sensör arızalarının hızlı bir şekilde tespit edilmesini ve sensör yedekliliğini sağlamıştır. Sanal sensörlerin, gerçek sensörlerle %10'dan düşük hata oranıyla uyum gösterdiği ve arızaların 1 saniyeden kısa sürede doğru şekilde tespit edildiği belirtilmiştir. Bu yöntem, ölçülemeyen parametrelerin başarılı bir şekilde tahmin edilmesini sağlamış ve arızaların etkili bir şekilde tespiti için artıklık analizi sunmuştur. Özellikle manifold basıncı sensöründeki diyafram arızası gibi kritik durumlarda güvenilirlik göstermiştir. Düşük maliyetli ve OBD-II uyumlu olan bu yaklaşım, gerçek zamanlı uygulamalar için uygun bir çözüm sunmaktadır [10]. Gao ve ark., soğutma sistemlerindeki sensör arızalarını tespit etmek için maksimum bilgi katsayısı (MIC) ile desteklenen bir LSTM tabanlı yöntem geliştirmiştir. Bu yöntem, MIC değerlerine göre sensör gruplarını

sınıflandırarak yüksek korelasyonlu sensörlerden sanal sensörler oluşturmayı hedeflemiştir. %0 yanlış alarm oranı ve %98.75 arıza tespit doğruluğu ile yöntemin başarılı bir performans sergilediği gösterilmiştir. LSTM tabanlı sanal sensörlerin, doğrusal regresyon (LR) ve yapay sinir ağı (ANN) modellerine kıyasla daha düşük hata oranına ve daha yüksek doğruluğa sahip olduğu belirlenmiştir. Ayrıca, aynı fiziksel sensör için farklı girişlerle oluşturulan sanal sensörlerin birlikte kullanımı, arıza tespitinde güvenilirliği artırmış ve enerji tüketiminin optimize edilmesine katkı sağlamıştır [11].

Liu ve ark., HVAC sistemlerindeki hava işleme ünitelerinde (AHU) sensör ve bileşen arızalarını tespit etmek ve kendi kendine kalibrasyon sağlamak amacıyla Bayes çıkarımı ve sanal sensörleri birleştiren bir yöntem geliştirmiştir. Çalışmada, sanal sensörler yardımıyla soğutma bobinindeki kirlenme seviyesi gibi ölçülmesi zor parametreler tahmin edilmiş, Bayes çıkarımı ve Markov Zinciri Monte Carlo (MCMC) algoritması kullanılarak arıza seviyeleri değerlendirilmiştir. Yöntem, az veri ile %98'e varan doğruluk oranı sağlamış ve farklı arıza senaryolarında arıza tespiti ve kalibrasyonda etkinliğini kanıtlamıştır. Bu yaklaşım, HVAC sistemlerinde enerji verimliliğini artırmak ve bakım maliyetlerini azaltmak için etkili bir çözüm sunmaktadır [18]. Hosseinpoor ve ark., kırık rotor çubuğu arızasını tespit etmek için ensemble öğrenme tabanlı bir sanal sensör yöntemi geliştirmiştir. Yöntem veri toplama, sinyal işleme ve karar verme olmak üzere üç modülden oluşmaktadır. Piezoelektrik sensörlerle kaydedilen titreşim sinyalleri, wavelet paket dönüşümü (WPT) ile işlenmiş ve kurtosis, skewness, RMS gibi özellikler çıkarılmıştır. Karar verme modülünde Dynamic Weighted Majority (DWM) algoritması kullanılarak veri akışındaki değişikliklere uyum sağlanmıştır.

Entropi tabanlı drift algılama mekanizması, veri dağılımındaki değişiklikleri ve yeni sınıf oluşumlarını tespit etmiş, gerektiğinde model güncellenmiştir. Çalışma, kırık rotor çubuğu ve pompa kavitasyonu arızalarını dört farklı deneyde %95'in üzerinde doğrulukla tespit ederek, indüksiyon motor arızalarının erken tespiti ve bakım süreçlerinin optimize edilmesinde etkili bir çözüm sunmuştur [3]. Zhang ve ark., soğutma sistemlerinde arıza teşhisi için bir ensemble öğrenme yöntemi geliştirmiştir. K-en yakın komşu (KNN), destek vektör makineleri (SVM), karar ağacı (DT), rastgele orman (RF) ve lojistik regresyon (LR) modelleri çoğunluk oylamasıyla birleştirilerek teşhis modeli oluşturulmuştur. ASHRAE verileri üzerinde test edilen yöntem, yedi tipik arıza için %99.58 genel doğruluk sağlamıştır. Farklı model kombinasyonlarının değerlendirildiği çalışmada, KNN, DT ve RF modellerinden oluşan bir alt model kombinasyonu %99.41 doğruluk elde ederken, tüm modellerin kullanıldığı yöntemden %96 daha düşük işlem süresiyle etkili bir performans göstermiştir. Parametre optimizasyonu yapılmaksızın uygulanan bu yöntem, bireysel modellerden daha yüksek teşhis doğruluğu ve daha düşük işlem süresi sunarak soğutma sistemlerinde arıza teşhisi için zaman ve maliyet avantajı sağlamıştır [19]. Bu çalışmalar fiziksel sensörlere olan bağımlılığı azaltarak veri analitiği, makine öğrenmesi ve derin öğrenme gibi modern teknolojilerle entegre, yenilikçi çözümler sunmakta ve sanayi uygulamalarında arıza teşhisi süreçlerini daha güvenilir, hızlı ve maliyet etkin hale getirmektedir.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Bu çalışmada ensemble learning yaklaşımı kullanılarak asenkron motorun akım ve titreşim sensörlerinden toplanan verilerle arıza sınıflandırması gerçekleştirilmiştir. Literatürdeki benzer çalışmalardan farklı olarak; giriş verisi yalnızca tek bir akım sinyali, tek bir titreşim sinyali veya bu iki sinyalin birleşimi yerine, tüm akım (Ia, Ib, Ic) ve tüm titreşim (Vib_acpe, Vib_acpi) sinyallerinin bir

arada kullanıldığı daha kapsamlı bir veri seti oluşturulmuştur. Bu yaklaşım sensör verilerinin çeşitliliğini artırarak modelin arıza tespit yeteneğini güçlendirmiştir. Böylece beş farklı arıza sınıfı için yüksek doğruluklu bir sınıflandırma sağlanmıştır.

Asenkron motorlar sanayi devriminin temel taşı niteliğinde olup, enerji tasarrufu ve üretim sürekliliği gibi kritik hedefler doğrultusunda endüstriyel süreçlerde yaygın olarak kullanılmaktadır. Bu motorlarda meydana gelebilecek arızaların erken teşhisi, işletmeler için ciddi maliyet avantajları ve operasyonel verimlilik sağlamaktadır. Çalışmanın önemi üç ana başlık altında incelenebilir:

Çalışmanın Hedefi: Bu çalışmanın temel amacı kırık rotor çubuğu arızalarının hızlı ve doğru bir şekilde tespit edilmesini sağlayarak, üretim hatlarında plansız duruşların önüne geçmektir. Geliştirilen yöntem, yalnızca bir sinyal türüne odaklanan geleneksel yaklaşımların aksine, akım (Ia, Ib, Ic) ve titreşim (Vib_acpe, Vib_acpi) sinyallerinden anlamlı özellikler çıkarıp bu özellikleri bir araya getirerek daha kapsamlı bir sınıflandırma sistemi sunmaktadır. Bu yaklaşım, bireysel modellerin sınırlamalarını aşarak, hata oranlarını minimize eden yenilikçi bir çözüm sağlamayı hedeflemektedir.

Çalışmanın Sektöre Katkıları: Bu çalışma, özellikle endüstriyel üretim sektöründe aşağıdaki alanlarda önemli katkılar sunmaktadır:

- ❖ **Verimlilik ve Süreklilik:** Sanal sensörlerin kullanımıyla, fiziksel sensörlere bağlı sistemlerde meydana gelen arıza risklerini en aza indirerek üretim süreçlerinde kesintisiz bir akış sağlanır.
- ❖ **Maliyetlerin Azaltılması:** Fiziksel sensörlerin yüksek maliyetli bakım ve kurulum gereksinimleri yerine, sanal sensörlerin düşük maliyetli ve kolay uygulanabilir yapısı sayesinde, endüstriyel işletmeler için ekonomik fayda sağlanır.
- ❖ **Proaktif Bakım Stratejileri:** Geleneksel reaktif bakım yöntemlerinin ötesine geçerek, arızaların meydana gelmeden önce tespit edilmesine olanak tanır. Bu da bakım süreçlerinin daha etkili bir şekilde planlanmasını mümkün kılar.
- ❖ **Kararlılık ve Genel Kullanılabilirlik:** Geliştirilen ensemble model, farklı endüstriyel ortamlarda ve motor tiplerinde uygulanabilir bir çözüm sunarak geniş bir kullanım alanına hitap etmektedir.

Çalışmanın Yenilikçi Yaklaşımı: Bu çalışma literatürdeki benzer çalışmalardan farklı olarak iki temel yenilikçi özelliğe sahiptir:

- ❖ **Çoklu Sinyal Füzyonu:** Akım ve titreşim verilerinin bir arada kullanılması, kırık rotor çubuğu arızalarının tespitinde daha kapsamlı ve güvenilir bir veri temsili sunmaktadır. Bu yöntem, yanlış pozitif ve negatif oranlarını azaltarak sınıflandırma performansını artırmıştır.
- ❖ **Ensemble Öğrenme:** Derin öğrenme modelleri (RNN, GRU, LSTM) bir araya getirilerek her bir modelin güçlü yönleri harmanlanmıştır. Bu yaklaşımla, modelin genellenebilirliği artırılmış ve farklı endüstriyel uygulamalar için kararlı bir çözüm üretilmiştir.

Önemli Noktalar (Highlights):

- **Endüstriyel Yenilik:** Akım ve titreşim verilerini birleştirerek, sanal sensör tabanlı arıza teşhisi için yenilikçi bir yöntem sunulmuştur.
- **Yüksek Performans:** Ensemble öğrenme yöntemiyle %94.44 doğruluk ve %95.25 kesinlik oranı elde edilmiştir.
- **Maliyet ve Verimlilik Avantajı:** Sanal sensörler, fiziksel sensörlere kıyasla daha düşük maliyetle daha geniş bir veri kapsamı sunarak endüstriyel süreçlerde sürdürülebilir çözümler sağlar.

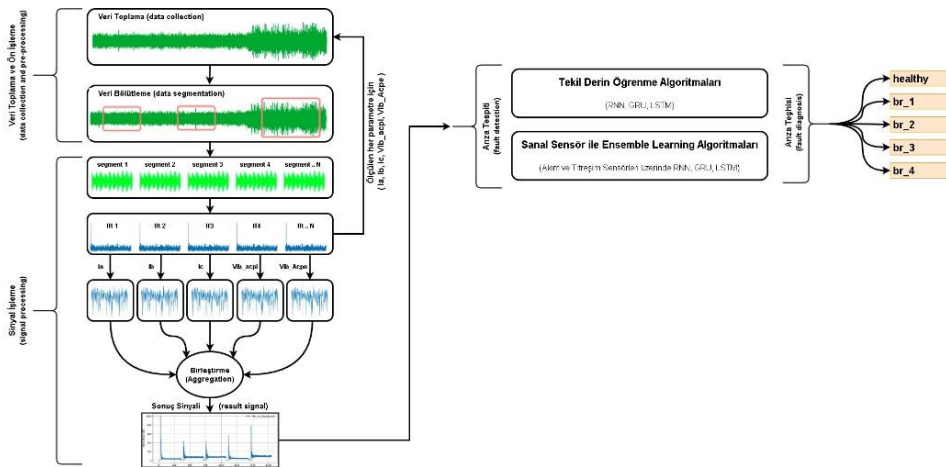
3. MATERYAL VE METHOD (MATERIALS AND METHODS)

3.1. Veri Toplama (Data Collection)

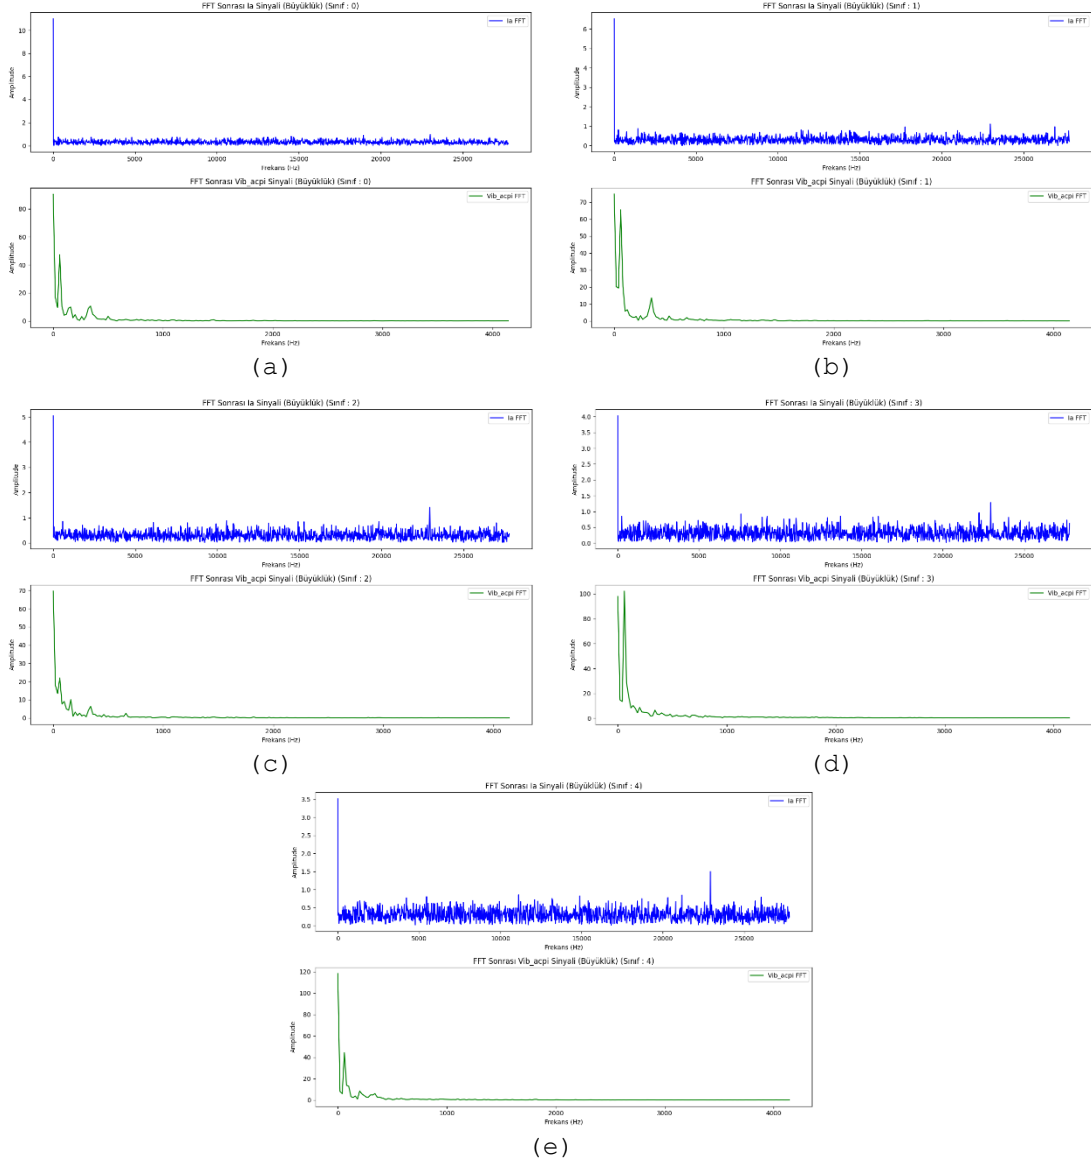
Kırık rotor çubuğu arızasının teşhisine yönelik analizlerde, herkese açık olarak erişilebilen bir veri seti kullanılmıştır [20]. Söz konusu veri seti, üç fazlı asenkron motorlardan toplanan elektriksel ve mekanik sinyalleri içermektedir. Veri toplama sürecinde, rotor çubuklarındaki arıza dereceleri farklı seviyelerde olacak şekilde motor çeşitli mekanik yükler altında test edilmiştir. Veri setinde, arızalı rotor durumlarının yanı sıra sağlıklı rotor durumuna ilişkin veriler de yer almaktadır. Kullanılan asenkron motor, 3 fazlı, 1 beygir gücünde (hp), 220/380V çalışma gerilimine sahip, 4 kutuplu ve 1785 dev/dak (rpm) nominal hıza sahip bir motordur. Deneysel veri seti, dört farklı arıza sınıfı (BR1-BR4) ve bir sağlıklı (Healthy) durum sınıfı olmak üzere toplam beş sınıfı kapsamaktadır. Veriler, 0.5 Nm ile 4.0 Nm arasında değişen tork değerlerinde farklı yük koşulları altında toplanmıştır. Her bir veri grubunun oluşturulması için on ayrı deney gerçekleştirilmiştir. Bu çalışmada analiz için kullanılan temel sinyal, motorun faz akım sinyalleri (I_a , I_b , I_c) ve titreşim sinyalleri (Vib_{acpe} , Vib_{acpi}) olmuştur. Elektriksel sinyallerin örnekleme frekansı 50kHz, mekanik titreşim sinyallerinin örnekleme frekansı ise 7600Hz olarak belirlenmiştir. Bu şekilde toplanan veriler, kırık rotor çubuğu arızalarının teşhisine yönelik sınıflandırma modellerinin eğitilmesi ve değerlendirilmesi amacıyla kullanılmıştır.

3.2. Özellik Çıkarımı (Feature Extraction)

Özellik çıkarımı için ham veriler (akım ve titreşim sinyalleri) önce veri bölütleme sürecinden geçirilmiş, peşinden sinyallerin frekans bileşenlerini ortaya çıkarmak için Fourier Dönüşümü (FFT) uygulanmıştır. Bu aşamaların ardından, belirli frekans bantlarındaki enerji yoğunluklarını analiz etmek amacıyla bant gücü analizi gerçekleştirilmiş ve bu sayede sınıflandırma sürecinde kullanılmak üzere anlamlı ve kompakt özellikler çıkarılmıştır. Özellik çıkarımı için uygulanan süreç Şekil 3'de gösterilmektedir. Bu işlem verilerin boyutunu azaltırken bilgi kaybını en aza indirerek sınıflandırma performansını artırmayı hedeflemiştir. Şekil 4'te, her bir çıkış sınıfına ait akım ve titreşim verilerinin Fourier Dönüşümü (FFT) sonrasında elde edilen frekans spektrumları sunulmaktadır. Bu görselleştirme, farklı sınıflar arasındaki frekans bileşenlerinin dağılımını ve arıza belirtilerinin frekans alanındaki yansımalarını açıkça göstermektedir.



Şekil 3. Özellik çıkarımı iş akışı
(Figure 3. Feature extraction workflow)

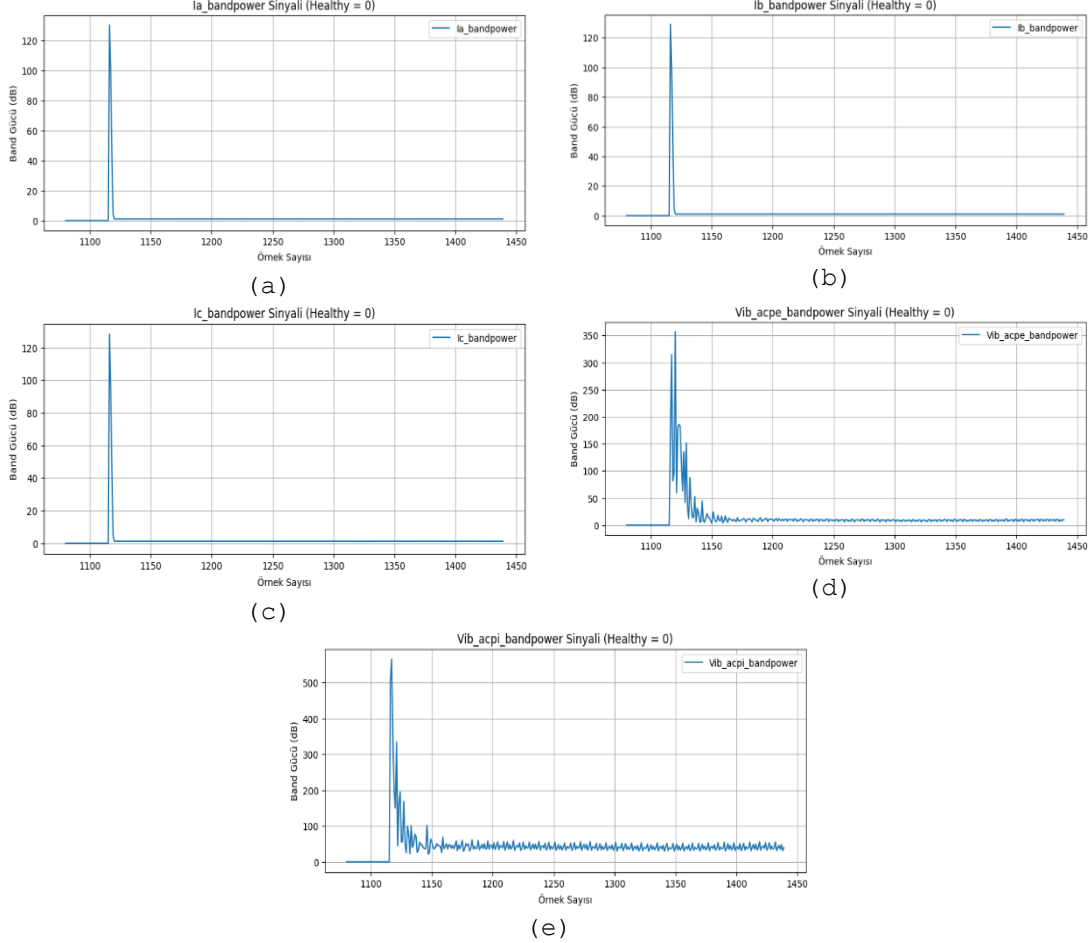


Şekil 4. Tüm sınıflar için Ia ve Vib_acpi sinyallerinin FFT dönüşümü
a)Sağlıklı b)Bir kırık çubuk c)İki kırık çubuk d)Üç kırık çubuk e)Dört kırık çubuk

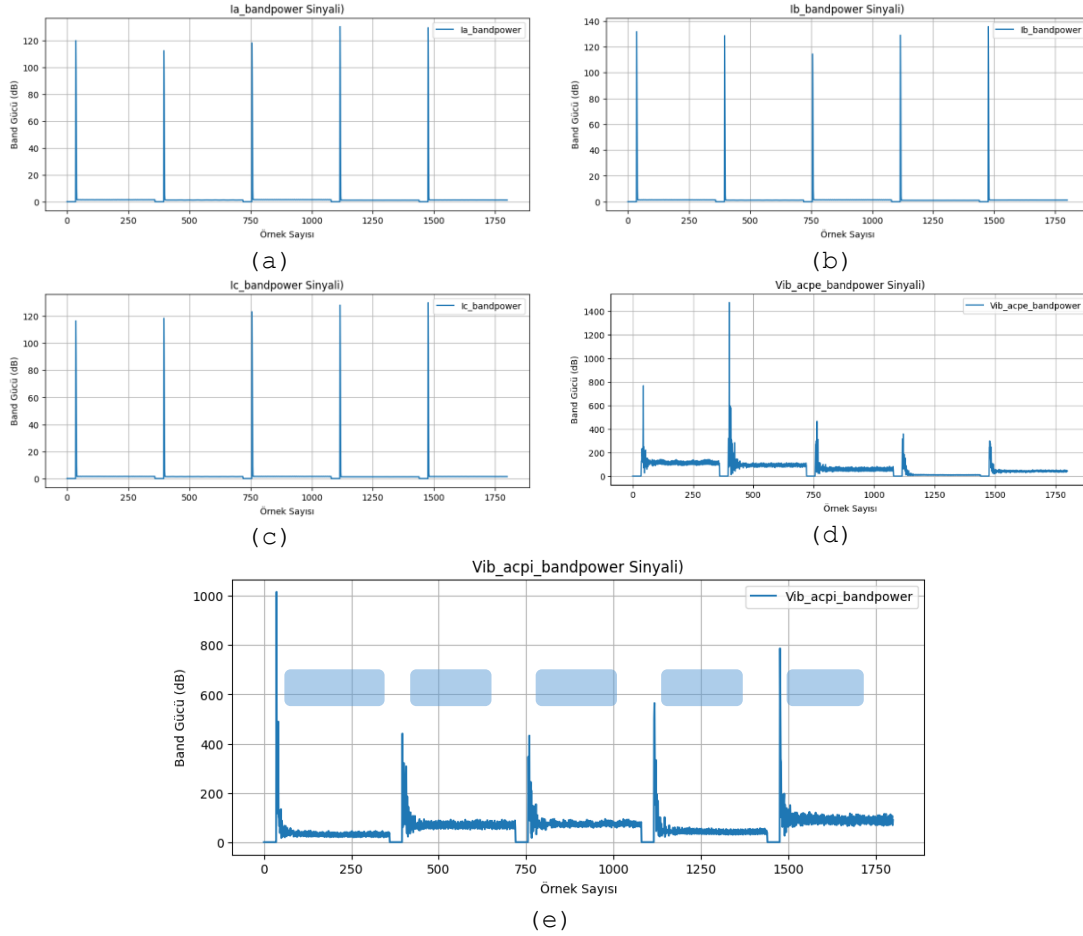
(Figure 4. FFT transformation of Ia and Vib_acpi signals for all classes a)Healthy b)One broken bar c)Two broken bars d)Three broken bars e)Four broken bars)

FFT işlemi sırasında, zaman serisi verileri belirli segmentlere bölünerek her bir segment üzerinde ayrı ayrı dönüşüm gerçekleştirilmiştir. Bu işlem, her bir zaman diliminde frekans bileşenlerinin daha net analiz edilmesini sağlamış ve verilerin homojen şekilde işlenmesine olanak tanımıştır. Segment boyutları, veri setinin örnekleme hızı ve analiz gereksinimleri dikkate alınarak belirlenmiştir. Her segment için FFT sonrası, spektral güç yoğunluğu (Power Spectral Density, PSD) hesaplanmış ve elde edilen spektrum, belirli frekans bantlarına ayrılmıştır. Bu frekans bantlarındaki enerji miktarı hesaplanarak, her segmentin yalnızca ilgili frekans aralıklarındaki enerjisi özetlenmiştir. Bu süreç, sinyalin boyutunu küçültürken gürültüyü azaltmış ve anlamlı özelliklerin çıkarılmasını sağlamıştır. Özellikle arıza durumlarında karakteristik frekanslar, belirli bantlarda

yüksek enerji yoğunluğu olarak öne çıkmıştır. Şekil 5'de, sağlıklı sınıfa ait akım ve titreşim verilerinin band gücü dönüşümleri, Şekil 6'da ise her bir sınıf etiketi için birleştirilmiş band gücü dönüşümleri görselleştirilmiştir. Bu görselleştirmeler, arıza tespitinde belirleyici olan frekans bantlarını ve her bir sınıfın ayırt edici özelliklerini net bir şekilde ortaya koymaktadır. Bu süreç sonunda, sağlıklı bir sınıflandırma için gerekli olan anlamlı ve ayırt edici özellikler elde edilmiştir.



Şekil 5. Sağlıklı çıkış sınıfı için akım ve titreşim sinyallerinin band gücü dönüşümleri a)Ia sinyali b)Ib sinyali c)Ic sinyali d)Vib_acpi sinyali e)Vib_acpe sinyali
(Figure 5. Band power transformations of current and vibration signals for the healthy output class a)Ia signal b)Ib signal c)Ic signal d)Vib_acpi signal e)Vib_acpe signal)




Şekil 6. Tüm çıkış sınıfları için birleştirilmiş band gücü dönüşümleri
a)Ia sinyali b)Ib sinyali c)Ic sinyali d)Vib_acpi sinyali e)Vib_acpe sinyali

(Figure 6. Combined band power transformations for all output classes
a)Ia signal b)Ib signal c)Ic signal d)Vib_acpi signal e)Vib_acpe signal)

3.3. Sınıflandırma Algoritmaları (Classification Algorithms)

3.3.1. Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN)


RNN (Recurrent Neural Network) ardışık verilerle çalışmak üzere tasarlanmış bir derin öğrenme modelidir. Zaman serisi analizi, metin işleme ve sinyal analizi gibi sıralı veri gerektiren uygulamalarda yaygın olarak kullanılmaktadır. RNN'in temel yapısı, her bir zaman adımındaki çıktıyı bir sonraki adıma taşıyarak geçmiş bilgilerin mevcut tahminlerde kullanılmasını sağlar. Bu döngüsel yapı, modelin önceki girişlerle mevcut giriş arasındaki bağımlılığı öğrenmesine olanak tanır. Bu özellik, kısa süreli bağımlılıkları başarılı bir şekilde öğrenmesini sağlar. Ancak uzun süreli bağımlılıklarda gradyan kaybolması veya gradyan patlaması gibi sorunlar yaşanabilir [21 ve 22]. Bu döngüsel yapının işleyişi, Şekil 7'de gösterilmektedir [23].



Şekil 7. Kapılı tekrarlayan RNN hücre mimarisi
(Figure 7. Gated recurrent RNN cell architecture)

3.3.2. Kapılı Tekrarlayan Ünite (Gated Recurrent Unit - GRU)

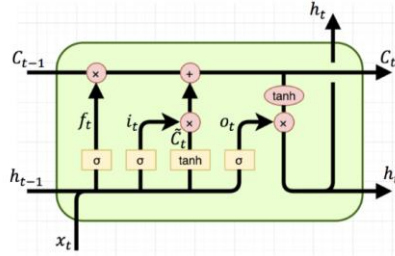
GRU (Gated Recurrent Unit), RNN'in gradyan kaybolması sorununu aşmak için geliştirilmiş bir modeldir. Giriş ve güncelleme kapıları sayesinde bilgi akışını kontrol ederek, uzun vadeli bağımlılıkları daha etkin bir şekilde öğrenir. Daha az parametreye sahip olması, GRU'nun hesaplama maliyetini düşürerek daha hızlı çalışmasını sağlar. Bu tezde, motor verilerindeki uzun vadeli bağımlılıkları izlemek ve arıza tespiti süreçlerinde daha doğru sonuçlar elde etmek amacıyla GRU modeli tercih edilmiştir. Şekil 8'de GRU yapısının genel mimarisi sunulmuştur [23 ve 24].



Şekil 8. Tek bir GRU hücresinin genel mimarisi
(Figure 8. General architecture of a single GRU cell)

3.3.3. Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM)

LSTM, uzun süreli bağımlılıkları öğrenmek için tasarlanmış bir model olup, giriş, unutma ve çıkış kapıları sayesinde hangi bilgilerin saklanacağına, unutulacağına ve kullanılacağına karar verir. Bu yapı sinyal verilerindeki uzun vadeli paternlerin doğru yakalanmasını sağlar ancak daha fazla parametre gerektirdiği için hesaplama maliyeti yüksektir [25, 26 ve 27]. Şekil 9'da LSTM yapısının genel mimarisi gösterilmiştir [23].




Şekil 9. Tek hücreli LSTM mimarisi
(Figure 9. Single-cell LSTM architecture)

3.3.4. Topluluk Öğrenmesi (Ensemble Learning)

Ensemble learning, birden fazla makine öğrenmesi ve derin öğrenme modelinin bir araya getirilerek daha güçlü, genelleştirilebilir ve kararlı bir model oluşturma tekniğidir [28]. Bu yöntem bireysel modellerin sınırlamalarını aşmayı ve tahmin doğruluğunu artırmayı amaçlamaktadır. Farklı algoritmaların güçlü yönlerini birleştiren ensemble modelleri, sınıflandırma, regresyon ve anomali tespiti gibi birçok alanda üstün performans sergilemektedir [29]. Bu makalede ensemble learning yapısının temel kurgusu Şekil 10'da sade bir şekilde görselleştirilmiştir. Özellik çıkarımı ile oluşturulan veri seti, alt veri kümelerine bölünerek her bir alt küme, RNN, LSTM ve GRU gibi derin öğrenme modelleriyle işlenmiştir. Her bir derin öğrenme modelinin ürettiği tahmin, aynı zamanda bir sanal sensör çıktısı olarak kabul edilmiştir. Bu yapı sayesinde, her modelin kendi alt veri kümesi üzerinde

gerçekleştirdiği sınıflandırma işlemlerinin çıktıları birleştirme aşamasına geçmiştir.



Şekil 10. Ensemble Learning yönteminin temel yapısı
(Figure 10. Basic structure of the ensemble learning method)

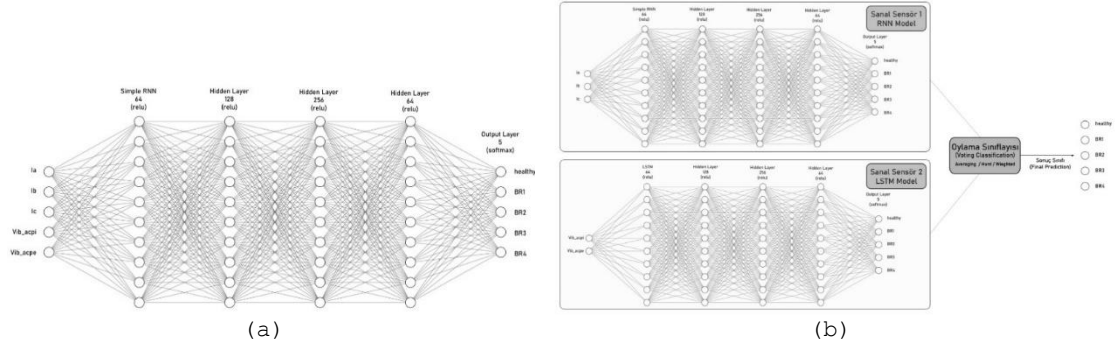
Birleştirme aşamasında, her bir modelin tahmin çıktıları, çoğunluk oylaması (Voting Classifier) yöntemiyle değerlendirilmiş ve nihai sınıf etiketi belirlenmiştir. Bu aşamada, farklı modellerin bağımsız olarak yaptığı tahminlerin ortak bir karara dönüştürülmesi sağlanmıştır. Nihai sınıflandırıcı, "Ensemble Meta Modeli" olarak işlev görmektedir ve tüm modellerin ortak sonucunu yansıtarak daha güçlü, kararlı ve güvenilir bir tahmin sağlamaktadır. Bu yapı, tek bir modelden elde edilebilecek doğruluğun ötesine geçerek, sınıflandırma başarısını artırmayı hedeflemektedir.

4. DENEYSSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

DeneySEL çalışmalar, veri işleme, model eğitimi ve performans değerlendirme süreçlerinin etkin bir şekilde yürütülmesi için yüksek hesaplama gücüne sahip bir donanım ve yazılım altyapısı üzerinde gerçekleştirilmiştir. Bu amaçla, 64 GB RAM'e sahip bir bilgisayar ve derin öğrenme algoritmalarının hızlandırılması için 45 GB VRAM'e sahip NVIDIA RTX A5000 GPU kullanılmıştır. Veri setinin işlenmesi ve modellerin eğitilmesi süreçlerinde MATLAB ve Python programlama dilleri kullanılmış, derin öğrenme algoritmalarının uygulanması için Python kütüphaneleri tercih edilmiştir. Bu altyapı, veri işleme, model eğitimi ve performans değerlendirme işlemlerinin verimli ve hızlı bir şekilde gerçekleştirilmesini sağlamıştır.

Sınıflandırma için model girdileri, akım sinyalleri (I_a, I_b, I_c), titreşim sinyalleri (Vib_{acpi} ve Vib_{acpe}) bilgisinden oluşmakta olup, toplamda beş giriş bileşeninden oluşmaktadır. Çıkış sınıfları ise sağlıklı(healthy) ve kırık rotor çubuğu(1-4) (BR1-BR4) olacak şekilde beş kategoriden oluşmaktadır. Sınıflandırmanın ilk aşaması için **RNN, GRU ve LSTM** tekil derin öğrenme modelleri kullanılmıştır. Model eğitim sürecinde, veri setinin %90'ı eğitim (train) için ayrılırken, kalan %10'luk kısım doğrulama ve test işlemleri için kullanılmıştır. Modellerin tutarlı ve karşılaştırılabilir sonuçlar üretebilmesi amacıyla, her bir modelde **random_state** parametresi 42 olarak sabitlenmiştir. Öğrenme sürecinde optimizasyon işlemleri için yaygın olarak tercih edilen **Adam optimizasyonu** algoritması kullanılmıştır. Her bir derin öğrenme modelinin yeterli bir öğrenme düzeyine ulaşmasını sağlamak için **model eğitimi 50 epoch** boyunca gerçekleştirilmiştir. Bu yapı, modellerin performansının karşılaştırılabilir ve tekrarlanabilir olmasını sağlayarak, sınıflandırma işlemlerinin doğruluğunu artırmıştır. Şekil 11a'da, RNN derin öğrenme modeli için kullanılan yapı ve hiper parametreler için örnek diyagram gösterilmektedir. Bu yapı, GRU ve LSTM

modelleri için de aynen uygulanmıştır. Şekil 11b'de, Ensemble Learning modeli üzerinde akım sinyalleri için RNN ve titreşim sinyalleri için LSTM modellerinin örnek bir uygulaması görselleştirilmiştir. Bu yapı, diğer model kombinasyonları için de benzer şekilde uygulanmıştır. Ensemble Learning yaklaşımının temel farkı, tekil öğrenme modellerinde tüm girişlerin aynı anda modele verilmesine karşın, bu yapıda akım ve titreşim sinyallerinin ayrı ayrı işlenmesidir.



(a)
Tekil derin öğrenme
hiperparametreleri
(Singular Deep Learning
Hyperparameters)

(b)
Ensemble learning hiperparametreleri
(Ensemble Learning Hyperparameters)

Şekil 11. Sınıflandırma modellerinin genel yapısı
(Figure 11. General structure of classification models)

Ensemble Learning modelinde, akım sinyalleri (Ia, Ib, Ic) RNN modeli üzerinden, titreşim sinyalleri (Vib_acpi, Vib_acpe) ise LSTM modeli üzerinden işlenmiştir. Her bir model, kendi veri girişini bağımsız olarak analiz etmiş ve elde edilen ara çıktı, nihai sınıflandırma kararına katkı sağlamıştır. Bu yapı, akım ve titreşim sinyallerinin özgün bilgi katkılarının korunmasını ve daha yüksek bir sınıflandırma doğruluğuna ulaşılmasını hedeflemiştir.

5. BULGULAR (FINDINGS)

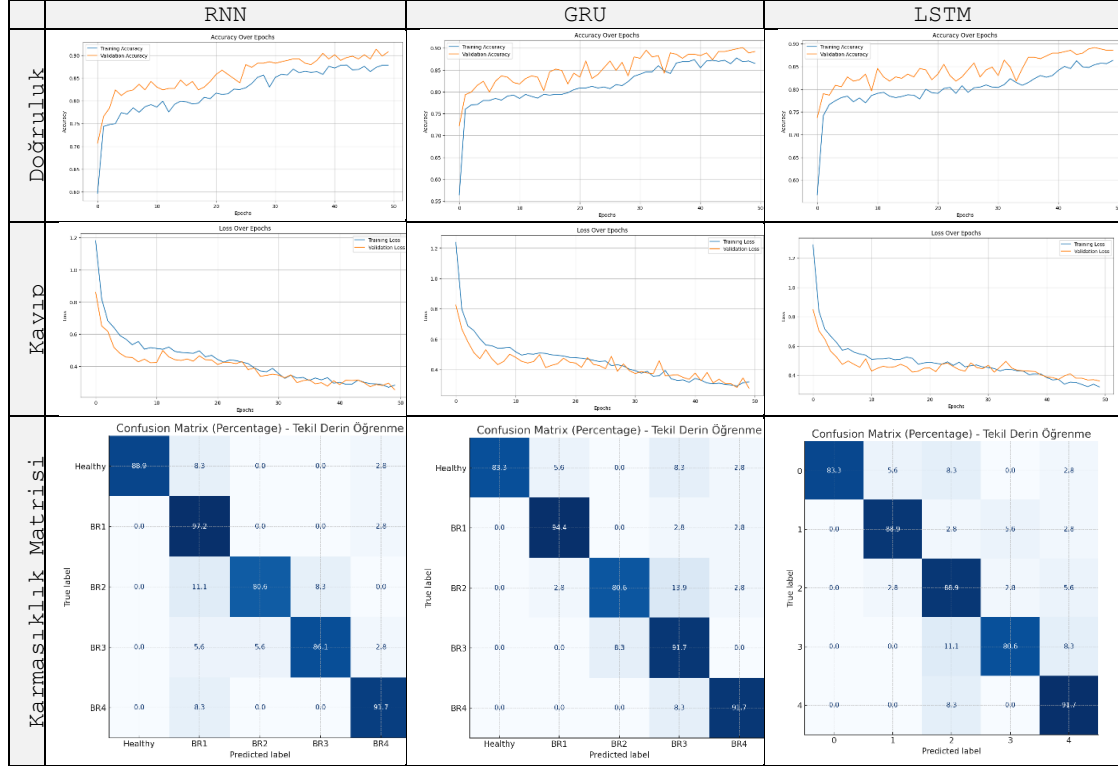
Çalışmanın ilk aşamasında, üç farklı tekil derin öğrenme modeli (RNN, GRU ve LSTM), veri setindeki sınıflandırma problemini farklı açılardan ele alarak motorun sağlıklı veya arızalı durumunu doğru ve güvenilir bir şekilde tahmin etmeyi hedeflemiştir. Modellerin performans sonuçları Tablo 1'de sunulmaktadır.

Tablo 1. Tekil derin öğrenme modellerinin performans sonuçları
(Table 1. Performance results of singular deep learning models)

Model	Accuracy	Precision	Recall	F1-score
RNN	0.8889	0.9017	0.8889	0.8905
GRN	0.8833	0.8950	0.8833	0.8850
LSTM	0.8667	0.8779	0.8667	0.8684

Sonuçlara göre RNN modeli %88.89 doğruluk oranıyla en iyi performansı sergilemiştir. GRU modeli %88.33 doğruluk oranıyla RNN'i yakından takip ederken, LSTM modeli %86.67 doğruluk oranıyla diğer iki modelin gerisinde kalmıştır. Bu durum, RNN'nin sekans verileri üzerindeki öğrenme kabiliyetinin, motorun arıza teşhisinde kullanılan karmaşık sinyal verilerini sınıflandırma açısından daha başarılı olduğunu göstermektedir. Tablo 2'de modellerin doğruluk (accuracy) ve kayıp (loss) grafikleri ile birlikte her bir model için elde edilen karmaşıklık matrisi (confusion matrix) sunulmuştur.

Tablo 2. Tekil derin öğrenme modellerine ait doğruluk ve kayıp grafikleri
(Table 2. Accuracy and loss graphs of singular deep learning models)



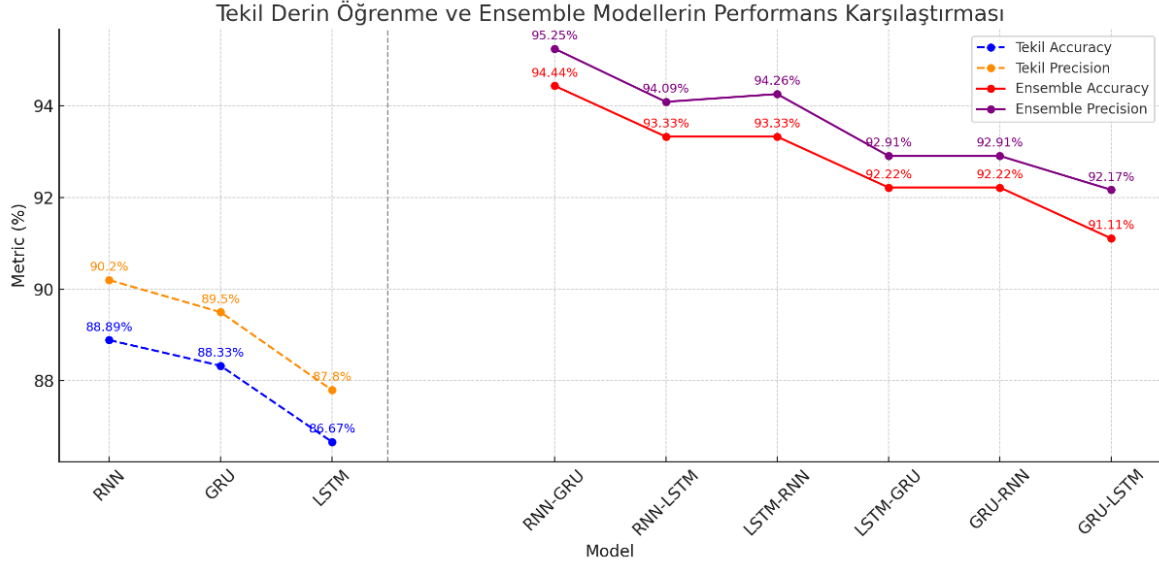
Tablo 2’de sunulan doğruluk (accuracy) ve kayıp (loss) grafikleri, RNN, GRU ve LSTM modellerinin performansını özetlemektedir. Tüm modeller eğitim ve doğrulama verilerinde yüksek doğruluk değerlerine ulaşmış ve kayıp oranları azalarak stabil bir seviyeye ulaşmıştır. Bu sonuçlar, modellerin öğrenme süreçlerinde başarılı olduğunu göstermektedir. Öte yandan sunulan karmaşıklık matrisleri, modellerin sınıflandırma performansını detaylı bir şekilde incelemektedir. RNN modeli, sağlıklı ve arızalı sınıflar arasında yüksek doğru tahmin oranı elde etmiş ancak bazı sınıflarda karışıklıklar gözlemlenmiştir. Bu durum, modelin belirli sınıflarda daha fazla hata yaptığını göstermektedir. GRU modeli, RNN’ye kıyasla daha düşük yanlış sınıflandırma oranı ile öne çıkmış ve özellikle arızalı sınıflarda daha başarılı bir performans sergilemiştir. LSTM modeli ise genel olarak diğer modellere benzer bir doğruluk sergilemiş olmasına rağmen, özellikle bazı küçük sınıflarda GRU’ya kıyasla daha yüksek bir yanlış sınıflandırma oranına sahip olduğu görülmüştür. Bu sonuçlar, modellerin her birinin güçlü ve zayıf yönlerini ortaya koyarak sınıflandırma performanslarının karşılaştırılmasına olanak tanımaktadır.

Çalışmanın ikinci aşamasında, sanal sensörlerin oluşturulması amacıyla Ensemble Learning yaklaşımı geliştirilmiştir. Tablo 3, farklı model kombinasyonları kullanılarak akım ve titreşim verileri üzerinden oluşturulan sanal sensörlerin doğruluk (accuracy) ve kesinlik (precision) performanslarını özetlemektedir. Her bir model kombinasyonu için Sanal Sensör 1 (akım verileri), Sanal Sensör 2 (titreşim verileri) ve bu sensörlerin ensemble model ile birleştirilmesi sonucu elde edilen Accuracy ve Precision değerleri detaylı bir şekilde sunulmuştur. Bu yapı, her bir sensörün ayrı ayrı ve birlikte kullanımının sınıflandırma performansı üzerindeki etkisini analiz etmek için güçlü bir temel sağlamaktadır.

Tablo 3. Sanal sensör için ensemble learning model eşleştirmeleri performans sonuçları
(Table 3. Performance results of ensemble learning model mappings for virtual sensors)

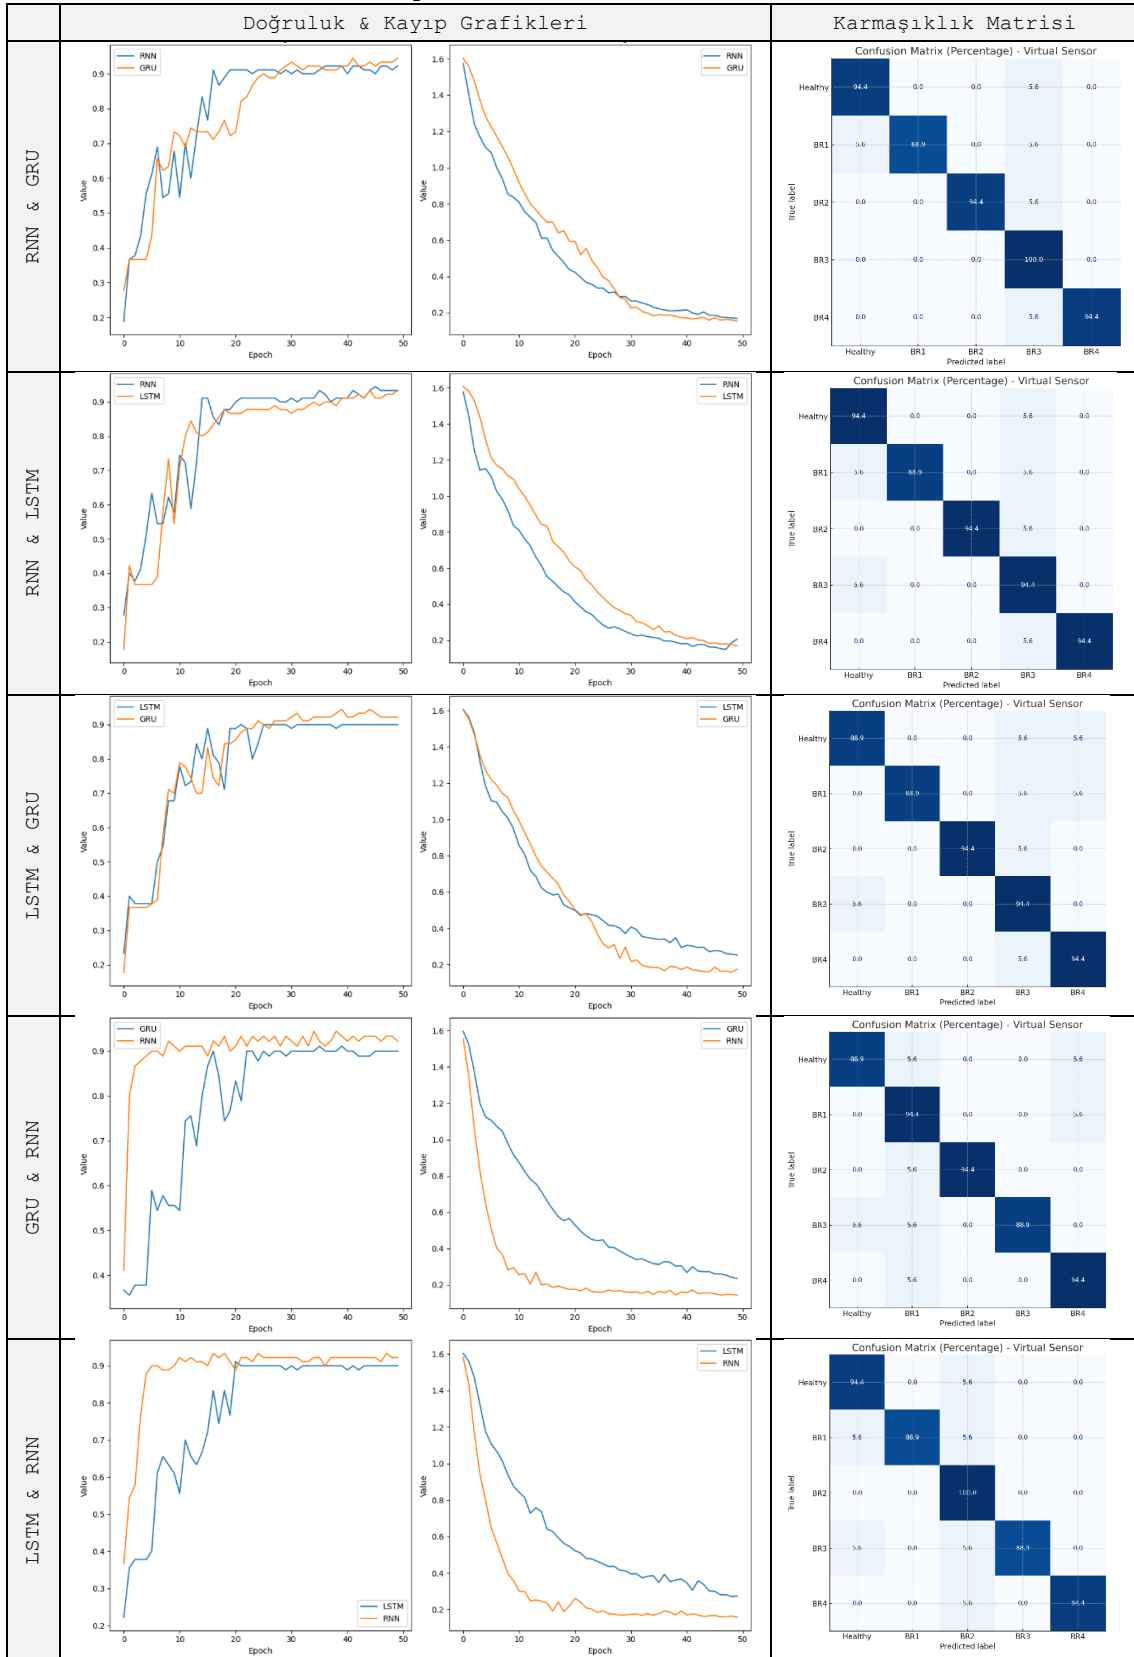
Model 1 (Akım Sinyalleri)	Model 2 (Titreşim Sinyalleri)	Sanal Sensör 1 (Ia, Ib, Ic)		Sanal Sensör 2 (Vib acpi, Vib acpe)		Ensemble Model	
		Accurac y	Precisio n	Accurac y	Precisio n	Accurac y ↓	Precisio n
RNN	GRU	0.9444	0.9525	0.9333	0.9500	0.9444	0.9525
RNN	LSTM	0.9111	0.9186	0.9222	0.9389	0.9333	0.9409
LSTM	RNN	0.9000	0.9101	0.9333	0.9409	0.9333	0.9426
LSTM	GRU	0.9000	0.9162	0.9333	0.9409	0.9222	0.9291
GRU	RNN	0.9000	0.9162	0.9333	0.9434	0.9222	0.9291
GRU	LSTM	0.9000	0.9081	0.9111	0.9322	0.9111	0.9217


Tablo 3 incelendiğinde, RNN ve GRU modellerinin birleştirilmesiyle oluşturulan ensemble modelin, %94.44 doğruluk ve %95.25 kesinlik oranıyla en yüksek performansı sağladığı görülmektedir. Diğer model kombinasyonlarında da ensemble modellerin, genellikle tekil sanal sensörlerin performansını önemli ölçüde artırdığı dikkat çekmiştir. Tablo 4’de Sanal sensör doğruluk/kayıp grafikleri ve karmaşıklık matrisi performans sonuçları gösterilmektedir. Tablo 4’den anlaşılacağı üzere, ensemble yöntemi, akım ve titreşim verilerinin birbirini tamamlayıcı özelliklerini etkili bir şekilde birleştirerek sınıflandırma doğruluğunu ve kesinliğini artırmıştır. Tablo 3’te elde edilen ensemble model sonuçları, sanal sensör yaklaşımı ile elde edilen doğruluk ve kesinlikte anlamlı bir iyileşme sağlamış, daha kararlı ve güvenilir bir sınıflandırma performansı sunmuştur. Şekil 12 bu karşılaştırmayı detaylı bir şekilde göstermektedir.



Şekil 12. Tekil derin öğrenme ve ensemble modellerinin performans sonuçlarının grafiksel karşılaştırması
(Figure 12. Graphical comparison of performance results between singular deep learning and ensemble models)

Tablo 4. Sanal sensör doğruluk/kayıp grafikleri ve karmaşıklık matrisi performans sonuçları
(Table 4. Virtual sensor accuracy/loss graphs and confusion matrix performance results)





Bu çalışmada tüm akım sinyalleri (Ia, Ib, Ic) ve tüm titreşim sinyalleri (Vib_acpe, Vib_acpi) bir arada kullanılarak daha kapsamlı ve zengin bir veri seti oluşturulmuştur. Tek bir akım (Ia) veya tek bir titreşim sinyali (Vib_acpi) yalnızca makinenin bir yönünü temsil eder. Ancak bir arıza, genellikle motorun farklı boyutlarda titreşim ve akım anormallikleri ile kendini gösterir. Örneğin, kırık rotor çubuğu arızası sadece tek bir faz akımında değil, tüm fazlardaki akım ve titreşim sinyallerinde belirgin izler bırakır. Bu nedenle, tüm akım ve titreşim sinyallerini kullanmak, arıza belirtilerini tespit etmek için daha kapsamlı bir ayrıcalık sunar. Tablo 5’de, aynı veri seti kullanılarak sınıflandırma yapılmış diğer literatür çalışmaları incelendiğinde, genellikle tek bir akım sinyali (örneğin, Ia) veya tek bir titreşim sinyali (örneğin, Vib_acpi) veya bu ikisinin birleştirilmesiyle sınıflandırma yapıldığı görülmektedir. Bu yaklaşım, sınıflandırma modellerinde doğruluk oranlarını artırırken, gerçek saha koşullarında karşılaşılabilecek çeşitli durumlara yanıt verme kabiliyetini sınırlamaktadır. Örneğin, yalnızca Ia sinyalinin veya Vib_acpi sinyalinin kullanıldığı çalışmalarda %97.2 ve %97.67 doğruluk oranları elde edilmiştir. Ancak bu sonuçlar, sınırlı veri çeşitliliği nedeniyle, farklı sınıflar arasında yeterli ayırt edicilik sağlayamamaktadır.

Tablo 5. Aynı veriseti ile oluşturulan literatür çalışmalarının model ve performans sonuçları

(Table 5. Model and performance results of literature studies conducted using the same dataset)

Yazar (Yıl)	Kullanılan Sinyaller	Kullanılan Modeller	Giriş Biçimi	Sınıflandırma Türü	Doğruluk (%)	Kesinlik (%)
Dişli ve diğerleri [30]	Ia, Vib_acpi	SVM, KNN, DT	Zaman-Frekans Görüntüleri	5 sınıf (Sağlıklı, kırık rotor çubuğu[1-4])	93.9	93.9
Aydın ve Akın [31]	Ia, Vib_acpi	MobileNetV2	CWT	5 sınıf (Sağlıklı, kırık rotor çubuğu[1-4])	97.2	97.2
Misra ve diğerleri [32]	Vib_acpi	VGG16, InceptionV3, Inception_ResNetV2, MobileNetV2	STFT	5 sınıf (Sağlıklı, kırık rotor çubuğu[1-4])	97.67	99.0
Aydın ve Akın [33]	Ia	Vision Transformer, gMLP, MLP-Mixer, FNet	Zaman-Frekans Görüntüleri	2 sınıf (Sağlıklı, Kusurlu)	100.0	100.0
Dişli ve diğerleri [34]	Ia, Vib_acpi	ResNet18, SVM	Zaman-Frekans Görüntüleri	5 sınıf (Sağlıklı, kırık rotor çubuğu[1-4])	100.0	100.0

Daha ileri düzeyde sınıflandırma modelleriyle yapılan çalışmalarda da, giriş verilerinin çeşitliliği sınırlı kalmıştır. Örneğin, ResNet18 ve SVM tabanlı yaklaşımların kullanıldığı bir çalışmada, akım (Ia) ve titreşim (Vib_acpi) sinyallerinin birleştirilmesiyle %100 doğruluk elde

edilmiştir. Ancak bu sınıflandırmalar da yalnızca iki sinyal türü ile gerçekleştirildiğinden, genelleme kabiliyetleri sınırlıdır. Benzer şekilde, Empirik Mod Ayrışımı (EMD) yönteminin kullanıldığı bir diğer çalışmada, yalnızca Ia ve Vib_acpi sinyallerine dayalı olarak %93.9 doğruluk oranına ulaşılmıştır. Bu çalışmalardaki sınırlı giriş çeşitliliği, modellerin yalnızca belirli koşullarda yüksek performans göstermesini sağlamış, ancak daha karmaşık ve çok yönlü veri setleriyle başa çıkma kapasitesini kısıtlamıştır.

Bu çalışmanın temel farkı ve üstünlüğü, tüm akım sinyalleri (Ia, Ib, Ic) ve tüm titreşim sinyalleri (Vib_acpe, Vib_acpi) bir arada kullanılarak sensör verilerinin çeşitliliğinin artırılmasıdır. Bu yaklaşım, sadece doğruluk oranını değil, aynı zamanda modelin genelleme yeteneğini de güçlendirmiştir. Literatürde tek bir akım veya titreşim sinyali kullanılarak elde edilen %97'nin üzerindeki doğruluk oranları dikkat çekici görünse de, bu sonuçlar genellikle daha az karmaşık veri setleriyle sağlandığından, sınıflandırma yeteneklerinin ayırt edici özellikleri sınırlı kalmaktadır. Bu çalışmada ise, veri setinin karmaşıklığının artırılmasıyla birlikte, %94.44 doğruluk ve %95.25 kesinlik oranı elde edilmiştir. Bu sonuçlar, giriş çeşitliliği nedeniyle modelin sınıflandırma zorluluğunun artmasına rağmen başarının sürdürülebilir olduğunu göstermektedir.

6. SONUÇLAR (CONCLUSIONS)

Bu çalışma asenkron motorların kırık rotor çubuğu arızalarının teşhisinde sanal sensör tabanlı ensemble öğrenme yaklaşımının etkinliğini ortaya koymuştur. Geliştirilen yöntem, akım (Ia, Ib, Ic) ve titreşim (Vib_acpe, Vib_acpi) sinyallerinin birleştirilmesiyle oluşturulan veri setinde, mevcut literatüre kıyasla önemli bir üstünlük sağlamıştır.

DeneySEL sonuçlar ensemble öğrenme modelinin bireysel derin öğrenme modelleri (RNN, GRU ve LSTM) ile karşılaştırıldığında daha yüksek doğruluk (%94.44) ve kesinlik (%95.25) oranları elde ettiğini göstermiştir. Bu bulgular, Tablo 3'te sunulan doğruluk ve kesinlik değerleriyle desteklenmektedir. Ensemble modelin, farklı sinyal türlerinin birbirini tamamlayan özelliklerini birleştirmesi sayesinde, yanlış pozitif ve negatif oranlarının önemli ölçüde azaldığı gözlemlenmiştir. Bu sonuçlar literatürde genellikle yalnızca bir akım veya titreşim sinyaline odaklanan çalışmalardan farklı olarak, daha kapsamlı bir yaklaşımın üstünlüğünü Tablo 5 ile teyit etmektedir.

Çalışmada kullanılan sanal sensör yaklaşımı, sadece fiziksel sensörlerin yerine geçmekle kalmamış, aynı zamanda farklı sinyal türlerinden elde edilen bilgilerin sinerjik bir şekilde kullanılarak teşhis doğruluğunu artırmıştır. Örneğin, sanal sensörlerle elde edilen performans artışı, Şekil 12'de bireysel modellerle karşılaştırmalı olarak açıkça görülmektedir. Ayrıca, çoğunluk oylaması yöntemiyle gerçekleştirilen ensemble öğrenme, sensör verilerinin çeşitliliğini koruyarak daha genellenebilir bir model oluşturmuş ve kırık rotor çubuğu teşhisinde sanal sensörlerin etkili bir şekilde kullanılabileceğini göstermiştir.

Sonuç olarak, sanal sensör tabanlı ensemble öğrenme yaklaşımı, endüstriyel süreçlerde arıza teşhisi ve bakım planlaması alanında yenilikçi ve sürdürülebilir bir çözüm sunmaktadır. Bu yöntem, plansız duruşların önlenmesi ve sistem verimliliğinin artırılması açısından endüstriyel uygulamalara önemli bir değer katmaktadır. Çalışma kapsamında elde edilen bulgular, akım ve titreşim verilerinin bütünleşik kullanımının motor arıza teşhisinde geleneksel yöntemlerin ötesinde daha etkili sonuçlar sağladığını açıkça ortaya koymaktadır.

Gelecek çalışmalarda, farklı arıza türlerinin (örneğin stator sargı hataları ve rulman arızaları) teşhis edilmesi, yöntemin

genellenebilirliğini artırabilir. Fiziksel ve sanal sensörlerin entegre kullanımı ile arıza teşhis performansı daha da iyileştirilebilir. Reel zamanlı uygulamalar ve IoT tabanlı sistemlere entegrasyon, yöntemin endüstriyel süreçlerdeki pratik uygulanabilirliğini artıracaktır. Ayrıca, farklı derin öğrenme modellerinin (örneğin Transformer tabanlı yaklaşımlar) kullanılması ve veri artırma teknikleriyle daha zengin veri setlerinin oluşturulması teşhis başarısını artırabilir. Son olarak, enerji verimliliği odaklı analizler ve proaktif bakım stratejilerinin optimizasyonu, yöntemin sürdürülebilir endüstriyel uygulamalar için daha etkin bir çözüm haline gelmesini sağlayabilir.

NOT (NOTICE)

Bu çalışma, Özgür Aydın tarafından Prof.Dr. 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)

Yazar(lar) çıkar çatışması bildirmemişlerdir.

FİNANSAL AÇIKLAMA (FINANCIAL DISCLOSURE)

Yazar(lar) bu çalışma için herhangi bir mali destek almadığını beyan etmiştir.

ETİK STANDARTLAR BEYANI (DECLARATION OF ETHICAL STANDARDS)

Makalenin yazar(lar)'ı 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] Sen, P.C., (2021). Principles of Electric Machines and Power Electronics, International Adaptation. John Wiley and Sons.
- [3] Hosseinpour, Z., Arefi, M.M., Razavi-Far, R., Mozafari, N., and Hazbavi, S., (2020). Virtual sensors for fault diagnosis: A case of induction motor broken rotor bar. IEEE Sensors Journal, 21(4):5044-5051.
- [4] Yakhni, M.F., Cauet, S., Sakout, A., Assoum, H., Etien, E., Rambault, L., and El-Gohary, M., (2023). Variable speed induction motors' fault detection based on transient motor current signatures analysis: A review. Mechanical Systems and Signal Processing, 184, 109737.
- [5] 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.
- [6] Tariq, M.F., Khan, A.Q., Abid, M., and Mustafa, G., (2018). Data-driven robust fault detection and isolation of three-phase induction motor. IEEE Transactions on Industrial Electronics, 66(6):4707-4715.
- [7] Doğan, Z., (2012). Ayrıklaştırma yöntemleri ve yapay sinir ağı kullanarak asenkron motorlarda arıza teşhisi (Doctoral dissertation, Marmara Üniversitesi (Türkiye)).
- [8] Boldea, I. and Nasar, S.A., (2002). Induction machines: An introduction. In The Induction Machine Handbook (p. 13). CRC Press.
- [9] Siddiqui, K.M., Sahay, K., and Giri, V.K., (2014). Health monitoring and fault diagnosis in induction motor-a review.

- International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, 3(1):6549-6565.
- [10] Ahmed, Q., Bhatti, A.I., and Iqbal, M., (2011). Virtual sensors for automotive engine sensors fault diagnosis in second-order sliding modes. *IEEE Sensors Journal*, 11(9):1832-1840.
- [11] Gao, L., Li, D., Li, D., Yao, L., Liang, L., and Gao, Y., (2019). A novel chiller sensors fault diagnosis method based on virtual sensors. *Sensors*, 19(13):3013.
- [12] Martin, D., Kühl, N., and Satzger, G., (2021). Virtual sensors. *Business and Information Systems Engineering*, 63:315-323.
- [13] Madria, S., Kumar, V., and Dalvi, R., (2013). Sensor cloud: A cloud of virtual sensors. *IEEE software*, 31(2):70-77.
- [14] Tegen, A., Davidsson, P., Mihailesc, R.C., and Persson, J.A., (2019). Collaborative sensing with interactive learning using dynamic intelligent virtual sensors. *Sensors*, 19(3):477.
- [15] Serpas, M., Chu, Y., and Hahn, J., (2013). Fault detection approach for systems involving soft sensors. *Journal of Loss Prevention in the Process Industries*, 26(3):443-452.
- [16] Mohammadi, A., Zarghami, R., Lefebvre, D., Golshan, S., and Mostoufi, N., (2019). Soft sensor design and fault detection using Bayesian network and probabilistic principal component analysis. *Journal of Advanced Manufacturing and Processing*, 1(4):e10027.
- [17] Kadlec, P., Gabrys, B., and Strandt, S., (2009). Data-driven soft sensors in the process industry. *Computers and chemical engineering*, 33(4):795-814.
- [18] Liu, Z., Huang, Z., Wang, J., Yue, C., and Yoon, S., (2021). A novel fault diagnosis and self-calibration method for air-handling units using Bayesian Inference and virtual sensing. *Energy and Buildings*, 250, 111293.
- [19] Zhang, Z., Han, H., Cui, X., and Fan, Y., (2020). Novel application of multi-model ensemble learning for fault diagnosis in refrigeration systems. *Applied Thermal Engineering*, 164, 114516.
- [20] 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*.
- [21] Poudel, S., (2023, August 28). Recurrent neural network (RNN) architecture explained. Medium. URL: <https://medium.com/@poudelsushmita878/recurrent-neural-network-rnn-architecture-explained-1d69560541ef>, Son Erişim Tarihi: 10.12.2024.
- [22] Akbari Asanjan, A., Yang, T., Hsu, K., Sorooshian, S., Lin, J., and Peng, Q., (2018). Short-term precipitation forecast based on the PERSIANN system and LSTM recurrent neural networks. *Journal of Geophysical Research: Atmospheres*, 123(22):12-543.
- [23] Dey, P., Hossain, E., Hossain, M.I., Chowdhury, M.A., Alam, M.S., Hossain, M.S., and Andersson, K., (2021). Comparative analysis of recurrent neural networks in stock price prediction for different frequency domains. *Algorithms*, 14(8):251.
- [24] Anishnama. (2023, May 4). Understanding gated recurrent unit (GRU) in deep learning. Medium. URL: <https://medium.com/@anishnama20/understanding-gated-recurrent-unit-gru-in-deep-learning-2e54923f3e2>, Son Erişim Tarihi: 10.12.2024.
- [25] Rojas, C.A., (2024, April 8). What is LSTM (Long Short Term Memory)? Medium. URL: <https://blog.ai-evergreen.club/what-is-lstm-long-short-term-memory-221099a981f7>

- Son Erişim Tarihi: 10.12.2024.
- [26] Hamad, R. (2023, December 3). What is LSTM? Introduction to long short-term memory. Medium. URL: <https://medium.com/@rebeen.jaff/what-is-lstm-introduction-to-long-short-term-memory-66bd3855b9ce>, Son Erişim Tarihi: 10.12.2024.
- [27] Elmaz, F., Eyckerman, R., Casteels, W., Latré, S., and Hellinckx, P., (2021). CNN-LSTM architecture for predictive indoor temperature modeling. *Building and Environment*, 206, 108327.
- [28] Mienye, I.D. and Sun, Y., (2022). A survey of ensemble learning: Concepts, algorithms, applications, and prospects. *IEEE Access*, 10:99129-99149.
- [29] Şirin, E., (2017, Aralık 19). Ensemble yöntemler (topluluk öğrenmesi): Basit teorik anlatım ve Python uygulama. URL: <https://www.veribilimiokulu.com/ensemble-yontemler-topluluk-ogrenmesi-basit-teorik-anlatim-ve-python-uygulama>, Son Erişim Tarihi: 10.12.2024.
- [30] Dişli, F., Gedikpınar, M., and Sengur, A., (2023). Kırık Rotor Çubuğu Sayısının Ampirik Mod Ayrışımı ve Makine Öğrenmesi Yaklaşımları İle Belirlenmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(2):783-795.
- [31] 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.
- [32] 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.
- [33] Aydın, Ö. and Akin, E., (2024). Kırık Rotor Çubuğu Arızalarının Belirlenmesinde Derin Öğrenme Yaklaşımları ve Motor Akım İmza Analizi. *Türk Doğa ve Fen Dergisi*, 13(3):1-7.
- [34] 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.