

ASENKRON MOTOR RULMAN ARIZA ANALİZİ İÇİN LabVIEW TABANLI GUI TASARIMIEyüp IRGAT¹, Abdurrahman ÜNSAL^{2*}¹ Kütahya Dumlupınar Üniversitesi, Kütahya Teknik Bilimler Meslek Yüksek Okulu, Kütahya,ORCID No : <https://orcid.org/0000-0003-0399-0436>² Kütahya Dumlupınar Üniversitesi, Elektrik Elektronik Mühendisliği, Kütahya,ORCID No : <https://orcid.org/0000-0002-7053-517X>

Anahtar Kelimeler	Öz
LabVIEW GUI CNN Asenkron motor Rulman arızaları	<i>Asenkron motorlarda meydana gelen rulman arızalarının erken teşhisi, endüstriyel süreçlerin verimliliği, güvenliği ve bakım maliyetlerinin düşürülmesi açısından kritik öneme sahiptir. Bu çalışmada, asenkron motor rulman arızalarının tespiti ve sınıflandırılması amacıyla çoklu sensör veri füzyonuna dayalı bir Evrişimli Sinir Ağı (CNN) modeli önerilmiştir. Çalışma kapsamında deneysel düzenden elde edilen üç eksenli titreşim, üç fazlı akım ve tork sinyalleri işlenerek spektrogram görüntülerine dönüştürülmüş ve derin öğrenme modeline giriş verisi olarak sunulmuştur. Sistemin uygulanabilirliğini artırmak adına, LabVIEW ve Python entegrasyonuna sahip Grafiksel Kullanıcı Arayüzleri (GUI) geliştirilmiştir. Bu arayüzler sayesinde veri toplama, ön işleme, model eğitimi ve test işlemleri gerçekleştirilebilmektedir. Deneysel sonuçlar, tekil sensör verileri yerine veri füzyonu yaklaşımının kullanılmasının sınıflandırma başarısını belirgin şekilde artırdığını göstermiştir. Tek başına akım ve titreşim verileriyle elde edilen doğrulama doğrulukları sırasıyla %83.91 ve %98.10 iken; titreşim, akım ve tork verilerinin birleştirilmesiyle oluşturulan füzyon modeli %99.48 doğruluk oranına ulaşmıştır. Elde edilen bulgular, önerilen yöntemin endüstriyel ortamlarda arızaları yüksek hassasiyetle tespit edebileceğini ve kestirimci bakım uygulamaları için etkin bir çözüm sunabileceğini ortaya koymaktadır.</i>

LabVIEW BASED GUI DESIGN FOR INDUCTION MOTOR BEARING FAULT ANALYSIS

Keywords	Abstract
LabVIEW GUI CNN Induction motor Bearing faults	<i>Early diagnosis of bearing faults in induction motors is of critical importance for industrial process efficiency, safety, and cost-effective maintenance. In this study, a Convolutional Neural Network (CNN) model based on multi-sensor data fusion is proposed for the detection and classification of induction motor bearing faults. Within the scope of the study, three-axis vibration, three-phase current, and torque signals obtained from the experimental setup were processed and converted into spectrogram images to serve as input data for the deep learning model. To enhance the applicability of the system, Graphical User Interfaces (GUIs) featuring integration with LabVIEW and Python were developed. Through these interfaces, data acquisition, preprocessing, model training, and testing processes can be performed. Experimental results demonstrated that using the data fusion approach instead of single sensor data significantly improved classification performance. While the validation accuracy rates obtained with current and vibration data individually were 83.91% and 98.10% respectively, the fusion model created by combining vibration, current, and torque data reached an accuracy rate of 99.48%. The findings reveal that the proposed method can detect faults with high precision in industrial environments, offering an effective solution for predictive maintenance applications.</i>

Araştırma Makalesi

Başvuru Tarihi : 21.05.2025

Kabul Tarihi : 11.12.2025

Research Article

Submission Date : 21.05.2025

Accepted Date : 11.12.2025

* Sorumlu yazar: unsal@dpu.edu.tr<https://doi.org/10.31796/ogummf.1703595>

Bu eser, Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>) hükümlerine göre açık erişimli bir makaledir.

This is an open access article under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>).

1. Giriş

Asenkron motorlar, güvenilirliği, sağlamlığı ve düşük maliyeti nedeniyle endüstride yaygın olarak kullanılan motor türüdür (Sengamalai, Anbazhagan, Thamizh Thentral, Vishnuram, Khurshaid ve Kamel, 2022). Ancak, zamanla aşınma, yıpranma veya arıza durumları motorların performansını etkileyebilir ve sistemde ciddi arızalara yol açabilir. Bu arızaların başında ise rulman arızaları gelmektedir. Asenkron motorlarda meydana gelen rulman arızaları, sistem performansını doğrudan etkileyen en yaygın arıza türlerinden biridir (Tyagi ve Panigrahi, 2017). Geleneksel arıza tespit yöntemleri, genellikle titreşim analizi, termal görüntüleme ya da akım sinyali analizi gibi fiziksel ölçümlere dayanmaktadır. Bu yöntemlerde analiz süreci çoğu zaman uzman operatörlerin bilgi ve deneyimlerine bağlıdır. Ancak uzmanlar hata yapabilir ve karar verme süreçleri çoğunlukla öznelidir. Ayrıca bu yöntemlerin bazıları anlık değil, dönemsel ölçümlerle sınırlı kalmaktadır. Bu nedenle arızaların erken tespiti zorlaşmakta ve bakım maliyetleri artmaktadır (Zhao, Yan, Chen, Mao, Wang ve Gao, 2019). Bu yüzden, arıza tespiti ve arıza düzeyinin değerlendirilmesini daha nesnel hale getirecek yaklaşımlar geliştirmek gerekmektedir (Ewert, Kowalski ve Orłowska-Kowalska, 2020). Bu noktada, insan uzmanlığını taklit edebilen ve büyük veri kümelerinden öğrenerek yüksek doğrulukta sonuçlar üretebilen yapay zeka teknikleri, bu süreci otomatikleştirmek ve güvenilir hale getirmek için güçlü bir potansiyel sunmaktadır. Son yıllarda yapay zeka teknikleri, özellikle de derin öğrenme algoritmaları, karmaşık sinyallerin analizi ve arıza tespiti alanlarında güçlü bir araç olarak öne çıkmaktadır (Demirci, Saraçbaşı, Emrah, Uzun, Genç ve Özkan, 2022; DüNDAR, Sarıççek, Çinar ve Yazıcı, 2021). Derin öğrenme algoritmalarından biri olan Evrişimli Sinir Ağları (CNN), görüntü işleme başta olmak üzere birçok alanda yüksek başarı oranları elde etmiş, ses ve titreşim gibi zaman serisi verilerinin sınıflandırılmasında da etkin biçimde kullanılmaya başlanmıştır. CNN, özellik çıkarımı ve sınıflandırma işlemlerini aynı yapıda gerçekleştirebildiği için, sinyal işleme süreçlerini basitleştirmekte ve daha yüksek doğrulukta kararlar alınmasını sağlamaktadır (Cengiz, Yaylak ve Gülbandır, 2022; Han, Choi, Hong ve Kim, 2019; Li, Deng, Wu, Chen ve Xu, 2020; Wang vd., 2021). Ancak sadece doğru sınıflandırma değil, aynı zamanda çıktıların operatör tarafından yorumlanabilir şekilde sunulması da önemlidir. Bu bağlamda LabVIEW (Laboratory Virtual Instrument Engineering Workbench), sinyal işleme, görsel arayüz tasarımı ve donanım kontrolü konularında sunduğu güçlü araçlarla ön plana çıkmaktadır. LabVIEW, National Instruments firması tarafından geliştirilmiş olup, mühendislik, bilimsel araştırma ve endüstriyel alanlarda test ve kontrol sistemlerinde yaygın olarak kullanılan bir görsel programlama dilidir. Özellikle veri toplama, test,

ölçüm ve analiz sistemleri geliştirmede etkili bir platformdur (Mekala, Jayabharathi, Rajkumar ve Darshini, 2022). LabVIEW, kullanıcıların bir program oluşturmak için görsel öğeleri sürükleyip bırakabilecekleri bir grafiksel programlama yaklaşımı sağlar. Bu yaklaşım, kullanıcıların sistem tasarımını daha sezgisel ve görsel bir biçimde gerçekleştirmelerine olanak tanımaktadır.

LabVIEW ile tasarlanan bir çalışmada (Chavhan ve Ugale, 2016) yeni satın alınan motorların performansının ve bütünlüğünün doğrulanması için motor üzerinde test yapılması üzerine bir grafiksel kullanıcı arayüzü (GUI) tasarımı geliştirmişlerdir. Tasarlanan GUI ile motorun hız ve yük kontrolü yapılarak motor performansını değerlendirmişlerdir. Başka bir çalışmada (Pavithra ve Rao, 2018) LabVIEW yazılımı, üç fazlı asenkron motorun hız ve dönüş yönü kontrolü için Programlanabilir Lojik Kontrol (PLC) ile iletişim kurmak amacıyla kullanılmıştır.

LabVIEW kullanılarak asenkron motorda arıza tanımlama için önerilen bir çalışmada (Sasireka, Vidhyalakshmi, Rupasri, Sanjai ve Sanjana, 2023), motorun titreşimi ve akım verilerini gerçek zamanlı olarak izleyebilen ve analiz edebilen bir GUI tasarlanmıştır. Makine öğrenimi ile sinyallerden özellikler çıkarıp analiz etmek için LabVIEW sinyal işleme işlevleri kullanılmıştır. Daha sonra, çıkarılan özelliklerin bir arızayı gösterebilecek sapmaları tespit etmek için sağlıklı bir motorun referans modeliyle karşılaştırılması yapılmıştır.

Yapılan bazı çalışmalar, yapay zeka modellerini LabVIEW ortamına entegre ederek kullanıcıya anlık görsel geri bildirim sağlamayı başarmıştır. Ancak literatürde, CNN tabanlı rulman arıza tespiti ile bu çıktıları LabVIEW GUI üzerinde görselleştiren bütünlümlü çözümler oldukça sınırlıdır. Bu çalışma, bu boşluğu doldurmayı amaçlamakta; hem yüksek doğruluklu bir arıza tespiti modeli sunmakta hem de bu modeli endüstriyel kullanım için uygun bir kullanıcı arayüzü ile desteklemektedir.

Literatürdeki iş akışları dikkate alınarak tasarlanan arayüzlerde, karmaşık teknik detayların arka planda tutulduğu kullanıcı dostu bir mimari hedeflenmiştir. “Giriş-İşlem-Sonuç” döngüsünü takip eden bu yapı, veri işleme süreçlerinin sıralı ve hatasız yürütülmesine olanak tanıyarak sistemin işlevsel performansını maksimize etmektedir.

Bu çalışmada, asenkron motorlarda rulman arızalarının tespiti için CNN tabanlı bir model geliştirilmiştir. Model, asenkron motordan toplanan titreşim, akım ve tork verileriyle eğitilmiş ve farklı rulman arıza türlerini (sağlam, dış bilezik, iç bilezik ve bilye arızası) sınıflandırmak üzere yapılandırılmıştır. Ayrıca, geliştirilen sistem veri toplama, analiz ve test çıktıları olmak üzere kullanıcıya anlık bilgi sunma amacıyla


LabVIEW ortamında tasarlanmış GUI üzerinden görselleştirilmiştir. Bu sayede hem arıza tespiti otomatik hale getirilmiş, hem de operatörlerin sistem durumunu anlık olarak takip edebileceği kullanıcı dostu bir platform oluşturulmuştur.

2. Metodoloji

Bu bölümde, asenkron motorlarda rulman arızalarının tespiti amacıyla geliştirilen derin öğrenme yaklaşımı sunulmaktadır. Çalışmanın metodolojisi, LabVIEW ortamında tasarlanan üç farklı arayüz ile yönetilen üç temel aşamadan oluşur. Birinci aşamada; Veri Toplama Arayüzü kullanılarak deney düzeneğinden ham sinyaller kaydedilmiştir. İkinci aşamada; veri ön işleme ve veri füzyonu (birleştirme) ile CNN modelinin eğitimi için gerekli olan veri setinin oluşturulması Eğitim Arayüzü üzerinden gerçekleştirilmiştir. Üçüncü aşamada ise Test Arayüzü aracılığıyla, daha önce görülmemiş veriler ile tahmin yapılmış ve sonuçlar görselleştirilmiştir. Bölümün devamında deneysel test düzeneği, arıza oluşturma ve deneysel senaryolar, GUI tasarımları ve model mimarisi ayrıntılı olarak açıklanmaktadır.

2.1 Deneysel Test Düzeneği

Çalışmada üç fazlı 50 Hz 1.5 kW 6 kutuplu bir asenkron motor kullanılmıştır. Titreşim, akım ve tork verileri Şekil 1'de verilen deneysel test düzeneği kullanılarak toplanmıştır. Veri toplamak için National Instrument (NI) cRio 9056 veri toplama sistemi kullanılmıştır. Titreşim sinyalleri, 3 eksenli bir titreşim sensörü (PCB 356a15) ve bir NI 9230 modülü ile, akım sinyalleri bir NI 9225 modülü ile ve tork sinyalleri de bir NI 9209 modülü ile toplanmıştır. NI 9230 modülü 3 kanal $\pm 30V$ analog giriş modülü olup maksimum 12.8 kHz veri okuma hızına sahiptir. 6400 Hz örnekleme hızında üç eksen titreşim sinyallerini okumak üzere ayarlanmıştır. NI 9225 modülü 3 kanal $\pm 300 V$ analog giriş modülü olup maksimum 50 kHz veri okuma hızına sahiptir. 6400 Hz örnekleme hızında üç faz stator akım sinyallerini okumak üzere ayarlanmıştır. NI 9209 modülü $\pm 10V$, 32 kanallı analog giriş modülü olup maksimum 500 Hz veri okuma hızına sahiptir. 100 Hz örnekleme hızında tork sinyallerini okumak üzere ayarlanmıştır.



Şekil 1. Deneysel Test Düzeneği

2.2 Arıza Oluşturma ve Deneysel Senaryolar

Çalışmada, endüstriyel ortamdaki rulman bozulmalarını simüle etmek amacıyla yapay hasar oluşturma yöntemi izlenmiştir. Bu kapsamda, motorun tahrik tarafındaki rulmanlar üzerinde mekanik işlem uygulanarak tek nokta arızaları meydana getirilmiştir. Arızalar; rulmanın dış bilezik, iç bilezik ve bilye yüzeylerinde 1.5 mm çapında delikler açılması suretiyle oluşturulmuştur.

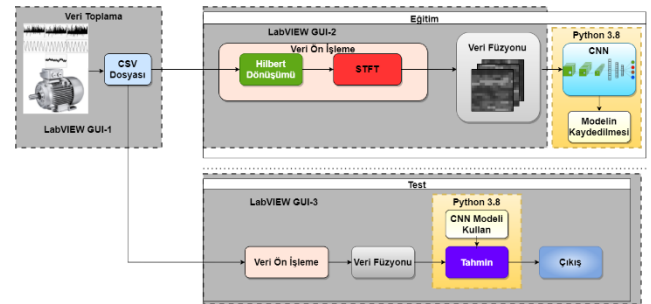
Oluşturulan her bir arıza türü, diğerlerinden bağımsız olarak analiz edilmiştir. Buna göre, geliştirilen arıza teşhis modelinin eğitimi ve testi için toplam dört farklı operasyonel durum tanımlanmıştır. Deneylerde SKF 6205 tipi rulmanlar kullanılmış olup her bir senaryo için tanımlanan rulmanlar Şekil 2'de gösterilmiştir.



Şekil 2. Çalışmada kullanılan rulmanlar a) sağlam, b) dış bilezik arızalı, c) iç bilezik arızalı, d) bilye arızalı

2.3. GUI Tasarımları

LabVIEW ortamında geliştirilen sistem; veri toplama, eğitim ve test bölümlerini içeren GUI tasarımlarından oluşmaktadır (Şekil 3). GUI'ler modüler bir şekilde tasarlanmış olup kullanıcıların farklı işlemlere hızlıca erişebilmesi amaçlanmıştır.



Şekil 3. GUI tasarımı


GUI-1 veri okuma ve CSV dosyasına kaydetme için tasarlanmıştır. GUI-1 arayüzü ile sağlam, dış bilezik arızalı rulman, iç bilezik arızalı rulman ve bilye arızalı rulman ile çalıştırılan deneysel test düzeneğinden her sınıf için ayrı ayrı 120 sn süre ile titreşim, akım ve tork verileri kaydedilmiştir. Her rulmandan kaydedilen 120 sn'lik verilerin ilk 100 sn'lik kısmı modelin eğitimi için kullanılırken sonraki 20 sn'lik veriler ise modelin test edilmesi için ayrılmıştır.

GUI-2 veri ön işleme ve veri füzyonu için tasarlanmıştır. GUI-1'de kaydedilen ham veriler (titreşim, akım ve tork) veri ön işlemede Hilbert dönüşümü alınıp STFT ile spektrogramlara çevrilmektedir. Elde edilen spektrogramlar birleştirilerek Python 3.8'de hazırlanan CNN modelinde eğitim verisi olarak kullanılmaktadır.


GUI-3 ise test verisini veri ön işleme, veri füzyonu, önceden eğitilip kaydedilen CNN modelini çağırıp, arka planda çalıştırma ve modelin tahmin sonucunu ekranda göstermek üzere tasarlanmıştır.

2.3.1 GUI-1 Veri Toplama Arayüzü

GUI-1 asenkron motora ait titreşim, akım ve tork verilerinin istenen sürede anlık olarak okunup CSV dosyasına kaydedilmesi için tasarlanmıştır. Verilerinin okunması için *DAQ Assistant* nesneleri kullanılmıştır. Blok diyagram sayfasında açılan pencerede *DAQ Assistant* nesnesi bulunarak sayfa üzerine taşınmıştır. Ayrıca sayfaya 6 adet *Write Delimited Spreadsheet.vi* nesnesi eklenmiştir. Bu nesne CSV dosyası oluşturmak için kullanılmıştır. Bu nesnelerin üçü başlık satırı eklemek için diğer üçü ise kayıt süresi boyunca okunan titreşim, akım ve tork verilerini kaydetmek için kullanılmaktadır. GUI-1'e ait blok diyagram Şekil 4'te, ön paneli ise Şekil 5'te görülmektedir.



Şekil 4. GUI-1 Blok Diyagramı



Şekil 5. GUI-1 Ön Panel


Şekil 5'te titreşim, akım ve tork verilerinin anlık görüntüleri görülmektedir.

2.3.2 GUI-2 Eğitim Arayüzü

Bu modül Python 3.8'de hazırlanmış CNN modeli için eğitim verisi hazırlamak üzere tasarlanmıştır. Şekil 3'de görüldüğü gibi 2 kısımdan oluşmaktadır. Birinci kısım veri ön işleme, ikinci kısım veri füzyonudur.

2.3.2.1 Veri Ön İşleme

Veri ön işlemede Hilbert Dönüşümü (HT) ve Kısa Zamanlı Fourier Dönüşümü (STFT) kullanılmıştır. HT, günümüzde arıza teşhisinde yaygın olarak kullanılan gelişmiş sinyal işleme yöntemlerinden biridir. HT, doğrusal olmayan ve durağan olmayan sinyalleri analiz etmek için kullanılan etkili bir zaman-frekans sinyal işleme yöntemi olarak tanımlanmaktadır (Dias ve Silva, 2022; El Idrissi, Derouich, Mahfoud, El Ouanjli, Chantoufi, Al-Sumaiti ve Mossa, 2022; Mahela, Sharma, Kumar, Khan ve Alhelou, 2020; Ramu, Irudayaraj ve Subramaniam, 2020). STFT ile frekansı zamana bağlı olarak değişen sinyallerin analizleri yapılabilmekte olup, asenkron motorların arızalarını tespit etmek için kullanılan en popüler yöntemlerden biridir (Liu, Cheng ve Wen, 2020; Pietrzak ve Wolkiewicz, 2022). Zaman-frekans analizinde kullanılan STFT pencereleri, sinyali küçük parçalara ayırarak, her bir parçanın frekans bileşenlerini incelememizi sağlayan spektrogramlara dönüştürür. Çalışmada kullanılan HT ve STFT işlemlerine ait blok diyagramlar Şekil 6'te verilmiştir.



Şekil 6. GUI-2 Veri Ön İşleme Blok Diyagramı

2.3.2.2 Veri Füzyonu

Bu bölümde, CNN modelinin eğitim veri setini oluşturmak amacıyla; titreşim, akım ve tork verilerinden elde edilen spektrogramların birleştirilmesi işlemi detaylandırılmıştır.

Öncelikle titreşim, akım ve tork verilerine ait spektrogram verileri farklı ölçekte olabileceği için normalizasyon işlemine tabi tutulur. Normalizasyon işlemi veriyi 0-1 aralığına sıkıştırır. Böylece büyük ölçekli değerlerin küçük ölçekli değerlere baskın çıkması engellenmiş olur. Bu da derin öğrenme modelinin özellikleri öğrenmesini kolaylaştırır. Normalizasyon işlemine ait formül eşitlik (1)'de verilmiştir.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$


burada x spektrogramda her bir pixele ait veriyi, x_{min} spektrogramdaki en küçük veriyi, x_{max} en büyük veriyi gösterir. x' ise normalizasyona çevrilmiş veriyi göstermektedir.

GUI-2 arayüzünde (Şekil 8) seçimleri yapılan X axis, Y axis, Z axis, $Phase1$, $Phase2$, $Phase3$ ve $Torque$ verileri, normalizasyon işleminin ardından Eşitlik (2)'deki formül ile birleştirilir (Şekil 7).


$$F = \sum_{i=1}^7 \begin{cases} x(i) & , \text{ eğer } i. \text{ veri seçildiyse} \\ 0 & , \text{ eğer } i. \text{ veri seçilmediyse} \end{cases} \quad (2)$$

Burada i sensör verisini temsil eden numardır. 1: X eksen titreşim, 2: Y eksen titreşim, 3: Z eksen titreşim, 4: akım faz1, 5: akım faz2, 6: akım faz3 ve 7: tork için kullanılmıştır. Eğer GUI-2 üzerinden ilgili sensör seçildiyse normalize edilmiş ilgili spektrogram verisi toplanacak aksi halde toplama dahil edilmeyecektir.

Birleştirme işlemi tamamlanan veri (F) train.csv adında yeni bir CSV dosyasına kaydedilir. Bu dosya Python 3.8 de hazırlanan CNN modelinin eğitim verisidir. Eğitilen CNN modeli .h5 formatında dışa aktarılır.




Şekil 7. GUI-2 Veri Füzyonu Blok Diyagramı



Şekil 8. GUI-2 Ön Panel

2.3.3 GUI-3 Test Modülü


GUI-3 Test modülü, veri ön işleme ve veri füzyonu aşamalarında GUI-2 ile aynı metodolojiyi izlemektedir. Bu modülün temel işlevi; .h5 formatında kaydedilen eğitilmiş CNN modelinin, LabVIEW ortamına entegre edilen Python betikleri (scripts) aracılığıyla arka planda yürütülmesidir.



Şekil 9. LabVIEW ile Python Entegrasyonu Blok Diyagramı

Şekil 9'da, LabVIEW ve Python ortamları arasındaki entegrasyonu sağlayan blok diyagram verilmiştir. Bu yapıda, arka planda çalışan Python betiklerinden elde edilen analiz sonuçları, arayüz üzerindeki 'output' etiketli metin kutusuna aktarılarak görüntülenir.

Modelden elde edilen sınıflandırma sonuçlarına göre ilgili arıza görselleri kullanıcı arayüzüne yansıtılır. Sistem, yeniden eğitim gerektirmeksizin doğrudan çıkarım işlemi gerçekleştirdiği için analiz sonuçları yüksek hızda üretilmektedir. GUI-3 Test Modülüne ait ön panel Şekil 10'da görülmektedir.



Şekil 10. GUI-3 Ön Panel

2.4 CNN Modeli

CNN modeli Python 3.8 ortamında TensorFlow/Keras kütüphaneleri kullanılarak geliştirilmiştir. Model, iki boyutlu (2D) evrişim işlemleri ile spektrogram verilerini kullanarak şekilde tasarlanmıştır. CNN modelinin katman mimarisi Tablo 1'de verilmiştir.

Çalışmada, görüntü sınıflandırma işlemi için Sıralı (Sequential) bir Derin Öğrenme modeli tasarlanmıştır. Model, öznetelik çıkarımı yapan evrişim (Convolution) blokları ve sınıflandırma yapan tam bağlı (Dense) katmanlardan oluşmaktadır. Modelin giriş kısmında üç adet Conv2D katmanı bulunmaktadır. Bu katmanlarda sırasıyla 8, 64 ve 128 filtre kullanılarak görüntü üzerindeki hiyerarşik özellikler öğrenilmektedir. Her evrişim katmanının ardından, işlem yükünü hafifletmek

ve en belirgin özellikleri korumak amacıyla MaxPool2D katmanı ile boyut indirgeme işlemi uygulanmıştır. Ara katmanlarda, negatif değerleri sıfırlayarak modelin doğrusal olmayan ilişkileri öğrenmesini sağlayan ReLU (Rectified Linear Unit) aktivasyon fonksiyonu tercih edilmiştir. Modelin eğitim verisini ezberlemesini engellemek için ağırlıklı belirli kısımlarına %25 oranında seyreltme (Dropout) uygulanmıştır. Bu işlem, eğitim sırasında rastgele nöronları kapatarak ağırlıklı daha güçlü olmasını sağlamaktadır. Öznetelik çıkarımı tamamlandıktan sonra veriler Flatten işlemi ile tek boyutlu vektöre dönüştürülmüştür. Sınıflandırma bloğunda sırasıyla 32 ve 16 nöronlu iki gizli katman bulunur. Son katmanda, modelin 4 farklı sınıfı ayırt etmesi beklendiğinden 4 nöron kullanılmıştır. Burada aktivasyon fonksiyonu olarak, çıktıların toplamının 1 olmasını sağlayan ve her sınıf için bir olasılık değeri üreten Softmax kullanılmıştır.

Modelin eğitimi 25 epok (Epoch) boyunca, her adımda 8 veri örneği (Batch size) işlenerek gerçekleştirilmiştir. Optimizasyon algoritması olarak Adam (Learning Rate=0.0001) seçilmiş ve hata hesaplamasında çoklu sınıflandırma problemlerine uygun olan Categorical Crossentropy kayıp fonksiyonu kullanılmıştır.

Tablo 1. CNN Modelinin Katman Mimarisi

Katman Tipi	Filtre / Nöron Sayısı	Kernel	Aktivasyon Fonksiyonu	İşlevi
Conv2D (Giriş)	8	4x4	ReLU	Özellik Çıkarımı
MaxPooling2D	-	2x2	-	Boyut İndirgeme
Conv2D	64	3x3	ReLU	Özellik Çıkarımı
MaxPooling2D	-	2x2	-	Boyut İndirgeme
Conv2D	128	2x2	ReLU	Özellik Çıkarımı
MaxPooling2D	-	2x2	-	Boyut İndirgeme
Dropout	Oran: 0.25	-	-	Aşırı Öğrenmeyi Önleme
Flatten	-	-	-	Veriyi Düzleştirme
Dense (Tam Bağlı)	32	-	ReLU	Sınıflandırma
Dropout	Oran: 0.25	-	-	Aşırı Öğrenmeyi Önleme
Dense (Tam Bağlı)	16	-	ReLU	Ara Sınıflandırma Katmanı
Dense (Çıkış)	4	-	Softmax	Sonuç / Olasılık Dağılımı

Bu çalışma kapsamında yapılan testler ve sonuçların sunulmasında araştırma ve yayın etiğine uyulmuştur.

3. Bulgular ve Tartışma

Bu bölümde, asenkron motor rulman arızalarının tespiti amacıyla geliştirilen veri füzyonu tabanlı CNN modelinin deneysel sonuçları sunulmaktadır. Modelin başarımları; tekil sensör verileri ve birleştirilmiş veri

setleri üzerinden elde edilen doğruluk oranları, karışıklık matrisi analizleri ve arayüz çıktıları dikkate alınarak kapsamlı bir şekilde değerlendirilmiştir.

Farklı sensör verilerinin (titreşim, akım ve tork) tek başlarına ve birleştirilerek kullanılması durumunda elde edilen model performansları karşılaştırmalı olarak analiz edilmiştir. Tekil veri ile veri füzyonu yönteminin eğitim ve doğrulama aşamalarındaki doğruluk oranları Tablo 2’de sunulmuştur.


Tablo 2. Farklı Veri Setleri İçin Elde Edilen Eğitim ve Doğrulama Doğruluk Oranları (%)

Veri Setleri	Eğitim Doğruluğu	Doğrulama Doğruluğu
Titreşim	98.70	98.10
Akım	84.28	83.91
Tork	97.61	97.51
Titreşim+Akım+Tork (Füzyon)	99.75	99.48

Tablo 2 incelendiğinde, tekil veri kaynakları arasında en düşük başarının akım verisiyle (%83.91), en yüksek başarının ise titreşim verisiyle (%98.10) elde edildiği görülmektedir. Bununla birlikte, önerilen yöntem ile tüm verilerin (titreşim, akım ve tork) birleştirilmesi sonucunda model performansı belirgin şekilde iyileşmiş ve doğrulama aşamasında %99.48 gibi yüksek bir doğruluk oranına ulaşılmıştır. Bu durum, veri füzyonu yaklaşımının arıza tespitindeki etkinliğini ve güvenilirliğini kanıtlar niteliktedir.

Tablo 2’de en yüksek performansı sergilediği görülen veri füzyonu modelinin sınıflandırma başarımı, Şekil 11’deki karışıklık matrisi ile detaylandırılmıştır. GUI-2 arayüzünde ön işleme ve birleştirme adımları tamamlanan spektrogram veri setlerinin kullanıldığı bu analizde; modelin eğitim ve doğrulama süreçlerinde her bir arıza sınıfını (Sağlam, Dış Bilezik, İç Bilezik, Bilye) ne kadar yüksek hassasiyetle ayırabildiği görülmektedir.

Çalışmada kullanılan veri seti her sınıf için 6400 adet olmak üzere toplam 25600 adet görüntüden oluşmaktadır. Veri seti, modelin yanlılık (Bias) oluşturmamasını engellemek için 4 farklı sınıf arasında dengeli bir şekilde dağıtılmıştır. Veri setinin %70’i eğitim ve %30’u doğrulama olarak ayrılmıştır.



Şekil 11. Eğitim ve Doğrulama Karışıklık Matrisi

Modelin sağlam rulmanı (0) kolaylıkla ayırt edebildiği, ancak dış bilezik (1), iç bilezik (2) ve bilye (3) arızaları arasında sınırlı da olsa karışıklık yaşadığı görülmüştür. Bu durum sinyallerin bazı frekans bileşenlerinin birbirine yakın olmasından kaynaklanabilir. Bu karışıklık, modelin hassasiyeti artırılarak veya daha fazla veriyle eğitim yapılmasıyla azaltılabilir.

Tablo 3. Doğrulama Performans Raporu

Sınıf	Kesinlik (Precision)	Duyarlılık (Recall)	F1	Örnek Sayısı	Sınıf Bazlı Doğruluk
0	1.000	1.000	1.000	1936	%99.99
1	0.998	0.982	0.990	1884	%99.50
2	0.996	0.997	0.997	1933	%99.84
3	0.986	1.000	0.993	1927	%99.62
Ort.	0.995	0.995	0.995		Genel: %99.48

Tablo 3’de her bir sınıf (0, 1, 2, 3) için hesaplanmış metrikler (Precision, Recall, F1) görülmektedir. En düşük performans Sınıf 1’de görülmektedir. Şekil 11’e bakıldığında, Sınıf 1 olması gereken 27 örneğin yanlışlıkla Sınıf 3 olarak tahmin edildiği anlaşılmaktadır. Ayrıca 7 örnek de Sınıf 2 ile karıştırılmıştır. Bu durum Sınıf 1’in Duyarlılık (Recall) değerini %98.2’ye çekmiştir. Sınıf 3’ün Duyarlılık değeri çok yüksek (%100’e yakın) olsa da, Kesinlik (Precision) değeri diğerlerine göre biraz düşüktür (0.986). Bunun sebebi, aslında Sınıf 1 olan örneklerin Sınıf 3 olarak tahmin edilmesidir. Modelin genel doğrulama başarısı %99.48’dir. Bu, modelin sınıfları ayırt etmede son derece başarılı olduğunu göstermektedir.

Modelin gerçek zamanlı test performansı ise geliştirilen GUI-3 arayüzü üzerinden doğrulanmıştır. Elde edilen test sonuçlarına ait ekran görüntüleri Şekil 12’de verilmiştir.

Şekil 12’de, asenkron motordan elde edilen üç eksenli titreşim, akım ve tork verilerinin test_model.py betiği ile işlenmesi sonucu elde edilen sınıflandırma çıktıları verilmiştir. Gerçekleştirilen testlerde; sağlam rulman durumu %99.65 doğruluk oranıyla '0- Healthy' sınıfına atanarak arayüzde yeşil gösterge ile görselleştirilmiştir (Şekil 12-a). Arızalı durumlar incelendiğinde ise; dış bilezik arızası kırmızı gösterge ile '1- Outer' %93.56 doğrulukla (Şekil 12-b), iç bilezik arızası sarı gösterge ile '2- Inner' %93.73 doğrulukla (Şekil 12-c) ve bilye arızası mavi gösterge ile '3- Ball' %95.78 doğrulukla (Şekil 12-d) başarıyla tespit edilip GUI-3 üzerinde operatöre sunulmuştur.

Önerilen model hem eğitim hem de test veri kümelerinde yüksek doğruluk oranları sergilemiştir. Ayrıca model çıktılarının LabVIEW arayüzü üzerinde görselleştirilmesi sayesinde, kullanıcıların karar verme süreci hızlandırılmış ve sistemin endüstriyel uygulanabilirliği artırılmıştır.



Şekil 12. GUI-3 Test Sonuçları a) Sağlam Rulman b) Dış Bilezik Arızası c) İç Bilezik Arızası d) Bilye Arızası

Geliştirilen arayüz kullanıcı deneyimi açısından test edilmiş ve aşağıdaki işlevsellikleri başarıyla yerine getirmiştir:

- **Veri analizi:** Kullanıcılar motor titreşim verilerini anlık olarak yükleyebilmiş ve CNN modelini çalıştırarak arıza türünü görebilmiştir.
- **Otomatik karar desteği:** CNN tarafından yapılan tahmin, arıza durumunu açık bir şekilde göstermektedir.
- **Otomasyon:** İnsan müdahalesine ihtiyaç duymadan teşhis süreci yürütülebilmektedir.
- **Entegrasyon kolaylığı:** LabVIEW-Python entegrasyonu sayesinde sistem kolayca donanım tabanlı uygulamalara uyarlanabilir.

Ancak sistemin bazı sınırlılıkları da göz önünde bulundurulmalıdır:

- Model sadece deneyde kullanılan veri seti üzerinde test edilmiştir; gerçek sistemlerde benzer performans için farklı motorlardan alınan verilerin adaptasyonu gerekebilir.
- LabVIEW arayüzü, büyük veriler ile uzun süreli analize uygun hale getirildiğinde daha yüksek performanslı donanım gerekebilir.

- Saha koşullarındaki gürültülü verilerde model kararlılığı ayrıca değerlendirilmelidir.

4. Sonuç ve Öneriler

Bu çalışmada, asenkron motor rulman arızalarını yüksek doğrulukla tespit etmek amacıyla CNN tabanlı bir model geliştirilmiş ve elde edilen sonuçlar, kullanıcı dostu bir arayüz ile LabVIEW ortamına entegre edilmiştir. Geliştirilen sistem, %99.75 eğitim ve %99.48 doğrulama doğruluğu ile geleneksel yöntemlere kıyasla üstün bir performans sergilemiştir. Veri ön işleme, özellik çıkarımı ve sınıflandırma aşamalarının CNN mimarisi ile otomatikleştirilmesi, manuel mühendislik süreçlerini ortadan kaldırarak sistemin verimliliğini artırmıştır. Ayrıca, LabVIEW entegrasyonu sayesinde bu gelişmiş model, üretim hatları gibi kontrol odaklı endüstriyel ortamlarda operatörler tarafından kolaylıkla kullanılabilir hale getirilmiştir.

Çalışmada elde edilen %99.75'lik sınıflandırma ve %99.48 doğrulama başarısı, yalnızca sağlıklı ve arızalı durumların ayrımında değil, aynı zamanda dış bilezik, iç bilezik ve bilye arızalarının teşhisinde de yüksek kararlılık göstermiştir. Bu yüksek ayırıcılık yeteneği, endüstriyel uygulamalar için şu kritik avantajları sağlayabilir:

- **Erken Uyarı ve Müdahale:** Hata türünün (örneğin bilye arızası) hassasiyetle belirlenmesi, bakım ekiplerinin doğru yedek parça ve ekipmanla en hızlı şekilde müdahale etmesine olanak tanır.
- **Güvenilirlik ve Yanlış Alarmların Önlenmesi:** Yüksek sınıflandırma doğruluğu, endüstriyel sahalarda operatörlerin sisteme olan güvenini sarsan "yanlış pozitif" alarmları minimize eder.
- **Maliyet Optimizasyonu:** Beklenmedik duruşların önüne geçilerek üretim kayıpları engellenir. Böylece reaktif bakımdan kestirimci bakıma geçiş sağlanarak işletme maliyetleri optimize edilir.

Son olarak, geliştirilen bu sistem yalnızca endüstriyel uygulamalar için değil, aynı zamanda görselleştirme yetenekleri sayesinde üniversiteler ve teknik eğitim kurumlarında, sinyal işleme ve yapay zeka tabanlı arıza tespiti konularının öğretilmesinde de etkili bir eğitim aracı olarak kullanılabilir.

Bu çalışmanın bir temel oluşturduğu göz önüne alındığında, gelecekte yapılabilecek geliştirme ve araştırma başlıkları aşağıdaki gibi özetlenebilir:

- **Gerçek zamanlı donanım entegrasyonu:** Sistem, endüstriyel motorlardan gelen canlı sinyallerle entegre edilerek çevrim içi arıza teşhisi yapılabilir.
- **Modelin genellenebilirliğinin artırılması:** Farklı motorlara ait verilerle model yeniden eğitilerek genelleme kapasitesi test edilebilir.

- Derin öğrenme model mimarilerinin karşılaştırılması: Farklı derin öğrenme yapılarıyla CNN performansı karşılaştırılabilir.
- Mobil ya da gömülü sistem entegrasyonu: Raspberry Pi, Jetson Nano, Arduino gibi sistemler kullanılarak taşınabilir bir bakım destek cihazı geliştirilebilir.

Sonuç olarak, bu çalışma, yapay zeka destekli arıza tespitinin endüstriyel otomasyon sistemlerine entegrasyonu konusunda uygulanabilir ve ölçeklenebilir bir yaklaşım sunmaktadır. Böylece, LabVIEW kullanılarak bir arıza tespit sistemi uygulanması, asenkron motorlarının güvenli ve güvenilir bir şekilde izlenmesini sağlayabilir ve işletme maliyetlerini azaltabilir.

Derin öğrenme algoritmalarının bu gibi uygulamalarda sunduğu yüksek doğruluk, gelecekte bakım stratejilerinin merkezinde yer alacağının güçlü bir göstergesidir.

Teşekkür

Bu çalışmada kullanılan veriler, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) 118C252 numaralı araştırma projesi kapsamında toplanmıştır.

Araştırmacıların Katkısı

Bu çalışmada; Eyüp IRGAT, makalenin taslağının hazırlanması, literatür taraması, GUI tasarımı, deneysel verilerin toplanması, derin öğrenme analizi; Abdurrahman ÜNSAL, çalışmanın her aşamasına katkı sağlamıştır.

Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

- Cengiz, E., Yaylak, F. ve Gülbandır, E. (2022). Investigation of polyps in endoscopy images by using deep learning algorithm. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 30(3), 441-453. doi: <https://doi.org/10.31796/ogummf.1122707>
- Chavhan, K. B. ve Ugale, R. T. (2016). Automated test bench for an induction motor using LabVIEW, 1-6. 2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES), Delhi, India: IEEE. doi: <https://doi.org/10.1109/ICPEICES.2016.7853547>
- Demirci, D., Saraçbaşı, E., Emrah, E., Uzun, İ., Genç, Y. ve Özkan, K. (2022). Domates hastalığı tahmini için gerçek zamanlı uygulama. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi*

Dergisi, 30(1), 90-95. doi: <https://doi.org/10.31796/ogummf.969487>

Dias, C. G. ve Silva, L. C. da. (2022). Induction motor speed estimation based on airgap flux measurement using hilbert transform and fast fourier transform. *IEEE Sensors Journal*, 22(13), 12690-12699. doi: <https://doi.org/10.1109/JSEN.2022.3176085>

Dündar, D. R., Sarıççek, İ., Çınar, E. ve Yazıcı, A. (2021). Kestirimci bakımda makine öğrenmesi: Literatür araştırması. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 29(2), 256-276. doi: <https://doi.org/10.31796/ogummf.873963>

El Idrissi, A., Derouich, A., Mahfoud, S., El Ouanjli, N., Chantoufi, A., Al-Sumaiti, A. S. ve Mossa, M. A. (2022). Bearing fault diagnosis for an induction motor controlled by an artificial neural network—direct torque control using the hilbert transform. *Mathematics*, 10(22), 4258. doi: <https://doi.org/10.3390/math10224258>

Ewert, P., Kowalski, C. T. ve Orlowska-Kowalska, T. (2020). Low-cost monitoring and diagnosis system for rolling bearing faults of the induction motor based on neural network approach. *Electronics*, 9(9), 1334. doi: <https://doi.org/10.3390/electronics9091334>

Han, J.-H., Choi, D.-J., Hong, S.-K. ve Kim, H.-S. (2019). Motor fault diagnosis using CNN based deep learning algorithm considering motor rotating speed. 2019 IEEE 6th International Conference on Industrial Engineering and Applications (ICIEA), 440-445. 2019 IEEE 6th International Conference on Industrial Engineering and Applications (ICIEA), sunulmuş bildiri, Tokyo, Japan: IEEE. doi: <https://doi.org/10.1109/IEA.2019.8714900>

Li, G., Deng, C., Wu, J., Chen, Z. ve Xu, X. (2020). Rolling bearing fault diagnosis based on wavelet packet transform and convolutional neural network. *Applied Sciences*, 10(3), 770. doi: <https://doi.org/10.3390/app10030770>

Liu, D., Cheng, W. ve Wen, W. (2020). Rolling bearing fault diagnosis via STFT and improved instantaneous frequency estimation method. *Procedia Manufacturing*, 49, 166-172. doi: <https://doi.org/10.1016/j.promfg.2020.07.014>

Mahela, O. P., Sharma, J., Kumar, B., Khan, B. ve Alhelou, H. H. (2020). An algorithm for the protection of distribution feeders using the stockwell and hilbert transforms supported features. *CSEE Journal of Power and Energy Systems*, 7(6), 1278-1288. doi: <https://doi.org/10.17775/CSEEJPES.2020.00170>

- Mekala, N., Jayabharathi, T., Rajkumar, T. ve Darshini, M. P., (2022). Fault analysis of induction motor using LabVIEW. *International Journal of Engineering Applied Sciences and Technology*, 7(8), 146-150. doi: <https://doi.org/10.33564/IJEAST.2022.v07i08.017>
- Pavithra, G. ve Rao, V. V. (2018). Remote monitoring and control of VFD fed three phase induction motor with PLC and LabVIEW software, 329-335. 2018 2nd International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC), sunulmuş bildiri, Palladam, India: IEEE. doi: <https://doi.org/10.1109/I-SMAC.2018.8653657>
- Pietrzak, P. ve Wolkiewicz, M. (2022). Machine learning-based stator current data-driven PMSM stator winding fault diagnosis. *Sensors*, 22(24), 9668. doi: <https://doi.org/10.3390/s22249668>
- Ramu, S. K., Irudayaraj, G. C. R., Subramani, S. ve Subramaniam, U. (2020). Broken rotor bar fault detection using hilbert transform and neural networks applied to direct torque control of induction motor drive. *IET Power Electronics*, 13(15), 3328-3338. doi: <https://doi.org/10.1049/iet-pel.2019.1543>
- Sasireka, M., Vidhyalakshmi, P., Rupasri, M., Sanjai, S. ve Sanjana, G. (2023). Fault identification in induction motor using LabView, 123-128. 2023 Third International Conference on Ubiquitous Computing and Intelligent Information Systems (ICUIS), Gobichettipalayam, India: IEEE. doi: <https://doi.org/10.1109/ICUIS60567.2023.00029>
- Sengamalai, U., Anbazhagan, G., Thamizh Thentral, T. M., Vishnuram, P., Khurshaid, T. ve Kamel, S. (2022). Three phase induction motor drive: a systematic review on dynamic modeling, parameter estimation, and control schemes. *Energies*, 15(21), 8260. doi: <https://doi.org/10.3390/en15218260>
- Tyagi, S. ve Panigrahi, S. K. (2017). A DWT and SVM based method for rolling element bearing fault diagnosis and its comparison with artificial neural networks. *Journal of Applied and Computational Mechanics*, 3(1). doi: <https://doi.org/10.22055/jacm.2017.21576.1108>
- Wang, X., Mao, D. ve Li, X. (2021). Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network. *Measurement*, 173, 108518. doi: <https://doi.org/10.1016/j.measurement.2020.108518>
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P. ve Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237. doi: <https://doi.org/10.1016/j.ymssp.2018.05.050>