



**DIAMOND DA20-C1 UÇAĞINDA DERİN
ÖĞRENME TABANLI MANYETO ARIZASI
TESPİTİ**

Yüksek Lisans Tezi

Faruk DUMAN

Eskişehir 2025

**DIAMOND DA20-C1 UÇAĞINDA DERİN ÖĞRENME TABANLI MANYETO
ARIZASI TESPİTİ**

Faruk DUMAN

YÜKSEK LİSANS TEZİ

Uçak Gövde ve Motor Bakımı Anabilim Dalı

Danışman: Prof. Dr. Ebru YAZGAN

(İkinci Danışman: Doç. Dr. Aziz KABA)

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Aralık 2025

JÜRİ VE ENSTİTÜ ONAYI

Faruk DUMAN'ın DIAMOND DA20-C1 UÇAĞINDA DERİN ÖĞRENME TABANLI MANYETO ARIZASI TESPİTİ başlıklı çalışması 05/12/2025 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Uçak Gövde ve Motor Bakımı Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Prof. Dr. Ebru YAZGAN

Üye

: Doç. Dr. Hakan AYGÜN

Üye

: Dr. Öğr. Üyesi Barış KARABAYRAK

Prof. Dr. Harun BÖCÜK

Lisansüstü Eğitim Enstitüsü Müdürü

05/12/2025

DANIřMAN ONAYI

Daniřmanlıęını yrttęm Yksek Lisans ęrencisi Faruk DUMAN, DIAMOND DA20-C1 UAęINDA DERİN ęRENME TABANLI MANYETO ARIZASI TESPİTİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduęu tez tarafımda incelenmiř ve ęrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Prof. Dr. Ebru YAZGAN

ÖZET

DIAMOND DA20-C1 UÇAĞINDA DERİN ÖĞRENME TABANLI MANYETO ARIZASI TESPİTİ

Faruk DUMAN

Uçak Gövde ve Motor Bakımı Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Aralık 2025

Danışman: Prof. Dr. Ebru YAZGAN

(İkinci Danışman: Doç. Dr. Aziz KABA)

Bu çalışmada, Diamond DA20-C1 uçağının Continental IO-240-B32B motorunda uçuş sırasında meydana gelebilecek manyeto arızalarının tespiti için derin öğrenme tabanlı bir sistem geliştirilmiştir. Motor seslerinden Mel Frekans Kepstral Katsayıları (MFKK) kullanılarak öznitelikler çıkarılmış ve Evrişimsel Sinir Ağları (ESA) ile sınıflandırılmıştır. Sistem, çift manyeto ve tek manyeto çalışma durumlarını ayırt edebilmektedir. Çalışma kapsamında 1000-2300 dakikadaki devir aralığında her 100 dakika devirde 30 saniyelik ses kayıtları toplanmış, toplamda 39 ham veri elde edilmiştir. Sınıf dengesizliğini gidermek için çift manyeto sesleri sınıfına veri artırma teknikleri uygulanmıştır. Geliştirilen model test veri setinde %98,23 doğruluk oranına ulaşmış, bağımsız denemede ise %84,62 başarı göstermiştir. Model özellikle tek manyeto sınıfında iyi performans sergilerken, çift manyeto sınıfında belirli devir dakika değerlerinde zorluklar yaşamıştır. Bu sistem, pilotlara uçuş sırasında gerçek zamanlı manyeto durumu bilgisi sunarak erken uyarı sağlama potansiyeline sahiptir ve mevcut yer testleriyle sınırlı prosedürlere önemli bir alternatif oluşturmaktadır.

Anahtar Sözcükler: Manyeto, Derin öğrenme, Ses analizi, Havacılık emniyeti, Evrişimsel sinir ağları.

ABSTRACT

DEEP LEARNING BASED MAGNETO FAILURE DETECTION IN DIAMOND DA20-C1 AIRCRAFT

Faruk DUMAN

Department of Aircraft Airframe and Engine Maintenance

Eskişehir Technical University, Institute of Graduate Programs, December 2025

Supervisor: Prof. Dr. Ebru YAZGAN

(Co-Supervisor: Assoc. Prof. Dr. Aziz KABA)

In this study, a deep learning-based system was developed to detect magneto failures that may occur during flight in the Continental IO-240-B32B engine of the Diamond DA20-C1 aircraft. Features were extracted from engine sounds using Mel-Frequency Cepstral Coefficients and classified via Convolutional Neural Networks. The system is capable of distinguishing between dual-magneto and single-magneto operating conditions. Within the scope of the study, 30-second audio recordings were collected for every 100 revolutions per minute increment within the 1000 to 2300 revolutions per minute range, resulting in a total of 39 raw data samples. To address class imbalance, data augmentation techniques were applied to the dual-magneto sound class. The developed model achieved an accuracy rate of 98.23% on the test dataset and 84.62% in an independent trial. While the model performed particularly well in the single-magneto class, it encountered difficulties at specific revolutions per minute values within the dual-magneto class. This system has the potential to provide pilots with real-time magneto status information during flight, offering an early warning and serving as a significant alternative to existing procedures limited to ground tests.

Keywords: Magneto, Deep learning, Sound analysis, Aviation safety, Convolutional neural networks.

TEŞEKKÜR

Tezimde desteęi olan tüm sevdiklerime, her zaman yardımcı olan sevgili hocalarıma ve çalışmalarına katkısı olan UTEK uçuş okulu teknik personeline teşekkürlerimi borç bilirim.

Faruk DUMAN



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Faruk DUMAN

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ	X
ŞEKİLLER DİZİNİ	XI
GÖRSELLER DİZİNİ	XII
SİMGELER VE KISALTMALAR DİZİNİ.....	XIII
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI.....	3
2.1. Diamond DA20-C1 Uçağı	3
2.2. Manyetolar.....	5
2.3. Manyeto Arızası ile İlgili Yaşanılan Kazalar	8
2.4. Yapay Zekâ ile Ses Analizi Yaklaşımları.....	9
2.4.1. Evrişimli sinir ağları (ESA) kullanan ses tabanlı arıza teşhisi çalışmaları	9
2.4.1.1. Otomotiv ve taşıt araçlarındaki uygulamalar	9
2.4.1.2. Sanayi ve ağır ekipmanlardaki uygulamalar.....	9
2.4.1.3. İnşaat ve madencilik sektörüne yönelik çalışmalar	10
2.4.1.4. Transfer öğrenme ile güçlendirilmiş ESA uygulamaları.....	10
2.4.2. Geleneksel makine öğrenimi yöntemleri kullanan ses tabanlı arıza teşhisi çalışmaları	11
2.4.2.1. Destek vektör makineleri (DVM) ile yapılan çalışmalar.....	11

2.4.2.2. Karar ağaçları ve türevleri ile yapılan çalışmalar.....	11
2.4.2.3. Aşırı öğrenme makinesi (AÖM) ile yapılan çalışmalar.....	12
2.4.3. İleri derin öğrenme mimarileri kullanan ses tabanlı arıza teşhisi çalışmaları	13
2.4.3.1. Otomatik kodlayıcılar ile yapılan çalışmalar.....	13
2.4.3.2. Üretici çekişmeli ağlar (ÜÇA) ve anomali tespiti	13
2.4.3.3. Graf sinir ağları (GSA) ve federatif öğrenme.....	14
2.4.3.4. Diğer ileri mimariler.....	14
2.4.4. Ön işleme ve özellik çıkarma yöntemleri kullanan ses tabanlı arıza teşhisi çalışmaları	15
2.4.4.1. Zaman-frekans analiz yöntemleri	15
2.4.4.2. Spektral ve ses tabanlı özellik çıkarma	15
2.4.4.3. Gürültü giderme ve sinyal iyileştirme	16
2.5. Ses Tabanlı Arıza Teşhisinde Yapay Zekâ Tekniklerinin Karşılaştırılması.....	16
3. DERİN ÖĞRENME	21
3.1. Evrişimli Sinir Ağı (ESA).....	22
3.2. Mel Frekans Kepstral Katsayıları (MFKK)	23
4. MATERYAL VE YÖNTEM.....	24
4.1. Ses Veri Setinin Toplanması	24
4.2. Yazılım ve Model Geliştirme.....	25
4.3. Model Performansı	26
4.3.1. ESA modelinin eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri	26
4.3.2. Sınıf bazlı performans analizi	27
4.4. Model Test Sonuçları	28
5. SONUÇ VE ÖNERİLER.....	31
KAYNAKÇA.....	33
EKLER	
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 2.1. Diamond DA20-C1 Genel Özellikleri (Diamond Aircraft Industries, 2022)	4
Tablo 4.1. Ses kayıtları esnasında kullanılan mikrofonun özellikleri	25
Tablo 4.2. Model test sonuçları tablosu	29



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Ses tabanlı arıza teşhisinde yöntemlere göre ortalama doğruluk	18
Şekil 2.2. Ses tabanlı arıza teşhisinde kullanılan yöntemler.....	19



GÖRSELLER DİZİNİ

Sayfa

Görsel 2.1. Diamond DA20-C1 Uçağının Genel Görünüşü (Diamond Aircraft,2025).....	4
Görsel 2.2. Continental IO-240-B32B Motoru Silindir Numaralandırılması (Continental Motors, 2011).....	6
Görsel 2.3. Diamond DA20-C1 Ateşleme Kontrol Anahtarı (Diamond Aircraft Industries, 2022)	6
Görsel 2.4. Continental Motors Manyetolar ve Ateşleme Noktaları (Continental Motors, 2011).....	7
Görsel 3.1. Yapay sinir ağı (Dizdar E, 2018).....	21
Görsel 4.1. Eğitim ve doğrulama sürecinde doğruluk ve kayıp değerlerinin eğitim döngüsüne göre değişimi	26
Görsel 4.2. Manyeto sınıflandırma sonuçlarına ait confusion matrix	27

SİMGELER VE KISALTMALAR DİZİNİ

MFKK	: Mel Frekans Kepstral Katsayıları
ESA	: Evrişimsel Sinir Ağları (Convolutional Neural Network)
FHİ	: Federal Havacılık İdaresi (Federal Aviation Administration)
UUGK	: Ulusal Ulaştırma Güvenliği Kurulu (National Transportation Safety Board)
YSA	: Yapay Sinir Ağları (Artificial Neural Networks)
UKSB	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
DCAE	: Derin Evrişimli Otomatik Kodlayıcı (Deep Convolutional Autoencoder)
YAMNet	: Yet Another Mobile Network (Bir Başka Mobil Ağ)
VGG	: Visual Geometry Group similar to (benzeri Ses Öznitelik Çıkarıcı Model)
DVM	: Destek Vektör Makineleri (Support Vector Machine)
RTF	: Radyal Tabanlı Fonksiyon (Radial Basis Function)
DVM	: Destek Vektör Makinesi (Support Vector Machine)
İHA	: İnsansız Hava Aracı
ÇDAA	: Çekirdek Doğrusal Ayırıcı Analiz (Kernel Linear Discriminant Analysis)
KYK	: K-En Yakın Komşu (K-Nearest Neighbors)
AÖM	: Aşırı Öğrenme Makinesi (Extreme Learning Machine)
ÜÇA	: Üretici Çekişmeli Ağlar (Generative Adversarial Networks)
GSA	: Graf Sinir Ağları (Graph Neural Networks)
FÖ	: Federatif Öğrenme (Federated Learning)
KSFD	: Kısa Süreli Fourier Dönüşümü (Short-Time Fourier Transform)
SOK	: Seyrek Otomatik Kodlayıcı (Sparse Autoencoder)
DDİBSA	: Denetimli Derin İleri Beslemeli Sinir Ağı (Supervised Deep Feedforward Neural Network)
YGGOK	: Yığılanmış Gürültü Giderici Otomatik Kodlayıcı (Stacked Denoising Autoencoder)

YBF : Yapısal Benzerlik Fonksiyonu (Structural Similarity Index Measure)



1. GİRİŞ

Havacılık endüstrisinde güvenlik, her zaman en öncelikli unsur olmuştur. Her uçuş, karmaşık sistemlerin kusursuz bir uyum içinde çalışmasını gerektirir; bu sistemlerden herhangi birinin arızalanması, ciddi sonuçlar doğurabilir. Özellikle küçük hava araçlarında yaygın olarak kullanılan pistonlu motorların ateşleme sisteminde yer alan manyetolar, bu kritik bileşenlerden biridir. Manyetolar, bujilere yüksek voltajlı elektrik sağlayan elektromekanik cihazlar olup, herhangi bir arıza durumunda motor performansında belirgin düşüşlere ve hatta motorun tamamen durmasına yol açabilmektedir (Continental Motors, 2011).

Bu riskleri azaltmak amacıyla piston motorlu hava araçlarında birbirinden bağımsız çalışan iki manyeto sistemi kullanılmaktadır. Bir manyetonun arızalanması durumunda motor, diğer manyeto ile çalışmaya devam edebilmektedir. Ancak bu durumda performans düşmekte ve ikinci bir arıza halinde motor tamamen durabilmektedir. Motor sesindeki hafif değişimler veya küçük performans düşüşleri genellikle belirsizlikle karşılanmakta ve kritik durumların fark edilmesi zorlaşmaktadır. Mevcut manyeto test prosedürleri ise yalnızca yer testleriyle sınırlıdır ve uçuş sırasında arıza tespiti sağlayamamaktadır.

Bu tez çalışmasının temel amacı, piston motorlu hava araçlarının uçuşları sırasında karşılaşılan manyeto kaynaklı performans düşüşlerini ve motorun beklenmedik davranışlarını önleyici bir tedbir geliştirme ihtiyacını akademik bir yaklaşımla ele almaktır. Bu kapsamda, yapay zekâ teknikleri kullanılarak motor sesinin analiz edilmesi ve uçuş sırasında bir manyetonun arızalanmasının otomatik olarak tespit edilmesi hedeflenmiştir. Motor sesindeki değişimlerin zamanında ve doğru biçimde algılanamaması hem can güvenliği hem de operasyonel güvenilirlik açısından kabul riskler ortaya çıkmaktadır. Ayrıca bir pilot olarak, uçuş sırasında bir manyetonun arızalanması durumunda meydana gelen hafif devir düşüşünü insan algısıyla fark etmenin çoğu zaman mümkün olmadığını, tek manyeto ile uçuşa devam etmek yerine, emniyet açısından en kısa sürede bir havalimanına güvenli iniş yapma kararı olası kazaların engellemesini sağlar.

Günümüzde manyeto arızalarının tespiti büyük ölçüde periyodik bakım kontrolleri ve pilot gözlemlerine dayanmaktadır. Pilotlar, motor çalışırken uçuştan önce yer kontrollerinde manyetoları tek tek devre dışı bırakarak devir düşüşünü gözlemlemekte ve bu düşüşün kabul edilebilir limitler içinde olup olmadığını değerlendirmektedir. Uçuş

sırasında ise acil durum prosedürlerine göre motorun düzensiz çalışması durumunda hava aracının tek manyeto ile mi çalıştığını anlamak için manyeto testi uygulanır (Diamond Aircraft Industries, 2012). Ancak uçuş sırasında yapılacak olası bir manyeto testi ise çalışan bir manyetonun da devreden çıkmasına ve motorun durmasına neden olabilir.

Bu bağlamda, uçuş anında meydana gelen manyeto arızalarının daha hızlı ve güvenilir biçimde tespit edilmesine yönelik harici bir güvenlik tedbirine duyulan ihtiyaç açıkça ortaya çıkmaktadır. Modern teknolojinin sunduğu imkânlar, özellikle yapay zekâ ve derin öğrenme alanındaki gelişmeler, bu soruna yenilikçi bir çözüm getirme potansiyeline sahiptir.

Bu çalışma kapsamında, Diamond DA20-C1 hava aracında uçuş esnasında tek manyeto ile çalışma durumunu, derin öğrenme tabanlı ses analizi yöntemiyle otomatik olarak tespit eden bir sistem geliştirilmiştir. Motor ses sinyallerinden Mel Frekans Kepstral Katsayıları (MFKK) kullanılarak öznitelikler çıkarılmış ve bu öznitelikler Evrişimsel Sinir Ağları (ESA) ile sınıflandırılarak sistemin çift manyeto veya tek manyeto çalışma durumlarını ayırt etmesi sağlanmıştır.

Yöntemin özgün katkısı, uçuş sırasında pasif ve sürekli bir manyeto izleme sistemi önermesi ve derin öğrenme teknikleriyle motor sesindeki karakteristik değişimleri otomatik olarak tanıyabilmesidir. Geliştirilen model, her iki manyetonun çalıştığı ses ile yalnızca bir manyetonun çalıştığı sesi ayırt edebilmekte ve daha önce öğrenilmemiş bir motor sesi verildiğinde bu sesin hangi duruma karşılık geldiğini sınıflandırabilmektedir. Bu yaklaşım, pilotlara uçuş sırasında anlık ve güvenilir manyeto durumu bilgisi sunarak olası ikincil arızalar öncesinde erken uyarı sağlamayı hedeflemektedir.

2. LİTERATÜR TARAMASI

Literatürde, üzerinde çalışma yapılan hava aracı hakkında genel bilgiler, ses analizi gerçekleştirilen motor ve ateşleme sisteminde kritik rol oynayan manyetolar hakkında temel teknik veriler yer almaktadır. Tek manyeto arızasının etkileyen gerçek olaylar incelenmiş ve son yıllarda yapay zekâ derin öğrenme yöntemleri kullanılarak motor seslerinin analizi yoluyla hata teşhisine yönelik yaklaşımlar incelenmiştir.

2.1. Diamond DA20-C1 Uçağı

Diamond Aircraft Industries, Avusturya merkezli bir hafif genel havacılık ve motorlu planör üreticisidir. Şirketin kökeni 1981 yılına, Wolf HOFFMANN tarafından kurulan Hoffmann Flugzeugbau adlı firmaya dayanmaktadır. Zamanla büyüyerek 1990'lı yıllarda “Diamond Aircraft” adını alan firma, genel havacılık pazarında özellikle kompozit malzeme teknolojisini kullanarak hafif ve dayanıklı uçaklar üretmesiyle tanınmıştır. Şirketin merkez ofisi Avusturya'nın Wiener Neustadt kentinde yer almakta olup, üretim tesisleri Kanada'nın Ontario eyaletinde ve Çin'de bulunmaktadır (Advantage Austria, 2025).

Diamond Aircraft, uçak gövdesinde karbon fiber ve fiber-cam esaslı kompozit malzeme kullanımıyla öne çıkar. Bu yaklaşım, uçakların hem ağırlık hem de bakım maliyeti açısından avantajlı olmasını sağlamaktadır. Firmanın ürün yelpazesi, tek motorlu ve çift motorlu uçakları bulunmaktadır (Diamond Aircraft, 2025). Şirketin vizyonu, güvenli, ekonomik ve çevreci uçuş sistemleri geliştirmeye yöneliktir.

Diamond DA20-C1 modeli, firmanın iki kişilik, tek motorlu, sabit üç tekerlekli iniş takımına sahip eğitim uçağıdır. DA20 serisinin kökeni 1990'ların ortasına kadar uzanmakta olup, C1 versiyonu 1998 yılında tanıtılmıştır. DA20-C1, önceki Rotax motorlu versiyonların (örneğin DA20-A1) aksine 125 beygir gücünde Continental IO-240-B32B motoruyla donatılmıştır (Wikipedia, 2025). Bu motor, geleneksel havacılık yakıtı avgas ile çalışmakta ve daha yüksek performans sunmaktadır.



Görsel 2.1. *Diamond DA20-C1 Uçağının Genel Görünüşü (Diamond Aircraft,2025)*

DA20-C1, çoğunlukla pilot eğitimi amacıyla kullanılır. Dünya genelinde birçok uçuş okulunda, ilk yalnız uçuşlar ve temel eğitim aşamalarında tercih edilir. Uçağın kompozit yapısı korozyona dayanıklı olduğu için bakım maliyetlerini azaltır. Kokpit tasarımı, orta kontrol çubuğu ve geniş görüş alanı sağlayan cam tavanıyla pilotlara rahat bir uçuş deneyimi sunar. Ayrıca düşük yakıt tüketimi ve yüksek manevra kabiliyeti sayesinde uçuş eğitimi maliyetlerini düşürür (Lifestyle Aviation, 2025). Diamond DA20-C1 uçağının genel özellikleri tablo 2.1’de sunulmuştur.

Tablo 2.1. *Diamond DA20-C1 Genel Özellikleri (Diamond Aircraft Industries, 2022)*


Özellik	Değer/Açıklama
Motor Gücü	125 beygir
Pervane	2 kanatlı sabit hatveli ahşap pervane
Yakıt Türü	AVGAS (havacılık benzini)
Yakıt Kapasitesi	92,7 litre
Azami Kalkış Ağırlığı	800 kilogram
Azami Hız	240 kilometre/saat
Azami Menzil	1 008 kilometre
Azami Uçuş Süresi	5,1 saat
Servis İrtifası	4 000 metre
Kalkış Mesafesi	383 metre
İniş Mesafesi	202 metre
Azami Uçuş Hızı	304 kilometre/saat
Kalkış Hızı	81 kilometre/saat
Azami Yanal Rüzgâr	37 kilometre/saat

Genel olarak, Diamond Aircraft Industries'in modern üretim teknolojileri, güvenli ve ekonomik uçak tasarımlarıyla birleştiğinde, DA20-C1 modeli hem eğitim hem de bireysel pilotaj açısından son derece uygun bir platform sunmaktadır. Kompozit malzeme teknolojisinin sağladığı avantajlar, aerodinamik verimlilik ve düşük işletme maliyetleri, bu uçağı hafif genel havacılık alanında önemli bir seçenek haline getirmiştir. Diamond Aircraft, modern kompozit malzemeler kullanarak hafif, verimli ve teknolojik olarak gelişmiş uçaklar üreten bir firmadır. Şirketin iki koltuklu, alçak kanatlı eğitim ve genel maksat uçağı olan DA20-C1, tercih edilen ürünüdür.

2.2. Manyetolar

Havacılıkta piston motorları, genellikle içten yanmalı dört zamanlı motor prensibine göre çalışır. Bu motorlarda ateşleme, buji elektrotları arasında yüksek gerilimli bir kıvılcım oluşturularak sağlanır. Uçaklarda, bu yüksek gerilimi üretmek için en yaygın yöntem manyeto sistemidir (FAA, 2016). Manyeto sistemi, elektromanyetik indüksiyon prensibine dayanarak mekanik enerjiyi elektrik enerjisine dönüştürür. Motor krank miline mekanik olarak bağlı olan manyeto, döndükçe bünyesinde bulunan mıknatıs ve bobinler aracılığıyla yüksek voltaj oluşturur ve bu enerji bujilere iletilerek silindir içerisindeki hava-yakıt karışımının ateşlenmesini sağlar (Kroes, Wild ve Delp, 2013). Bu özelliğı sayesinde manyeto, uçak elektrik sisteminden bağımsız çalışır ve elektriksel bir arıza durumunda dahi motorun çalışmaya devam edebilmesine olanak tanır.


Diamond DA20-C1 uçağında bir çok farklı motor kullanılmıştır. Bu çalışmada Continental IO-240-B32B motoru üzerinde çalışmalar gerçekleştirilmiştir. Continental IO-240-B32B motoru, hava soğutmalı, dört silindirli bir piston motordur. 3.9 litre hacme sahip olan bu motor, 125 beygir gücü üretebilmekte ve dakikada 2575 devir ile maksimum güce ulaşmaktadır (Continental Motors, 2011). Continental IO-240-B32B motoru silindir numaralandırması görsel 2.2.'de sunulmuştur. Tüm hava araçlarında olduğu gibi motor, birbirinden bağımsız olarak çalışan çift manyeto sistemi ile donatılmıştır. Bu sistem, emniyet açısından kritik öneme sahiptir çünkü bir manyetonun arızalanması durumunda diğer manyeto motorun çalışmasını sürdürmesine olanak tanımaktadır.



Görsel 2.2. Continental IO-240-B32B Motoru Silindir Numaralandırılması (Continental Motors, 2011)


Manyetolar, Faraday'ın elektromanyetik indüksiyon yasasına göre çalışır. Rotor mıknatıs, manyetik akı çizgilerini bobin üzerinde hareket ettirir. Kam mili, kırıcı platinleri uygun zamanda açarak manyetik alanın aniden çökmesine neden olur. Bu çökme, bobin üzerinde yüksek gerilim oluşturur ve bu enerji bujiye iletilir (Jeppesen, 2022).

Manyetoların performansı, uçuş öncesi kontrollerde pilot tarafından yapılan manyeto testiyle değerlendirilir. Motor belirli bir devrede çalıştırılırken sol, sağ ve her iki manyeto pozisyonları arasında geçiş yapılır. 1700 devir/dakika ya ayarlanan motor ardından, ateşleme anahtarıyla sol ve sağ pozisyonları seçilir. 25 ile 150 devir/dakika düşüş kabul edilir limitlerdir. İki manyeto arasında maksimum 50 devir/dakika fark normal kabul edilir (Diamond Aircraft Industries, 2012). Bu test, ateşleme sistemindeki arızaları veya buji hatalarını erken tespit etmeye yardımcı olur. Diamond DA20-C1 hava aracına ait ateşleme kontrol anahtarlaması görsel 2.3.'de sunulmuştur.



Görsel 2.3. Diamond DA20-C1 Ateşleme Kontrol Anahtarı (Diamond Aircraft Industries, 2022)

IO-240-B32B motorunda kullanılan manyetolar, manyeto başına yaklaşık 3000-5000 volt arasında değişen yüksek voltaj üretebilmektedir. Manyetik devrenin sürekli olarak manyetik akı değişimine dayanan bu sistemde, manyetik alan değişimleri birincil devrede düşük voltajlı akım indüklemekte, kırıcı mekanizmasının devreyi aniden açmasıyla manyetik alanın hızla çökmesi sonucu ikincil sargıda yüksek voltaj oluşmakta ve bu voltaj distribütör aracılığıyla ilgili bujiye iletilmektedir. Görsel 2.4.'de gösterildiği gibi sağ manyeto silindirlerin üst bujilerini enerjilendirirken, sol manyeto ise silindirlerin alt bujilerini enerjilendirmektedir (Continental Motors, 2011).



Görsel 2.4. Continental Motors Manyetolar ve Ateşleme Noktaları (Continental Motors, 2011)

Manyetolar, motorun tamamen bağımsız bir elektrik kaynağına sahip olmasını sağlar. Bu sayede, uçağın elektrik sistemi arızalansa bile motor çalışmaya devam eder. Bu durum özellikle uçuş güvenliği açısından büyük avantaj sağlar (Jeppesen, 2022). Ayrıca çift manyeto sistemi hem ateşleme güvenilirliğini artırır hem de yanma verimini iyileştirir. Manyetolar, piston motorlu uçakların kalbi sayılabilecek kadar kritik bir bileşendir. Basit ama güvenilir yapıları sayesinde, modern havacılığın temel güvenlik prensiplerinden biri olan yedeklilik ilkesini somutlaştırırlar.

Günümüzde elektronik ateşleme sistemleri gelişmiş olsa da mekanik olarak çalışan manyetolar hâlâ dünya genelinde yaygın şekilde kullanılmakta ve uçuş emniyetinde önemli bir rol oynamaktadır.

2.3. Manyeto Arızası ile İlgili Yaşanılan Kazalar

Bu çalışma, piston motorlu uçaklarda kullanılan manyeto sistemlerinin yapısı, çalışma prensibi, avantajları ve havacılık emniyeti açısından önemini incelemektedir. Manyetolar, uçak motorlarında yakıt-hava karışımının ateşlenmesi için gereken kıvılcımı, harici bir enerji kaynağına ihtiyaç duymadan üreten bağımsız ateşleme sistemleridir. Herhangi bir manyetonun arızalanması sonucunda uçuş tek manyeto ile devam etmektedir. Herhangi bir manyetonun devreden çıkması oluşturacağı küçük devir düşüşü pilot tarafından hissedilemeyebilir.

26 Mayıs 2018'de Hillsboro, Oregon'da bir eğitim uçuşu sırasında, Cessna 152 tipi uçak inişten vazgeçip tekrar tırmanış esnasında kısmi motor gücü kaybı yaşadı. Yapılan incelemeler, kazanın sol manyetodaki bakır elektrot parmağının yerinden oynamasından kaynaklandığını ortaya koydu. Bu arıza, manyetonun düzensiz kıvılcım üretmesine ve motorun güç kaybetmesine neden oldu. Zorunlu iniş sonucu uçak ters döndü ve ağır hasar gördü, ancak mürettebat yara almadı (UUGK, 2021).

12 Temmuz 2000 tarihinde Texas eyaletinin Columbus kenti yakınlarında meydana gelen kazada, Cessna 172N tipi uçak seyir uçuşu sırasında tam motor gücü kaybı yaşamıştır. Kalkış öncesi yapılan manyeto kontrolünde sağ manyetoda 300–500 devir/dakika aralığında anormal bir devir düşüşü tespit edilmiş, ancak tekrarlanan kontrollerde manyetoların normal çalıştığı değerlendirilmiştir. Seyir irtifasında motor devrinin yeniden düşmesi üzerine yapılan kontrolde sağ manyetonun devre dışı kaldığı belirlenmiştir. Pilot, en yakın bakım imkânı bulunan havaalanına yönelmiş, ancak kısa süre sonra motor tamamen durmuştur ve uçak zorunlu iniş yapmak zorunda kalmıştır. Kaza sonrasında yapılan incelemelerde motorun çalıştırılmadığı, tek tahrikli çift manyetolu sistemde bulunan her iki manyetonun da kıvılcım üretmediği tespit edilmiştir. Detaylı incelemede, manyetolardaki neopren kam takipçilerinin erimesi nedeniyle kontakların açılmadığı ve ateşlemenin gerçekleşmediği belirlenmiştir. UUGK tarafından kazanın muhtemel nedeni, çift manyetolu üniteye her iki manyetonun da arızalanması

olarak açıklanmış; zorunlu iniş için uygun arazi bulunmaması kazaya katkıda bulunan faktör olarak belirtilmiştir (UUGK, 2001).

2.4. Yapay Zekâ ile Ses Analizi Yaklaşımları

2.4.1. Evrişimli sinir ağları (ESA) kullanan ses tabanlı arıza teşhisi çalışmaları

Evrişimli Sinir Ağları (ESA), ses sinyallerinin spektrogram veya diğer görsel temsilleri üzerinde yüksek doğrulukla özellik çıkarabildiği için ses tabanlı arıza teşhisinde en yaygın kullanılan derin öğrenme yöntemlerinden biridir.

2.4.1.1. Otomotiv ve taşıt araçlarındaki uygulamalar

Otomobil motorlarından motosikletlere kadar geniş bir yelpazede, ESA'lar ses sinyallerini kullanarak yüksek doğrulukta arıza teşhisi için kullanılmıştır. Otomobil motorlarındaki arızaların tespiti için 1 ve 2 boyutlu Evrişimli Sinir Ağları, Yapay Sinir Ağları (YSA) ve Uzun Kısa Süreli Bellek (UKSB) ağları gibi modeller denenmiş ve %99 doğruluk oranına ulaşılmıştır (Erdoğan, Küçükmanisa ve Kilimci, 2023). Benzer şekilde, elektrikli motosiklet arızalarının teşhisinde ses sinyallerinin spektrogramları ESA ile analiz edilerek etkili bir yöntem olduğu kanıtlanmıştır (Chen vd., 2021). Başka bir çalışmada, araç arıza teşhisi için AlexNet, GoogLeNet, ShuffleNet gibi önceden eğitilmiş popüler ESA mimarileri kullanılmış ve %95'in üzerinde doğruluk elde edilmiştir (Liu vd., 2025).

2.4.1.2. Sanayi ve ağır ekipmanlardaki uygulamalar

Endüstriyel ekipmanların sürekliliğini sağlamak için önleyici bakım kritik öneme sahiptir. Su altı itici pervanelerinin arıza teşhisi için Derin Evrişimli Sinir Ağları (DESA) kullanılmış, akım ve ses sinyallerinin birleştirilmesiyle %99.88 gibi olağanüstü bir doğruluk sağlanmıştır (Wang vd., 2024). Sıhhi tesisat arızalarının tespiti için 1 boyutta ESA'lar kullanılarak %99'un üzerinde doğruluk ve son derece hızlı işlem süresi elde edilmiştir (Monteiro ve Bastos-Filho, 2019). Dişli arıza teşhisi alanında, manuel özellik çıkarımına gerek kalmadan ham ses sinyallerini işleyebilen uçtan uca bir ESA modeli geliştirilmiş ve %100'e varan doğruluk performansı gösterilmiştir (Yao vd., 2018). Santrifüj pompa fanları ve genel döner makineler üzerine yapılan çalışmalar da ESA

tabanlı yaklaşımların, geleneksel yöntemlere kıyasla üstün teşhis doğruluğu sağladığını ortaya koymuştur (Janssens vd., 2016; Sacaklıdır ve Koc, 2024).

2.4.1.3. İnşaat ve madencilik sektörüne yönelik çalışmalar

Ağır çalışma koşullarına sahip sektörlerdeki ekipmanlar için de ESA'lar başarıyla uygulanmıştır. Sondaj makinelerinin arıza teşhisi için ses sinyallerinin skalogram ve Mel spektrogram temsilleri, GoogLeNet gibi bir ESA mimarisi ile sınıflandırılmış ve yöntemin sağlamlığı kanıtlanmıştır (Tran ve Lundgren, 2020). Bir başka sondaj çalışmasında, seslerin güç spektrumundan oluşturulan görüntüleri, bir Derin Evrişimli Otomatik Kodlayıcı (DEOK) ile işlenerek ayırt edici özellikler çıkarılmış ve gürültülü ortamlarda bile başarılı teşhisler yapılmıştır (Vununu vd., 2018).

2.4.1.4. Transfer öğrenme ile güçlendirilmiş ESA uygulamaları

Veri miktarının sınırlı olduğu durumlarda, transfer öğrenmesi ESA'ların performansını artırmada hayati bir rol oynar. Rulman arıza teşhisi alanında, bir çalışma başlangıçta YouTube kliplerinden milyonlarca ses örneği üzerine eğitilmiş olan YAMNet adlı önceden eğitilmiş ESA modelini kullanmıştır (Brusa vd., 2021). Benzer şekilde, diğer çalışmalar ses sınıflandırması için önceden eğitilmiş VGGish mimarisini titreşim verileri üzerinde ince ayar yaparak kullanmış ve %99'un üzerinde doğruluk elde etmiştir. Bu yaklaşım, özellikle sınırlı sayıda arıza verisi bulunan endüstriyel senaryolarda pratik bir çözüm sunmaktadır (Di Maggio, 2023; Jia vd., 2017).

Evrişimli Sinir Ağlarının otomotivden ağır sanayiye, enerjiden madencilığe kadar çok çeşitli sektörlerdeki ses tabanlı arıza teşhisi problemlerinde hakim bir teknik olduğunu açıkça göstermektedir. Bu çalışmalar, ESA'ların hem ham ses verilerinden doğrudan özellik öğrenebilme hem de spektrogram gibi 2 boyutlu temsiller üzerinde yüksek performans gösterme yeteneği sayesinde, tutarlı bir şekilde %90'ın çok üzerinde teşhis doğruluğuna ulaştığını belgelemektedir.

2.4.2. Geleneksel makine öğrenimi yöntemleri kullanan ses tabanlı arıza teşhisi çalışmaları

Derin öğrenmenin yaygınlaşmasına rağmen, geleneksel makine öğrenimi algoritmaları özellikle sınırlı veri setlerinde, düşük hesaplama maliyeti gerektiren uygulamalarda veya yorumlanabilirliğin ön planda olduğu durumlarda ses tabanlı arıza teşhisinde etkin bir şekilde kullanılmaya devam etmektedir. Bu yöntemler, genellikle ses sinyallerinden çıkarılan manuel olarak seçilmiş MFKK, istatistiksel parametreler vb. özellikler üzerinde eğitilir.

2.4.2.1. Destek vektör makineleri (DVM) ile yapılan çalışmalar

DVM, sınıflar arasında optimal bir ayırma hiper düzlemi bulmaya dayalı, güçlü bir sınıflandırma algoritmasıdır. Rulman arıza teşhisi üzerine yapılan bir çalışmada, ses sinyalleri kullanılarak lineer, Radyo Tabanlı Fonksiyon (RTF) ve sigmoid çekirdek fonksiyonlarıyla test edilen c-DVM ve v-DVM modelleri karşılaştırılmıştır (Hemantha Kumar vd., 2012). Sonuçta, RTF çekirdeği kullanan c-SVM modeli %92.22 doğruluk oranıyla en yüksek performansı göstermiştir. Başka bir uygulamada, gaz yalıtımlı şalt cihazlarının mekanik arızalarının tespiti için MFKK ile DVM kombinasyonu kullanılmış ve ortam gürültüsünden etkilenmeyen %95-99 aralığında F1 skoru elde edilmiştir (Chen vd., 2020). Ayrıca, İnsansız Hava Aracı (İHA) motorlarındaki pervane, eksenel ve yatak arızalarının tespitinde DVM algoritması, titreşim sinyallerinden çıkarılan istatistiksel özelliklerle beslenerek %99.75 gibi son derece yüksek bir doğruluk oranına ulaşmıştır (Altınors vd., 2021). Dönen rulmanlarda ise tek bir mikrofonla yakalanan ses sinyallerinden çıkarılan özellikler üzerinde DVM'nin performansı, K-en Yakın Komşu (KYK) ve Çekirdek Doğrusal Ayırıcı Analiz (ÇDAA) gibi diğer geleneksel yöntemlerle karşılaştırılmıştır (Altaf vd., 2019).

2.4.2.2. Karar ağaçları ve türevleri ile yapılan çalışmalar

Karar ağaçları, özellikle küçük ve orta ölçekli veri setlerinde etkili ve yorumlanması kolay modeller sunar. Rulman arızalarını tanımak amacıyla yapılan bir araştırmada (Amarnath vd., 2013) ses sinyallerinden çıkarılan özellikler C4.5 karar ağacı algoritması ile sınıflandırılmış ve 10 katlı çapraz doğrulama sonucunda %95.5 doğruluk elde

edilmiştir. Bu çalışma, düşük maliyetli mikrofonlarla endüstriyel uygulamaların önünü açmıştır. Frezeleme takımının sağlıklı ve arızalı durumlarının sınıflandırılmasında ise J48 karar ağacı algoritması kullanılmış ve %81 civarında bir sınıflandırma doğruluğu sağlanmıştır (Madhusudana C. K. vd., 2018). Helisel dişli kutusu arızalarının teşhisine yönelik bir başka çalışma, KYK algoritmasını ses sinyalleri üzerinde uygulamış ve %94.3 gibi yüksek bir sınıflandırma doğruluğuna ulaşmıştır (Amarnath vd., 2016).

2.4.2.3. Aşırı öğrenme makinesi (AÖM) ile yapılan çalışmalar

AÖM, tek katmanlı ileri beslemeli sinir ağları için hızlı bir öğrenme algoritmasıdır ve geleneksel yöntemlere kıyasla daha kısa eğitim süreleri sunar. Motosikletlerdeki motor arızalarının sınıflandırılması için ses sinyallerinden çıkarılan zaman, frekans ve dalgacık gibi hibrit özellik setleri AÖM ile kullanılmış ve geleneksel YSA'lara kıyasla daha yüksek doğruluk elde edilmiştir (Jayasree ve Prem Ananth, 2020). İnsansız su altı araçlarında sık görülen itki sistemi arızalarının teşhisinde, hidrofonla kaydedilen ses sinyallerinin temel frekansı ses sinyallerinden temel frekansı tahmin etmek için kullanılan, interpolasyon tekniğine dayanan bir algoritma tahmincisi ile çıkarılarak AÖM'de değerlendirilmiştir (Chan ve Chin, 2017). Dalgıç motor pompalarında yapılan karşılaştırmalı bir incelemede, ELM sınıflandırıcısının alternatif yöntemlere kıyasla üstün genelleme yeteneği ve yüksek performans sergilediği doğrulanmıştır (Rauber vd., 2017). Eksenel pistonsuz hidrolik pompalardaki karmaşık arızaların çözümünde ise MFKK özellikleri ile AÖM kombinasyonu kullanılmış; AÖM'nin, geri yayılımlı sinir ağı ve DVM yöntemleri ile karşılaştırıldığında tanıma doğruluğu ve süresi açısından daha avantajlı olduğu kanıtlanmıştır (Jiang vd., 2019).

Geleneksel makine öğrenimi yöntemleri, özellikle hesaplama kaynaklarının kısıtlı olduğu, verinin az olduğu veya modelin yorumlanabilirliğinin önem taşıdığı ses tabanlı arıza teşhisi senaryolarında geçerliliğini korumaktadır. DVM, Karar Ağaçları ve AÖM gibi algoritmalar, uygun özellik mühendisliği ile birleştirildiğinde, birçok pratik uygulamada %80 ile %99 üzerinde arasında değişen yüksek teşhis doğruluklarına ulaşabilmektedir. Bu yöntemler, derin öğrenmenin karmaşıklığına gerek duyulmayan durumlarda sağlam, verimli ve güvenilir alternatifler sunar.

2.4.3. İleri derin öğrenme mimarileri kullanan ses tabanlı arıza teşhisi çalışmaları

Derin öğrenmenin temel mimarilerinin ötesinde, otomatik kodlayıcılar, üretici çekişmeli ağlar (ÜÇA), graf sinir ağları (GSA) ve Federatif Öğrenme (FÖ) gibi daha ileri yöntemler, ses tabanlı arıza teşhisinde önemli yenilikler getirmiştir. Bu mimariler, genellikle denetimsiz öğrenme, veri sentezi, ilişkisel modelleme veya gizlilik koruma gibi spesifik zorlukları ele almak için kullanılır.

2.4.3.1. Otomatik kodlayıcılar ile yapılan çalışmalar

Otomatik kodlayıcılar, veriyi verimli bir şekilde temsil etmeyi öğrenerek anomali tespiti için güçlü araçlardır. Rulman arıza teşhisi üzerine bir çalışma, ses sinyallerini önce Kısa Süreli Fourier Dönüşümü (KSFD) ile zaman-frekans alanına eşlemiş, ardından bu temsillerden içsel arıza özelliklerini otomatik olarak çıkarmak için İstiflenmiş Seyrek Otomatik Kodlayıcı (SOK) kullanmış ve yöntemin geniş bir makine yelpazesinde uygulanabilir olduğunu göstermiştir (Liu vd., 2016). Titreşim, ses ve akustik emisyon sinyallerini kullanan başka bir araştırma, Denetimli Derin İleri Beslemeli Sinir Ağı (DDİBSA) ve SOK gibi mimarileri karşılaştırmış ve SOK'un titreşim ve akustik emisyon sinyalleri kullanılarak daha yüksek sınıflandırma doğruluğu sağladığını kanıtlamıştır (Kumar vd., 2024). Dişli arıza teşhisi alanında ise, yüksek hesaplama maliyetlerini aşmak için marjinalleştirilmiş SOK yöntemi önerilmiş ve bu yöntemin, geleneksel SOK'a kıyasla yüksek tanılama doğruluğunu korurken daha düşük hesaplama maliyeti sunduğu doğrulanmıştır (Xiao vd., 2020).

2.4.3.2. Üretici çekişmeli ağlar (ÜÇA) ve anomali tespiti

ÜÇA'lar, özellikle normal verilerin bol miktarda bulunduğu ancak anormal/arızalı verilerin nadir olduğu denetimsiz anomali tespiti senaryolarında kullanılır. Hava kompresörlerinin anormal ses algılamasını gerçekleştirmek için yapılan bir çalışma, derin evrişimli ÜÇA modelini başlangıç ağı ve yapısal benzerlik fonksiyonu (YBF) ile geliştirerek kullanmış ve anormal seslerin ayırt edilmesinde %95 doğruluk oranına ulaşmıştır (Zhao, 2022). Soğutma üniteleri için yapılan iki ayrı araştırma, ses sinyallerinin spektrogramlarına dönüştürülmesinin ardından verimli ÜÇA tabanlı bir denetimsiz anomali tespit yöntemi önermiş ve bu yöntemin, otomatik kodlayıcı ve varyasyonel

otomatik kodlayıcı gibi diğer derin üretici modellere kıyasla daha yüksek doğruluk sağladığını göstermiştir (Hatanaka, 2021; Saçaklıdır ve Koç, 2024).

2.4.3.3. Graf sinir ağları (GSA) ve federatif öğrenme

Bu mimariler, veri gizliliği ve karmaşık ilişkilerin modellenmesi gibi gelişmiş gereksinimleri ele alır. Asansör kapı sistemi arıza tahmini üzerine yapılan karmaşık bir çalışma, Grafik Sinir Ağı (GSA) ile UKSB ağını bir araya getiren ve Etki Alanı Uyarlamalı Çekişmeli Ağ ile güçlendirilmiş yeni bir modeli önermiştir (Pan vd., 2024). Bu model, veri noktaları arasındaki karmaşık ilişkileri ve derin zaman serisi özelliklerini ortaya çıkararak, diğer aktarım öğrenimi yöntemlerine kıyasla üstün tahmin performansı sergilemiştir. Döner makinelerde veri gizliliğini koruyarak arıza teşhisi için yapılan bir araştırma, FÖ tabanlı metodolojisini önermiştir (Vijyalakshmi vd., 2024). Bu yöntem, verileri merkezi bir sunucuda toplamak yerine yerel cihazlarda tutarak modelleri eğitmiş ve Çok Katmanlı Algılayıcı ve ESA için tahmin doğruluğunda %3.5'lik bir iyileşme sağlamıştır.

2.4.3.4. Diğer ileri mimariler

Döner makinelerde sağlam arıza tespiti için yapılan bir çalışma, geleneksel Evrişimli Sinir Ağlarından farklı olarak, öz-örgütlü işlemsel sinir ağları kullanmıştır (Kiranyaz ve diğ., 2024). Bu mimari, ses tabanlı arıza tespit performansının, en iyi titreşim tabanlı muadiliyle eşleşebileceğini ve hatta sensör konumundaki değişikliklere karşı daha dayanıklı olabileceğini göstermiştir.

İleri derin öğrenme mimarileri, ses tabanlı arıza teşhisi alanını denetimsiz öğrenme, veri sentezi, karmaşık ilişki modellemesi ve gizlilik koruma gibi yönlerden zenginleştirmektedir. Otomatik kodlayıcılar ve ÜÇA'lar anomali tespitinde, GSA'lar ilişki verilerde, FÖ ise dağıtık ve gizli verilerle çalışmada yeni ufuklar açmaktadır. Bu yöntemler, geleneksel ve temel derin öğrenme yaklaşımlarının çözemediği daha karmaşık endüstriyel problemlere etkili çözümler sunma potansiyeline sahiptir.

2.4.4. Ön işleme ve özellik çıkarma yöntemleri kullanan ses tabanlı arıza teşhisi çalışmaları

Ses sinyallerinin ham halinden anlamlı bilgi çıkarabilmek için uygulanan ön işleme ve özellik çıkarma teknikleri, herhangi bir makine öğrenimi veya derin öğrenme tabanlı arıza teşhis sisteminin başarısında kritik bir rol oynar. Bu yöntemler, sinyali daha iyi temsil edilebilir ve sınıflandırılabilir bir forma dönüştürür.

2.4.4.1. Zaman-frekans analiz yöntemleri

Ses sinyallerinin durağan olmama özelliği, zaman ve frekans bilgisini aynı anda içeren temsilleri gerekli kılar. Rulman arıza teşhisi için yapılan bir çalışma, sinyalleri ilk olarak KSFD ile zaman-frekans alanına eşleyerek sonraki özellik çıkarma aşamasına hazır hale getirmiştir (Sacaklıdır ve Koc, 2024). Değişen hız koşulları altında çalışan makinelerin ses sinyallerini analiz eden bir araştırma, her bir ses kaydının bir zaman-frekans gösterimi olan mel spektrogramını kullanarak giriş özelliğinin boyutunu küçültmeyi başarmıştır (Frusque, Michau, ve Fink, 2021). Sondaj kusurlarının tespiti ve hidrolik piston pompası arıza teşhisi gibi farklı uygulamalarda, ses sinyallerinin 2 boyutta zaman-frekans görüntülerine dönüştürülmesi için Sürekli Dalgacık Dönüşümü başarıyla uygulanmıştır (Tang, Zhu, ve Yuan, 2021; Tran ve Lundgren, 2020). Hidroelektrik üretim ünitelerinin anormal ses teşhisinde, sürekli dalgacık dönüşümü ve görselleştirmeye dayalı zaman-frekans analizi yapılmış ve ağır arka plan gürültüsüne rağmen %98'in üzerinde doğruluklara ulaşılmıştır (Liu vd., 2024).

2.4.4.2. Spektral ve ses tabanlı özellik çıkarma

Endüstriyel ürünlerin anormal ses tespiti için yapılan bir çalışma, MFKK kısa süreli enerji özelliklerini de ekleyerek geliştirdiği hibrit bir özellik çıkarma yöntemi önermiş ve bu yöntemin saf MFKK'ya kıyasla daha iyi performans ve daha doğru anomali tespiti sağladığını göstermiştir (Fan, 2022). Matkap uçlarının izlenmesi için yapılan araştırma, seslerin güç spektrumunu görüntüler olarak temsil etmiş ve bu görüntüleri bir derin evrişimli otomatik kodlayıcı ile işleyerek yüksek seviyeli, gürültüye karşı sağlam özellikler çıkarmayı başarmıştır (Vununu ve ark., 2018). Dişli kusur tespit sistemlerinde hesaplama süresini azaltmayı amaçlayan bir çalışma, yalnızca birkaç spesifik frekans

bandının toplamalarını kullanarak, geleneksel spektrogram tabanlı yöntemlere kıyasla daha düşük hesaplama gereksinimiyle %95.5 doğruluk sağlamıştır (Kim vd., 2022). Bant konveyör rulmanlarının arıza tespitinde ve mekanik arıza teşhisinde MFKK özellikleri DVM ile başarıyla eşleştirilmiştir (Chen vd., 2019; Liu vd., 2020).

2.4.4.3. Gürültü giderme ve sinyal iyileştirme

Endüstriyel ortamlarda ses sinyalleri genellikle yüksek seviyeli gürültü ile kirlenmiştir. Güçlü gürültü ortamında bantlı konveyör silindir arızalarını tespit etmek için yapılan bir çalışma, ses sinyallerini temizlemek üzere Varyasyonel Model Ayırıştırma kullanmış ve ardından temizlenmiş sinyalleri bir Swin Transformer ağı ile sınıflandırarak %99.36'ya varan doğruluk elde etmiştir (Ban vd., 2024). Akıllı fabrika ortamında gürültü desen analizi yapan bir diğer araştırma, iki aşamalı bir veri ön işleme yöntemi önermiş; ham ses verilerini sayısal verilere dönüştürerek eğitim süresini önemli ölçüde kısaltmış ve modelin aşırı öğrenme sorununu çözmede başarılı olmuştur (Pradeep vd., 2022).

Ön işleme ve özellik çıkarma, bir arıza teşhis sisteminin temel taşıdır. Zaman-frekans analizleri sinyalin yapısını yakalamak için vazgeçilmezdir. MFKK gibi ses-tabanlı özellikler ise makine seslerinin karakteristik desenlerini yakalamada son derece etkilidir. Ayrıca, gürültünün hakim olduğu gerçek koşullarında, Varyasyonel Model Ayırıştırma gibi gelişmiş gürültü giderme teknikleri, teşhis performansını büyük ölçüde artırmaktadır. Doğru ön işleme ve özellik çıkarma stratejisi seçimi, kullanılan sınıflandırıcıdan bağımsız olarak sistemin genel başarısını doğrudan belirler.

2.5. Ses Tabanlı Arıza Teşhisinde Yapay Zekâ Tekniklerinin Karşılaştırılması

Endüstriyel bakım stratejilerinde öngörücü bakımın önemi arttıkça, makine arızalarının erken tespiti için geliştirilen otomatik teşhis sistemlerine olan ihtiyaç da artmıştır. Geleneksel titreşim analizine alternatif olarak, ses sinyali analizi düşük maliyetli, temasız ve uzaktan uygulanabilir olması nedeniyle son yıllarda önemli bir araştırma alanı haline gelmiştir. Bu makalede, ses tabanlı arıza teşhisi alanında kullanılan yapay zekâ teknikleri dört ana kategori altında incelenmiş ve her bir yöntemin avantajları ile sınırlılıkları literatürdeki çalışmalar üzerinden değerlendirilmiştir.

Derin öğrenme tabanlı ses analizi üzerine yürütülen çalışmalar, makine ve ekipman arızalarının ses sinyalleri aracılığıyla teşhis edilmesi, anomali tespiti, performans izleme ve durum değerlendirme gibi farklı uygulama alanlarını kapsamaktadır. Her bir makale, kullanılan yöntem, öznelilik çıkarım tekniği, doğruluk oranı ve modelleme yaklaşımı açısından sistematik biçimde sınıflandırılmıştır. Bu sınıflandırma sonucunda, derin öğrenme yöntemlerinin son yıllarda ses tabanlı arıza teşhisinde baskın hale geldiği; buna karşın geleneksel makine öğrenimi algoritmalarının belirli koşullarda hâlâ etkin biçimde kullanıldığı görülmüştür.


Elde edilen sonuçlara göre, ESA ve transfer öğrenme modelleri, ses sinyallerinden doğrudan öznelilik öğrenebilme yetenekleri sayesinde en yüksek doğruluk oranlarına ulaşmıştır. Bununla birlikte, bu modellerin eğitimi için yüksek işlem gücü ve büyük miktarda etiketli veri gereksinimi dikkat çekmektedir. Buna karşın, DVM ve AÖM gibi geleneksel yaklaşımlar, daha az veriyle bile tutarlı performans göstermeleri ve kısa eğitim süreleri nedeniyle birçok endüstriyel uygulamada tercih edilmektedir. Bu durum, literatürdeki farklı metodolojilerin aslında birbirini tamamlayıcı nitelikte olduğunu göstermektedir.

Derin öğrenme tabanlı ses analizi literatürünün dikkat çeken bir başka yönü de ön işleme tekniklerinin başarımlar üzerindeki belirleyici rolüdür. MFKK, Sürekli Dalgacık Dönüşümü ve Kısa Süreli Fourier Dönüşümü gibi zaman-frekans tabanlı dönüşümler hem geleneksel hem derin modellerin girişinde yaygın biçimde kullanılmıştır. Özellikle MFKK, literatür araştırmasındaki çalışmaların yaklaşık %40'ında temel öznelilik çıkarım tekniği olarak yer almıştır. Bu, derin öğrenmenin yükselişine rağmen sinyal işleme temellerinin hâlâ önemini koruduğunu göstermektedir. Ayrıca transfer öğrenme temelli yaklaşımlar, YouTube, AudioSet gibi geniş veri tabanlarında önceden eğitilmiş VGGish ve YAMNet ağlarının kullanımıyla küçük veri setlerinde bile yüksek doğruluk sağlamıştır.

Bu kapsamlı analiz, derin öğrenme tabanlı ses analizi alanında metodolojik bir olgunlaşmanın yaşandığını ortaya koymaktadır. Başlangıçta MFKK + DVM gibi hibrit yaklaşımlar hâkimken, 2018 sonrasında ESA ve UKSB gibi mimarilerin artan başarımları, bu alanda paradigma değişimini tetiklemiştir. Son yıllarda ise ÜÇA ve Autoencoder tabanlı modellerin anomali tespiti, veri artırma ve gürültüden arındırma gibi alanlarda hızla yayıldığı görülmektedir. Bu çeşitlilik, yapay zekâ temelli ses analizinin yalnızca

sınıflandırma değil, aynı zamanda veri kalitesi iyileştirme ve kestirimsel bakım gibi alanlara da genişlediğini göstermektedir.


Yapılan bu literatür çalışması sonucunda, ses tabanlı arıza tespitinde tek bir ideal yöntem bulunmadığını; aksine, seçilecek yöntemin sistem gereksinimleri, veri miktarı, gürültü ortamı ve açıklanabilirlik ihtiyacına göre belirlenmesi gerektiğini ortaya koymaktadır. Derin öğrenme tabanlı yaklaşımlar, doğruluk bakımından tartışmasız üstünlük sağlarken; geleneksel yöntemler, düşük maliyetli ve gerçek zamanlı uygulamalar için hâlen güçlü bir alternatif oluşturmaktadır.



Şekil 2.1. Ses tabanlı arıza teşhisinde yöntemlere göre ortalama doğruluk

Şekil 2.1.'de, incelenen yüz çalışmadan seçilen ses analizi temelli yöntemlerin ortalama doğruluk yüzdeleri artan sırayla gösterilmektedir. En düşük doğruluk ortalaması %93 ile Karar Ağaçları ve KYK grubuna aitken, en yüksek değer %99,1 ile Transfer Öğrenme modellerine aittir. ESA tabanlı derin öğrenme yaklaşımları yaklaşık %98,5 ortalama ile ikinci sırada yer almakta; bu da ses sinyallerinin karmaşık yapısal özelliklerini evrişim katmanlarıyla doğrudan öğrenebilme kapasitesinin etkisini göstermektedir. DVM ve AÖM yöntemleri %95–96 bandında toplanarak, geleneksel makine öğrenimi yaklaşımlarının hâlen rekabetçi olduğunu ortaya koymuştur. ÜÇA, otomatik kodlayıcı, GSA ve FÖ gibi ileri mimariler de %97 civarında doğruluk oranıyla yenilikçi fakat kararlı performans sergilemiştir.

Bu veriler genel olarak değerlendirildiğinde, transfer öğrenme ve ESA tabanlı derin ağların yüksek doğruluk avantajı sunduğu, ancak veri miktarı ve hesaplama maliyetinin bu başarıyı etkilediği görülmektedir. Buna karşılık AÖM ve DVM gibi yöntemler, düşük maliyetli ve hızlı uygulamalarda yüksek verimlilik sağlamaktadır. Dolayısıyla, doğruluk değerlerinin sıralı görünümü yalnızca hangi yöntemin en iyi performansı verdiğini değil, aynı zamanda hangi metodun hangi koşullarda tercih edilmesi gerektiğini de görsel biçimde vurgulamaktadır. Özellikle kısıtlı veriyle çalışan endüstriyel akustik sistemlerde AÖM ve DVM öne çıkarken, geniş veri kümeleri ve karmaşık akustik örüntüler söz konusu olduğunda transfer öğrenme yaklaşımları ideal çözüm olarak belirlenmiştir.



Şekil 2.2. Ses tabanlı arıza teşhisinde kullanılan yöntemler

Şekil 2.2’de her bir dilim, belirli bir yöntemin literatür araştırmasındaki temsili payını göstermektedir. En geniş dilimi %26,3 oranıyla ESA ve DESA (Evrşimli ve Derin Evrşimli Sinir Ağları) tabanlı çalışmalar oluşturmaktadır. Bunu %17,3 pay ile genel derin öğrenme yaklaşımları izlemektedir. DVM ve KYK yöntemleri ile Karar Ağaçları birlikte


değerlendirildiğinde, bu klasik makine öğrenmesi yaklaşımlarının toplam payının %12,8 olduğu görülmektedir. Transfer öğrenme yöntemleri literatürde %9,1 oranında temsil edilmektedir. YSA ve DSA tabanlı çalışmalar %7,3'lük bir paya sahipken, otomatik kodlayıcılar ve derin inanç ağları (DBN) %5,5, AÖM (Aşırı Öğrenme Makinesi) ise %4,5 oranında yer almaktadır. Bu değerler birlikte değerlendirildiğinde, ileri öğrenme yaklaşımlarının toplam payının %17,3 olduğu görülmektedir. ESA tabanlı ve transfer öğrenmeye dayalı çalışmaların literatürdeki payı artış gösterirken, geleneksel yöntemlerin daha çok karşılaştırmalı referans veya hibrit sistemlerin bir bileşeni olarak kullanıldığı anlaşılmaktadır. Bu dağılım, çalışmada tercih edilen MFKK tabanlı ESA yaklaşımının, güncel literatür eğilimleriyle uyumlu olduğunu açıkça ortaya koymaktadır.



3. DERİN ÖĞRENME

Derin öğrenme, yapay zekâ alanında son yıllarda yaşanan en büyük paradigma değişimlerinden birini temsil etmektedir. Geleneksel makine öğrenmesi yöntemlerinin sınırlı temsil gücünü aşarak, çok katmanlı yapay sinir ağları aracılığıyla veriden otomatik olarak anlamlı temsiller çıkarabilen bu yaklaşım, özellikle büyük ve karmaşık veri kümeleriyle çalışırken olağanüstü başarılar göstermiştir. Biyoinformatik alanında protein fonksiyon tahmini (Boadu, F., Lee, A., Cheng, J., 2024) ve mühendislikte yapısal sağlık izleme (Wang ve Cha, 2022) gibi kritik uygulamalarda derin öğrenme hem doğruluk hem de genelleme açısından önceki yöntemleri geride bırakmıştır.

Yapay sinir ağları, derin öğrenmenin temel yapı taşlarıdır. Bu ağlar, giriş verilerini bir dizi doğrusal olmayan dönüşümden geçirerek yüksek seviyeli temsiller üretir. Her katman, bir önceki katmanın çıktısını alır, ağırlıklarla çarpar, bir aktivasyon fonksiyonu uygular ve bir sonraki katmana aktarır. Bu yapı, hem denetimli hem de denetimsiz öğrenme senaryolarında kullanılabilir. Özellikle denetimsiz öğrenmenin hasar tespiti gibi etiketli veri bulmanın zor olduğu alanlarda daha uygun olduğunu vurgulamaktadır. Denetimsiz öğrenme, yalnızca normal verilerle eğitilen modellerin, daha sonra karşılaştıkları anormal verileri ayırt edebilmesini sağlar. Bu yaklaşım, özellikle büyük altyapı sistemlerinde hasar verisinin sınırlı olduğu durumlarda büyük avantaj sunar (Yeager vd., 2017; Sarmadi ve Karamodin, 2019).



Görsel 3.1. Yapay sinir ağı (Dizdar E, 2018)

Derin öğrenme modelleri, bir kayıp fonksiyonunu minimize ederek eğitilir. Bu fonksiyon, modelin tahminleri ile gerçek değerler arasındaki farkı ölçer. Geri yayılım algoritması ile ağ ağırlıkları güncellenir. Bu süreçte kullanılan optimizasyon algoritmaları arasında Stokastik Gradyan İnişi, Adam ve RMSProp gibi yöntemler yer alır. Özellikle Adam algoritması, öğrenme hızını adaptif olarak ayarlayarak daha hızlı ve kararlı bir öğrenme süreci sağlar. Wang ve Cha'nın çalışmasında, leave-one-out çapraz doğrulama yöntemiyle parametre optimizasyonunun hasar tespitinde başarıyı artırdığı gösterilmiştir (Wang ve Cha, 2022).

Derin öğrenme mimarileri arasında Evrişimli Sinir Ağları (ESA), Tekrarlayan Sinir Ağları (TSA), dikkat mekanizması ve Transformer yapıları öne çıkmaktadır. ESA'ler, uzamsal verilerde yerel örüntüleri tanımada etkilidir. Protein dizilerindeki motiflerin tanımlanmasında yapısal hasar tespitinde ise ivme verilerinden özellik çıkarımında kullanılır (Rao, R., Meier, J., Sercu, T., Ovchinnikov, S., ve Rives, A. 2021).

Derin öğrenme yalnızca bir algoritma ailesi değil, aynı zamanda veriden anlam çıkarma biçiminde köklü bir dönüşümü temsil etmektedir. Hem biyolojik hem de mühendislik sistemlerinde karmaşık örüntülerin tanımlanması, sınıflandırılması ve yorumlanması için güçlü bir araç sunar. Derin öğrenmenin temellerini anlamak, bu teknolojinin sunduğu olanakları etkili biçimde kullanabilmek için kritik öneme sahiptir.

3.1. Evrişimli Sinir Ağı (ESA)

Evrişimli Sinir Ağları (ESA), yapısal olarak görüntü işleme ve desen tanıma problemleri için geliştirilmiş olmakla birlikte, ses verilerinin analizinde de yüksek başarı göstermektedir. Bu başarının temel nedeni, ses sinyallerinin spektrogramlar veya Mel Frekans Kepstral Katsayıları (MFKK) gibi iki boyutlu matrisler halinde görsel bir temsiline kullanılabilesidir. Bu tür temsillerde bir eksen frekans içeriğini, diğer eksen ise zaman akışını ifade etmektedir. Bu yapı, ses verisinin ESA mimarileri tarafından bir görüntü girdisi olarak ele alınmasını mümkün kılmaktadır (Goodfellow vd., 2016).

ESA'ların geleneksel yöntemlere kıyasla en önemli üstünlüklerinden biri, öznetelik çıkarım sürecini otomatik olarak öğrenebilme yetenekleridir. Klasik ses analizi yaklaşımlarında, hangi özneteliklerin (örneğin ortalama enerji veya sıfır geçiş oranı) kullanılacağı insan tarafından belirlenirken, ESA'lar filtreler veya çekirdekler olarak adlandırılan küçük pencereler aracılığıyla veri üzerinde kaydırma işlemi yaparak sınıflandırma açısından kritik örüntüleri kendiliğinden keşfeder. Her bir filtre, dikey ve

yatay çizgiler ya da belirli frekans bantlarındaki ani değişimler gibi temel ve yerel desenleri algılamayı öğrenir (LeCun vd., 2015).

ESA mimarileri, hiyerarşik bir öğrenme süreci ile çalışmaktadır. İlk katmanlar, frekans–zaman uzayındaki basit bileşenleri ve temel değişimleri yakalarken, daha derin katmanlar bu basit örüntüleri birleştirerek sesin ton karakteristiği veya konuşma biçimi gibi daha karmaşık ve soyut özellik temsillerini öğrenir. Bu sayede, MFKK matrisleri bir ESA için çok boyutlu ve anlamlı bir desenler bütünü haline gelir. Ağ, bu örüntüleri analiz ederek sesin tek manyetodan veya her iki manyetodan bir etkinlik olup olmadığını ayırt edebilir. ESA'nın bu tür problemlerdeki başarısı, hem frekans eksenini boyunca hem de zaman eksenini boyunca ilişkileri eş zamanlı olarak modelleyebilme kapasitesinden kaynaklanmaktadır.

3.2. Mel Frekans Kepstral Katsayıları (MFKK)

MFKK, özellikle konuşma tanıma ve genel ses analizi alanlarında en yaygın kullanılan ve etkinliği uzun yıllardır kanıtlanmış öznelilik çıkarım yöntemlerinden biridir. MFKK'nın temel amacı, ses sinyalini insan işitme sisteminin frekans algılama özelliklerine en yakın biçimde temsil eden kompakt ve bilgilendirici bir öznelilik kümesi elde etmektir. İnsan kulağı, düşük frekanslardaki değişimlere yüksek frekanslara kıyasla daha duyarlıdır. MFKK yöntemi, bu biyolojik prensibi modellemek amacıyla Mel ölçeğini kullanmakta ve frekans spektrumunu doğrusal olmayan bir dönüşümden geçirerek kritik frekans bantlarına daha fazla ağırlık verilmesini sağlamaktadır.

Zaman eksenini boyunca hesaplanan MFKK katsayıları bir araya getirildiğinde, iki boyutlu bir matris yapısı elde edilmektedir. Bu matrisin bir boyutu frekans bileşenlerini veya kepsral katsayıları, diğer boyutu ise zamanı temsil etmektedir. Bu tür bir yapı, Evrişimli Sinir Ağları (ESA) için son derece uygun bir girdi formatı sunmaktadır. ESA'lar, MFKK matrisleri üzerindeki yerel uzamsal ve zamansal örüntüleri, örneğin belirli bir frekans bandındaki enerjinin zaman içerisindeki değişimini, otomatik olarak öğrenebilmekte ve bu sayede ses sınıflandırma, konuşma analizi ve anomali tespiti gibi görevlerde yüksek başarı elde etmektedir (Goodfellow vd., 2016).

4. MATERYAL VE YÖNTEM

Bu çalışmanın test ve deney aşaması, Diamond DA20-C1 uçağının Continental IO-240-B32B motoruna ait ses verilerinin sistematik bir şekilde toplanması ve işlenmesiyle başlamıştır. Veri toplama işlemi, motorun manyeto testi için gerekli olan optimum çalışma koşullarında gerçekleştirilmiştir. Motor yağ sıcaklığının yeterli seviyeye gelmesi beklenmiş ve bu sayede motorun kararlı çalışma durumuna ulaşması sağlanmıştır.

Veri toplama sürecinde, dakikada 1000 devirden 2300 devire kadar her 100 devir artışında, her biri 30 saniye süren kapsamlı ses kayıtları alınmıştır. Her devir değeri için sol manyeto, sağ manyeto ve her iki manyeto için ayrı ayrı kaydedilerek toplamda 39 adet ham ses verisi elde edilmiştir. sol ve sağ manyeto konfigürasyonları tek manyeto çalışma durumunu temsil ettiği için tek manyeto sınıfı altında birleştirilmiştir. Bu durumda tek manyeto sınıfı 26 kayıt, çift manyeto sınıfı ise 13 kayıt içermektedir.

Sınıf dengesizliğini gidermek amacıyla, geliştirdiğimiz yazılımda sadece çift manyeto sınıfına yönelik veri artırma teknikleri uygulanmıştır. Kod analizinde görüldüğü üzere, çift manyeto sınıfı seslerine gürültü ekleme fonksiyonu ile veri artırma yöntemi uygulanmış ve böylece yapay veriler üretilerek sınıf dengesi sağlanmıştır. Bu yaklaşım, modelin çift manyeto sınıfını daha iyi öğrenmesine olanak tanımıştır.

4.1. Ses Veri Setinin Toplanması

Ses sinyalleri hava aracının gösterge paneli üzerine sabitlenmiş mikrofon ve sinyalleri dijitalleştirecek ses kartı yardımı ile toplanmıştır. Ses verilerinin kaydı esnasında çevresel gürültülerden uzak ortamda havaracı motoru çalıştırılmış olup, sistem profesyonel mikrofon (Behringer ECM8000) ve ses kartından (Behringer U-Phoria Um2) oluşmaktadır. Mikrofonun teknik özellikleri tablo 4.1.'de sunulmuştur. Mikrofon XLR kablo ile ses kartına, sert kartı ise diz üstü bilgisayara bağlanmıştır. Ücretsiz ve açık kaynaklı dijital ses editörü ve ses kayıt yazılımı olan Audacity ses sinyallerinin kaydedilmesinde kullanılmıştır. Ses dosyaları wav ses dosyası formatında kaydedilmiştir.

Tablo 4.1. Ses kayıtları esnasında kullanılan mikrofonun özellikleri

Özellik	Behringer ECM8000 Mikrofon
Tip	Elektret kondenser
Yönel Özellik	Her yöne
Empedans	200 Ohm
Hassasiyet	70 dB
Frekans Tepkisi	20-20000 Hz

Ses kayıtları, hava aracının yerde sabit konumda bulunduğu ve uygun meteorolojik koşulların sağlandığı durumlarda, teknik ekip gözetiminde yer çalıştırması gerçekleştirilerek elde edilmiştir. İlk deneme kayıtları 21 Ağustos 2023 tarihinde alınmıştır. 22 Ağustos 2023 tarihinde ise motor devri dakikada 1000 devirden başlayarak 2200 devire kadar, 100 devirlik artışlarla, sol manyeto, sağ manyeto ve her iki manyeto anahtarlama pozisyonlarında, derin öğrenme tabanlı analizlerde kullanılmak üzere ses verileri kaydedilmiştir. Buna ek olarak, 24 ve 25 Ağustos 2023 tarihlerinde, aynı uçak modeli ve aynı motor tipine sahip farklı bir hava aracından test amacıyla ses verileri toplanmıştır. Bu kayıtlar, dakikada 1000 ile 2200 devir aralığında, herhangi bir sabit devir veya manyeto konfigürasyonu gözetilmeksizin gerçekleştirilmiş olup, toplamda 13 adet test kaydı elde edilmiştir.

Hava aracının yer çalıştırmasına ilişkin tüm gerekli izinler alınmış ve veri toplama süreci emniyet kuralları çerçevesinde yürütülmüştür. Veri setinin oluşturulması sırasında karşılaşılan temel kısıtlama, motorun yerde uzun süre çalıştırılması nedeniyle yeterli soğutmanın sağlanamaması ve buna bağlı olarak yağ sıcaklığının üst sınır değerlere yaklaşması olmuştur. Her ne kadar ilgili motorun azami devri 2575 devir/dakika olsa da, termal sınırlar dikkate alınarak testler 2200 devir/dakika ile sınırlandırılmıştır.

4.2. Yazılım ve Model Geliştirme


Geliştirdiğimiz Python tabanlı yazılım, ses işleme ve derin öğrenme tekniklerini bir araya getiren kapsamlı bir sistemdir. Veri ön işleme ve özellik çıkarımında ses dosyalarından 40 adet MFCC çıkarılmış, 30 saniyelik kayıtlar %50 örtüşmeli 1 saniyelik segmentlere bölünmüştür. Tüm MFCC vektörleri 90 frame uzunluğuna sabitlenerek standart bir giriş formatı oluşturulmuştur.

Model mimarisi, 64, 128 ve 256 filtre içeren üç katmanlı Evrişimli Sinir Ağı kullanılmıştır. Her evrişim katmanı sonrasında Batch Normalization uygulanmış, modelin overfitting'den kaçınması için L2 regularizasyon ve %20 Dropout oranı kullanılmıştır. Eğitim sürecinde early stopping ile 25 epoch patience değeri uygulanmış, learning rate her epoch'ta %5 azaltılarak modelin kararlı bir şekilde yakınsaması sağlanmıştır. Sınıf dengesizliğini gidermek için sadece her iki manyeto sınıfına yönelik veri artırma teknikleri uygulanmıştır.

4.3. Model Performansı

4.3.1. ESA modelinin eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri

Eğitim süreci sonucunda geliştirilen model, test veri seti üzerinde %98,23 doğruluk oranı elde etmiştir. Model, eğitim sürecinin ilk aşamalarında hızlı bir öğrenme eğrisi sergilemiş; ilk eğitim döngüsünde yaklaşık %50 doğruluk değerinden başlayarak 6. eğitim döngüsünde %93,58 doğrulama doğruluğuna, 17. eğitim döngüsünde %98,074 doğrulama doğruluğuna ve 45. eğitim döngüsünde en yüksek performans değeri olan %98,234 doğrulama doğruluğuna ulaşmıştır.




Görsel 4.1. Eğitim ve doğrulama sürecinde doğruluk ve kayıp değerlerinin eğitim döngüsüne göre değişimi

Görsel 4.1'in sol tarafında yer alan doğruluk grafiğinde, yatay eksen eğitim döngüsü sayısını, dikey eksen ise doğruluk oranını temsil etmektedir. Grafikten de görülebileceği üzere, modelin doğruluk değeri ilk eğitim döngülerinden itibaren hızlı bir artış göstermiş ve yaklaşık 20. eğitim döngüsü civarında %95 seviyesinin üzerine çıkarak doygunluğa ulaşmıştır. Eğitim doğruluğu, 100. eğitim döngüsünden sonra %99

seviyesine yaklaşılarak kararlı bir yapı sergilemiştir. Doğrulama doğruluğunun da eğitim doğruluğuna yakın bir seyir izlemesi, modelin genelleme kabiliyetinin yüksek olduğunu ve aşırı öğrenme eğiliminin düşük seviyede kaldığını göstermektedir. Eğitim ve doğrulama doğruluklarının birbirine yakın olması, modelin hem eğitim verisini hem de daha önce görmediği doğrulama verisini başarılı bir şekilde temsil edebildiğini ortaya koymaktadır.

Görsel 4.1'in sağ tarafında yer alan kayıp grafiğinde ise yatay eksen eğitim döngüsü sayısını, dikey eksen kayıp değerini ifade etmektedir. Eğitim ve doğrulama kayıplarının başlangıçta yüksek olduğu, ancak eğitim süreci ilerledikçe belirgin biçimde azaldığı görülmektedir. Eğitim kaybı, ilk 30 eğitim döngüsü içerisinde hızlı bir düşüş göstermiş, sonraki aşamalarda ise 0,3–0,4 aralığında kararlı bir seviyede sabitlenmiştir. Doğrulama kaybının da benzer bir eğilim sergileyerek eğitim kaybına paralel şekilde azalması, modelin uygun öğrenme oranı ile eğitildiğini ve optimizasyon sürecinin başarılı olduğunu göstermektedir. Modelin eğitim süreci değerlendirildiğinde boyunca istikrarlı bir yakınsama davranışı sergilediği söylenebilir. Her iki ölçütte (doğruluk artışı ve kayıp azalması) gözlemlenen paralel eğilim, modelin iyi genelleştiğini, öğrenme sürecinde aşırı gürültüye veya dengesizliğe maruz kalmadığını ortaya koymaktadır. Sonuç olarak model, hem eğitim hem de doğrulama verileri üzerinde yüksek doğruluk, kararlılık ve dengeli bir öğrenme performansı elde etmiştir.

4.3.2. Sınıf bazlı performans analizi



Görsel 4.2. Manyeto sınıflandırma sonuçlarına ait confusion matrix

Modelin sınıflandırma başarımını değerlendirmek amacıyla doğrulama verisi üzerinde elde edilen sonuçlar karmaşıklık matrisi kullanılarak analiz edilmiştir. Görsel 4.2’de sunulan bu matris, modelin tahmin ettiği sınıflar ile gerçek sınıflar arasındaki ilişkiyi hem görsel hem de sayısal olarak ortaya koymaktadır. İki sınıflı bir sınıflandırma problemine ait olan bu analiz, tek ve çift manyeto çalışma durumlarının doğru biçimde ayrıştırılmasını hedeflemektedir.

Şekil 4.2 incelendiğinde, gerçek sınıfı çift olan toplam 311 örneğin 303’ünün doğru şekilde ÇİFT olarak sınıflandırıldığı, 8 örneğin ise hatalı biçimde tek olarak tahmin edildiği görülmektedir. Benzer şekilde, gerçek sınıfı tek olan 312 örneğin 309’u doğru biçimde TEK olarak sınıflandırılmış, yalnızca 3 örnek çift olarak yanlış etiketlenmiştir.

Bu sonuçlar doğrultusunda modelin genel doğruluk oranı %98,23 olarak hesaplanmıştır. Bu oran, modelin tüm sınıflar üzerindeki toplam sınıflandırma başarımını ifade etmektedir. Sınıf bazında değerlendirildiğinde, çift sınıfı için modelin kesinlik değeri %99,02, duyarlılık değeri ise %97,43 olarak belirlenmiştir. Bu bulgular, modelin çift sınıfına ait örnekleri yüksek doğrulukla tanımladığını ve bu sınıfa ait verilerin büyük bölümünü doğru şekilde yakalayabildiğini göstermektedir.

Tek sınıfı için ise kesinlik %97,47, duyarlılık ise %99,04 olarak hesaplanmıştır. Bu değerler, modelin TEK sınıfına ait örnekleri yüksek başarıyla ayırt edebildiğini ve yanlış sınıflandırma oranının oldukça düşük olduğunu ortaya koymaktadır. Her iki sınıf için hesaplanan F1 başarı ölçütleri de dengeli bir sınıflandırma performansına işaret etmektedir. Çift sınıfı için F1 değeri %98,22, tek sınıfı için ise %98,25 olarak elde edilmiştir. Bu sonuçlar, modelin hem kesinlik hem de duyarlılık açısından dengeli bir başarı sergilediğini ve sınıflar arasında tutarlı bir performans ortaya koyduğunu göstermektedir.

Genel olarak değerlendirildiğinde, düşük hata oranları ve yüksek doğru sınıflandırma sayıları, MFKK kullanılarak eğitilen Evrişimli Sinir Ağı mimarisinin, ses tabanlı manyeto çalışma durumu sınıflandırma probleminde güvenilir, kararlı ve yüksek doğrulukta bir çözüm sunduğunu açıkça ortaya koymaktadır.

4.4. Model Test Sonuçları

Modelin gerçek performansını değerlendirmek amacıyla, aynı model ve motora sahip başka bir uçağın farklı bir zamanda alınan eğitim ve test veri setlerinden bağımsız 13 adet ses dosyası üzerinde denemeler yapılmıştır. Tablo 4.2. modelin test verileri

üzerindeki sınıflandırma sonuçlarını ayrıntılı olarak sunmaktadır. Tabloda her bir test örneği için motor devri, gerçek manyeto çalışma durumu, her iki sınıfa ait olasılık değerleri, model tarafından yapılan sınıf tahmini ve buna karşılık gelen doğru/hatalı sonucu yer almaktadır. Bu yapı sayesinde modelin farklı devir aralıklarında ve manyeto çalışma durumlarında verdiği kararlar sayısal olarak izlenebilmekte ve örnek bazında performansı değerlendirilebilmektedir.

Tablo 4.2. Model test sonuçları tablosu

Motor Devri	Gerçek Manyeto Seçimi	Both Olasılığı	Single Olasılığı	Tahmin Edilen	Sonuç
1500	Çift	%18,12	%81,88	Tek	Hatalı
1100	Çift	%65,93	%34,07	Çift	Doğru
1600	Çift	%90,91	%9,09	Çift	Doğru
1800	Çift	%93,98	%6,02	Çift	Doğru
2200	Çift	%40,14	%59,86	Tek	Hatalı
1000	Tek	%4,65	%95,35	Tek	Doğru
1300	Tek	%2,47	%97,53	Tek	Doğru
1400	Tek	%5,35	%94,65	Tek	Doğru
1700	Tek	%26,61	%73,39	Tek	Doğru
2000	Tek	%40,05	%59,95	Tek	Doğru
1200	Tek	%4	%96	Tek	Doğru
1900	Tek	%12,72	%87,28	Tek	Doğru
2100	Tek	%43,33	%56,67	Tek	Doğru

Model test sonuçları incelendiğinde, geliştirilen derin öğrenme tabanlı ses analizi sisteminin bağımsız test verisi üzerinde toplam 13 ses kaydından 11'ini doğru şekilde sınıflandırdığı ve %84,62 genel doğruluk oranına ulaştığı görülmektedir. Bu sonuç, modelin manyeto durumlarını ayırt etme konusunda genel olarak başarılı bir performans sergilediğini göstermektedir.

Performans sınıf bazında değerlendirildiğinde, tek manyeto sınıfında yüksek bir başarı elde edildiği dikkat çekmektedir. Test setinde yer alan sekiz adet tek manyeto kaydının tamamı doğru şekilde sınıflandırılmıştır. Bu durum, modelin tek manyeto durumuna ait ses karakteristiklerini daha belirgin ve tutarlı biçimde öğrendiğini göstermektedir. Çift manyeto sınıfında ise beş kayıttan üçü doğru tahmin edilirken, iki

kayıtta hatalı sınıflandırma yapılmıştır. Hatalı tahminler ayrıntılı olarak incelendiğinde, 1500 devir/dakika hızındaki çift manyeto kaydının %18,12 gibi oldukça düşük bir güven değeriyle tek manyeto olarak tahmin edildiği görülmektedir. Benzer şekilde, 2200 devir/dakika hızındaki çift manyeto kaydı da %40,14 güven değeriyle yanlış sınıflandırılmıştır. Buna karşılık, doğru tahmin edilen çift manyeto kayıtlarında modelin güven değerlerinin %65,93 ile %93,98 arasında değiştiği belirlenmiştir.

Tek manyeto sınıfındaki tahminlerde modelin genel olarak yüksek güven değerleri ürettiği gözlemlenmiştir. Örneğin, 1300 devir/dakika hızındaki tek manyeto kaydı %97,53, 1200 devir/dakika hızındaki kayıt ise %96,00 güven değeriyle doğru şekilde sınıflandırılmıştır. Bu sonuçlar, modelin tek manyeto seslerini daha ayırt edilebilir özellikler üzerinden değerlendirdiğini düşündürmektedir.

Sonuç olarak, geliştirilen model genel doğruluk açısından tatmin edici bir performans ortaya koymaktadır. Bununla birlikte, çift manyeto sınıfında düşük güven değerleriyle yapılan hatalı tahminler, bu sınıfa ait ses verilerinin daha fazla çeşitlendirilmesi ve modelin bu duruma yönelik öğrenme kapasitesinin artırılması gerektiğini göstermektedir. Düşük güven değerine sahip tahminler, modelin kararsız kaldığı durumların belirlenmesi açısından önemli bir gösterge olarak değerlendirilebilir.

5. SONUÇ VE ÖNERİLER

Bu çalışmada geliştirilen derin öğrenme tabanlı manyeto arıza tespit sistemi, Diamond DA20-C1 uçağına ait motor seslerini analiz ederek çift ve tek manyeto çalışma durumlarını yüksek doğrulukla ayırt edebilmiştir. Model, test verisi üzerinde %98,23 doğruluk oranına ulaşırken, bağımsız deneme verisi üzerinde %84,62 genel doğruluk elde etmiştir. Elde edilen bu sonuçlar, ses tabanlı analiz yaklaşımının havacılıkta manyeto durumunun izlenmesi ve arıza tespiti için etkin ve güvenilir bir yöntem olduğunu göstermektedir.

Sınıf bazında yapılan değerlendirmelerde, tek manyeto sınıfında modelin son derece başarılı bir performans sergilediği görülmüştür. Bağımsız deneme setinde yer alan tüm tek manyeto kayıtları doğru şekilde sınıflandırılmıştır. Ayrıca bu sınıfa ait tahminlerde modelin güven değerlerinin oldukça yüksek olduğu gözlemlenmiştir. Örneğin bazı tek manyeto kayıtlarında tahmin olasılığı $P = 0,97$ ve üzeri seviyelere ulaşmıştır. Bu durum, tek manyeto çalışma koşulunun motor sesi üzerinde belirgin ve ayırt edilebilir bir karakteristik oluşturduğunu ortaya koymaktadır.

Çift manyeto sınıfında ise model genel olarak doğru tahminler üretmiş olmakla birlikte, bazı devir/dakika aralıklarında güven değerlerinin düştüğü ve hatalı sınıflandırmaların meydana geldiği görülmüştür. Özellikle bazı çift manyeto kayıtlarında tahmin olasılığının $P = 0,40$ seviyelerine kadar gerilediği tespit edilmiştir. Buna karşılık doğru tahmin edilen çift manyeto kayıtlarında güven değerlerinin $P = 0,65$ ile $P = 0,93$ arasında değiştiği belirlenmiştir. Bu bulgular, modelin yüksek olasılık değerlerinde daha kararlı ve güvenilir tahminler ürettiğini göstermektedir. Tahmin olasılıklarının analizi, modelin karar verme sürecini anlamak açısından önemli bir gösterge sunmaktadır. Düşük olasılık değerleri, modelin kararsız kaldığı veya sınıflar arasında benzer ses özellikleri tespit ettiği durumlara işaret etmektedir. Bu nedenle olasılık temelli değerlendirme, yalnızca doğru veya yanlış sınıflandırmayı değil, aynı zamanda tahminin güvenilirliğini de ortaya koymaktadır.

Çalışmanın en önemli katkılarından biri, geleneksel manyeto test yöntemlerinden farklı olarak uçuş sırasında sürekli ve pasif izleme imkânı sunmasıdır. Mevcut yöntemler çoğunlukla yerde yapılan kısa süreli testlerle sınırlıyken, önerilen sistem sayesinde manyeto durumu uçuş boyunca motor sesi üzerinden izlenebilmektedir. Bu yaklaşım, olası arızaların erken aşamada fark edilmesine ve uçuş güvenliğinin artırılmasına katkı sağlamaktadır. Pratik uygulanabilirlik açısından değerlendirildiğinde, sistemin düşük

maliyetli mikrofonlar ve mevcut ses kayıt donanımlarıyla entegre edilebilmesi önemli bir avantajdır. Ayrıca geliştirilen yapının mobil uygulama formatına dönüştürülmesi, motor sesinin sürekli analiz edilmesine olanak tanıyarak bakım süreçlerine destek sağlayabilecek bir sistemin önünü açmaktadır.

Gelecek çalışmalarda, farklı uçak tiplerinden ve daha geniş devir/dakika aralıklarından elde edilecek ses verileriyle modelin eğitilmesi, özellikle çift manyeto sınıfındaki performansın artırılmasına katkı sağlayacaktır. Bunun yanı sıra, düşük güven değerine sahip tahminler için uyarı mekanizmalarının geliştirilmesi, sistemin operasyonel güvenilirliğini daha da artıracaktır.

Sonuç olarak, bu çalışma derin öğrenme tabanlı ses analizinin havacılıkta manyeto arıza tespiti için etkili, uygulanabilir ve yenilikçi bir yöntem olduğunu ortaya koymaktadır. Elde edilen yüksek doğruluk oranları ve olasılık temelli değerlendirme yaklaşımı, bu tür sistemlerin havacılık güvenliği ve bakım yönetimi alanlarında yaygınlaşması açısından umut verici bir potansiyel sunmaktadır.

KAYNAKÇA

- Amarnath, M., Sugumaran, V. and Hemantha Kumar, T. A. (2013). Exploiting sound signals for fault diagnosis of bearings using decision tree. *Measurement*, 46(3), 1250–1256.
- Ban, Y., Liu, C., Yang, F., Guo, N., Ma, X., Sui, X. and Huang, Y. (2024). Failure Identification Method of Sound Signal of Belt Conveyor Rollers under Strong Noise Environment. *Electronics*, 13, 34.
- Brusa, E., Delprete, C. and Di Maggio, L. G. (2021). Deep Transfer Learning for Machine Diagnosis: From Sound and Music Recognition to Bearing Fault Detection. *Applied Sciences*, 11(24), 11663.
- Chan, T. K. and Chin, C. S. (2017). Proposed framework for multi-level extreme machine learning for underwater thruster's fault classification using YIN fundamental frequency estimator and pitch sound. *2017 2nd International Conference on Advanced Robotics and Mechatronics (ICARM)*.
- Chen, H., Xu, M., Li, Z. and Fu, C. (2019). Mechanical Fault Diagnosis of GIS Based on MFCCs of Sound Signals. *2019 IEEE 8th International Conference on Advanced Power System Automation and Protection (APAP)*, 33–37.
- Chen, Y. L., Lai, C. Y., Yeh, C. F. and Wu, Y. P. (2021). Sound Visualization and Convolutional Neural Network in Fault Diagnosis of Electric Motorbike. *2021 IEEE 11th International Conference on System Engineering and Technology (ICSET)*.
- Continental Motors. (2011). *IO-240 Series Engine Installation and Operation Manual*.
- Di Maggio, L. G. (2023). Intelligent Fault Diagnosis of Industrial Bearings Using Transfer Learning and CNNs Pre-Trained for Audio Classification. *Sensors*, 23, 211.
- Diamond Aircraft Industries Inc. (2012). *DA20-C1 Flight Manual* (Doküman No: DA202-C1, Revizyon 26). London, Ontario.

- Diamond Aircraft Industries. (2022). *DA20-C1 Brochure* (Revision 2). London, ON, Canada.
- Diamond Aircraft Industries. (2022). *DA20-C1 Illustrated Parts Catalog* (Rev. 13). Diamond Aircraft Industries Inc.
- Diamond Aircraft. (2025). *DA20-C1 Overview*. Diamond Aircraft Industries Official Website. Erişim tarihi: 10 Kasım 2025, <https://www.diamondaircraft.com/>
- Erdoğan, F. A., Küçükmanisa, A. ve Kilimci, Z. H. (2023). Detection of Fault from Acoustic Signals in Automobile Engines using Deep Learning Techniques. *Kocaeli Journal of Science and Engineering*.
- Fan, H. (2022). Sound anomaly detection of industrial products based on MFCC fusion short-time energy feature extraction. *2022 IEEE Conference on Telecommunications, Optics and Computer Science (TOCS)*, 126–129.
- Federal Aviation Administration (FAA). (2016). *Aviation maintenance technician handbook – Powerplant, Vol. 1* (FAA-H-8083-32A). U.S. Department of Transportation.
- Frusque, G., Michau, G. and Fink, O. (2021). Canonical Polyadic Decomposition and Deep Learning for Machine Fault Detection. *European Conference Of The Prognostics And Health Management Society 2021*.
- Hatanaka, S. (2021). Efficient GAN-Based Unsupervised Anomaly Sound Detection for Refrigeration Units. *2021 IEEE 30th International Symposium on Industrial Electronics (ISIE)*.
- Hemantha Kumar, T. A., Ranjit Kumar, M. Amarnath and Sugumaran, V. (2012). Fault diagnosis of antifriction bearings through sound signals using support vector machine. *Journal of Vibroengineering*, 14(4).
- Janssens, O., Slavkovikj, V., Vervisch, B., Stockman, K., Loccufier, M., Verstockt, S., Van de Walle, R. and Van Hoecke, S. (2016). Convolutional Neural Network Based Fault Detection for Rotating Machinery. *Journal of Sound and Vibration*, 377, 331–345.

- Jayasree, T. and Prem Ananth, R. (2020). Sound Signal Based Fault Classification System in Motorcycles Using Hybrid Feature Sets and Extreme Learning Machine Classifiers. *Sound and Vibration*.
- Jeppesen. (2022). *Aircraft powerplants* (9th ed.). Jeppesen Sanderson, Inc.
- Jia, X., Zhao, M., Di, Y., Jin, C. and Lee, J. (2017). Investigation on the kurtosis filter and the derivation of convolutional sparse filter for impulsive signature enhancement. *Journal of Sound and Vibration*, 386, 433–448.
- Jiang, W., Li, Z., Li, J., Zhu, Y. and Zhang, P. (2019). Study on a Fault Identification Method of the Hydraulic Pump Based on a Combination of Voiceprint Characteristics and Extreme Learning Machine. *Processes*, 7(12), 856.
- Kim, J., Kim, J. and Kim, H. (2022). A Study on Gear Defect Detection via Frequency Analysis Based on DNN. *Machines*, 10(8), 659.
- Kiranyaz, S., Devecioglu, O. C., Alhams, A., Sassi, S., Ince, T., Avci, O. and Gabbouj, M. (2024). Exploring sound vs vibration for robust fault detection on rotating machinery. *IEEE Transactions on Industrial Informatics*, 20(1), 1373–1382.
- Kroes, M. J., Wild, T. W. and Delp, F. J. (2013). *Aircraft powerplants* (8th ed.). McGraw-Hill Education.
- Kumar, T. P., Buvaanesh, R., Saimurugan, M., Naresh, G., Muthiya, S. J. and Basavanakattimath, M. (2024). Performance evaluation of deep learning approaches for fault diagnosis of rotational mechanical systems using vibration, sound, and acoustic emission signals. *Journal of Low Frequency Noise, Vibration and Active Control*, 43(3), 1363–1380.
- Lifestyle Aviation. (2025). *Diamond DA20 aircraft specifications*. Erişim tarihi: 10 Kasım 2025, <https://www.lifestyleaviation.com/>
- Liu, H., Li, L. and Ma, J. (2016). Rolling Bearing Fault Diagnosis Based on STFT-Deep Learning and Sound Signals. *Shock and Vibration*, 2016, Article ID 6127479.
- Liu, S., Huang, Y., Li, C., Qin, S., Zhang, X. and Zhu, B. (2025). Fault diagnosis of Rolling element bearing based on time-frequency analysis and convolutional neural network. *Neural Computing and Applications*.

- Liu, X., Pei, D., Lodewijks, G., Zhao, Z. and Mei, J. (2020). Acoustic signal based fault detection on belt conveyor idlers using machine learning. *Advanced Powder Technology*, 31(7), 2689–2698.
- Liu, Y., Xu, Z., Guo, P. and Sun, L. (2024). Abnormal-Sound Diagnosis for Kaplan Hydroelectric Generating Units Based on Continuous Wavelet Transform and Transfer Learning. *Sensors*, 24, 7441.
- Madhusudana C. K., Hemantha Kumar, T. A. and Narendranath, S. (2018). Fault Diagnosis of Face Milling Tool using Decision Tree and Sound Signal. *Materials Today: Proceedings*, 5(5), 12035–12044.
- Monteiro, R. P. ve Bastos-Filho, C. J. A. (2019). Detecting Defects in Sanitary Wares Using Deep Learning. *The Institute of Electrical and Electronics Engineers*.
- National Transportation Safety Board. (2001). *Aviation accident final report: Cessna 172N, N3392E, Columbus, Texas* (Accident No. FTW00LA207).
- National Transportation Safety Board. (2021). *Aviation investigation final report: Loss of engine power (partial) accident involving Cessna 152, N152GB, Hillsboro, Oregon, May 26, 2018* (Accident No. WPR18LA148).
- Pan, J., Shao, C., Dai, Y., Wei, Y., Chen, W. and Lin, Z. (2024). Research on Fault Prediction Method of Elevator Door System Based on Transfer Learning. *Sensors*, 24(7), 2135.
- Pradeep, S., Sharma, Y. K., Verma, C., Constantin, N. B., Illes, Z., Raboaca, M. S. and Mihaltan, T. C. (2022). Smart Factory Setting Awareness by Noise-Pattern Analysis. *2022 11th International Conference on System Modeling and Advancement in Research Trends (SMART)*.
- Rauber, T. W., Oliveira-Santos, T., de Assis Boldt, F., Rodrigues, A., Varejao, F. M. and Ribeiro, M. P. (2017). Kernel and random extreme learning machine applied to submersible motor pump fault diagnosis. *2017 International Joint Conference on Neural Networks (IJCNN)*.

- Sacaklıdır, I. ve Koc, S. (2024). Fault Detection from Horizontal Shaft Centrifugal Pump Fan Sound Analysis Using Artificial Intelligence. *BALKAN JOURNAL OF ELECTRICAL AND COMPUTER ENGINEERING*, 12(4).
- Tang, S., Zhu, Y. and Yuan, S. (2021). An improved convolutional neural network with an adaptable learning rate towards multi-signal fault diagnosis of hydraulic piston pump. *Advanced Engineering Informatics*, 50, 101406.
- Teledyne Continental Motors. (2011). *IO-240 Series Engine Installation and Operation Manual* (Doküman No: OI-6ELEC). Yayın tarihi: 31 Ekim 2011, 36-37.
- Tran, T. and Lundgren, J. (2020). Drill fault diagnosis based on the scalogram and Mel spectrogram of sound signals using artificial intelligence. *IEEE Access*, 8, 203655–203667.
- Vijyalakshmi, K., Rajakannu, A., Ramachandran, K. P. and Srirajkavin, A. V. (2024). Federated learning based futuristic fault diagnosis and standardization in rotating machinery. *Preprints.org*.
- Vununu, C., Moon, K.-S., Lee, S.-H. and Kwon, K.-R. (2018). A Deep Feature Learning Method for Drill Bits Monitoring Using the Spectral Analysis of the Acoustic Signals. *Sensors*, 18(8), 2636.
- Wang, M. Y., Lu, H. Y., Chen, D. Z. and An, W. N. (2024). Multi-Sensor Fault Diagnosis of Underwater Thruster Propeller. *Ocean Engineering*, 302, 117621.
- Xiao, D., Tao, Z., Qin, C., Yu, H., Huang, Y. and Liu, C. (2020). Fast Machine Fault Diagnosis Using Marginalized Denoising Autoencoders Based on Acoustic Signal. *2020 Prognostics and Health Management Conference (PHM-Besançon)*.
- Yao, Y., Wang, H., Li, S., Liu, Z., Gui, G., Dan, Y. and Hu, J. (2018). End-To-End Convolutional Neural Network Model for Gear Fault Diagnosis Based on Sound Signals. *Applied Sciences*, 8(9), 1584.
- Yürekli, A. (2019). *Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzu*. Eskişehir Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, 1-12.
- Zhao, W. (2022). Application of Adversarial Network Model in Robot Inspection Heterophony Detection. *2022 2nd International Conference on Computer*

Science, Electronic Information Engineering and Intelligent Control Technology (CEI).



EK

Bu ek kapsamında sunulan belge, yüksek lisans tez çalışması çerçevesinde Diamond DA20-C1 tipi hava aracında gerçekleştirilen yer testleri sırasında motor sesi kayıtlarının alınmasına yönelik resmi çalışma iznini içermektedir. İlgili izin, UTEK Uzay Havacılık Teknoloji Eğitim Sanayi ve Ticaret A.Ş. tarafından verilmiş olup, çalışmaların emniyet kuralları ve teknik personel gözetiminde, uçuş içermeyecek şekilde yürütüleceğini belgelemektedir.





UTEK UZAY HAVACILIK TEKNOLOJİ EĞİTİM SANAYİ VE TİCARET A.Ş.

Konu: Yüksek Lisans Tez Çalışması Kapsamında Uçak Üzerinde Çalışma İzni

21.08.2023

UTEK Uzay Havacılık Teknoloji Eğitim Sanayi ve Ticaret A.Ş. bünyemizde görev yapmakta olan Faruk DUMAN tarafından yürütülen *"Diamond DA20-C1 Uçağında Derin Öğrenme Tabanlı Manyeto Arızası Tespiti"* başlıklı yüksek lisans tez çalışması kapsamında tarafımıza iletilen izin talebi doğrultusunda 21.08.2023 – 25.08.2023 tarihleri arasında, Diamond DA20-C1 tipi hava aracının yerde motor çalıştırması ve bu esnada motor sesi kayıtlarının alınması, emniyet kurallarına ve teknik ekip gözetiminde gerçekleştirilecek şekilde onaylanmıştır.

Söz konusu faaliyet, uçuş içermemekte olup sadece yerde gerçekleştirilecektir. Tüm işlemler kurumumuzun teknik personel eşliğinde ve ilgili prosedürlere uygun biçimde icra edilecektir.

Bilgilerinize sunar, iyi çalışmalar dileriz.

Mehmet TIRAK
Kalite&SMS Müdürü

ÖZGEÇMİŞ

ORCID NO: 0000-0003-0530-6909

Ad Soyad : Faruk DUMAN

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2024-Halen, Teknisyen/Pilot, Bursa Uzay ve Havacılık, Bursa
- 2021-2024, Teknisyen/Pilot, UTEK Uçuş Okulu, Bursa
- 2022-2026, Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Uçak Gövde ve Motor Bakımı
- 2017-2020, Eskişehir Teknik Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Uçak Gövde-Motor Bakım
- 2015-2017, Anadolu Üniversitesi, Ulaştırma Meslek Yüksek Okulu, Uçak Teknolojisi