



**T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI**

**HİDROLİK SİSTEMLERDE ARIZA TESPİTİ İÇİN DERİN
ÖĞRENME TABANLI KESTİRİMCİ BAKIM YÖNTEMİ**

(Yüksek Lisans Tezi)

Özkan AK

**Danışman
Doç. Dr. Erkan Caner ÖZKAT**

**RİZE
2026**

KABUL VE ONAY

Recep Tayyip Erdoğan Üniversitesi, Lisansüstü Eğitim Enstitüsü, Makine Mühendisliği Anabilim Dalında, Doç. Dr. Erkan Caner ÖZKAT danışmanlığında, Özkan AK tarafından hazırlanan *Hidrolik Sistemlerde Arıza Tespiti İçin Derin Öğrenme Tabanlı Kestirimci Bakım Yöntemi* adlı bu tez çalışması, 22/01/2026 tarihinde yapılan savunma sınavı sonucunda oy birliğiyle/~~oy çokluğuyla~~ başarılı bulunarak jürimiz tarafından **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Jüri Üyeleri	Ünvanı, Adı SOYADI	İmza
Başkan	: Doç. Dr. Erkan Caner ÖZKAT	
Üye	: Dr. Öğr. Üyesi Hamdi KULEYİN	
Üye	: Doç. Dr. Mehmet KONAR	

ETİK BEYAN

Makine Mühendisliği Tezli Yüksek Lisans Programından mezun olmak üzere teslim ettiğim “Hidrolik Sistemlerde Arıza Tespiti İçin Derin Öğrenme Tabanlı Kestirimci Bakım Yöntemi” adlı tezim, bilim ve araştırma etiği prensiplerine riayet edilerek tarafımdan yazılmıştır.

Tez çalışmamda, başka kaynaklardan aktarılan bütün bilgi ve alıntılar, Enstitünüz Tez Yazım Kılavuzuna uygun olarak açıkça gösterilmiştir. Kaynağı gösterilenler dışında kalan bütün bilgiler uygun araştırma yöntemi kullanılarak tarafımdan edinilmiş ve esere bu şekilde yansıtılmıştır. Şahsıma ait olmayan hiçbir bilgi, kasıt veya kusurlar, şahsıma aitmiş gibi gösterilmemiştir. İnternet kaynakları dâhil, sahibine/kaynağına atıf yapılmaksızın hiçbir bilgi kullanılmamıştır. Aksinin ortaya çıkması halinde doğacak bütün hukuki, idari, akademik ve etik sorumluluk tarafıma ait olacaktır. Eserin tesliminden sonra herhangi bir zamanda, bilim etiğine aykırılık tespit edilmesi ve / veya eserimle ilgili intihal veya intihal şeklinde anlaşılabilecek bir durumun ortaya çıkması halinde; Üniversiteniz ve eğitim kadronuzun hiçbir şekilde sorumlu tutulmayacağını hür irademle kabul, beyan ve taahhüt ederim.

22/01/2026

Özkan AK

ÖN SÖZ

Bu tez çalışması, endüstriyel hidrolik sistemlerde meydana gelen iç kaçak arızalarının erken aşamada tespiti ve arıza şiddetinin güvenilir biçimde sınıflandırılmasına yönelik, derin öğrenme tabanlı bir kestirimci bakım yaklaşımı geliştirmek amacıyla hazırlanmıştır. Hidrolik sistemlerde oluşan iç kaçaklar; enerji verimliliğinin azalmasına, sistem performansının düşmesine ve uzun vadede ciddi ekipman hasarlarına yol açabilmektedir. Bu nedenle, arızaların erken evrede ve güvenilir biçimde belirlenmesi, endüstriyel tesislerde bakım maliyetlerinin azaltılması ve sistem sürekliliğinin sağlanması açısından büyük önem taşımaktadır.

Geleneksel bakım ve arıza tespit yöntemleri çoğu zaman tekil sensör verilerine veya eşik tabanlı karar mekanizmalarına dayanmakta ve özellikle erken evre arızaların tespitinde yetersiz kalabilmektedir. Bu tez kapsamında, çoklu sensörlerden elde edilen zaman serisi verileri, zaman–frekans alanına dönüştürülerek derin öğrenme tabanlı hibrit bir modelleme yaklaşımı ile ele alınmıştır. Geliştirilen yöntem; konvolüsyonel sinir ağları ve uzun kısa süreli bellek ağlarının birlikte kullanıldığı bütüncül bir yapı sunarak, hidrolik sistemlerdeki arıza mekanizmalarının hem yerel hem de zamansal özelliklerini modellemeyi hedeflemektedir. Elde edilen bulgular, önerilen yaklaşımın özellikle hafif şiddetli iç kaçak arızalarının tespitinde anlamlı bir ayırt edicilik sunduğunu göstermiştir.

Bu tez çalışmasının ortaya çıkmasında bilgi ve deneyimleriyle yol gösteren, her aşamada yapıcı eleştirileri ve desteğiyle katkı sağlayan tez danışmanım Sayın Doç. Dr. Erkan Caner ÖZKAT'a; ayrıca tez jürimde yer alarak değerli görüş ve katkılarını sunan Dr. Öğr. Üyesi Hamdi KULEYİN'e ve Doç. Dr. Mehmet KONAR'a içtenlikle teşekkür ederim. Akademik gelişimime sağladıkları katkılar ve çalışmaya kazandırdıkları bilimsel bakış açısı, bu tezin şekillenmesinde belirleyici olmuştur.

Bu zorlu ve uzun süreç boyunca sabır, anlayış ve desteğini hiçbir zaman esirgemeyen eşim Şeyma'ya ve hayatıma anlam katan, varlığıyla bana her zaman motivasyon kaynağı olan oğlum Metehan'a; ayrıca her zaman yanımda olan, desteklerini benden esirgemeyen aileme sonsuz teşekkür ederim. Onların desteği ve sevgisi, bu çalışmanın tamamlanmasındaki en büyük güç kaynağım olmuştur.

Özkan AK
RİZE/2026

İÇİNDEKİLER

KABUL VE ONAY	I
ETİK BEYAN	II
ÖN SÖZ	III
İÇİNDEKİLER	IV
ÖZET	VII
ABSTRACT.....	VIII
KISALTMALAR	IX
TABLolar LİSTESİ	X
ŞEKİLLER LİSTESİ	XI
GİRİŞ	1
1. LİTERATÜR ARAŞTIRMASI.....	3
1.1. Bakım Yöntemi	3
1.1.1. Düzeltici Bakım.....	4
1.1.2. Periyodik Bakım.....	5
1.1.3. Kestirimci Bakım	5
1.2. Kestirimci Bakımda Kullanılan Veriler.....	6
1.3. Yapay Zekâ Tabanlı Arıza Tespit Yaklaşımları.....	9
1.3.1. Klasik Makine Öğrenmesi Yöntemleri.....	10
1.3.2. Zaman–Frekans Tabanlı Yöntemler	11
1.3.3. Derin Öğrenme ve Hibrit Yöntemler.....	13
1.4. Tezin Kapsamı ve Amacı	17
2. KULLANILAN VERİ SETİ.....	18
2.1. Hidrolik Test Düzenegi	18
2.1.1. Birincil Çalışma Devresi	19
2.1.1.1. Hidrolik Pompa.....	19
2.1.1.2. Yön Kontrol Valfi	20
2.1.1.3. Hidrolik Akümülatör (Basınç Dengeleme Elemanı)	20
2.1.1.4. Hidrolik Silindir ve Mekanik Yük Simülasyonu	20
2.1.2. İkincil Soğutma–Filtrasyon Devresi.....	21
2.1.2.1. Yağ Soğutma Ünitesi	21
2.1.2.2. Filtrasyon Elemanları ve Kontrol Vanaları	21

2.1.2.3. Hacimsel Akış Sensörleri.....	21
2.1.3. Sistem Çalışma Çevrimleri ve Veri Toplama Stratejisi	22
2.2. Sensör Yapısı ve Ölçülen Büyüklükler	22
2.2.1. Basınç Sensörleri.....	23
2.2.2. Elektriksel Güç Sensörü	23
2.2.3. Hacimsel Akış Sensörleri	23
2.2.4. Sıcaklık Sensörleri.....	24
2.2.5. Titreşim Sensörü.....	24
2.2.6. Sanal Sensörler ve Türetilmiş Büyüklükler.....	24
2.3. Arıza Türleri ve Arıza Şiddeti Seviyeleri	25
2.3.1. Pompa Arızaları	25
2.3.2. Yön Kontrol Valfi Arızaları	26
2.3.3. Hidrolik Akümülatör Arızaları	26
2.3.4. Soğutma Sistemi Arızaları.....	27
2.3.5. Arıza Şiddeti Seviyelerinin Genel Değerlendirmesi	27
2.4. Veri Seti Yapısı ve Boyutu	28
3. YÖNTEM	31
3.1. Veri Ön İşleme.....	33
3.1.1. Sensör Seçimi ve Birleştirilmesi	33
3.1.2. Eksik ve Gürültülü Verilerin Ele Alınması.....	34
3.1.3. Normalizasyon.....	34
3.2. Zaman Serisi Segmentasyonu	35
3.3. Zaman–Frekans Alanına Dönüşüm	35
3.4. Segment Bazlı Etiketleme	37
3.5. Hibrit CNN + LSTM Modelleme Yaklaşımı.....	38
3.5.1. CNN ile Zaman–Frekans Özelliklerinin Öğrenilmesi.....	38
3.5.2. LSTM ile Zamansal Bağımlılıkların Modellenmesi	40
3.6. Arıza Sınıflandırması	42
4. BULGULAR VE TARTIŞMA.....	44
4.1. Zaman Alanı Bulguları.....	44
4.2. Segmentasyon Sonuçlarının Değerlendirilmesi	48
4.3. Zaman–Frekans Alanı Bulguları	50

4.4. Derin Öğrenme Modeli Performans Bulguları.....	51
5. SONUÇLAR.....	58
KAYNAKÇA.....	60



Recep Tayyip Erdoğan Üniversitesi Lisansüstü Eğitim Enstitüsü

Anabilim Dalı : Makine Mühendisliği
Tez Türü : Yüksek Lisans
Danışman : Doç. Dr. Erkan Caner ÖZKAT
Hazırlayan : Özkan AK
Yıl : 2026
Sayfa Sayısı : 74

ÖZET

**HİDROLİK SİSTEMLERDE ARIZA TESPİTİ İÇİN DERİN ÖĞRENME
TABANLI KESTİRİMCİ BAKIM YÖNTEMİ**

Hidrolik sistemler, endüstriyel tesislerde yaygın olarak kullanılan ve arızaları ciddi üretim kayıplarına yol açabilen kritik makine sistemleridir. Bu nedenle, hidrolik sistemlerde arızaların erken aşamada tespit edilmesi, kestirimci bakım uygulamaları açısından büyük önem taşımaktadır. Bu tez çalışmasında, hidrolik bir test sistemine ait zaman serisi verileri kullanılarak, derin öğrenme tabanlı bir arıza tespit yöntemi geliştirilmiştir.

Bu tez çalışmasında, herhangi bir yeni deneysel ölçüm yapılmamış, literatürde paylaşılan mevcut bir veri seti kullanılmıştır. Geliştirilen model kapsamında öncelikle normalize edilen çoklu sensör zaman serileri sabit uzunluklu pencereler kullanılarak segmentlere ayrılmıştır. Elde edilen segmentler, Sürekli Dalgacık Dönüşümü ile zaman–frekans alanına dönüştürülerek skalogram temsilleri hâline getirilmiştir. Bu temsiller üzerinden Konvolüsyonel Sinir Ağları kullanılarak ayırt edici zaman–frekans özellikleri otomatik olarak öğrenilmiş; ardışık segmentlerden elde edilen bu derin özellikler ise Uzun Kısa Süreli Bellek ağı ile otomatik olarak öğrenilen zaman–frekans özelliklerinin zamana göre değişimi modellenmiştir.

Model performansı, karışıklık matrisi, doğruluk, kesinlik, duyarlılık ve F1-skoru metrikleri kullanılarak değerlendirilmiştir. Test veri kümesi üzerinde yapılan değerlendirmelerde model, yaklaşık %89 doğruluk skoru elde etmiştir. Sınıf bazlı performans incelendiğinde, eğitim veri kümesi üzerinde model, normal çalışma sınıfı için kesinlik 0,936, duyarlılık 0,922 ve F1-skoru 0,929; hafif arıza sınıfı için kesinlik 0,605, duyarlılık 0,654 ve F1-skoru 0,628; şiddetli arıza sınıfı için ise kesinlik 0,841, duyarlılık 0,810 ve F1-skoru 0,825 değerlerini sağlamıştır. Test veri kümesi üzerinde elde edilen sonuçlara göre normal çalışma sınıfı için kesinlik 0,959, duyarlılık 0,941 ve F1-skoru 0,950; hafif arıza sınıfı için kesinlik 0,721, duyarlılık 0,779 ve F1-skoru 0,749; şiddetli arıza sınıfı için ise kesinlik 0,898, duyarlılık 0,874 ve F1-skoru 0,886 olarak hesaplanmıştır.

Sonuç olarak, bu tez çalışmasında geliştirilen derin öğrenme tabanlı yaklaşımın, hidrolik sistemlerde arıza tespitine yönelik kestirimci bakım uygulamalarında etkin biçimde kullanılabileceği değerlendirilmiştir. Özellikle önerilen modelin kritik arızaları; hafif iç kaçak durumlarını ayırt etmede yüksek doğruluk ve kararlılık sunduğunu göstermiştir.

Anahtar Kelimeler: Kestirimci Bakım, Hidrolik Sistemler, Zaman–Frekans Analizi, Derin Öğrenme, CNN, LSTM

Recep Tayyip Erdogan University Institute of Graduate Studies

Department : Mechanical Engineering

Thesis Type : Master Thesis

Supervisor : Assoc. Prof. Dr. Erkan Caner ÖZKAT

Author : Özkan AK

Year : 2026

Pages : 74

ABSTRACT

DEEP LEARNING-BASED PREDICTIVE MAINTENANCE METHOD FOR FAULT DETECTION IN HYDRAULIC SYSTEMS

Hydraulic systems are critical machinery systems widely used in industrial facilities, and their failures can lead to significant production losses. Therefore, early detection of failures in hydraulic systems is of great importance for predictive maintenance applications. In this thesis, a deep learning-based fault detection method was developed using time series data of a hydraulic test system.

In this thesis, no new experimental measurements were made; an existing dataset shared in the literature was used. Within the developed model, normalized multi-sensor time series were first segmented using fixed-length windows. The resulting segments were transformed into time-frequency domain scalogram using the Continuous Wavelet Transform. From these, distinctive time-frequency features were automatically learned using Convolutional Neural Networks; features obtained from these segments were then modeled using a Long Short-Term Memory network to forecast the time-dependent variation of these features.

Model performance was evaluated using confusion matrix, accuracy, precision, sensitivity, and F1-score metrics. In evaluations conducted on the test dataset, the model achieved an accuracy score of approximately 89%. When class-based performance was examined, on the training dataset, the model achieved precision of 0.936, sensitivity of 0.922, and F1-score of 0.929 for the normal operation class; precision of 0.605, sensitivity of 0.654, and F1-score of 0.628 for the mild failure class; and precision of 0.841, sensitivity of 0.810, and F1-score of 0.825 for the severe failure class. According to the results obtained on the test dataset, the precision was 0.959, sensitivity 0.941, and F1-score 0.950 for the normal operation class; and precision of 0.721, sensitivity 0.779, and F1-score 0.749 for the mild failure class. For the severe fault class, the accuracy was calculated as 0.898, the sensitivity as 0.874, and the F1 score as 0.886.

In conclusion, this thesis study evaluates that the deep learning-based approach developed can be effectively used in predictive maintenance applications for fault detection in hydraulic systems. Specifically, the proposed model has demonstrated high accuracy and stability in distinguishing critical faults and minor internal leakage conditions.

Keywords: Predictive Maintenance, Hydraulic Systems, Time-Frequency Analysis, Deep Learning, CNN, LSTM

KISALTMALAR

AI	:	Artificial Intelligence (Yapay Zekâ)
ANN	:	Artificial Neural Network (Yapay Sinir Ağı)
AUC	:	Area Under the Curve
CE	:	Cooling Efficiency (Soğutma Verimi Sensörü)
CNN	:	Convolutional Neural Network (Konvolüsyonel Sinir Ağı)
CP	:	Cooling Power (Soğutma Gücü Sensörü)
CWT	:	Continuous Wavelet Transform (Sürekli Dalgacık Dönüşümü)
DL	:	Deep Learning (Derin Öğrenme)
EPS	:	Electric Power Sensor (Elektrik Güç Sensörü)
FN	:	False Negative
FP	:	False Positive
FS	:	Flow Sensor (Akış Sensörü)
LSTM	:	Long Short-Term Memory (Uzun Kısa Süreli Bellek)
ML	:	Machine Learning (Makine Öğrenmesi)
PdM	:	Predictive Maintenance (Kestirimci Bakım)
PS	:	Pressure Sensor (Basınç Sensörü)
PSD	:	Power Spectral Density (Güç Spektral Yoğunluğu)
RMS	:	Root Mean Square (Kök Ortalama Kare)
RNN	:	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
TN	:	True Negative
TP	:	True Positive
TS	:	Temperature Sensor (Sıcaklık Sensörü)
VS	:	Vibration Sensor (Titreşim Sensörü)

TABLÖLAR LİSTESİ

Tablo 1. Kestirimci bakım (PdM) alanında yapay zekâ tabanlı arıza tespit yaklaşımlar	15
Tablo 2. Hidrolik deney düzeneğinde kullanılan sensörler ve örnekleme frekansları	30
Tablo 3. Zaman–frekans skalogramları için kullanılan CNN mimarisi	40
Tablo 4. Veri setinde kullanılan tüm sensörlere ait tanımlayıcı istatistikler.....	45
Tablo 5. LSTM ağının mimari ve eğitim parametreleri	52
Tablo 6. Eğitim veri kümesi üzerindeki sınıflandırma performansı.....	55
Tablo 7. Test veri kümesi üzerindeki sınıflandırma performansı.....	55

ŞEKİLLER LİSTESİ

Şekil 1. Ekipmanın sağlık durumu ve bakım yöntemleri ilişkisi.....	4
Şekil 2. PdM’de kullanılan başlıca veri türleri ve temsil ettikleri arıza mekanizmaları	9
Şekil 3. PdM alanında klasik makine öğrenmesi yaklaşımlarını gösteren süreç.....	11
Şekil 4. Zaman-Frekans tabanlı kestirimci bakım analizlerin aşamaları.....	12
Şekil 5. PdM alanında derin öğrenme ve hibrit modellerin gelişimini.....	14
Şekil 6. Deneysel hidrolik test sisteminin diyagramı (Helwig & Schütze, 2020).....	19
Şekil 7. Hibrit CNN–LSTM tabanlı segment-temelli zaman–frekans analizine dayalı anomali tespiti yönteminin genel iş akışı.....	32
Şekil 8. Kaçak olmayan durumda örnek bir çalışma çevrimine ait normalize edilmiş çoklu sensör zaman serileri.....	46
Şekil 9. Hafif iç kaçak durumunda örnek bir çalışma çevrimine ait normalize edilmiş çoklu sensör zaman serileri.....	46
Şekil 10. Şiddetli iç kaçak durumunda örnek bir çalışma çevrimine ait normalize edilmiş çoklu sensör zaman serileri.....	47
Şekil 11. Normal çalışma, hafif arıza ve şiddetli arıza durumları için titreşim (VS1), motor gücü (EPS1) ve debi (FS1) sensörlerinden elde edilen normalize edilmiş zaman serisi sinyalleri.	48
Şekil 12. PS1 basınç sensörüne ait 60 saniyelik çalışma çevriminin sabit uzunluklu kayan pencere yaklaşımı ile segmentlere ayrılması.....	49
Şekil 13. Hafif kaçak (Sınıf 1) durumuna ait PS1 basınç sensöründen elde edilen örnek bir zaman serisi segmentinin ($L = 5$ s) (a) zaman alanı temsili ve (b) Sürekli Dalgacık Dönüşümü (CWT) ile elde edilen zaman–frekans skalogramı.	50
Şekil 14. CWT–CNN–LSTM tabanlı model için k-katlı çapraz doğrulama ve eğitim–test ayrımını içeren eğitim iş akış şeması.....	53
Şekil 15. (a) Eğitim veri kümesi ve (b) test veri kümesi üzerinde dahili pompa sızıntısı sınıflandırması için karışıklık matrisi.	54

GİRİŞ

Günümüzde üretim sistemlerinin sürekliliği ve güvenilirliği, küresel rekabet ortamında endüstriyel işletmelerin başarısını doğrudan etkileyen en önemli faktörlerden biri hâline gelmiştir. Bu bağlamda, endüstriyel ekipmanlarda meydana gelebilecek beklenmedik arızaların önceden tahmin edilmesi ve bu arızaların neden olacağı plansız duruşların önlenmesi büyük önem taşımaktadır. Geleneksel bakım yaklaşımları; arıza meydana geldikten sonra müdahale edilen “reaktif bakım” ve belirli zaman aralıklarında önleyici olarak yapılan “periyodik bakım” olmak üzere iki ana grupta toplanmaktadır. Ancak her iki yöntemin de etkinliği sınırlıdır. Reaktif bakım, sistemin arıza sonrasında devre dışı kalmasına neden olurken, periyodik bakım ise ekipmanların henüz ömürlerini tamamlamadan değiştirilmesine veya gereksiz bakım işlemlerine yol açarak zaman ve maliyet açısından verimsizlik yaratmaktadır. Bu sorunların üstesinden gelebilmek amacıyla, son yıllarda endüstriyel sistemlerde “kestirimci bakım (predictive maintenance)” kavramı giderek önem kazanmıştır. Kestirimci bakım, sistemin durumunu sürekli izleyerek ekipmanın sağlık durumunu değerlendirmeyi ve arıza oluşmadan önce müdahale edilebilmesini hedefleyen veri odaklı bir yaklaşımdır. Bu yöntem, sistemdeki fiziksel sensörlerden elde edilen titreşim, sıcaklık, akustik emisyon, akım veya basınç gibi çok boyutlu verilerin analizine dayanır. Böylece, makinenin çalışma koşullarındaki olağandışı değişiklikler tespit edilerek olası arızalar öngörülebilir. Bu yaklaşım, yalnızca arıza öncesi erken uyarı sistemi oluşturmakla kalmaz, aynı zamanda bakım planlamasının optimizasyonuna da katkı sağlar. Kestirimci bakım uygulamaları sayesinde plansız duruş süreleri azalmakta, bakım maliyetleri düşmekte ve sistem güvenilirliği önemli ölçüde artmaktadır.

Endüstri 4.0 süreciyle birlikte ortaya çıkan akıllı üretim sistemleri, kestirimci bakım yaklaşımlarına yeni bir boyut kazandırmıştır. Sensör teknolojilerindeki gelişmeler, Nesnelerin İnterneti (IoT), Büyük Veri (Big Data) analitiği ve Yapay Zekâ (AI) tabanlı modelleme yöntemleri, endüstriyel verilerin gerçek zamanlı olarak toplanması ve işlenmesini mümkün kılmıştır. Bu gelişmelerin bir sonucu olarak, arıza tahmini ve anomali tespiti alanında makine öğrenmesi (ML) ve derin öğrenme (DL) tabanlı yöntemler giderek daha fazla kullanılmaya başlanmıştır. Gelişen bilgisayar ve

sensör teknolojileriyle birlikte, zaman serisi verilerine özel olarak tasarlanan otokodlayıcı tabanlı modeller, ekipmanın normal çalışma düzenini öğrenerek arızaya işaret eden sapmaları yüksek doğrulukla tespit edebilmektedir. Bu nedenle modern kestirimci bakım araştırmaları, DL tabanlı anomali tespiti yaklaşımlarına yoğunlaşmış durumdadır (Thai, 2022; Vadyala vd., 2022; Amini vd., 2023; Paulson vd., 2022; Wang vd., 2022; Greener vd., 2022).

Bu tez çalışmasında, hidrolik test düzeneğinden elde edilen çok sensörlü veri seti kullanılmıştır. Test sistemi, birincil çalışma çevrimi ile ikincil soğutma-filtrasyon çevriminden oluşmakta olup; 60 saniyelik tekrarlayan yük döngüleri sırasında basınç, debi ve sıcaklık sensörlerinden eş zamanlı ölçümler alınmaktadır. Bu tez çalışmanın temel amacı, çok boyutlu hidrolik sensör sinyallerinden elde edilen zaman-frekans temsilini kullanarak ekipmanın sağlık durumunu modelleyen bir yapay zekâ yaklaşımı geliştirmektir.

Mevcut literatürde yapılan çalışmaların önemli bir kısmı tek bir sensör türüne (örneğin yalnızca titreşim) ya da tek bir arıza türüne odaklanmakta; çoklu sensör füzyonunu sistematik bir şekilde ele almamaktadır. Ayrıca pek çok çalışmada arıza tespiti ikili sınıflandırma (arızalı–arızasız) düzeyinde değerlendirilmekte olup arızanın derecesinin nicel olarak tahmin edilmesi sınırlı biçimde ele alınmıştır. Bu tezde önerilen yaklaşım ise, hem çoklu sensör kaynağını bir arada işleyen hem de farklı arıza seviyelerini ayırt edebilen çok sınıflı bir modelleme yapısı içerdiğinden mevcut literatüre önemli bir yenilik getirmektedir.

Bu tez çalışması toplam 5 bölümden oluşmaktadır. Giriş bölümünü izleyen birinci bölümde, kestirimci bakım, endüstriyel sinyal işleme yöntemleri ve yapay zekâ tabanlı anomali tespiti üzerine yapılan önceki araştırmalar kapsamlı biçimde ele alınmaktadır. İkinci bölümde veri seti, deneysel düzene, kullanılan sinyal işleme yöntemleri ve derin öğrenme mimarileri ayrıntılı olarak açıklanmaktadır. Üçüncü bölümde geliştirilen modelin metodolojisi sunulmakta; dördüncü bölümde bu bulgular literatür ile karşılaştırılarak tartışılmaktadır. Son bölümde ise genel değerlendirmeler yapılmakta ve geleceğe yönelik araştırma önerileri verilmektedir.

1. LİTERATÜR ARAŞTIRMASI


Bu bölümde, endüstriyel ekipmanlarda kestirimci bakım uygulamalarının teorik temelleri, kullanılan yapay zekâ yöntemleri ve hidrolik sistemler özelindeki çalışmalar sistematik biçimde ele alınmaktadır. Literatür taraması; bakım stratejilerinin sınıflandırılması, kestirimci bakımın kuramsal gelişimi, yapay zekâ tabanlı arıza tespit yaklaşımları ve çalışmada kullanılan hidrolik veri setine dayanan araştırmalar olmak üzere dört ana başlık altında sunulmuştur.

1.1. Bakım Yöntemi

Bakım faaliyetleri; makinelerin ve endüstriyel ekipmanların güvenilir biçimde çalışmasını sağlamak, hizmet ömürlerini uzatmak, plansız duruşları en aza indirmek, işletme maliyetlerini kontrol altında tutmak ve iş sağlığı ile güvenliğini artırmak amacıyla planlanan teknik ve yönetsel süreçlerin bütünüdür. Günümüzde endüstriyel tesislerde makine parkının büyümesi, üretim süreçlerinin karmaşıklaşması ve rekabet baskısının artması, bakım faaliyetlerini yalnızca arıza sonrası gerçekleştirilen bir onarım işlemi olmaktan çıkarmış; bakım, üretim planlaması ve operasyonel karar alma süreçleriyle entegre edilen stratejik bir fonksiyon hâline gelmiştir. Özellikle Endüstri 4.0 yaklaşımıyla birlikte, bakım faaliyetlerinin veri temelli, sistematik ve öngörülebilir bir yapıya kavuşturulması, işletmelerin sürdürülebilirliği açısından kritik önem taşımaktadır (Nishat Toma ve Kim, 2020; Tandon ve Choudhury, 2005; Bektash vd., 2022).

Literatürde bakım stratejileri, bakımın hangi zamanda, hangi bilgiye dayanarak ve hangi müdahale düzeyinde gerçekleştirildiği temel alınarak sınıflandırılmaktadır. Bu bağlamda bakım programları çoğunlukla üç ana yaklaşım altında ele alınmaktadır: Düzeltici Bakım (Corrective Maintenance, CM), Periyodik Bakım (Preventive Maintenance, PM) ve Kestirimci Bakım (Predictive Maintenance, PdM). Bu üç yaklaşım, ekipman arızalarına karşı izlenen strateji, bakımın zamanlaması ve karar verme mekanizmaları açısından birbirinden önemli ölçüde ayrılmaktadır. Düzeltici bakım arıza gerçekleşikten sonra müdahaleyi esas alırken, periyodik bakım belirli zaman aralıklarında planlı müdahaleleri öngörmekte; kestirimci bakım ise ekipmanlardan elde edilen ölçülebilir veriler üzerinden arıza oluşmadan önce

müdahale edilmesini hedeflemektedir. Bakım yöntemlerinin ekipman sağlık durumu ile ilişkisini ve aralarındaki temel farkları kavramsal olarak ortaya koymak amacıyla Şekil 1’de genel bir karşılaştırma sunulmaktadır. Bu çerçevede, izleyen alt bölümlerde sırasıyla düzeltici bakım, periyodik bakım ve kestirimci bakım yaklaşımları ayrıntılı olarak ele alınacaktır (Arena vd., 2022; Abidi vd., 2022; Vallim vd., 2022; Ozkat vd., 2023).



Şekil 1. Ekipmanın sağlık durumu ve bakım yöntemleri ilişkisi.

1.1.1. Düzeltici Bakım

Düzeltici bakım (Corrective Maintenance, CM), ekipmanın arızalanmasının ardından gerçekleştirilen tamir ve iyileştirme faaliyetlerini ifade eden, reaktif karakterli bir yaklaşımdır. Bu yaklaşımda temel anlayış, ekipman çalışabildiği sürece müdahale edilmemesi; arıza gerçekleştikten sonra onarımın devreye alınmasıdır.

CM’nin en belirgin dezavantajı, arızaların öngörülemez olması nedeniyle üretimde plansız duruşlar oluşturmalarıdır. Plansız duruşlar; üretim kaybı, teslimat gecikmesi ve acil bakım organizasyonu gerektirdiğinden, toplam maliyeti yükseltir. Ayrıca arızanın ilerlemiş aşamada fark edilmesi; ikincil hasarların (örn. yatak–mil–kasnak zinciri hasarı) oluşmasına ve onarım kapsamının genişlemesine neden olabilir. Bu durum, yalnızca bakım maliyetini değil, yedek parça lojistiği ve stok yönetimi üzerindeki baskıyı da artırmaktadır. Bu nedenle CM yaklaşımının uygulanacağı

ekipmanlarda, kritik yedek parçaların stokta bulundurulması çoğu zaman zorunlu hâle gelir (Vallim vd., 2022; Ozkat vd., 2023; Hesabi vd., 2022).

Bununla birlikte CM, bazı ekipman gruplarında (kritik olmayan, arızası güvenlik riski oluşturmeyen ve değişimi kolay bileşenler gibi) “kabul edilebilir” olabilir. Ancak üretim sürekliliği, iş güvenliği ve toplam maliyet açısından değerlendirildiğinde CM, genel olarak proaktif yaklaşımlara göre daha riskli ve maliyetli bir strateji olarak kabul edilmektedir (Bastías vd., 2023; Arena vd., 2022).

1.1.2. Periyodik Bakım

Periyodik bakım (Periodic Maintenance, PM), ekipmanın güvenilirliğini korumak amacıyla belirli periyotlarda, önceden planlanmış bakım faaliyetlerinin uygulanmasıdır. PM yaklaşımında bakım zamanlaması çoğunlukla takvim süresine (gün/hafta/ay) veya kullanım miktarına (çalışma saati/çevrim sayısı) göre belirlenir.

PM'nin temel avantajı, bakım faaliyetlerinin önceden planlanabilmesi ve bu sayede bakım kaynaklarının (iş gücü, yedek parça, duruş planı) daha düzenli yönetilebilmesidir. Ayrıca düzenli kontroller, potansiyel arıza belirtilerinin erken aşamada fark edilmesine ve daha büyük hasarlar oluşmadan müdahale edilmesine katkı sağlayabilir. Bu durum; ekipman ömrünü uzatabilir, büyük arıza olasılığını düşürebilir ve bakım maliyetlerini daha öngörülebilir hâle getirebilir. Bununla birlikte PM'nin önemli bir sınırlılığı, ekipmanın gerçek sağlığından bağımsız olarak uygulanabilmesidir. Başka bir ifadeyle PM, bazı durumlarda gereksiz bakım ve erken parça değişimi üretebilir. Bu durum hem bakım maliyetini artırabilir hem de bakım için planlanan duruş nedeniyle üretim kaybına yol açabilir. Ayrıca yanlış planlama; bakım süresinin uzamasına, bakım faaliyetlerinin üretim takvimini olumsuz etkilemesine ve toplam verimliliğin düşmesine neden olabilmektedir. Bu nedenle PM planlamasında ekipman kullanım yoğunluğu, kritikliği, işletme koşulları ve geçmiş arıza kayıtları gibi faktörler dikkate alınmalıdır (Zonta vd., 2020).

1.1.3. Kestirimci Bakım

Kestirimci bakım (Predictive Maintenance, PdM), ekipmanlardan elde edilen verilerin analiz edilmesiyle ekipmanın mevcut sağlık durumunun değerlendirilmesi ve gelecekte oluşabilecek arızaların önceden tahmin edilmesi prensibine dayanan bir

bakım stratejisidir. PdM yaklaşımında amaç, bakım kararlarını yalnızca zaman tabanlı periyotlara göre değil, ekipmanın gerçek çalışma koşullarından türetilen verilere dayanarak vermektir.

PdM'nin temel avantajları; ekipman arızalarının erken tespiti sayesinde plansız duruşların azaltılması ve üretim sürekliliğinin desteklenmesi, bakım faaliyetlerinin yalnızca ihtiyaç duyulduğunda gerçekleştirilmesiyle gereksiz duruş ve parça değişimlerinin önlenerek bakım kaynaklarının daha etkin kullanılması, bozunma davranışlarının erken evrede belirlenmesi yoluyla ekipman ömrünün uzatılması ve kritik arızaların önceden öngörülebilmesi sayesinde iş güvenliğinin artırılması olarak özetlenebilir (Efeoğlu ve Tuna, 2022; Eddarhri vd., 2022; Wu ve Zheng, 2023).

Buna karşın PdM'nin uygulanmasında bazı pratik gereksinimler ve sınırlılıklar bulunmaktadır. Öncelikle sensör altyapısı, veri toplama–depolama sistemleri, yazılım ve insan kaynağı gereksinimi nedeniyle başlangıç yatırım maliyeti yükselir. İkinci olarak, PdM'nin başarısı “veri kalitesi” ve “analiz doğruluğu” ile doğrudan ilişkilidir. Hatalı sensör, eksik veri, yanlış ön işleme veya uygun olmayan modelleme tercihleri; yanıltıcı sonuçlar üretirek bakım maliyetini artırabilir ya da arızayı kaçırma riskini doğurabilir. Bu nedenle PdM uygulamaları, yalnızca bir model kurmaktan ibaret olmayıp, verinin izlenmesi, doğrulanması ve bakım karar süreçlerine entegre edilmesini gerektiren bütüncül bir sistem yaklaşımıyla ele alınmalıdır.

1.2. Kestirimci Bakımda Kullanılan Veriler

PdM yaklaşımının temelini, ekipmanların çalışma süresince ürettiği ölçülebilir verilerin sistematik olarak toplanması, analiz edilmesi ve bu analizler doğrultusunda bakım kararlarının verilmesi oluşturmaktadır. PdM'de bakım faaliyetleri, yalnızca belirli zaman aralıklarına dayalı planlardan ziyade, ekipmanın gerçek çalışma koşullarını ve bozunma davranışlarını yansıtan nicel verilere dayandırılmaktadır. Bu nedenle PdM uygulamalarında hangi verilerin toplandığı, bu verilerin hangi sıklıkta ve hangi ölçüm doğruluğuyla elde edildiği ile toplanan verilerin hangi analitik yöntemlerle işlendiği, bakım stratejisinin başarısını doğrudan etkileyen temel unsurlar olarak değerlendirilmektedir (Jardine, Lin & Banjevic, 2006; Lee, Bagheri & Kao, 2014).

Endüstriyel tesislerde PdM kapsamında kullanılan veriler çoğunlukla saha sensörleri, veri kaydediciler ve kontrol–otomasyon sistemleri aracılığıyla elde edilmektedir. Özellikle PLC ve SCADA tabanlı otomasyon altyapıları; ekipmanın akım, gerilim, basınç, sıcaklık, hız, yük ve çevrim sayısı gibi işletim parametrelerini sürekli olarak kaydederek bakım analitiği için kapsamlı bir veri altyapısı sunmaktadır. Bu tür sistemlerde verilerin zaman damgası bütünlüğü, sensör kalibrasyonu ve ölçüm güvenilirliği, ileri düzey analizlerin sağlıklı biçimde gerçekleştirilebilmesi için kritik ön koşullar olarak kabul edilmektedir (Mobley, 2002; Pech, Vrchota & Bednář, 2021).

PdM uygulamalarında kullanılan veri türleri, ekipmanların maruz kaldığı arıza mekanizmalarına bağlı olarak farklı fiziksel büyüklükleri temsil etmekte ve çoğu zaman birbirini tamamlayıcı nitelik taşımaktadır. Literatürde en yaygın olarak kullanılan veri türleri arasında titreşim (Vibration, VIB), yağ analizi (Oil Analysis, OA), kızılötesi termografi (Infrared Thermography, IRT), sıcaklık (Temperature, TEMP), ultrasonik test (Ultrasonic Testing, UT), gürültü/akustik (Acoustic/Noise, ACO) ve duman/gaz analizi (Smoke/Gas Analysis, SGA) verileri yer almaktadır (Randall, 2011; Tiboni vd., 2022). Bu veri türleri, arızaların erken evrede tespit edilmesi, arıza türlerinin ayrıştırılması ve arıza şiddetinin izlenmesi açısından PdM sistemlerine farklı açılardan katkı sağlamaktadır (Karabacak vd., 2022).

Titreşim verileri, döner makineler ve mekanik aktarma organlarında PdM'nin en yaygın kullanılan veri kaynağı olarak kabul edilmektedir. Rulman, dişli, mil–kaplin ve kasnak sistemlerinde meydana gelen dengesizlik, hizasızlık, gevşeklik ve yuvarlanma elemanı hasarları, çoğu zaman titreşim sinyalinde karakteristik değişimlere yol açmaktadır. Bu nedenle titreşim tabanlı koşul izleme, hem erken arıza tespiti hem de arıza sınıflandırması açısından yüksek ayırt edicilik sunmaktadır. Literatürde titreşim sinyallerinin zaman alanı, frekans alanı ve zaman–frekans alanında incelenmesiyle arıza tanısında güvenilir sonuçlar elde edilebildiği belirtilmektedir (Randall, 2011; Tiboni vd., 2022).

Yağ analizi verileri, ekipman içerisindeki aşınma ve bozunma süreçlerine ilişkin dolaylı fakat kritik bilgiler sunmaktadır. Yağlayıcı akışkan içerisinde bulunan metal partiküller, su kontaminasyonu, kirlilik seviyesi ve viskozite değişimleri; özellikle dişli kutuları, yataklar ve hidrolik sistemlerde meydana gelen içsel hasarların göstergesi olarak değerlendirilmektedir. Yağ analizinin PdM süreçlerine


entegrasyonunun, titreşim ve sıcaklık verileriyle birlikte kullanıldığında arıza tespitinin güvenilirliğini artırdığı literatürde vurgulanmaktadır (Mobley, 2002; Rigolli vd., 2023).

Kızılötesi termografi ve sıcaklık verileri, ekipmanların termal davranışlarının izlenmesine dayanmaktadır. Kızılötesi termografi, temassız ölçüm imkânı sağlayarak elektrik bağlantı direnci artışı, sürtünme kaynaklı aşırı ısınma ve akışkan kaçaqlarının tespitinde yaygın olarak kullanılmaktadır. Sürekli sıcaklık ölçümleri ise ekipmanın belirli noktalarındaki termal eğilimlerin izlenmesine olanak tanıyarak aşırı yüklenme veya soğutma performansı düşüşü gibi durumlar hakkında erken uyarılar sunmaktadır. Termal tabanlı verilerin titreşim verileriyle birlikte kullanılması, PdM sistemlerinin tanısal doğruluğunu artıran önemli bir unsurdur (Bagavathiappan vd., 2013).

Ultrasonik ve akustik veriler, özellikle yüksek frekanslı bileşenlerdeki değişimlere duyarlı olmaları nedeniyle erken evre arıza belirtilerinin yakalanmasında önemli bir role sahiptir. Basıncı hatlardaki kaçaqlar, valf sızıntıları ve erken rulman hasarları çoğu zaman ultrasonik sinyallerde belirginleşmektedir. Akustik veriler ise ekipmanın çalışma sırasında ürettiği ses örüntülerindeki değişimleri analiz ederek anormallik tespitine katkı sağlamaktadır. Bu yöntemler, titreşim verileriyle birlikte kullanıldığında çoklu sensör yaklaşımı sayesinde PdM uygulamalarının güvenilirliğini artırmaktadır (Al-Ghamd & Mba, 2006).

Duman ve gaz analizi verileri, yanma, aşırı ısınma veya kimyasal reaksiyon kaynaklı arızalarda kritik bir erken uyarı mekanizması sunmaktadır. Elektrik kablolarındaki izolasyonun yanması veya endüstriyel proseslerde gaz bileşimi değişimleri, ciddi arızalar meydana gelmeden önce bu tür ölçümler aracılığıyla tespit edilebilmektedir. Bununla birlikte bu veri türlerinin etkin kullanımı, sensör seçimi ve ölçüm ortamının doğru tanımlanmasına doğrudan bağlıdır (Mobley, 2002).

Şekil 2, PdM’de kullanılan başlıca veri türleri ve temsil ettikleri arıza mekanizmaları, kestirimci bakım uygulamalarında yaygın olarak kullanılan sensör tabanlı ölçümlerin, ekipmanlarda ortaya çıkan farklı arıza türleriyle olan ilişkisini kavramsal olarak özetlemektedir. Bu bütüncül yapı, PdM uygulamalarında tek bir veri türüne dayalı analizlerin çoğu zaman yetersiz kaldığını; çoklu sensör verilerinin birlikte değerlendirilmesinin arıza tespiti ve arıza şiddeti belirleme doğruluğunu önemli ölçüde artırdığını açıkça ortaya koymaktadır (Samuel ve Pines, 2005).



Şekil 2. PdM’de kullanılan başlıca veri türleri ve temsil ettikleri arıza mekanizmaları.

Son yıllarda PdM uygulamalarında bu heterojen veri türlerinin birlikte değerlendirilmesi, Makine Öğrenmesi (Machine Learning, ML) ve Derin Öğrenme (Deep Learning, DL) tabanlı yöntemlerin yaygınlaşmasıyla daha sistematik hâle gelmiştir. Bu yaklaşımlar, çoklu sensör verilerinden karmaşık örüntüleri otomatik olarak öğrenebilmekte ve arıza tespiti ile arıza şiddeti tahmininde yüksek doğruluk sağlamaktadır. Bununla birlikte literatür, ML ve DL tabanlı PdM çözümlerinin başarısının büyük ölçüde veri kalitesi, sensör güvenilirliği ve doğru etiketleme süreçlerine bağlı olduğunu göstermektedir. Bu nedenle PdM’de veri toplama ve veri yönetimi süreci, bakım stratejisinin temel bileşenlerinden biri olarak ele alınmalıdır (Lee vd., 2014; Jardine vd., 2006).

1.3. Yapay Zekâ Tabanlı Arıza Tespit Yaklaşımları

PdM literatüründe arıza tespiti ve durum izleme problemleri, zaman içerisinde istatistiksel yöntemlerden veri güdümlü yapay zekâ yaklaşımlarına doğru evrilmiştir. Bu evrim, sensör teknolojilerindeki gelişmeler, endüstriyel sistemlerden elde edilen veri miktarının artması ve hesaplama kapasitesinin yükselmesiyle doğrudan ilişkilidir. Yapay zekâ tabanlı yöntemler, karmaşık ve doğrusal olmayan sistem davranışlarını


modelleyebilme yetenekleri sayesinde PdM alanında giderek baskın hâle gelmiştir. Literatürde bu gelişim süreci; klasik makine öğrenmesi yöntemleri, zaman–frekans tabanlı temsiller ve derin öğrenme ile hibrit modeller olmak üzere üç ana aşamada incelenmektedir (Özkat, 2021; Ceryan vd., 2021; Koca ve Ünsal, 2017).

1.3.1. Klasik Makine Öğrenmesi Yöntemleri

PdM alanında yapay zekâ tabanlı arıza tespit yaklaşımlarının temelleri, klasik makine öğrenmesi algoritmalarına dayanmaktadır. Bu dönemdeki çalışmalar, büyük ölçüde sensör verilerinden çıkarılan istatistiksel özniteliklerin (örneğin RMS, crest factor, kurtosis ve benzeri zaman/frekans alanı göstergeleri) denetimli öğrenme algoritmalarına giriş olarak verilmesi esasına dayanmıştır. Bu yaklaşımın PdM literatüründe yaygınlaşmasında, Destek Vektör Makineleri'nin (Support Vector Machine, SVM) sunduğu yüksek ayırt edicilik ve sınırlı veriyle çalışabilme avantajı belirleyici olmuştur.

Widodo ve Yang (2007), SVM tabanlı yöntemlerin makine koşullu izleme ve arıza teşhisinde etkin biçimde kullanılabileceğini sistematik olarak göstermiştir. Çalışmada, döner makinelerden elde edilen titreşim verileri üzerinden farklı arıza türlerinin yüksek doğrulukla sınıflandırılabilirdiği raporlanmıştır; SVM'in PdM uygulamaları için güvenilir bir sınıflandırıcı olduğu ortaya konmuştur. Bu çalışma, PdM literatüründe veri güdümlü sınıflandırma yaklaşımlarının temel referanslarından biri olarak kabul edilmektedir.

Bununla birlikte klasik makine öğrenmesi yaklaşımlarının en önemli sınırlılığı, öznitelik mühendisliğine olan güçlü bağımlılıktır. Kullanılacak özelliklerin manuel olarak seçilmesi ve tasarlanması, hem uzman bilgisi gerektirmekte hem de farklı çalışma koşulları altında model performansının önemli ölçüde değişmesine neden olmaktadır. Özellikle çok sensörlü, doğrusal olmayan ve değişken yük koşullarına sahip endüstriyel sistemlerde, el ile seçilen özniteliklerin genellenebilirliği sınırlı kalmıştır. Bu durum, PdM literatüründe daha otomatik ve veri temelli temsil öğrenme yaklaşımlarına yönelimin temel motivasyonlarından biri olmuştur. Şekil 3, PdM alanında klasik makine öğrenmesi yaklaşımlarında sensör verilerinden öznitelik çıkarımı yapılması, bu özniteliklerin denetimli öğrenme algoritmalarıyla işlenmesi ve sürecin öznitelik mühendisliğine olan bağımlılığını kavramsal olarak göstermektedir.



Şekil 3. PdM alanında klasik makine öğrenmesi yaklaşımlarını gösteren süreç.

1.3.2. Zaman–Frekans Tabanlı Yöntemler


Endüstriyel ekipmanlardan elde edilen sensör sinyalleri çoğu zaman durağan değildir ve arıza imzaları geçici (transient) karakter sergileyebilir. Bu nedenle yalnızca zaman alanı veya frekans alanı analizleri, PdM uygulamalarında arıza belirtilerini yeterli hassasiyetle yakalamakta yetersiz kalabilmektedir. Bu sınırlılık, zaman–frekans tabanlı analiz yöntemlerinin PdM literatüründe giderek daha fazla önem kazanmasına yol açmıştır.

Bu bağlamda Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT), sinyalin frekans içeriğini zaman eksenı boyunca çok çözünürlüklü biçimde temsil edebilmesi nedeniyle öne çıkmaktadır. Kedadouche, Thomas ve Tahan (2016), döner makinelerde arıza teşhisi için ampirik dalgacık dönüşümü (EWT) ve dalgacık paket dönüşümünü (WPT) karşılaştırmış; dalgacık temelli yöntemlerin, arızaya özgü frekans bileşenlerini daha belirgin biçimde ortaya koyabildiğini göstermiştir. Bu

çalışma, CWT tabanlı skalogramın arıza imzalarının ayrıştırılmasında güçlü bir temsil sunduğunu ortaya koyan önemli referanslardan biridir.

Zaman-frekans temsillerinin en önemli avantajlarından biri, sinyalin iki boyutlu (2B) bir görüntü hâline dönüştürülebilmesidir. CWT tabanlı skalogram, PdM problemlerini klasik sinyal işleme çerçevesinden çıkararak, görüntü işleme ve derin öğrenme yaklaşımlarıyla ele alınabilir hâle getirmiştir. Bu dönüşüm, PdM literatüründe derin öğrenmeye geçişin kritik ara basamaklarından biri olarak değerlendirilmektedir.

Şekil 4, PdM uygulamalarında durağan olmayan sensör sinyallerinin zaman-frekans dönüşümü ile iki boyutlu skalograma dönüştürülmesini ve bu temsillerin arıza tespiti ile bakım karar süreçlerinde kullanılmasını özetlemektedir.



Şekil 4. Zaman-Frekans tabanlı kestirimci bakım analizlerin aşamaları.

1.3.3. Derin Öğrenme ve Hibrit Yöntemler

2015 sonrasında PdM literatüründe derin öğrenme tabanlı yaklaşımlar belirgin biçimde baskın hâle gelmiştir. Bu dönemde Konvolüsyonel Sinir Ağları (Convolutional Neural Network, CNN), Uzun-Kısa Süreli Bellek ağları (Long Short-Term Memory, LSTM) ve bu yapıların hibrit kombinasyonları yaygın olarak kullanılmaya başlanmıştır. Derin öğrenme modellerinin en önemli avantajı, manuel öznetelik mühendisliğine olan ihtiyacı azaltarak, ham veya dönüştürülmüş sensör verilerinden otomatik özellik öğrenimi gerçekleştirebilmeleridir.

Zhao vd. (2017), CNN ile çift yönlü LSTM (BiLSTM) yapılarını birleştirerek, hem uzamsal (zaman–frekans veya frekans alanı) hem de zamansal bağımlılıkların aynı mimari içerisinde öğrenilebildiğini göstermiştir. Bu çalışma, PdM’de hibrit CNN–RNN mimarilerinin karmaşık arıza örüntülerini yakalamada önemli avantajlar sunduğunu ortaya koymuştur.


Derin öğrenme modellerinin yorumlanabilirliğini ve ayırt ediciliğini artırmaya yönelik olarak, dikkat (attention) haritaları tabanlı derin öğrenmesi modellerini de PdM literatürüne entegre edilmiştir. Shao vd. (2018), dikkat haritaları tabanlı bir derin öğrenme modeliyle rulman arıza teşhisi gerçekleştirmiş; modelin sinyaldeki kritik zaman–frekans bölgelerine adaptif olarak odaklanabildiğini ve bu sayede sınıflandırma performansının arttığını göstermiştir. Bu yaklaşım, PdM’de yalnızca derinlik değil, bilginin seçici biçimde ağırlıklandırılmasının da önemli olduğunu vurgulamaktadır.

Zhang vd. (2019) tarafından sunulan kapsamlı derleme çalışması, CNN, LSTM ve otoenkoder (Autoencoder, AE) tabanlı yöntemlerin PdM literatüründeki yükselişini sistematik biçimde belgelemekte; klasik makine öğrenmesi yaklaşımlarının çoğunlukla karşılaştırma amaçlı kullanıldığını göstermektedir. Bu çalışma, derin öğrenmenin PdM’de ana akım hâline geldiğini açık biçimde ortaya koymaktadır.

Daha yakın dönemde, derin öğrenme alanında transformer tabanlı mimariler PdM literatüründe öne çıkan yeni bir eğilim olarak dikkat çekmektedir. Chen, Li ve Sanchez (2022), transformer ağlarının koşul izleme ve PdM uygulamalarındaki potansiyelini ele alarak, self-attention mekanizmasının uzun dönem bağımlılıkları modellemedeki üstünlüğünü vurgulamıştır. Bu yaklaşım, özellikle uzun süreli ve çok sensörlü zaman serilerinde önemli avantajlar sunmaktadır.

Hibrit mimarilerin geliřimi, transformer yapılarını da kapsayacak řekilde devam etmiştir. Li, Wang ve Xu (2024), zamansal konvolüsyon katmanları ile transformer bloklarını birleřtiren hibrit bir model önererek, hem kısa vadeli yerel örüntülerin hem de uzun vadeli bağımlılıkların daha etkili biçimde öğrenilebildiğini göstermiştir. Benzer řekilde, otoenkoder tabanlı özellik öğrenimini CNN sınıflandırmasıyla birleřtiren yaklaşımlar, yüksek boyutlu sensör verilerinde anomali tespiti ve arıza sınıflandırması için güçlü bir çerçeve sunmaktadır (Cui, Tang & Chen, 2023).

Bu kronolojik gelişim, PdM literatüründe yapay zekâ tabanlı arıza tespit yaklaşımlarının; istatistiksel temelli modellerden, klasik makine öğrenmesine; oradan zaman–frekans temsilleriyle desteklenen derin ve hibrit mimarilere doğru evrildiğini açık biçimde göstermektedir. Tablo 1, kestirimci bakım (PdM) alanında yapay zekâ tabanlı arıza tespit yaklaşımlarının istatistiksel temellerden derin ve hibrit modellere uzanan kronolojik evrimini özetlemektedir. Şekil 5 ise PdM alanında derin öğrenme ve hibrit modellerin gelişimini göstermektedir.



Şekil 5. PdM alanında derin öğrenme ve hibrit modellerin gelişimini.

Tablo 1. Kestirimci bakım (PdM) alanında yapay zekâ tabanlı arıza tespit yaklaşımları.

Çalışma	Temel Yaklaşım	Kullanılan Veri / Temsil	Literatüre Katkı
Jardine vd., (2006)	CBM ve istatistiksel-prognostik temeller	Sensör verileri ve istatistiksel göstergeler.	PdM'nin teorik temelini oluşturmuş, durum temelli bakım (CBM) kapsamında tanı ve prognostik süreçleri sistematik biçimde tanımlamıştır.
Gebraeel (2006)	Olasılıksal RUL modellemesi	Sensör tabanlı bozunma verileri.	Sensör verileriyle güncellenen Bayesyen kalan faydalı ömür (RUL) dağılımlarını tanımlayarak PdM'de belirsizlik altında karar verme yaklaşımını geliştirmiştir.
Widodo ve Yang (2007)	Klasik makine öğrenmesi (SVM)	İstatistiksel öznitelikler (RMS, kurtosis vb.).	Destek Vektör Makineleri'nin (SVM) makine koşul izleme ve arıza teşhisinde etkin biçimde kullanılabileceğini göstermiştir.
Lee vd., (2014)	Veri odaklı PdM ve PHM çerçevesi	Çok sensörlü zaman serileri.	PdM'yi veri güdümlü bir problem olarak ele almış, 2009 PHM çalışmalarını bütünleştiren metodolojik bir çerçeve sunmuştur.
Schütze vd., (2015)	Akıllı sensörler ve Endüstri 4.0	Çok sensörlü hidrolik test düzeneği.	UCI Hidrolik Veri Seti'nin temelini oluşturan deneysel altyapıyı tanımlamış ve PdM araştırmaları için referans ortam sağlamıştır.
Kedadouche vd., (2016)	Zaman-frekans analizi (CWT, EWT, WPT)	Dalgacık tabanlı zaman-frekans temsilleri.	CWT tabanlı temsillerin arıza imzalarını daha belirgin biçimde ortaya koyduğunu göstermiştir.
Zhao vd., (2017)	Derin öğrenme (CNN-BiLSTM)	Ham sinyal ve zaman-frekans temsilleri.	Uzamsal ve zamansal bağımlılıkların aynı mimari içinde birlikte öğrenilebildiğini göstermiştir.

Tablo 1 (Devam). Kestirimci bakım (PdM) alanında yapay zekâ tabanlı arıza tespit yaklaşımları.

Shao vd., (2018)	Dikkat haritaları tabanlı derin öğrenme	Zaman ve frekans temelli sinyal temsilleri.	Dikkat haritaları mekanizmasının kritik bilgiye odaklanarak arıza teşhis performansını artırdığını ortaya koymuştur.
Zhang vd., (2019)	Derin öğrenme modelleri	CNN, LSTM ve AE tabanlı yöntemler.	Derin öğrenmenin PdM literatüründe baskın hâle geldiğini belgeleyen kapsamlı bir derleme sunmuştur.
Helwig ve Schütze (2020)	Transfer learning	Çok sensörlü hidrolik sistem verileri.	Hidrolik sistemlerde transfer öğrenmenin koşul izleme doğruluğunu artırdığını göstermiştir.
Wen vd., (2017)	CWT + CNN ve transfer learning	CWT skalogramı.	Zaman–frekans görüntülerinin CNN tabanlı arıza teşhisi için güçlü bir temsil sunduğunu göstermiştir.
Chen vd., (2022)	Aktarımlı öğrenim tabanlı	Uzun süreli çok sensörlü zaman serileri.	Öz-dikkat mekanizmasının uzun dönem bağımlılıkları modellemedeki üstünlüğünü ortaya koymuştur.
Cui vd., (2023)	Otoenkoder + CNN	Yüksek boyutlu sensör verileri.	AE tabanlı özellik öğrenimi ile CNN sınıflandırmasını birleştirerek güçlü bir arıza tespit çerçevesi sunmuştur.
Li vd., (2024)	Hibrit CNN + transformer	Zamansal konvolüsyon ve dikkat haritaları modelleri.	Kısa ve uzun vadeli bağımlılıkları birlikte modelleyen hibrit mimarilerin PdM performansını artırdığını göstermiştir.

1.4. Tezin Kapsamı ve Amacı

Bu tez çalışmasının temel amacı, endüstriyel hidrolik sistemlerde meydana gelen iç kaçak arızalarının erken evrede tespit edilmesi ve arıza şiddetinin güvenilir biçimde sınıflandırılmasına yönelik, derin öğrenme tabanlı bir kestirimci bakım yöntemi geliştirmektir. Hidrolik sistemlerde oluşan iç kaçaklar, çoğu zaman ani bir arıza şeklinde ortaya çıkmamakta; sistem performansında kademeli bozulmalar ve verim kayıpları ile ilerleyen karmaşık süreçler olarak gelişmektedir. Bu durum, geleneksel bakım ve eşik tabanlı arıza tespit yaklaşımlarının erken evre arızaları ayırt etmesini zorlaştırmaktadır.

Tez kapsamında, deneysel bir hidrolik test düzeneğinden elde edilen çoklu sensör tabanlı zaman serisi verileri kullanılmıştır. Bu veriler; normal çalışma durumu, hafif iç kaçak ve şiddetli iç kaçak olmak üzere farklı sistem durumlarını temsil edecek şekilde etiketlenmiştir. Zaman serisi verileri, sistem dinamiklerini daha etkin biçimde temsil edebilmek amacıyla zaman–frekans alanına dönüştürülmüş ve derin öğrenme modellerine uygun girdi yapıları hâline getirilmiştir.

Çalışmanın kapsamında, konvolüsyonel sinir ağları ile zamansal özelliklerin çıkarılması ve uzun kısa süreli bellek ağları ile ardışık veri segmentleri arasındaki zamansal bağımlılıkların modellenmesi hedeflenmiştir. Önerilen derin öğrenme modeli, hidrolik sistemlerde özellikle erken evre iç kaçak arızalarının ayırt edilmesinde yüksek doğruluk ve kararlılık sağlamayı amaçlamaktadır. Sonuç olarak bu tez çalışması, hidrolik sistemler için veri odaklı, genellenebilir ve endüstriyel uygulamalara uyarlanabilir bir kestirimci bakım çerçevesi sunmayı hedeflemekte; kestirimci bakım yaklaşımı sayesinde bakım maliyetlerinin azaltılması, plansız duruşların önlenmesi ve sistem güvenilirliğinin artırılmasına katkı sağlamayı amaçlamaktadır.

2. KULLANILAN VERİ SETİ


Bu tez çalışmasında kullanılan veri seti, “Condition Monitoring of Hydraulic Systems” başlığıyla UCI Machine Learning Repository’de araştırmacılara açık olarak sunulan, çok sensörlü ve çoklu arıza tiplerini içeren deneysel bir hidrolik sistem veri setidir. Veri seti, Almanya’da Saarland Üniversitesi Ölçüm Teknolojileri Laboratuvarı ve ZeMA – Zentrum für Mechatronik und Automatisierungstechnik GmbH iş birliğiyle geliştirilen gerçekçi bir hidrolik test düzeneği üzerinde uzun süreli ve kontrollü deneyler sonucunda elde edilmiştir (Helwig & Schütze, 2020). Endüstriyel hidrolik devrelerde gerçekleşen tipik arızaların kontrollü olarak uygulanması ve çoklu sensörler üzerinden sürekli veri toplanması sayesinde, veri seti kestirimci bakım ve anomali tespiti çalışmalarında uluslararası düzeyde yaygın bir referans hâline gelmiştir. Veri setinin temel amacı; endüstride yaygın olarak karşılaşılan pompa, valf, akümülatör ve soğutma ünitesi arızalarının, farklı şiddet seviyelerinde ve kontrollü koşullar altında modellenmesi ve bu süreçlerin çoklu sensör verileri üzerinden izlenebilmesidir. Bu yönüyle veri seti, kestirimci bakım ve anomali tespiti alanlarında literatürde en sık kullanılan referans veri setlerinden biri hâline gelmiştir.

2.1. Hidrolik Test Düzeneği

Deneysel hidrolik test sistem, endüstride kullanılan tipik bir hidrolik güç ünitesinin laboratuvar ölçekli fakat işlevsel bir modeli olarak tasarlanmıştır. Sistem, ortak bir yağ tankı üzerinden birbirine bağlı iki ana devreden oluşmaktadır: (a) Çalışma Devresi ve (b) Soğutma–Filtrasyon Devresi.

Şekil 6’da deneysel hidrolik test sisteminin genel yapısı ve temel bileşenleri şematik olarak gösterilmektedir. Diyagramda, birincil çalışma devresinde yer alan hidrolik pompa, yön kontrol valfi, hidrolik akümülatör ve mekanik yük altında çalışan hidrolik silindir açıkça görülmektedir. İkincil soğutma–filtrasyon devresi ise yağ soğutma ünitesi, filtrasyon elemanları ve ilgili akış hatları ile temsil edilmiştir. Ayrıca basınç, akış, sıcaklık, titreşim ve güç ölçümlerini gerçekleştiren sensörlerin sistem üzerindeki konumları da diyagram üzerinde gösterilerek, veri toplama altyapısının bütüncül yapısı vurgulanmıştır. Bu diyagram, deneysel düzeneğe arızaların kontrollü

biçimde uygulanabildiğini ve çoklu sensör verilerinin eş zamanlı olarak elde edildiğini görsel olarak ortaya koymaktadır.



Şekil 6. Deneyisel hidrolik test sisteminin diyagramı (Helwig & Schütze, 2020).

2.1.1. Birincil Çalışma Devresi

Birincil çalışma devresi, hidrolik enerjinin üretildiği, yönlendirildiği ve mekanik işe dönüştürüldüğü ana devredir. Bu devre, hidrolik sistemin performansını ve arıza davranışlarını doğrudan etkileyen temel bileşenleri içermektedir.

2.1.1.1. Hidrolik Pompa

Hidrolik pompa, sistemin temel enerji kaynağıdır ve mekanik enerjiyi hidrolik enerjiye dönüştürerek sisteme basınçlı yağ akışı sağlar. Pompanın çalışma durumu, sistem genelindeki basınç, akış ve verim karakteristiklerini doğrudan etkilemektedir.

Bu veri setinde pompa üzerinde özellikle iç kaçak oluşumu kontrollü olarak modellenmiştir. Pompa iç kaçakları, basınç düşüşü ve akış dengesizliği gibi belirtilerle kendini göstermekte olup, kestirimci bakım çalışmalarında tespiti kritik öneme

sahiptir. Pompa arızaları genellikle yavaş gelişen ve erken aşamada fark edilmediğinde ciddi sistem hasarlarına yol açabilen arızalardır.

2.1.1.2. Yön Kontrol Valfi

Yön kontrol valfi, hidrolik akışın yönünü ve zamanlamasını kontrol ederek silindir hareketlerini düzenlemektedir. Valfin anahtarlama performansı, sistemin dinamik davranışı üzerinde belirleyici bir etkiye sahiptir.

Bu veri setinde valf arızaları, kısmi tıkanma ve anahtarlama gecikmesi şeklinde modellenmiştir. Valf gecikmeleri, basınç ve akış sinyallerinde özellikle geçici (transient) bölgelerde belirgin değişimlere neden olmaktadır. Bu nedenle valf davranışı, zaman alanı analizleri ve geçici rejimlerin incelenmesi açısından önemli bir araştırma alanı sunmaktadır.

2.1.1.3. Hidrolik Akümülatör (Basınç Dengeleme Elemanı)

Hidrolik akümülatör, sistemdeki basınç dalgalanmalarını sönümlemek ve ani yük değişimlerinde enerji dengelemesi sağlamak amacıyla kullanılmaktadır. Akümülatör, özellikle sistem kararlılığının korunmasında kritik bir rol oynamaktadır.

Veri setinde akümülatör arızaları, ön şarj basıncının düşürülmesi yoluyla modellenmiştir. Akümülatör basıncındaki azalma, sistemin kararlı çalışma yeteneğini zayıflatmakta ve basınç sinyallerinde karakteristik değişimlere yol açmaktadır. Bu tür arızalar genellikle dolaylı belirtilerle ortaya çıktığından, anomali tespiti açısından zorlayıcı bir problem oluşturmaktadır.

2.1.1.4. Hidrolik Silindir ve Mekanik Yük Simülasyonu

Hidrolik silindir, basınçlı yağ enerjisini doğrusal mekanik harekete dönüştüren elemandır. Test düzeneğinde silindir, gerçek endüstriyel uygulamaları temsil edecek şekilde mekanik yük altında çalıştırılmaktadır.

Mekanik yük simülasyonu sayesinde sistem, sabit ve tekrarlanabilir çalışma koşulları altında test edilmiştir. Bu durum, her çevrimin benzer fiziksel anlam taşımamasını sağlamakta ve çevrim-bazlı veri analizini mümkün kılmaktadır. Ayrıca yük altında çalışma, sistemde oluşan küçük arızaların sensör sinyallerine daha belirgin şekilde yansımaya katkı sağlamaktadır.

2.1.2. İkincil Soğutma–Filtrasyon Devresi

İkincil devre, hidrolik sistemin uzun süreli ve güvenli çalışmasını sağlamak amacıyla yağın sıcaklık ve temizlik koşullarını kontrol eden yardımcı devredir. Bu devre, sistem performansını dolaylı olarak etkileyen ancak arıza gelişiminde kritik rol oynayan bileşenleri içermektedir.

2.1.2.1. Yağ Soğutma Ünitesi

Yağ soğutma ünitesi, hidrolik yağın çalışma sıcaklığını belirli sınırlar içerisinde tutarak sistem verimini ve bileşen ömrünü korumayı amaçlamaktadır. Hidrolik sistemlerde sıcaklık artışı, sürtünme kayıplarının ve verim düşüşünün önemli bir göstergesidir.

Bu veri setinde soğutma ünitesi arızaları, soğutma veriminin kontrollü olarak düşürülmesi şeklinde modellenmiştir. Soğutma performansındaki azalma, sıcaklık sensörlerinde yavaş fakat sürekli bir artışa neden olmakta ve bu durum erken arıza tespiti açısından önemli bir gösterge sunmaktadır.

2.1.2.2. Filtrasyon Elemanları ve Kontrol Vanaları

Filtrasyon elemanları, hidrolik yağ içerisindeki partiküllerin temizlenmesini sağlayarak sistem bileşenlerinin aşınmasını önlemektedir. Filtre kirliliği ve buna bağlı basınç kayıpları, hidrolik sistemlerde sık karşılaşılan dolaylı arıza nedenlerindendir.

Kontrol vanaları ise yağ akışının soğutma ve filtrasyon devresi içerisindeki yönlendirilmesini sağlamaktadır. Bu elemanlar, sistemin ısı ve akış dengesinin korunmasında önemli rol oynamaktadır.

2.1.2.3. Hacimsel Akış Sensörleri

İkincil devrede yer alan hacimsel akış sensörleri, yağın soğutma ve filtrasyon hattındaki akış miktarını ölçmektedir. Akış değerlerindeki ani veya kademeli değişimler, filtre tıkanması ve soğutma performansındaki bozulmalar hakkında dolaylı bilgi sağlamaktadır.

Bu sensörler, özellikle basınç ve sıcaklık sensörleri birlikte değerlendirildiğinde, sistem sağlığının çok boyutlu olarak izlenmesine katkı sunmaktadır.

2.1.3. Sistem Çalışma Çevrimleri ve Veri Toplama Stratejisi

Bu tez çalışmasında, deneysel ölçüm yapılmamış, literatürde paylaşılan mevcut bir hidrolik test sistemi veri seti kullanılmıştır. Veri setinin oluşturulması sırasında sistem, yaklaşık 60 saniyelik sabit yük çevrimleri altında çalıştırılmış ve bu çevrimler, veri setinin üretildiği çalışma süresi boyunca 2205 kez tekrarlanmıştır. Her bir çevrim, endüstride karşılaşılan tipik bir hidrolik çalışma görevini temsil edecek şekilde tanımlanmıştır. Böylece hem normal çalışma durumlarını hem de gelişen arıza süreçlerini içeren geniş kapsamlı bir veri elde edilmiştir

Her çevrim süresince basınç, sıcaklık, hacimsel akış ve mekanik titreşim gibi temel proses değişkenleri eş zamanlı olarak kaydedilmiştir. Bu sayede veri seti, hidrolik sistemin hem kararlı (steady-state) hem de geçici (transient) çalışma koşullarını içerecek biçimde yapılandırılmıştır.

Çevrim-temelli bu veri yapısı, her bir ölçümün fiziksel olarak anlamlı bir çalışma periyodunu temsil etmesini sağlamakta; aynı zamanda makine öğrenmesi tabanlı kestirimci bakım ve anomali tespiti yöntemleri için düzenli, karşılaştırılabilir ve etiketlenebilir bir veri kümesi sunmaktadır. Bu çalışma kapsamında, söz konusu veri seti kullanılarak hidrolik sistemlerde arıza tespitine yönelik derin öğrenme tabanlı analizler gerçekleştirilmiştir.

2.2. Sensör Yapısı ve Ölçülen Büyüklükler

Bu tez çalışmasında kullanılan veri seti, hidrolik sistemin davranışını kapsamlı ve çok boyutlu biçimde izleyebilmek amacıyla farklı fiziksel büyüklükleri ölçen çok sensörlü bir yapı üzerine kurulmuştur. Toplam 17 farklı sensör sinyali, sistemin basınç, akış, sıcaklık, titreşim ve enerji verimliliği gibi temel dinamiklerini temsil etmektedir.

Sensörlerin farklı örnekleme frekanslarında çalışması, gerçek endüstriyel uygulamalarda yaygın olarak karşılaşılan çok oranlı (multi-rate) veri yapısını yansıtmaktadır. Bu durum, veri setini hem klasik istatistiksel yöntemler hem de derin öğrenme tabanlı yaklaşımlar açısından zengin ve zorlayıcı bir araştırma problemi hâline getirmektedir.

2.2.1. Basınç Sensörleri

Basınç sensörleri, hidrolik sistemin en kritik ölçüm elemanlarıdır ve sistemin çalışma durumuna ilişkin doğrudan bilgi sunmaktadır. Veri setinde yer alan altı adet basınç sensörü (PS1–PS6), hidrolik pompa çıkışı, yön kontrol valfi giriş–çıkışı, akümülatör hattı ve soğutma devresindeki stratejik noktalara yerleştirilmiştir.

Bu sensörler 100 Hz örnekleme frekansı ile çalışmakta olup, özellikle sistemde meydana gelen geçici (transient) basınç değişimlerini yüksek zaman çözünürlüğü ile yakalayabilmektedir. Valf anahtarlama süreçleri, pompa kaçaqları ve akümülatör basınç kayıpları gibi arızalar, basınç sinyallerinde karakteristik dalgalanmalar ve seviye değişimleri oluşturmaktadır.

Basınç sensörlerinden elde edilen veriler, bu tez kapsamında hem zaman alanı analizlerinde hem de zaman–frekans tabanlı anomali tespiti çalışmalarında temel girdi olarak kullanılmıştır. Bu yönüyle basınç sensörleri, veri setinin en yüksek bilgi içeriğine sahip bileşenleri arasında yer almaktadır.

2.2.2. Elektriksel Güç Sensörü

Elektriksel güç sensörü (EPS1), hidrolik pompanın elektrik motoruna ait giriş gücünü ölçmektedir. Bu sensör de 100 Hz örnekleme frekansında çalışmakta ve pompanın yük altındaki enerji tüketimini yüksek çözünürlükle izlemektedir.

Pompa iç kaçaqları ve mekanik aşınmalar, genellikle doğrudan basınç veya akış sinyallerinde ani değişimlere yol açmadan önce, enerji verimliliğinde düşüş şeklinde kendini göstermektedir. Bu nedenle EPS1 sensörü, özellikle erken aşamadaki pompa arızalarının tespitinde dolaylı fakat kritik bir gösterge sunmaktadır. Bu tez çalışmasında elektriksel güç verileri, basınç ve akış sensörleri ile birlikte değerlendirilerek sistemin enerji–hidrolik etkileşimi analiz edilmiştir.

2.2.3. Hacimsel Akış Sensörleri

Hacimsel akış sensörleri (FS1 ve FS2), hidrolik sistem içerisindeki yağ akış miktarını ölçmektedir. Bu sensörler 10 Hz örnekleme frekansı ile çalışmakta olup, akış dengesindeki değişimleri yeterli zaman çözünürlüğü ile izleyebilmektedir.

Akış sensörleri, özellikle valf tıkanmaları, pompa iç kaçaqları, filtrasyon hattındaki direnç artışları gibi arızaların tespitinde önemli rol oynamaktadır. Akış

değerlerindeki anormallikler, çoğu zaman basınç değişimlerinden önce ortaya çıkarak erken uyarı sinyali niteliği taşımaktadır. Bu nedenle akış sensörleri, bu tez kapsamında hem bağımsız bir gösterge hem de basınç ve sıcaklık verilerini tamamlayan destekleyici bir ölçüm kaynağı olarak değerlendirilmiştir.

2.2.4. Sıcaklık Sensörleri

Sıcaklık sensörleri (TS1–TS4), hidrolik yağın ve sistem bileşenlerinin termal durumunu izlemek amacıyla kullanılmıştır. Bu sensörler 1 Hz örnekleme frekansı ile çalışmakta olup, hidrolik sistemlerdeki yavaş gelişen termal değişimleri yakalamaya uygundur. Hidrolik sistemlerde sıcaklık artışı genellikle: artan sürtünme kayıpları, soğutma verimindeki azalma, filtre kirliliği gibi arızaların dolaylı bir sonucu olarak ortaya çıkmaktadır. Bu nedenle sıcaklık verileri, ani arıza tespitinden ziyade uzun vadeli bozulma eğilimlerinin izlenmesi açısından kritik öneme sahiptir. Bu tez kapsamında sıcaklık sensörleri, özellikle erken aşama anomalilerin belirlenmesinde destekleyici bir rol üstlenmiştir.

2.2.5. Titreşim Sensörü

Titreşim sensörü (VS1), hidrolik sistemdeki mekanik titreşimleri ölçmek amacıyla kullanılmıştır. Sensör 1 Hz örnekleme frekansında çalışmakta olup, sistemin genel mekanik sağlığına ilişkin özet bir gösterge sunmaktadır.

Pompa ve valf gibi döner ve hareketli bileşenlerde meydana gelen mekanik aşınmalar, titreşim seviyelerinde artışa neden olabilmektedir. Bu nedenle titreşim verileri, diğer sensörlerle birlikte değerlendirildiğinde mekanik kaynaklı anomalilerin tespitine katkı sağlamaktadır.

2.2.6. Sanal Sensörler ve Türetilmiş Büyüklükler

Veri setinde fiziksel sensörlerin yanı sıra, sistem performansını özetleyen sanal sensörler de bulunmaktadır. Bunlar, SE (System Efficiency) – sistem genel verimi, CE (Cooling Efficiency) – soğutma verimi, CP (Cooling Power) – soğutma gücü olarak tanımlanmıştır. Bu sanal sensörler, doğrudan ölçüm yerine fiziksel sensör verilerinden türetilmiş olup, sistemin yüksek seviyeli davranışını temsil etmektedir. Özellikle

soğutma ünitesi arızalarının izlenmesinde CE ve CP sensörleri önemli bir rol oynamaktadır.

2.3. Arıza Türleri ve Arıza Şiddeti Seviyeleri

Bu çalışmada kullanılan Condition Monitoring of Hydraulic Systems veri seti, endüstriyel hidrolik sistemlerde sık karşılaşılan arızaların kontrollü ve tekrarlanabilir biçimde modellenmesine olanak tanıyacak şekilde tasarlanmıştır. Veri setinde, hidrolik sistemin performansı ve güvenilirliği açısından kritik öneme sahip dört temel bileşen üzerinde arıza senaryoları uygulanmıştır. Bu bileşenler; pompa, yön kontrol valfi, hidrolik akümülatör ve soğutma ünitesi olarak belirlenmiştir.

Her bir bileşen için arızalar, fiziksel sistem davranışını temsil edecek biçimde çok seviyeli bir şiddet ölçeği ile tanımlanmıştır. Böylece veri seti, yalnızca arıza-sağlam ayrımı yapan ikili sınıflandırma problemleri için değil; aynı zamanda arıza derecesinin nicel olarak tahmin edilmesini hedefleyen regresyon ve çok sınıflı kestirimci bakım çalışmalarına da uygun hâle getirilmiştir.

2.3.1. Pompa Arızaları

Hidrolik pompa, sistemde mekanik enerjinin hidrolik enerjiye dönüştürülmesinden sorumlu temel bileşendir. Pompa arızaları genellikle iç kaçak artışı ile karakterize edilir ve bu durum sistem basıncında düşüş, verim kaybı ve ısınma gibi olumsuz etkiler doğurur.

Veri setinde pompa arızaları, pompa içindeki yüksek ve düşük basınç bölgeleri arasında oluşturulan kontrollü kaçaklar ile modellenmiştir. Bu kaçaklar, pompanın nominal debisine oranla farklı seviyelerde artırılarak aşağıdaki şiddet sınıfları elde edilmiştir.

- 0 – Kaçak Yok (Normal Çalışma): Pompa tam verimli çalışmakta, iç kaçak bulunmamaktadır.
- 1 – Hafif Kaçak: Nominal debinin yaklaşık %3–4’ü seviyesinde iç kaçak mevcuttur.
- 2 – Şiddetli Kaçak: Nominal debinin yaklaşık %4–5’i seviyesinde belirgin iç kaçak bulunmaktadır.

Bu arıza türü, özellikle basınç sensörleri, akış sensörleri ve sistem verimliliğini temsil eden sanal sensörler üzerinden dolaylı olarak gözlemlenebilmektedir. Pompa arızaları, veri setinde teşhisi en zor arıza gruplarından biri olarak kabul edilmektedir.

2.3.2. Yön Kontrol Valfi Arızaları

Yön kontrol valfi, hidrolik akışın yönlendirilmesinden ve silindir hareketinin kontrolünden sorumludur. Valf arızaları çoğunlukla sürgü hareketinde gecikme, sürtünme artışı ve kısmi tıkanma şeklinde ortaya çıkar.

Bu veri setinde valf arızaları, valfi süren elektriksiz kontrol akımının düşürülmesi yoluyla modellenmiştir. Bu yöntem, valf içinde artan mekanik sürtünme veya kirlenme etkisini temsil etmektedir. Valf durumu aşağıdaki yüzde bazlı seviyelerle tanımlanmıştır.

- 100% – Normal Çalışma: Valf ideal anahtarlama davranışı göstermektedir.
- 90% – Hafif Bozulma: Küçük gecikmeler ve geçici akış düzensizlikleri gözlemlenmektedir.
- 80% – Orta Seviye Bozulma: Valf hareketi belirgin biçimde yavaşlamaktadır.
- 73% – İleri Seviye Arıza: Valf, neredeyse işlevini yerine getiremez hâle gelmektedir.

Valf arızaları özellikle geçici (transient) çalışma fazlarında basınç ve akış sinyallerinde karakteristik değişimlere neden olmaktadır. Bu nedenle zaman–frekans tabanlı analiz yöntemleri için uygun bir arıza türüdür.

2.3.3. Hidrolik Akümülatör Arızaları

Hidrolik akümülatör, sistem basıncını dengelemek ve ani yük değişimlerini sönümlemek amacıyla kullanılan bir enerji depolama elemanıdır. Akümülatör arızaları çoğunlukla gaz kaçağına bağlı ön basınç kaybı şeklinde ortaya çıkar. Veri setinde akümülatör arızaları, farklı ön şarj basıncı seviyeleri kullanılarak modellenmiştir. Bu seviyeler aşağıda verilmiştir:

- 130 bar – Normal Durum: Akümülatör tam kapasiteyle çalışmaktadır.
- 115 bar – Hafif Basınç Kaybı: Performans düşüşü başlangıç seviyesindedir.
- 100 bar – Orta Seviye Bozulma: Basınç dengeleme kabiliyeti belirgin biçimde azalmıştır.
- 90 bar – İleri Seviye Arıza: Akümülatör işlevini büyük ölçüde yitirmiştir.

Akümlatör arızaları, özellikle yük geçişleri sırasında basınç dalgalanmalarının artmasıyla kendini göstermektedir.

2.3.4. Soğutma Sistemi Arızaları

Soğutma ünitesi, hidrolik yağın sıcaklığını kontrol altında tutarak sistemin güvenli ve verimli çalışmasını sağlar. Soğutma arızaları genellikle fan performansının düşmesi, filtre tıkanması veya ısı transfer veriminin azalması ile ilişkilidir. Veri setinde soğutma arızaları, fan görev çevriminin (duty-cycle) düşürülmesi yoluyla modellenmiştir. Soğutma durumu aşağıdaki seviyelerle ifade edilmiştir:

- 100% – Tam Verim: Soğutma sistemi ideal çalışmaktadır.
- 20% – Azaltılmış Verim: Yağ sıcaklığında uzun vadeli artış gözlemlenmektedir.
- 3–5% – İleri Seviye Arıza: Soğutma kapasitesi ciddi biçimde düşmüştür.

Bu arıza türü, özellikle sıcaklık sensörleri ve sanal soğutma verimliliği sensörleri üzerinden net biçimde izlenebilmektedir ve sınıflandırma açısından görece daha kolay bir arıza grubudur.

2.3.5. Arıza Şiddeti Seviyelerinin Genel Değerlendirmesi

Veri setindeki arızalar, genel olarak aşağıdaki dört seviyeli şiddet ölçeği ile ifade edilmektedir:

- 0: Arızasız / normal çalışma
- 1: Hafif bozulma
- 2: Orta şiddetli bozulma
- 3: İleri seviyede arıza

Bu yapı sayesinde veri seti, hem durum izleme (condition monitoring) hem de kestirimci bakım (predictive maintenance) uygulamalarında farklı öğrenme paradigmalarına uygun, zengin ve gerçekçi bir test ortamı sunmaktadır.

2.4. Veri Seti Yapısı ve Boyutu

Bu tez çalışmasında kullanılan veri seti, hidrolik sistemin sabit yük altında tekrarlanan çalışma döngülerinin her biri için eş zamanlı olarak kaydedilen çoklu sensör verilerinden oluşmaktadır. Bu yapı, her bir gözlemin fiziksel olarak anlamlı bir çalışma periyodunu temsil etmesini sağlamakta ve kestirimci bakım uygulamaları açısından önemli bir avantaj sunmaktadır.

Veri setinde toplam 2205 adet çalışma çevrimi (instance) bulunmaktadır. Her bir çevrim, 60 saniyelik sabit bir çalışma süresini temsil etmekte ve sistemin hem geçici (transient) hem de kararlı (steady-state) davranışlarını içermektedir. Bu çevrimler, deney süresi boyunca binlerce kez tekrarlanarak farklı arıza türleri ve şiddet seviyeleri altında ölçüm alınmasını mümkün kılmıştır.

Veri setinin ayırt edici özelliklerinden biri, sensörlerin farklı örnekleme frekanslarında çalışmasıdır. Bu çok oranlı (multi-rate) yapı, gerçek endüstriyel hidrolik sistemlerde karşılaşılan ölçüm koşullarını doğrudan yansıtmaktadır. Sensör gruplarına ait örnekleme frekansları aşağıdaki gibidir:

- Basınç sensörleri (PS1–PS6): 100 Hz
- Elektriksel güç sensörü (EPS1): 100 Hz
- Hacimsel akış sensörleri (FS1–FS2): 10 Hz
- Sıcaklık sensörleri (TS1–TS4): 1 Hz
- Titreşim sensörü (VS1): 1 Hz
- Sanal sensörler (SE, CE, CP): 1 Hz

Bu yapı sonucunda, her bir 60 saniyelik çevrim için sensör başına farklı uzunluklarda zaman serileri elde edilmiştir. Örneğin, bir basınç sensörü için çevrim başına 6000 örnek, bir sıcaklık sensörü için ise 60 örnek bulunmaktadır. Bu durum, veri setinin toplam öznitelik sayısını önemli ölçüde artırmakta ve veri setini yüksek boyutlu bir problem hâline getirmektedir.

Veri setinde yer alan sensörlerin tamamı dikkate alındığında, tek bir çevrim için toplam 43.680 adet sayısal öznitelik bulunmaktadır. Bu öznitelikler, aşağıdaki bileşenlerden oluşmaktadır:

- 6 adet basınç sensörü $\times$ 6000 örnek
- 1 adet güç sensörü $\times$ 6000 örnek
- 2 adet akış sensörü $\times$ 600 örnek
- 4 adet sıcaklık sensörü $\times$ 60 örnek
- 1 adet titreşim sensörü $\times$ 60 örnek
- 3 adet sanal sensör $\times$ 60 örnek

Bu yüksek boyutluluk, klasik eşik-tabanlı veya düşük boyutlu istatistiksel yöntemler için zorlayıcı bir durum oluştururken; gelişmiş özellik çıkarımı, boyut indirgeme ve derin öğrenme tabanlı yaklaşımlar için zengin bir bilgi kaynağı sunmaktadır.

Veri seti, sensör türlerine göre ayrılmış çoklu dosyalar hâlinde sunulmaktadır. Her dosya, ilgili sensörün tüm çevrimlere ait zaman serisi verilerini içermektedir. Ayrıca her çevrim için, sistem bileşenlerine ait arıza durumlarını tanımlayan etiketler bulunmaktadır. Bu etiketler;

- Soğutma ünitesi durumu,
- Yön kontrol valfi durumu,
- Pompa iç kaçak seviyesi,
- Akümülatör ön şarj basıncı,
- Kararlı çalışma durumu (stable flag)

gibi bilgileri içermekte ve her çevrim için karşılık gelen arıza türü ve şiddet seviyesini açıkça tanımlamaktadır. Etiketlerin çevrim-bazlı olarak verilmiş olması, gözetimli öğrenme yöntemlerinin doğrudan uygulanabilmesine olanak sağlamaktadır.

Veri setinin önemli bir avantajı, eksik veri içermemesidir. Tüm sensör ölçümleri deneysel süreç boyunca sürekli ve senkronize biçimde kaydedilmiştir. Bu durum, veri temizleme ve eksik veri tamamlama gibi ön işleme adımlarının minimum

düzeyde tutulmasını sağlamış ve modelleme aşamasında elde edilen sonuçların güvenilirliğini artırmıştır.

Tablo 2, hidrolik deney düzeneğinde kullanılan sensörleri, her bir sensörün ölçtüğü fiziksel büyüklüğü, ölçüm birimini ve ilgili örnekleme frekansını özetlemektedir. Sensörlerin farklı örnekleme frekanslarında çalışması, hidrolik sistemin hem hızlı dinamik davranışlarının (basınç ve motor gücü) hem de yavaş gelişen termal ve performans temelli süreçlerinin (sıcaklık, titreşim ve verimlilik göstergeleri) eş zamanlı olarak izlenmesine olanak sağlamaktadır. Bununla birlikte, farklı arıza türleri ve şiddet seviyeleri arasındaki örnek sayılarının eşit olmaması, veri setinde doğal bir sınıf dengesizliği oluşturmuştur. Bu durum, özellikle nadir görülen arıza seviyelerinin tespiti açısından modelleme aşamasında dikkate alınması gereken bir husustur.

Tablo 2. Hidrolik deney düzeneğinde kullanılan sensörler ve örnekleme frekansları.

Sensör	Ölçülen Büyüklük	Birim	Örnekleme Frekansı
PS1 – PS6	Basınç	bar	100 Hz
FS1 – FS2	Debi (Hacimsel Akış)	l/dk	10 Hz
TS1 – TS4	Sıcaklık	°C	1 Hz
EPS1	Motor Gücü	W	100 Hz
VS1	Titreşim	mm/s	1 Hz
SE	Verimlilik Faktörü	%	1 Hz
CE	Soğutma Verimi (Sanal)	%	1 Hz
CP	Soğutma Gücü (Sanal)	kW	1 Hz

3. YÖNTEM

Bu bölümde, hidrolik sistemlerde anomali tespiti ve arıza şiddeti tahmini amacıyla bu tez çalışmasında kullanılan yöntemsel yaklaşım ayrıntılı olarak açıklanmaktadır. Bölüm 2’de tanıtılan Condition Monitoring of Hydraulic Systems veri seti esas alınarak; veri ön işleme, özellik çıkarımı, zaman–frekans temsilleri, modelleme stratejileri ve değerlendirme metrikleri sistematik bir iş akışı çerçevesinde ele alınmıştır.


Hidrolik sistemler, doğrusal olmayan dinamiklere sahip olmaları, çoklu sensör verisi içermeleri ve farklı zaman ölçeklerinde gelişen arıza mekanizmalarını barındırmaları nedeniyle klasik eşik-tabanlı yöntemlerle etkin biçimde izlenmesi güç sistemlerdir. Özellikle iç kaçak, aşınma ve verim kaybı gibi arızalar çoğu zaman ani bir kırılma şeklinde değil, zaman içerisinde kademeli olarak gelişen bozulma süreçleri şeklinde ortaya çıkmaktadır. Bu durum, yalnızca tek bir sensör sinyaline veya tekil zaman anlarına dayalı karar mekanizmalarının yetersiz kalmasına neden olmaktadır.

Bu nedenle, bu tezde kullanılan yöntem; çoklu sensör füzyonu, segment-temelli zaman serisi modelleme ve veri güdümlü derin öğrenme yaklaşımlarını bir araya getiren bütüncül bir çerçeve olarak tasarlanmış ve Şekil 7’te, bu tez kapsamında önerilen segment-temelli ve hibrit derin öğrenme yönteminin genel işleyişi şematik olarak sunulmuştur.

Bu yöntem, hidrolik sistemlerden elde edilen çok sensörlü zaman serisi verilerinin, ardışık ve birbirini tamamlayan dört temel aşama üzerinden işlenmesine dayanmaktadır: (i) zaman serisi segmentasyonu, (ii) zaman–frekans dönüşümü, (iii) konvolüsyonel sinir ağları (CNN) ile otomatik özellik öğrenimi ve (iv) uzun kısa süreli bellek (LSTM) tabanlı zamansal modelleme.

İlk adımda, ham zaman serisi sinyalleri öncelikle sabit uzunluklu pencereler kullanılarak segmentlere ayrılmaktadır. Bu segmentasyon işlemi, sinyal içerisindeki yerel ve kısa süreli davranışların ayrı ayrı ele alınmasını sağlamakta; özellikle geçici (transient) anomalilerin ve erken bozulma izlerinin daha etkin biçimde yakalanmasına olanak tanımaktadır. Her bir segment, sistemin belirli bir zaman aralığındaki çalışma durumunu temsil eden bağımsız bir örnek olarak değerlendirilmiştir.

İkinci aşamada, elde edilen her bir zaman serisi segmenti zaman–frekans alanına dönüştürülmektedir. Bu dönüşüm, Sürekli Dalgacık Dönüşümü (CWT) kullanılarak gerçekleştirilmiş ve her segment için iki boyutlu skalogram temsilleri elde edilmiştir. Skalogramlar, sinyal enerjisinin zaman ve frekans eksenlerindeki dağılımını görselleştirerek, zaman alanında doğrudan gözlemlenmesi güç olan frekans temelli anomalilerin ortaya çıkarılmasını sağlamaktadır. Bu aşamada her skalogram, ilgili segmentin ait olduğu çevrimin arıza etiketi ile eşleştirilmiştir.



Şekil 7. Hibrit CNN–LSTM tabanlı segment-temelli zaman–frekans analizine dayalı anomali tespiti yönteminin genel iş akışı.

Bir sonraki aşamada, skalogram görüntülerinin Konvolüsyonel Sinir Ağları (CNN) tarafından işlendiği otomatik özellik öğrenimi aşaması yer almaktadır. CNN katmanları, zaman–frekans uzayındaki ayırt edici desenleri ve enerji yoğunluk bölgelerini otomatik olarak öğrenerek, her bir segment için yüksek seviyeli derin özellik vektörleri üretmektedir. Bu yaklaşım, elle tanımlanan istatistiksel özniteliklere duyulan ihtiyacı ortadan kaldırarak, veri içerisindeki yapısal bilgilerin doğrudan öğrenilmesini mümkün kılmaktadır.

Son aşamada ise, CNN tarafından çıkarılan ardışık segment özelliklerinin Uzun Kısa Süreli Bellek (LSTM) ağlarına aktarıldığı zamansal modelleme aşaması gösterilmektedir. LSTM mimarisi, segmentler arasındaki zamansal bağımlılıkları öğrenerek, arızaların zaman içerisindeki gelişim sürecini modellemektedir. Bu sayede model, yalnızca tekil segmentlere değil, segment dizilerinin tamamına dayalı olarak karar verebilmektedir. Son katmanda elde edilen çıktı, hidrolik sistemin çalışma durumuna ilişkin sınıf olasılıklarını (Kaçak Yok, Hafif Kaçak, Şiddetli Kaçak) temsil etmektedir.

3.1. Veri Ön İşleme

Bu tez çalışmasında kullanılan veri seti, her biri 60 saniyelik sabit yük çevrimlerini temsil eden toplam 2205 zaman adımından ve hidrolik sistemin farklı fiziksel davranışlarını izleyen 17 sensör ölçümünden oluşmaktadır. Derin öğrenme tabanlı modellerin güvenilir ve kararlı biçimde eğitilebilmesi için, ham sensör verileri üzerinde bir dizi veri ön işleme (pre-processing) adımı uygulanmıştır. Bu adımlar, gürültü etkilerinin azaltılması, sensörler arası ölçek farklılıklarının giderilmesi ve çoklu sensör verisinin tutarlı bir yapıda modele aktarılması amacıyla gerçekleştirilmiştir.

3.1.1. Sensör Seçimi ve Birleştirilmesi

Bu çalışmada, hidrolik sistemin farklı alt bileşenlerini temsil eden sensörler birlikte değerlendirilmiştir. Basınç sensörleri (PS1–PS6), hacimsel akış sensörleri (FS1–FS2), sıcaklık sensörleri (TS1–TS4), pompa elektriksel gücü/verimi (EPS1), soğutma sistemine ait sanal sensörler (CE, CP) ve titreşim sensörü (VS1) kullanılarak çok boyutlu bir giriş matrisi oluşturulmuştur.

Bu yaklaşım sayesinde sistemin yalnızca tek bir fiziksel büyüklüğü değil; hidrolik, termal ve mekanik davranışları eş zamanlı olarak modele aktarılmıştır. Çoklu sensör birleştirme (sensor fusion) yaklaşımı, hidrolik arızaların çoğunlukla birden fazla fiziksel büyüklük üzerinde etkiler oluşturması nedeniyle tercih edilmiştir. Böylece, tekil sensörlere dayalı analizlere kıyasla daha bütüncül ve ayırt edici bir temsil elde edilmiştir.

3.1.2. Eksik ve Gürültülü Verilerin Ele Alınması

Kullanılan veri setinde eksik gözlem bulunmamakla birlikte, gerçekçi ölçüm koşullarına bağlı olarak sensör sinyallerinde ani sıçramalar, uç değerler ve ölçüm gürültüsü gözlemlenebilmektedir. Bu tür gürültü bileşenlerinin, özellikle zaman-frekans dönüşümleri ve derin öğrenme tabanlı modeller üzerinde olumsuz etkilere yol açabileceği bilinmektedir.

Bu nedenle, sensör sinyallerindeki aykırı değerleri bastırmak amacıyla Hampel filtresi, yüksek frekanslı rastgele gürültüyü azaltmak amacıyla ise hareketli ortalama (moving average) tabanlı düşük geçiren filtre uygulanmıştır. Bu filtreleme işlemleri, sinyalin temel yapısını bozmadan ani ve fiziksel olarak anlamsız sıçramaların etkisini azaltmış; böylece daha kararlı ve temsil gücü yüksek sinyaller elde edilmiştir.

3.1.3. Normalizasyon

Hidrolik sistemde kullanılan sensörler, farklı fiziksel büyüklükleri ve farklı ölçüm aralıklarını temsil etmektedir. Örneğin basınç, sıcaklık, akış ve titreşim sinyalleri sayısal olarak farklı ölçeklerde değerlere sahiptir. Bu durum, doğrudan modele verilen verilerde bazı sensörlerin diğerlerine baskın hâle gelmesine ve öğrenme sürecinin dengesizleşmesine neden olabilmektedir. Bu problemi ortadan kaldırmak amacıyla tüm sensör verilerine Z-score normalizasyonu uygulanmıştır. Normalizasyon işlemi Denklem 1’de tanımlanmaktadır.

$$x_{norm}(t) = \frac{x(t) - \mu}{\sigma} \quad (1)$$

Burada μ ilgili sensör sinyalinin ortalamasını, σ ise standart sapmasını ifade etmektedir. Normalizasyon parametreleri yalnızca eğitim veri seti üzerinden

hesaplanmış; elde edilen parametreler doğrulama ve test veri setlerine aynen uygulanmıştır. Bu yaklaşım, veri sızıntısının (data leakage) önlenmesi açısından kritik öneme sahiptir.

3.2. Zaman Serisi Segmentasyonu

Hidrolik sistemlerde meydana gelen arızalar, çoğu zaman tüm çalışma çevrimine yayılan ani ve keskin değişimler şeklinde değil; belirli zaman aralıklarında ortaya çıkan yerel ve geçici (transient) bozulmalar şeklinde gelişmektedir. Bu tür bozulmalar, sinyalin yalnızca belirli bölümlerinde frekans içeriği ve enerji dağılımında değişimlere yol açmakta; tüm zaman serisinin tek bir bütün olarak ele alındığı yaklaşımlarda bu etkiler zayıflayarak gözden kaçabilmektedir.

Bu nedenle normalize edilen zaman serisi sinyalleri sabit uzunluklu segmentlere ayrılarak analiz edilmiştir. Segmentasyon işlemi, sinyalin zamansal yapısını koruyarak, yerel davranışların ayrı ayrı modellenmesini mümkün kılmaktadır. Normalize edilen zaman serileri, kayan pencere (sliding window) yaklaşımı kullanılarak segmentlere ayrılmıştır. Bu yaklaşımda her bir segment, belirlenen pencere uzunluğu L boyunca alınan ardışık örneklerden oluşmakta; pencereler arasında belirli bir bindirme oranı uygulanarak segmentler elde edilmektedir. Segmentasyon işlemi matematiksel olarak Denklem 2’de ifade edilebilir.

$$x_{norm}(t) = \{x_1(t), x_1(t), \dots, x_i(t), \dots, x_N(t)\} \quad (2)$$

Burada $x_i(t)$, normalize edilmiş zaman serisinin i . segmentini, N ise toplam segment sayısını temsil etmektedir.

3.3. Zaman–Frekans Alanına Dönüşüm

Zaman serisi segmentasyonu ile elde edilen normalize edilmiş sinyal parçaları, hidrolik sistemlerde meydana gelen bozulmaların yalnızca genlik düzeyinde değil, aynı zamanda frekans içeriği ve enerji dağılımı açısından da incelenmesini mümkün kılmaktadır. Özellikle erken evre arızalar, çoğu zaman sinyalin belirli frekans bantlarında ortaya çıkan enerji yoğunlaşmaları veya frekans bileşeni değişimleri şeklinde kendini göstermektedir. Bu tür değişimlerin yalnızca zaman alanında yapılan

analizlerle güvenilir biçimde tespit edilmesi güç olduğundan, bu tez çalışmasında her bir zaman serisi segmenti zaman–frekans alanına dönüştürülerek analiz edilmiştir.

Zaman–frekans dönüşümü için Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform – CWT) tercih edilmiştir. CWT, sinyali farklı ölçeklerde analiz ederek hem düşük frekanslı uzun vadeli eğilimleri hem de yüksek frekanslı ani değişimleri eş zamanlı olarak temsil edebilme yeteneğine sahiptir. Bu özellik, hidrolik sistemlerde görülen arızaların çok ölçekli ve doğrusal olmayan doğasının modellenmesi açısından önemli bir avantaj sunmaktadır. Bir $x_{norm}(t)$ zaman serisinin CWT’si Denklem 3’de formüle edilmiştir.

$$C(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (3)$$

Burada a ölçek parametresini, b zaman kaymasını ve $\psi(\cdot)$ mother-wavelets dalgacık fonksiyonunu ifade etmektedir. Bu çalışmada, zaman–frekans yerleştirme yeteneği ve titreşim temelli arıza analizlerindeki başarısı nedeniyle Morlet dalgacığı kullanılmıştır. CWT sonucunda elde edilen katsayılar, sinyal enerjisinin zaman ve frekans eksenlerindeki dağılımını temsil etmekte olup, bu katsayıların mutlak değerlerinin karesi alınarak her bir segment için iki boyutlu bir zaman–frekans skalogram elde edilmiştir. Bu elde edilen skalogramlar, sinyaldeki ani frekans geçişlerini, titreşim kaynaklı enerji artışlarını ve arıza başlangıcına işaret eden yerel desenleri görsel olarak ortaya koymaktadır.

Skalogramlar, görüntü benzeri yapıları sayesinde konvolüsyonel sinir ağları için doğal bir giriş temsili sunmaktadır. Bu tez kapsamında, farklı segmentlerden elde edilen zaman–frekans temsillerinin modele tutarlı biçimde aktarılabilmesi amacıyla tüm skalogramlar standart bir boyuta yeniden ölçeklendirilmiş ve derin öğrenme mimarisine giriş olarak verilmiştir.

Sürekli Dalgacık Dönüşümünün (CWT) tercih edilmesinin temel nedenlerinden biri, kısa zamanlı Fourier dönüşümü gibi alternatif yöntemlerin sabit zaman–frekans çözünürlüğüne sahip olmasıdır. Buna karşılık CWT, yüksek frekans bileşenlerinde daha iyi zaman çözünürlüğü, düşük frekans bileşenlerinde ise daha iyi frekans çözünürlüğü sunarak, hidrolik sistemlerde hem geçici anomalilerin hem de uzun vadeli bozulma eğilimlerinin aynı çerçevede temsil edilmesine olanak

sağlamaktadır. Bu özellik, özellikle segment-temelli analizlerde, sinyal içeriğinin daha ayrıntılı ve ayırt edici bir biçimde modellenmesine katkı sağlamaktadır.

3.4. Segment Bazlı Etiketleme

Segmentasyon işlemi ile her bir çalışma çevrimine ait sensör sinyalleri, sabit uzunluklu parçalara ayrılmış ve her bir parça, zaman–frekans alanında temsil edilerek bağımsız bir örnek hâline getirilmiştir. Bu yaklaşım, derin öğrenme modellerinin yerel anomalileri daha etkin biçimde öğrenebilmesini sağlamakla birlikte, segmentlerin doğru ve tutarlı biçimde etiketlenmesini zorunlu kılmaktadır. Bu yaklaşım matematiksel olarak Denklem 4’te ifade edilebilir:

$$(Segment_i, y_c) \quad \forall i \in c \quad (4)$$

Burada, $Segment_i$, c . çalışma çevriminden elde edilen i . segmenti, y_c ise ilgili çevrimin arıza sınıfı etiketini temsil etmektedir.

Kullanılan veri setinde arıza bilgileri, çevrim (cycle) bazında tanımlanmış olup her bir çevrim, belirli bir arıza türü ve şiddet seviyesine karşılık gelen bir etiket ile ilişkilendirilmiştir. Bu çalışmada, çevrim bazlı etiketleme bilgisi, segment-temelli yapıya uyarlanarak kullanılmıştır. Buna göre, aynı çalışma çevrimine ait tüm segmentler, ilgili çevrimin arıza etiketi ile eşleştirilmiştir. Böylece her bir segmentin skalogramı ve etiketi, denetimli öğrenme kapsamında bir girdi–etiket çifti oluşturarak hibrit CNN–LSTM modelinin eğitimi için kullanılmıştır. Bu yapı sayesinde, zaman–frekans alanındaki yerel desenler ve enerji dağılımları, sonraki aşamada gerçekleştirilen otomatik özellik öğrenimi ve zamansal modelleme süreçlerine doğrudan aktarılmıştır.

Bu tez kapsamında, veri setinde yer alan arıza şiddeti bilgileri kullanılarak üç sınıflı bir etiketleme yapısı benimsenmiştir. Buna göre etiketler aşağıdaki şekilde tanımlanmıştır:

- Normal Çalışma: Pompa tam verimli çalışmakta, herhangi bir kaçak bulunmamaktadır.

- Hafif Kaçak: Nominal debinin yaklaşık %3–4’ü seviyesinde iç kaçak mevcuttur.
- Şiddetli Kaçak: Nominal debinin yaklaşık %4–5’i seviyesinde belirgin iç kaçak bulunmaktadır.

3.5. Hibrit CNN + LSTM Modelleme Yaklaşımı

Bu tez çalışmasında, hidrolik sistemlerdeki anomalilerin ve arıza şiddeti seviyelerinin tespiti amacıyla zaman–frekans temelli yerel özellikler ile zamansal bağımlılıkları birlikte modelleyebilen hibrit bir derin öğrenme mimarisi önerilmiştir. Bu kapsamda, Sürekli Dalgacık Dönüşümü (CWT) ile elde edilen skalogram temsilleri üzerinden Konvolüsyonel Sinir Ağları (CNN) kullanılarak ayırt edici uzamsal/zamansal–frekans özellikler öğrenilmiş; ardından bu özellikler Uzun Kısa Süreli Bellek (LSTM) ağı ile zamansal bağlam içerisinde modellenmiştir.

Bu hibrit yaklaşım, CNN’in güçlü yerel desen öğrenme kabiliyeti ile LSTM’in ardışık bağımlılıkları temsil edebilme yeteneğini bir araya getirerek, hidrolik sistemlerdeki karmaşık ve çok ölçekli arıza mekanizmalarının daha etkin biçimde yakalanmasını amaçlamaktadır.

3.5.1. CNN ile Zaman–Frekans Özelliklerinin Öğrenilmesi

Bu tez çalışmasında, zaman serisi segmentlerinden elde edilen zaman–frekans temsillerinin otomatik ve ayırt edici biçimde modellenmesi amacıyla Konvolüsyonel Sinir Ağları (Convolutional Neural Networks – CNN) kullanılmıştır. Sürekli Dalgacık Dönüşümü (CWT) sonucunda elde edilen skalogramlar, zaman ve frekans eksenlerinde iki boyutlu enerji dağılımlarını temsil eden görüntü benzeri yapılar sunmaktadır. Bu özellikleri sayesinde skalogramlar, CNN mimarileri için doğal ve anlamlı bir giriş temsili oluşturmaktadır. Her bir zaman serisi segmenti için elde edilen skalogram,

$$\mathbf{S}_i \in R^{H \times W} \quad (5)$$

şeklinde tanımlanan iki boyutlu bir giriş matrisi olarak CNN modeline aktarılmıştır. Burada H ve W , sırasıyla zaman ve frekans eksenlerindeki örnek sayısını

ifade etmektedir. CNN mimarisinin temel bileşeni olan konvolüsyon işlemi, skalogram üzerinde yerel zaman–frekans desenlerini yakalamayı amaçlamaktadır. Bir konvolüsyon katmanında gerçekleştirilen işlem Denklem 6’da tanımlanır.

$$\mathbf{F}_k = \sigma(\mathbf{S}_i * \mathbf{W}_k + b_k) \quad (6)$$

Burada, $*$ iki boyutlu konvolüsyon işlemini, $\mathbf{W}_k$ k . konvolüsyon filtresini, b_k bias terimini, $\sigma(\cdot)$ doğrusal olmayan aktivasyon fonksiyonunu (ReLU) ifade etmektedir. Bu işlem sonucunda elde edilen özellik haritaları ($\mathbf{F}_k$), zaman–frekans alanındaki yerel enerji yoğunlaşmalarını, frekans bantlarındaki değişimleri ve arıza başlangıcına özgü desenleri temsil etmektedir. Konvolüsyon katmanları boyunca kullanılan çoklu filtreler sayesinde, farklı ölçek ve yönelimlerdeki zaman–frekans desenleri paralel olarak öğrenilmektedir.

Konvolüsyon katmanlarını takiben uygulanan havuzlama (pooling) işlemi, özellik haritalarının uzamsal boyutunu azaltarak modelin hesaplama yükünü düşürmekte ve öğrenilen temsillerin küçük zamansal/frekans kaymalarına karşı daha dayanıklı hâle gelmesini sağlamaktadır. Bu işlem genel olarak şu şekilde ifade edilebilir.

$$\mathbf{F}_k^{Pool} = Pool(\mathbf{F}_k) \quad (7)$$

CNN mimarisi boyunca ardışık olarak uygulanan konvolüsyon, aktivasyon ve havuzlama işlemleri sonucunda, skalogramlardaki düşük seviyeli zaman–frekans desenleri giderek daha soyut ve yüksek seviyeli temsillere dönüştürülmektedir. Son konvolüsyon katmanından sonra elde edilen özellik haritaları, düzleştirme (flatten) işlemi ile sabit boyutlu bir özellik vektörüne dönüştürülmüştür.

$$\mathbf{f}_k^{CNN} = Flatten(\mathbf{F}_k^{Pool}) = Pool(\mathbf{F}_k) \quad (8)$$

Bu vektör, k . segmente ait zaman–frekans alanındaki ayırt edici özellikleri içeren kompakt bir temsil sunmaktadır. CNN tarafından öğrenilen bu özellikler, hidrolik sistemlerde anomaliye yol açan frekans bileşeni değişimlerini, titreşim artışlarını ve enerji dağılımındaki bozulmaları otomatik olarak kodlamaktadır.

Elde edilen CNN tabanlı özellik vektörleri, tek başına sınıflandırma için kullanılabileceği gibi, bu tez kapsamında tercih edilen hibrit yaklaşım doğrultusunda zamansal bağlamın modellenmesi amacıyla LSTM ağına giriş olarak aktarılmıştır. Böylece CNN, zaman–frekans alanındaki yerel ve segment-bazlı anomalilerin öğrenilmesini sağlarken, LSTM mimarisi bu özelliklerin segmentler arasındaki zamansal evrimini modelleyerek arıza gelişim sürecinin bütüncül biçimde temsil edilmesine olanak tanımıştır.

Tablo 3’de, zaman–frekans alanında elde edilen skalogramların işlenmesi için kullanılan konvolüsyonel sinir ağı (CNN) mimarisi özetlenmiştir. Giriş olarak 128×128 boyutunda ölçeklendirilmiş skalogramlar kullanılmıştır. CNN mimarisi, ardışık konvolüsyon ve havuzlama katmanları aracılığıyla zaman–frekans alanındaki yerel enerji yoğunlaşmalarını, frekans geçişlerini ve arızaya özgü desenleri hiyerarşik olarak öğrenmektedir. Katman derinliği arttıkça öğrenilen temsiller daha soyut ve ayırt edici hâle gelmektedir. Son konvolüsyon katmanından elde edilen özellik haritaları düzleştirilerek sabit boyutlu bir özellik vektörüne dönüştürülmüş ve bu vektör, zamansal bağımlılıkların modellenmesi amacıyla LSTM tabanlı yapıya giriş olarak verilmiştir. Dropout katmanı, modelin aşırı öğrenme eğilimini azaltmak amacıyla kullanılmıştır.

Tablo 3. Zaman–frekans skalogramları için kullanılan CNN mimarisi.

Katman	İşlem	Filtre	Çekirdek Boyutu	Çıkış Boyutu
Giriş	Skalogram	–	–	$128 \times 128 \times 1$
Conv2D-1	Konvolüsyon + ReLU	32	3×3	$128 \times 128 \times 32$
MaxPool-1	Havuzlama	–	2×2	$64 \times 64 \times 32$
Conv2D-2	Konvolüsyon + ReLU	64	3×3	$64 \times 64 \times 64$
MaxPool-2	Havuzlama	–	2×2	$32 \times 32 \times 64$
Conv2D-3	Konvolüsyon + ReLU	128	3×3	$32 \times 32 \times 128$
MaxPool-3	Havuzlama	–	2×2	$16 \times 16 \times 128$
Flatten	Düzleştirme	–	–	32768
Dense	Tam bağlantılı	256	–	256
Dropout	Aşırı öğrenme önleme	–	0,3	256
Çıkış	Özellik vektörü	–	–	f_k^{CNN}

3.5.2. LSTM ile Zamansal Bağımlılıkların Modellenmesi

CNN mimarisi tarafından her bir zaman serisi segmenti için öğrenilen zaman–frekans tabanlı derin özellikler, hidrolik sistemlerde iç kaçak arızalarının yalnızca anlık

bozulmalar şeklinde değil, çoğu zaman zamansal olarak kademeli ve süreklilik gösteren süreçler hâlinde geliştiğini ortaya koymaktadır. Bu nedenle, ardışık segmentler arasında oluşan zamansal bağımlılıkların modellenmesi, hem anomali tespiti hem de arıza şiddeti sınıflandırma performansının artırılması açısından kritik öneme sahiptir. Bu amaçla, CNN tarafından her bir segment için elde edilen özellik vektörleri

$$f_k^{\{CNN\}} \in \mathbb{R}^d \quad (9)$$

şeklinde tanımlanarak, Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM) ağına giriş olarak verilmiştir. Burada k , segment indeksini; d ise CNN çıkış özelliklerinin boyutunu ifade etmektedir. LSTM ağına sunulan giriş dizisi,

$$F = [f_1^{\{CNN\}}, f_2^{\{CNN\}}, \dots, f_T^{\{CNN\}}] \quad (10)$$

şeklinde tanımlanmış olup, T ardışık segment sayısını temsil etmektedir. LSTM mimarisi, klasik tekrarlayan sinir ağlarının (RNN) karşılaştığı gradyan sönümlenmesi ve patlaması problemlerini çözmek üzere geliştirilen kapı (gate) mekanizmalarına sahiptir. Bu yapı sayesinde, uzun vadeli zamansal bağımlılıklar etkin biçimde öğrenilebilmekte ve arızaya ilişkin bilgi, zaman boyunca taşınabilmektedir. Bir LSTM hücresinde gerçekleştirilen temel işlemler matematiksel olarak Denklemler 11-16 ile ifade edilmektedir:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (11)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (12)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (13)$$

$$\hat{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (14)$$

$$c_t = f_t \odot c_{\{t-1\}} + i_t \odot \hat{c}_t \quad (15)$$

$$h_t = o_t \odot \tanh(c_t) \quad (16)$$

Burada i_t , f_t ve o_t sırasıyla giriş, unutma ve çıkış kapılarını; c_t hücre durumunu; h_t gizli durumu; $\sigma(\cdot)$ sigmoid aktivasyon fonksiyonunu ve $\odot$ eleman bazlı çarpımı ifade etmektedir. Giriş vektörü x_t , ilgili zaman adımıdaki CNN tabanlı özellik vektörünü temsil etmektedir.

LSTM ağıının son zaman adımıda elde edilen gizli durum, tam bağlantılı bir çıkış katmanına aktarılmakta ve softmax aktivasyon fonksiyonu aracılığıyla çıktı olasılıkları hesaplanmaktadır.

$$\hat{y} = \text{softmax}(W_y h_T + b_y) \quad (17)$$

Burada $\hat{y}$, sistemin normal çalışma (Sınıf 0), hafif iç kaçak (Sınıf 1) ve şiddetli iç kaçak (Sınıf 2) durumlarına ait olasılık dağılımını temsil etmektedir. Bu yapı sayesinde önerilen CNN–LSTM tabanlı model, zaman–frekans alanında öğrenilen yerel anomalileri, segmentler boyunca oluşan zamansal evrimle birlikte değerlendirilerek, tekil segmentlere dayalı yaklaşımlara kıyasla daha kararlı, güvenilir ve fiziksel olarak anlamlı bir anomali tespiti ve arıza şiddeti sınıflandırması gerçekleştirmektedir.

3.6. Arıza Sınıflandırması

Bu tez çalışmasında geliştirilen hibrit CNN–LSTM tabanlı modelin, pompa iç kaçak durumlarını doğru biçimde sınıflandırma başarısını değerlendirmek amacıyla yaygın olarak kullanılan sınıflandırma performans ölçütlerinden yararlanılmıştır. Model performansının temelini oluşturan değerlendirme aracı karışıklık matrisi (confusion matrix)dir. Karışıklık matrisi, modelin her bir sınıfa ait örnekleri ne ölçüde doğru veya hatalı sınıflandırdığını göstermektedir. Bu matris üzerinden, modelin genel ve sınıf bazlı başarısını nicel olarak ifade eden performans ölçütleri hesaplanmıştır. Öncelikle, doğruluk metriği kullanılarak modelin tüm örnekler üzerindeki genel sınıflandırma başarısı değerlendirilmiştir. Doğruluk, doğru sınıflandırılan örneklerin

toplam örnek sayısına oranını ifade etmektedir. Bunun yanı sıra, her bir sınıf için kesinlik ve duyarlılık değerleri hesaplanmıştır. Kesinlik, modelin ilgili sınıfa ait olarak tahmin ettiği örneklerin ne kadarının gerçekten o sınıfa ait olduğunu gösterirken; duyarlılık, ilgili sınıfa ait gerçek örneklerin ne kadarının doğru biçimde tespit edildiğini ifade etmektedir. Bu iki ölçütün birlikte değerlendirilmesi, özellikle hafif kaçak gibi erken evre arızaların analizinde önemlidir. Kesinlik ve duyarlılık değerlerinin dengeli bir birleşimi olan F1-skoru, modelin sınıflar arasındaki ayrım performansını tek bir değerle özetlemek amacıyla kullanılmıştır.

Özetle, bu tez kapsamında karışıklık matrisi temel alınarak doğruluk, kesinlik, duyarlılık, F1-skoru metrikleri hesaplanmış; geliştirilen modelin anomali tespiti ve arıza şiddeti sınıflandırma performansı kapsamlı biçimde değerlendirilmiştir. Sonuç olarak, Sürekli Dalgacık Dönüşümü ile elde edilen zaman–frekans temsilleri, bu tezde önerilen segment-temelli ve derin öğrenme tabanlı yöntemin temel bileşenlerinden birini oluşturmakta; hidrolik sistemlerdeki karmaşık ve çok ölçekli arıza mekanizmalarının etkin biçimde modellenmesine olanak tanımaktadır.

4. BULGULAR VE TARTIŞMA

Bu bölümde, hidrolik sistemlerde iç kaçak arızalarının tespiti ve şiddetinin belirlenmesine yönelik olarak önerilen yöntem kapsamında elde edilen bulgular sunulmakta ve tartışılmaktadır. İlk olarak, zaman alanı analizleri aracılığıyla farklı arıza seviyelerine karşılık gelen sensör davranışları incelenerek, tekil ve çoklu sensör sinyallerinin ayırt edicilik düzeyi değerlendirilmiştir. Ardından, segmentasyon sonuçları ele alınarak sinyallerin yerel ve geçici dinamiklerinin daha etkin biçimde temsil edilmesi tartışılmıştır. Üçüncü aşamada, zaman–frekans alanı (CWT) bulguları üzerinden, zaman alanında zayıf biçimde gözlemlenen arıza etkilerinin nasıl daha belirgin hâle geldiği ortaya konmuştur. Son olarak, elde edilen bu temsiller kullanılarak eğitilen hibrit CNN–LSTM tabanlı derin öğrenme modelinin performansı nicel ölçütler üzerinden değerlendirilmiş ve sonuçlar literatür ile karşılaştırmalı olarak tartışılmıştır.

4.1. Zaman Alanı Bulguları

Hidrolik sistemdeki iç kaçak arızalarının farklı şiddet seviyelerine karşılık gelen zaman alanı davranışları incelenmiştir. Şekil 8–10’da kaçak olmayan (Sınıf 0), hafif iç kaçak (Sınıf 1) ve şiddetli iç kaçak (Sınıf 2) durumları için örnek bir çalışma çevriminden elde edilen PS1 (basınç), FS1 (akış) ve TS1 (sıcaklık) sensör sinyalleri birlikte sunulmaktadır. Bu sensörler, hidrolik sistemin basınç, debi ve termal davranışlarını temsil eden temel fiziksel büyüklükleri yansıtmaktadır.

Normal çalışma koşullarında (Şekil 8), tüm sensör sinyallerinin zamansal olarak kararlı, düşük varyanslı ve süreklilik gösteren bir yapı sergilediği görülmektedir. Basınç ve akış sinyalleri nominal çalışma rejimi etrafında sınırlı dalgalanmalar içerirken, sıcaklık sinyali sistemin termal dengesini yansıtan yavaş ve düzgün bir değişim göstermektedir. Bu gözlemler, Tablo 4’te sunulan düşük standart sapma ve sınırlı tepe-tepe değerleri ile de tutarlıdır.

Hafif iç kaçak durumunda (Şekil 9), zaman alanındaki ayrıştırmanın belirgin biçimde zorlaştığı gözlemlenmektedir. Basınç sinyalinde çoğu zaman açık bir kırılma veya ani sapma oluşmazken, özellikle akış (FS1) ve sıcaklık (TS1) sensörlerinde sınırlı genlik değişimleri ve geçici bozulmalar ortaya çıkmaktadır. Ancak bu değişimler,

normal çalışma koşullarındaki dalgalanmalarla örtüşebilecek düzeyde olduğundan, yalnızca zaman alanına dayalı analizlerle hafif kaçak senaryolarının güvenilir biçimde tespit edilmesi güçleşmektedir. Bu durum, hafif arızaların sistem üzerinde daha çok yerel ve geçici etkiler oluşturduğunu göstermektedir.

Şiddetli iç kaçak durumunda ise (Şekil 10), zaman alanındaki farklılıklar belirgin hâle gelmektedir. Basınç ve akış sensörlerinde gözlemlenen ani ve sürekli sapmalar, sistemin kararlı çalışma rejiminden uzaklaştığını açık biçimde ortaya koymaktadır. Akış sinyalindeki büyük genlikli değişimler ve basınç seviyesindeki düzensizlikler, iç kaçak şiddetinin artmasıyla birlikte hidrolik dengenin bozulduğunu göstermektedir. Bu davranışlar, Tablo 4'te yer alan yüksek standart sapma ve geniş tepe-tepe aralıkları ile nicel olarak da desteklenmektedir.


Tablo 4. Veri setinde kullanılan tüm sensörlere ait tanımlayıcı istatistikler.

Sensör	Ortalama	Standart Sapma	RMS	Minimum	Maksimum	Tepe-Tepe
CE	31,30	11,58	33,37	17,04	48,78	31,74
CP	1,81	0,28	1,83	1,02	2,91	1,89
EPS1	2495,51	218,22	2505,03	2097,80	2995,20	897,40
FS1	6,20	3,21	6,98	0,00	20,48	20,48
FS2	9,65	0,45	9,66	8,76	10,45	1,69
PS1	160,49	16,13	161,29	133,13	191,92	58,79
PS2	109,38	48,10	119,49	0,00	167,77	167,77
PS3	1,75	0,93	1,99	0,00	18,83	18,83
PS4	2,60	4,30	5,02	0,00	10,27	10,27
PS5	9,16	0,58	9,18	8,32	10,04	1,72
PS6	9,08	0,55	9,10	8,27	9,91	1,64
SE	55,29	25,64	60,94	0,00	100,60	100,60
TS1	45,42	7,99	46,12	34,98	58,21	23,22
TS2	50,37	7,40	50,91	40,71	62,18	21,47
TS3	47,66	7,45	48,24	38,15	59,54	21,39
TS4	52,02	7,98	52,63	41,13	63,92	22,79
VS1	1,42	0,37	1,47	0,54	2,60	2,06


Tablo 4'te sunulan tüm sensörlere ait tanımlayıcı istatistikler birlikte değerlendirildiğinde, iç kaçak arızalarının farklı fiziksel büyüklükler üzerinde farklı duyarlılıklar oluşturduğu görülmektedir. Basınç sensörleri hızlı ve ani dinamiklere daha duyarlı iken, akış sensörleri hidrolik dengenin bozulmasını, sıcaklık sensörleri ise enerji kayıplarına bağlı uzun vadeli termal etkileri yansıtmaktadır. Bu tamamlayıcı

yapı, tekil sensörlere dayalı karar mekanizmalarının özellikle erken evre arızalarda yetersiz kalabileceğini ortaya koymaktadır.


Şiddetli kaçak durumunda ise (Şekil 10), tüm sensörlerde daha belirgin ve sürekli sapmaların olduğu, basınç ve akış sinyallerindeki ani değişimlerin sistemin kararlı çalışma rejiminden uzaklaştığını açıkça ortaya koyduğu gözlemlenmektedir. Bu karşılaştırmalı analiz, iç kaçak arızalarının farklı fiziksel büyüklükler üzerinde farklı duyarlılıklar oluşturduğunu ve tekil sensörlere dayalı karar mekanizmalarının özellikle erken evre arızalarda yetersiz kalabileceğini göstermektedir.



Şekil 8. Kaçak olmayan durumda örnek bir çalışma çevrimine ait normalize edilmiş çoklu sensör zaman serileri.



Şekil 9. Hafif iç kaçak durumunda örnek bir çalışma çevrimine ait normalize edilmiş çoklu sensör zaman serileri.



Şekil 10. Şiddetli iç kaçak durumunda örnek bir çalışma çevrimine ait normalize edilmiş çoklu sensör zaman serileri.


Zaman alanı analizleri, şiddetli arıza durumlarının belirlenmesinde faydalı bilgiler sunmasına rağmen, hafif iç kaçak gibi ayrımı zor senaryolarda sınırlı kalmaktadır. Bu bulgular, çoklu sensör verilerinin birlikte değerlendirilmesini ve zaman alanında zayıf biçimde temsil edilen arıza etkilerinin daha ayırt edici biçimde ortaya konabilmesi için zaman–frekans temelli analizlere ve veri güdümlü öğrenme yaklaşımlarına ihtiyaç duyulduğunu göstermektedir. Bu gereksinim, bir sonraki bölümde ele alınan segmentasyon ve zaman–frekans alanı analizlerinin temel motivasyonunu oluşturmaktadır.

Şekil 11, geliştirilen CWT–CNN–LSTM modeline giriş olarak kullanılan sensör sinyallerinin zaman alanındaki davranışları gösterilmektedir. Tüm sinyaller normalize edilerek ortak bir ölçeğe taşınmış ve CWT ile zaman–frekans alanına dönüştürüldükten sonra, CNN ile öznitelik çıkarımı ve LSTM ile zamansal bağımlılıkların modellenmesi amacıyla kullanılmıştır.

Birinci satırda, VS1 titreşim sensöründen elde edilen hız genliği sinyallerinin normalize edilmiş hâlini göstermektedir. Normal çalışma koşullarında sinyaller daha kararlı ve düşük varyanslı bir yapı sergilerken, hafif ve şiddetli arıza durumlarında titreşim genliğinin hem genlik hem de zamansal dalgalanma açısından belirgin biçimde arttığı gözlemlenmektedir. Bu durum, hidrolik sistemdeki iç kaçak seviyesinin artmasına bağlı olarak mekanik düzensizliklerin yükseldiğini göstermektedir.

İkinci satırda, EPS1 sensöründen ölçülen motor gücü sinyalleri yer almaktadır. Motor gücü sinyalleri, sistemin farklı yükleme evrelerini yansıtan basamaklı bir yapı sergilemektedir. Normal çalışma durumunda güç profili daha tekrarlanabilir ve düzenliyken, arıza seviyesinin artmasıyla birlikte güç sinyalindeki geçişlerin daha düzensiz hâle geldiği ve normalize edilmiş genlik seviyelerinde sapmalar olduğu görülmektedir. Bu değişimler, pompanın aynı hidrolik çıktıyı sağlamak için daha fazla enerji tükettiğini göstermektedir.

Üçüncü satırda ise FS1 debi sensörüne ait normalize edilmiş sinyaller sunulmaktadır. Normal çalışma koşullarında debi sinyali nominal değerler etrafında daha stabil bir yapı gösterirken, hafif ve özellikle şiddetli arıza durumlarında ani pikler ve dalgalanmalar meydana gelmektedir. Bu durum, iç kaçak seviyesinin artmasına bağlı olarak hidrolik akışın kararsızlaştığını ve sistem verimliliğinin düştüğünü ortaya koymaktadır.




Şekil 11. Normal çalışma, hafif arıza ve şiddetli arıza durumları için titreşim (VS1), motor gücü (EPS1) ve debi (FS1) sensörlerinden elde edilen normalize edilmiş zaman serisi sinyalleri (Helwig & Schütze, 2020).

4.2. Segmentasyon Sonuçlarının Değerlendirilmesi

Zaman alanı analizlerinde özellikle hafif iç kaçak durumlarında arıza etkilerinin zamansal olarak homojen bir dağılım sergilemediği görülmüştür. Bu

nedenle, sinyalin tamamının tek bir bütün olarak ele alınması yerine, yerel ve geçici dinamiklerin ayrı ayrı incelenmesine olanak tanıyan segment-temelli bir yaklaşım benimsenmiştir. Bu alt bölümde, uygulanan segmentasyon stratejisinin gerekçesi açıklanmakta ve elde edilen segmentlerin sonraki zaman–frekans analizi ve derin öğrenme tabanlı modelleme adımları için nasıl bir temel oluşturduğu değerlendirilmektedir.

Şekil 12’te, yüksek frekansta örneklenen EPS1 basınç sinyalinin bir çalışma çevrimi boyunca sabit uzunluklu pencereler kullanılarak segmentlere ayrılması gösterilmektedir. Bu tez kapsamında segmentasyon işlemi, arızaya ilişkin bozulmaların çoğu zaman çevrimin tamamına homojen biçimde yayılmak yerine belirli zaman aralıklarında ortaya çıkan yerel değişimler şeklinde gelişmesi nedeniyle tercih edilmiştir. Pencere uzunluğunun 5 saniye olarak seçilmesi, her bir segmentin çevrim içerisindeki belirli bir çalışma rejimini temsil eden bağımsız bir örnek olarak ele alınmasına olanak tanımaktadır. Bindirme oranının %0 seçildiği bu örnekte, 60 saniyelik çevrim boyunca segmentler çakışmadan ilerlemekte ve her çevrimden 12 adet segment elde edilmektedir. Elde edilen bu segmentler, bir sonraki adımda Sürekli Dalgacık Dönüşümü (CWT) ile zaman–frekans alanına dönüştürülerek skalogram temsillerinin oluşturulmasında ve CNN–LSTM tabanlı mimarinin eğitilmesinde kullanılmaktadır.




Şekil 12. PS1 basınç sensörüne ait 60 saniyelik çalışma çevriminin sabit uzunluklu kayan pencere yaklaşımı ile segmentlere ayrılması.

4.3. Zaman–Frekans Alanı Bulguları

Zaman alanı analizleri, özellikle hafif iç kaçak senaryolarında arıza etkilerinin sınırlı ve geçici değişimler şeklinde ortaya çıktığını ve bu nedenle doğrudan ayrıştırmanın güçleştiğini göstermiştir. Bu bağlamda, segmentasyon işlemi ile elde edilen zaman serisi parçaları, arızaya ilişkin çok ölçekli dinamiklerin daha ayrıntılı biçimde incelenebilmesi amacıyla zaman–frekans alanına dönüştürülmüştür. Bu tez kapsamında, zaman alanından elde edilen sinyaller CWT kullanılarak elde edilen zaman–frekans temsillerine dönüştürülmüştür.

Şekil 13’te, segmentasyon işlemi sonucunda elde edilen PS1 basınç sinyaline ait örnek bir segmentin zaman alanı ve zaman–frekans alanındaki temsilleri karşılaştırmalı olarak sunulmaktadır. Zaman alanında incelendiğinde, sinyalin yalnızca belirli bir anda meydana gelen ani bir seviye değişimi içerdiği görülmektedir. Ancak bu temsil, söz konusu değişimin frekans içeriği ve çok ölçekli yapısı hakkında sınırlı bilgi sunmaktadır. Buna karşılık, aynı segmentin CWT ile elde edilen skalogramında, geçiş anına karşılık gelen bölgede düşük ve orta frekans bantlarına yayılan belirgin enerji yoğunlaşmaları gözlemlenmektedir. Bu durum, hidrolik sistemlerde hafif şiddetli arızaların zaman alanında zayıf biçimde temsil edilmesine karşın, zaman–frekans alanında daha ayırt edici örüntüler üretebildiğini göstermektedir. Dolayısıyla CWT tabanlı skalogram temsilleri, segment-temelli derin öğrenme mimarilerinde kullanılmak üzere daha zengin ve ayrıştırıcı bir giriş uzayı sağlamaktadır.



Şekil 13. Hafif kaçak (Sınıf 1) durumuna ait PS1 basınç sensöründen elde edilen örnek bir zaman serisi segmentinin ($L = 5$ s) (a) zaman alanı temsili ve (b) Sürekli Dalgacık Dönüşümü (CWT) ile elde edilen zaman–frekans skalogramı.

Bu tez kapsamında tüm zaman serisi segmentleri için benzer şekilde elde edilen zaman–frekans skalogramları, Konvolüsyonel Sinir Ağları (CNN) tarafından otomatik özellik öğrenimi amacıyla kullanılmış; ardışık segmentlerden elde edilen bu derin özellikler ise Uzun Kısa Süreli Bellek (LSTM) ağı ile zamansal bağımlılıkların modellenmesinde değerlendirilmiştir.

4.4. Derin Öğrenme Modeli Performans Bulguları

Zaman–frekans alanında elde edilen skalogram temsilleri, Tablo 3’te mimarisi verilen CNN yapısı kullanılarak işlenmiştir. CNN mimarisi; ardışık konvolüsyon, aktivasyon (ReLU) ve havuzlama katmanları aracılığıyla, skalogramlardaki yerel enerji yoğunlaşmalarını, frekans bantlarındaki değişimleri ve arızaya özgü desenleri hiyerarşik biçimde öğrenmektedir. CNN’in temel rolü, elle tanımlanmış istatistiksel özniteliklere ihtiyaç duymadan, zaman–frekans alanındaki ayırt edici örüntüleri otomatik olarak kodlayan yüksek seviyeli özellik vektörleri üretmektir. Tablo 3’te verilen mimari sonucunda, her bir zaman serisi segmenti için sabit boyutlu bir derin özellik vektörü elde edilmiştir. Bu vektörler, doğrudan sınıflandırma yerine, zamansal bağımlılıkların modellenmesi amacıyla LSTM ağına giriş olarak verilmiştir.

CNN tarafından elde edilen segment-bazlı özellikler, hidrolik sistemlerde arızaların kademeli ve zamana yayılan doğası nedeniyle tek başına yeterli değildir. Bu nedenle, ardışık segmentlerden oluşan özellik dizileri, Uzun Kısa Süreli Bellek (LSTM) ağı kullanılarak modellenmiştir. LSTM mimarisi, klasik tekrarlayan sinir ağlarının karşılaştığı gradyan sönümlenmesi problemini kapı (gate) mekanizmaları aracılığıyla aşarak, uzun vadeli bağımlılıkları etkin biçimde öğrenebilmektedir. Bu bağlamda, LSTM ağı; CNN tarafından çıkarılan derin özelliklerin segmentler arasındaki geçişlerini ve arıza evrimini temsil eden zamansal örüntüleri öğrenmektedir. CNN’den türetilen özellikler kullanılarak eğitilen LSTM ağının mimari ve eğitim parametreleri Tablo 5’te verilmiştir.


Tablo 5. LSTM ağıının mimari ve eğitim parametreleri.

Parametre	Değer / Açıklama
Girdi	CNN'den elde edilen özellik vektörleri
Zaman adımı (T)	Ardışık segment sayısı
LSTM katman sayısı	1
LSTM hücre sayısı	64
Aktivasyon	tanh (hücre), sigmoid (kapılar)
Dropout	0,3
Çıkış katmanı	Fully connected + Softmax
Çıkış sınıf sayısı	3 (Kaçak Yok, Hafif Kaçak, Şiddetli Kaçak)
Kayıp fonksiyonu	Categorical Cross-Entropy
Optimizasyon algoritması	Adam
Öğrenme oranı	1e-3
Mini-batch boyutu	32
Erken durdurma	Doğrulama kaybına göre

LSTM ağı, CNN tarafından her bir zaman serisi segmenti için çıkarılan öznitelik vektörlerini ardışık yapılarını koruyacak şekilde giriş olarak alacak biçimde eğitilmiştir. Bu yapı sayesinde, hidrolik sistemlerde arızaların yalnızca anlık sinyal değişimleriyle değil, zaman içerisinde kademeli olarak gelişen dinamik davranışları da modellenilebilmiştir. CNN katmanı tarafından elde edilen yüksek seviyeli zaman-frekans temsilleri, LSTM ağına beslenerek segmentler arası zamansal bağımlılıkların öğrenilmesi sağlanmıştır.

Model geliştirme sürecinde kullanılan veri seti, rastgele ve sınıf dağılımı korunacak şekilde %70 eğitim ve %30 test alt veri setlerine ayrılmıştır. Eğitim veri seti üzerinde, modelin doğrulanması ve hiperparametre ayarlamalarının gerçekleştirilmesi amacıyla k-katlı çapraz doğrulama (k-fold cross validation) yöntemi uygulanmıştır. Bu kapsamda, eğitim veri seti kendi içerisinde $k = 10$ olacak şekilde eşit alt kümelere bölünmüş; her bir yinelemede dokuz alt küme modelin eğitimi için kullanılırken, kalan bir alt küme doğrulama amacıyla değerlendirilmiştir. Bu işlem, her bir alt kümenin doğrulama veri seti olarak kullanıldığı toplam on yineleme boyunca tekrarlanmıştır. Eğitim veri seti, hiperparametre ayarlama amacıyla kullanılırken, aynı zamanda erken durdurma (early stopping) mekanizmasının uygulanabilmesi için doğrulama amacıyla değerlendirilmiştir. Erken durdurma yöntemi, doğrulama kaybındaki iyileşmenin belirli bir nesil sayısı boyunca devam etmemesi durumunda eğitimin sonlandırılması esasına dayanmakta olup, modelin aşırı öğrenme (overfitting) eğilimini azaltmak ve

genelleme kabiliyetini artırmak amacıyla uygulanmıştır. Şekil 14, veri setinin %70 eğitim ve %30 test alt kümelerine ayrılması sonrasında izlenen CWT-CNN-LSTM tabanlı model eğitim süreci gösterilmektedir.



Şekil 14. CWT-CNN-LSTM tabanlı model için k-katlı çapraz doğrulama ve eğitim-test ayrımını içeren eğitim iş akış şeması.


Test veri seti ise model eğitimi sürecine hiçbir aşamada dâhil edilmemiş, yalnızca eğitilmiş CNN-LSTM mimarisinin daha önce görülmemiş veriler üzerindeki performansını nesnel biçimde değerlendirmek amacıyla kullanılmıştır. Bu ayrım sayesinde, geliştirilen modelin gerçek çalışma koşullarında hidrolik sistemlerdeki normal çalışma, hafif arıza ve şiddetli arıza durumlarını ayırt etme başarımı güvenilir bir şekilde analiz edilebilmiştir.

Eğitim süreci boyunca modelin öğrenme davranışını izlemek ve değerlendirmek amacıyla, modelin eğitim ve doğrulama veri setleri üzerindeki kayıp (loss) değerleri izlenerek öğrenmenin kararlılığı ve yakınsama durumu analiz edilmiştir. Aynı zamanda eğitim ve doğrulama doğruluğu (accuracy) değerleri takip edilerek modelin sınıflandırma başarımının eğitim süreci boyunca nasıl değiştiği gözlemlenmiştir. Ayrıca, LSTM katmanına ait gizli durumlar (hidden states) incelenerek, modelin ardışık segmentler arasındaki zamansal bağlamı ne ölçüde öğrendiği değerlendirilmiştir. Buna ek olarak, çıkış katmanında elde edilen softmax

çıktıları analiz edilerek her bir sınıf için hesaplanan olasılık dağılımları üzerinden modelin karar verme eğilimi ve sınıflar arasındaki ayırt ediciliği yorumlanmıştır. Bu ara çıktılar, modelin aşırı öğrenme (overfitting) eğiliminin kontrol edilmesi ve zamansal bağımlılıkları gerçekten öğrenip öğrenmediğinin değerlendirilmesi açısından kritik öneme sahiptir.

Önerilen hibrit CNN–LSTM tabanlı derin öğrenme modelinin sınıflandırma başarımı, eğitim ve test veri kümeleri üzerinde elde edilen karışıklık matrisleri (Şekil 15) ve sınıf bazlı performans metrikleri (Tablo 6 ve Tablo 7) kullanılarak değerlendirilmiştir. Model performansı; doğruluk, kesinlik, duyarlılık ve F1-skoru ölçütleri üzerinden nicel olarak analiz edilmiştir.

Şekil 15'te sunulan karışıklık matrisleri incelendiğinde, modelin her iki veri kümesinde de sınıflar arasında tutarlı ve dengeli bir sınıflandırma performansı sergilediği görülmektedir. Eğitim veri kümesi için elde edilen doğruluk değeri yaklaşık %84, test veri kümesi için ise yaklaşık %89 olarak hesaplanmıştır. Test veri kümesinde elde edilen doğruluk değerinin eğitim veri kümesine kıyasla daha yüksek olması, geliştirilen modelin aşırı öğrenme (overfitting) göstermediğini ve farklı veri örnekleri üzerinde başarılı bir genelleme performansı sergilediğini göstermektedir.



Şekil 15. (a) Eğitim veri kümesi ve (b) test veri kümesi üzerinde dahili pompa sızıntısı sınıflandırması için karışıklık matrisi.

Eğitim veri kümesine ait karışıklık matrisi incelendiğinde (Şekil 15a), modelin normal çalışma ve şiddetli arıza sınıflarını yüksek doğrulukla ayırt edebildiği görülmektedir. Normal çalışma durumlarının büyük bir bölümü doğru sınıflandırılmış

olup, bu sınıfın esas olarak hafif arıza ile sınırlı düzeyde karıştığı gözlemlenmektedir. Benzer şekilde, şiddetli arıza sınıfına ait örneklerin tamamına yakını doğru şekilde tanımlanmış, yanlış sınıflandırmaların ise ağırlıklı olarak hafif arıza sınıfında yoğunlaştığı tespit edilmiştir.

Hafif arıza sınıfı, her iki karışıklık matrisinde de diğer sınıflara kıyasla daha yüksek yanlış sınıflandırma oranına sahiptir. Bu durum, hidrolik sistemlerde hafif arıza koşullarının sinyal karakteristiklerinin normal çalışma ve şiddetli arıza durumları ile kısmen örtüşmesi ile açıklanabilir. Özellikle erken evre arızalarda, basınç, akış ve titreşim gibi proses değişkenlerindeki sapmaların sınırlı olması, sınıflar arası ayrımın zorlaşmasına neden olmaktadır.

Test veri kümesine ait sonuçlar (Şekil 15b) incelendiğinde, eğitim veri kümesi ile benzer bir hata dağılımı elde edildiği görülmektedir. Bu durum, geliştirilen derin öğrenme modelinin yalnızca eğitim verisini ezberlemediğini, farklı veri örnekleri üzerinde de tutarlı bir genelleme performansı sergilediğini göstermektedir. Normal çalışma ve şiddetli arıza sınıflarında yüksek doğruluk korunurken, hafif arıza sınıfındaki sınıflandırma zorluklarının test aşamasında da devam ettiği gözlemlenmiştir. Bununla birlikte, eğitim ve test veri kümelerinin sınıflandırma performans metrikleri sırasıyla Tablolar 6 ve 7’de verilmiştir.

Tablo 6. Eğitim veri kümesi üzerindeki sınıflandırma performansı.

Sınıf	Kesinlik	Duyarlılık	F1-skoru
Normal çalışma	0,936	0,922	0,929
Hafif arıza	0,605	0,654	0,628
Şiddetli arıza	0,841	0,810	0,825

Tablo 7. Test veri kümesi üzerindeki sınıflandırma performansı.

Sınıf	Kesinlik	Duyarlılık	F1-skoru
Normal çalışma	0,959	0,941	0,950
Hafif arıza	0,721	0,779	0,749
Şiddetli arıza	0,898	0,874	0,886

Eğitim veri kümesi sonuçları incelendiğinde (Tablo 6), normal çalışma sınıfı için yüksek kesinlik (0,936) ve duyarlılık (0,922) değerleri elde edildiği görülmektedir. Bu durum, modelin normal çalışma koşullarını hem doğru tanımlama hem de yanlış

pozitif üretmeme açısından başarılı olduğunu göstermektedir. Benzer şekilde, şiddetli arıza sınıfı için elde edilen F1-skoru (0,825), modelin belirgin arıza durumlarını güvenilir biçimde ayırt edebildiğini ortaya koymaktadır. Buna karşın, hafif arıza sınıfı eğitim aşamasında diğer sınıflara kıyasla daha düşük performans sergilemiştir. Hafif arıza sınıfına ait kesinlik (0,605) ve duyarlılık (0,654) değerlerinin görece düşük olması, bu sınıfa ait örneklerin normal çalışma ve şiddetli arıza durumları ile kısmen örtüşen sinyal karakteristiklerine sahip olmasından kaynaklanmaktadır. Bu durum, hidrolik sistemlerde erken evre arızaların tespiti için doğası gereği daha zor olduğunu göstermektedir.

Test veri kümesi sonuçları (Tablo 7), modelin genelleme yeteneğinin güçlü olduğunu açık biçimde ortaya koymaktadır. Normal çalışma sınıfı için elde edilen F1-skoru (0,950), eğitim aşamasına benzer biçimde yüksek doğrulukla korunmuştur. Şiddetli arıza sınıfında da yüksek kesinlik (0,898) ve duyarlılık (0,874) değerleri elde edilmiş, bu da modelin kritik arıza durumlarını test verisi üzerinde de başarılı şekilde tespit edebildiğini göstermiştir. Dikkat çekici bir diğer bulgu, hafif arıza sınıfındaki performansın test veri kümesinde belirgin biçimde artmış olmasıdır. Bu sınıf için F1-skorunun 0,628'den 0,749'a yükselmesi, modelin aşırı öğrenme (overfitting) eğilimi göstermediğini ve hafif arıza örneklerini genellenebilir biçimde öğrenebildiğini ortaya koymaktadır.

Test aşamasında duyarlılığın (0,779) artması, hafif arıza durumlarının kaçırılma oranının azaldığını göstermesi açısından özellikle önemlidir. Hafif arıza sınıfında test kümesinde elde edilen performans artışı, zaman–frekans tabanlı skalogram temsillerinin ve LSTM ile gerçekleştirilen zamansal bağımlılık modellemesinin, zayıf ve geçici arıza imzalarının yakalanmasında önemli katkı sağladığını göstermektedir.

Genel olarak değerlendirildiğinde, önerilen CNN–LSTM tabanlı yaklaşım; belirgin arızalarda yüksek doğruluk sağlarken, literatürde tespiti zor olduğu bilinen hafif iç kaçak arızaları için de anlamlı bir ayırt edicilik sunmaktadır. Bu sonuçlar, yöntemin endüstriyel hidrolik sistemlerde erken arıza tespiti ve kestirimci bakım uygulamaları için uygulanabilir ve güvenilir bir çözüm sunduğunu göstermektedir. Bu sonuçlar, hafif arıza koşullarında zamansal bağlam bilgisinin ve çok ölçekli frekans içeriğinin modele dâhil edilmesinin kritik önem taşıdığını göstermektedir. Şiddetli iç

kaçak sınıfı, model tarafından yüksek doğrulukla sınıflandırılan bir diğer sınıf olmuştur.

Şiddetli kaçak durumlarında basınç ve akış sensörlerinde meydana gelen ani seviye değişimleri ve yüksek enerjili frekans bileşenleri, zaman–frekans alanında güçlü ve ayırt edici örüntüler üretmiştir. Bu örüntüler, CNN tarafından etkin biçimde öğrenilmiş; LSTM ağı ise bu bilgileri ardışık segmentler boyunca zamansal bağlam içerisinde başarıyla modellemiştir.

Tablo 6, Tablo 7 ve Şekil 15 birlikte değerlendirildiğinde, önerilen CNN–LSTM tabanlı yaklaşımın; normal çalışma koşullarını yüksek doğrulukla tanıyabildiği, hafif iç kaçak senaryolarında fiziksel benzerlikler nedeniyle sınırlı bir belirsizlik yaşamakla birlikte, anlamlı bir ayırım gücü sağladığı, şiddetli iç kaçak arızalarını ise yüksek güvenilirlikle tespit edebildiği sonucuna ulaşılmaktadır.

5. SONUÇLAR

Bu tez çalışmasında, hidrolik sistemlerde iç kaçak arızalarının tespiti ve şiddetinin sınıflandırılması amacıyla, çoklu sensör verilerine dayalı segment-temelli, zaman–frekans destekli ve derin öğrenme tabanlı bütüncül bir yaklaşım önerilmiştir. Çalışma kapsamında, farklı örnekleme hızlarına sahip basınç, akış ve sıcaklık sensörlerinden elde edilen zaman serileri; öncelikle zaman alanında analiz edilmiş, ardından sabit uzunluklu pencereler kullanılarak segmentlere ayrılmış ve Sürekli Dalgacık Dönüşümü (CWT) ile zaman–frekans alanına dönüştürülmüştür. Elde edilen skalogram temsilleri, Konvolüsyonel Sinir Ağları (CNN) ile otomatik özellik çıkarımı için kullanılmış; ardışık segmentlerden türetilen derin özellikler ise Uzun Kısa Süreli Bellek (LSTM) ağı ile zamansal bağlam içerisinde modellenmiştir.

Zaman alanı bulguları, şiddetli iç kaçak durumlarının basınç ve akış sensörlerinde belirgin ve sürekli sapmalara yol açtığını açık biçimde ortaya koyarken, hafif iç kaçak senaryolarında arıza etkilerinin zayıf, geçici ve yerel bozulmalar şeklinde ortaya çıktığını göstermiştir. Bu durum, yalnızca zaman alanına dayalı analizlerin özellikle erken evre arızalarda sınırlı kalabileceğini ortaya koymuştur. Segmentasyon yaklaşımı sayesinde, bu yerel bozulmalar bağımsız örnekler hâlinde ele alınabilmiş ve arızaya özgü dinamiklerin daha etkin biçimde temsil edilmesi sağlanmıştır.

Zaman–frekans alanı analizleri, CWT tabanlı skalogram temsillerinin, zaman alanında zayıf biçimde gözlemlenen arıza etkilerini düşük ve orta frekans bantlarında belirgin enerji yoğunlaşmaları şeklinde ortaya koyabildiğini göstermiştir. Bu çok ölçekli temsil, özellikle hafif iç kaçak senaryolarında ayırt edici örüntülerin açığa çıkarılmasında kritik bir rol oynamıştır. CNN tarafından öğrenilen bu örüntülerin, LSTM ağı ile ardışık segmentler boyunca modellenmesi, arızaların zamansal evriminin yakalanmasına olanak tanımıştır.

Önerilen hibrit CNN–LSTM modelinin performans değerlendirmeleri, eğitim ve test veri kümeleri üzerinde tutarlı ve dengeli sonuçlar verdiğini göstermiştir. Normal çalışma koşulları yüksek doğrulukla sınıflandırılırken, şiddetli iç kaçak arızaları da belirgin sensör bozulmaları sayesinde güvenilir biçimde tespit edilmiştir. Hafif iç kaçak sınıfı, fiziksel olarak diğer sınıflara yakın davranışlar sergilemesi nedeniyle en

zorlayıcı sınıf olmasına rağmen, zaman–frekans temsilleri ve zamansal modelleme sayesinde anlamlı bir ayırım gücü elde edilmiştir. Eğitim ve test performansları arasındaki yakınlık, önerilen modelin aşırı öğrenme eğilimi göstermediğini ve iyi bir genelleme yeteneğine sahip olduğunu doğrulamıştır.

Sonuç olarak, bu tezde geliştirilen segmentasyon + CWT + CNN–LSTM tabanlı yaklaşım; hidrolik pompa iç kaçaklarının hem tespitinde hem de şiddet seviyelerinin ayrıştırılmasında yüksek doğruluk, kararlılık ve genellenebilirlik sunmaktadır. Elde edilen bulgular, çoklu sensör verilerinin birlikte değerlendirilmesi ve zaman–frekans temelli temsillerin zamansal bağlamla entegre edilmesinin, endüstriyel hidrolik sistemlerde güvenilir kestirimci bakım uygulamaları için güçlü ve uygulanabilir bir çözüm sunduğunu ortaya koymaktadır.

KAYNAKÇA

- Abidi, M.H., Mohammed, M.K., & Alkhalefah, H. (2022). Predictive maintenance planning for industry 4.0 using machine learning for sustainable manufacturing. *Sustainability*, 14(6), 3387.
- Al-Ghamd, A. M., & Mba, D. (2006). A comparative experimental study on the use of acoustic emission and vibration analysis for bearing defect identification and estimation of defect size. *Mechanical Systems and Signal Processing*, 20(7), 1537–1571. <https://doi.org/10.1016/j.ymssp.2005.06.002>
- Amini, M., Sharifani, K., & Rahmani, A. (2023). Machine Learning Model Towards Evaluating Data gathering methods in Manufacturing and Mechanical Engineering. *International Journal of Applied Science and Engineering Research*, 15(2023), 349-362.
- Arena, F., Collotta, M., Luca, L., Ruggieri, M., & Termine, F.G. (2022). Predictive maintenance in the automotive sector: A literature review. *Mathematical and Computational Applications*, 27(1), 2.
- Arena, S., Florian, E., Zennaro, I., Orrù, P. F., & Sgarbossa, F. (2022). A novel decision support system for managing predictive maintenance strategies based on machine learning approaches. *Safety science*, 146, 105529.
- Bagavathiappan, S., Lahiri, B. B., Saravanan, T., Philip, J., & Jayakumar, T. (2013). Infrared thermography for condition monitoring – A review. *Infrared Physics & Technology*, 60, 35–55. <https://doi.org/10.1016/j.infrared.2013.03.006>
- Bastías, O.A., Díaz, J., & López Fenner, J. (2023). Exploring the Intersection between Software Maintenance and Machine Learning—A Systematic Mapping Study. *Applied Sciences*, 13(3), 1710.
- Bekdash, S., Tufekci, M., & Kahraman, A. (2022). A data-driven predictive maintenance framework for industrial equipment. *Journal of Manufacturing Systems*, 62, 175–187. <https://doi.org/10.1016/j.jmsy.2021.12.004>
- Ceryan, N., Ozkat, E.C., Korkmaz Can, N., & Ceryan, S. (2021). Machine learning models to estimate the elastic modulus of weathered magmatic rocks. *Environmental Earth Sciences*, 80(12), 448.
- Chen, Z., Li, C., & Sanchez, R.-V. (2022). Transformer-based deep learning for intelligent fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 170, 108767. <https://doi.org/10.1016/j.ymssp.2022.108767>
- Cui, Z., Tang, B., & Chen, J. (2023). A hybrid autoencoder–CNN framework for intelligent fault diagnosis of machinery. *IEEE Transactions on Industrial Informatics*, 19(3), 2567–2576. <https://doi.org/10.1109/TII.2022.3189213>

- Eddarhri, M., Adib, J., Hain, M., & Marzak, A. (2022). Towards predictive maintenance: the case of the aeronautical industry. *Procedia Computer Science*, 203, 769-774.
- Efeoğlu, E., & Tuna, G. (2022). Machine Learning for Predictive Maintenance: Support Vector Machines and Different Kernel Functions. *Journal of Machinery Manufacture and Reliability*, 51(5), 447-456.
- Gebraeel, N. (2006). Sensory-updated residual life distributions for components with exponential degradation patterns. *IEEE Transactions on Automation Science and Engineering*, 3(4), 382–393. <https://doi.org/10.1109/TASE.2006.880541>
- Greener, J.G., Kandathil, S.M., Moffat, L., & Jones, D.T. (2022). A guide to machine learning for biologists. *Nature Reviews Molecular Cell Biology*, 23(1), 40-55.
- Helwig, N., & Schütze, A. (2020). Condition monitoring of hydraulic systems using multivariate statistics. *Mechanical Systems and Signal Processing*, 135, 106346. <https://doi.org/10.1016/j.ymssp.2019.106346>
- Hesabi, H., Nourelfath, M., & Hajji, A. (2022). A deep learning predictive model for selective maintenance optimization. *Reliability Engineering & System Safety*, 219, 108191.
- Jardine, A. K. S., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483–1510. <https://doi.org/10.1016/j.ymssp.2005.09.012>
- Karabacak, Y.E., Özmen, N.G., & Gümüşel, L. (2022). Intelligent worm gearbox fault diagnosis under various working conditions using vibration, sound and thermal features. *Applied Acoustics*, 186, 108463.
- Kedadouche, M., Thomas, M., & Tahan, A. (2016). A comparative study between EMD and EWT for gearbox fault diagnosis. *Mechanical Systems and Signal Processing*, 75, 450–471. <https://doi.org/10.1016/j.ymssp.2015.12.017>
- Koca, Y.B. and Ünsal, A., 2017, Asenkron motorların elektriksel ve mekaniksel arızalarının değerlendirilmesi, *Süleyman Demirel Üniversitesi Teknik Bilimler Dergisi*, 7(2), pp. 37–46.
- Lee, J., Bagheri, B., & Kao, H.-A. (2014). A cyber-physical systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*, 3, 18–23. <https://doi.org/10.1016/j.mfglet.2014.12.001>
- Li, X., Wang, Y., & Xu, M. (2024). Hybrid CNN–Transformer networks for remaining useful life prediction under variable operating conditions. *Reliability Engineering & System Safety*, 238, 109387. <https://doi.org/10.1016/j.ress.2023.109387>

- Mobley, R. K. (2002). An introduction to predictive maintenance (2nd ed.). Butterworth-Heinemann.
- Nishat Toma, R., & Kim, J. (2020). A review of predictive maintenance using IoT and big data analytics. *Journal of Manufacturing Systems*, 56, 139–153. <https://doi.org/10.1016/j.jmsy.2020.05.010>
- Ozkat, E. C., Bektas, O., Nielsen, M.J., & la Cour-Harbo, A. (2023). A data-driven predictive maintenance model to estimate RUL in a multi-rotor UAS. *International Journal of Micro Air Vehicles*, 15, 17568293221150171.
- Özkat, E.C. (2021). Makine Öğrenmesi Metodolojisi Kullanılarak Yüksek Hızlı Rulmanlarda Sağlık Göstergesinin Belirlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (22), 176-183.
- Paulson, N.H., Kubal, J., Ward, L., Saxena, S., Lu, W., & Babinec, S.J. (2022). Feature engineering for machine learning enabled early prediction of battery lifetime. *Journal of Power Sources*, 527, 231127.
- Pech, M., Vrchota, J., & Bednář, J. (2021). Predictive maintenance and Industry 4.0. *Sensors*, 21(4), 1470. <https://doi.org/10.3390/s21041470>
- Randall, R. B. (2011). *Vibration-based condition monitoring: Industrial, aerospace and automotive applications*. Wiley.
- Rigolli, M., Zonta, T., da Costa, C. A., & Righi, R. R. (2023). Machine learning approaches for oil analysis-based predictive maintenance. *Applied Soft Computing*, 132, 109858. <https://doi.org/10.1016/j.asoc.2022.109858>
- Samuel, P.D., & Pines, D.J. (2005). A review of vibration-based techniques for helicopter transmission diagnostics. *Journal of sound and vibration*, 282(1-2), 475-508.
- Shao, S., Yan, R., Lu, Y., Wang, P., & Gao, R. X. (2018). DCNN-based multi-signal induction motor fault diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 68(5), 1508–1517. <https://doi.org/10.1109/TIM.2018.2865258>
- Schütze, A., Helwig, N., & Schneider, T. (2015). Sensors 4.0 – Smart sensors and measurement technology enable Industry 4.0. *Journal of Sensors and Sensor Systems*, 4(2), 359–371. <https://doi.org/10.5194/jsss-4-359-2015>
- Tandon, N., & Choudhury, A. (2005). A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings. *Tribology International*, 32(8), 469–480. [https://doi.org/10.1016/S0301-679X\(99\)00077-8](https://doi.org/10.1016/S0301-679X(99)00077-8)
- Thai, H.T. (2022). Machine learning for structural engineering: A state-of-the-art review. In *Structures*, 38, 448-491.

- Tiboni, M., Remino, C., & Amici, C. (2022). Predictive maintenance strategies for industrial applications: A review. *Applied Sciences*, 12(6), 2931. <https://doi.org/10.3390/app12062931>
- Vadyala, S.R., Betgeri, S.N., Matthews, J.C., & Matthews, E. (2022). A review of physics-based machine learning in civil engineering. *Results in Engineering*, 13, 100316.
- Vallim Filho, A.R.D.A., Farina Moraes, D., Bhering de Aguiar Vallim, M.V., Santos da Silva, L., & da Silva, L.A. (2022). A machine learning modeling framework for predictive maintenance based on equipment load cycle: an application in a real world case. *Energies*, 15(10), 3724.
- Wang, X., Mazumder, R.K., Salarieh, B., Salman, A.M., Shafieezadeh, A., & Li, Y. (2022). Machine learning for risk and resilience assessment in structural engineering: Progress and future trends. *Journal of Structural Engineering*, 148(8), 03122003.
- Wen, L., Li, X., Gao, L., & Zhang, Y. (2017). A new convolutional neural network-based data-driven fault diagnosis method. *IEEE Transactions on Industrial Electronics*, 65(7), 5990–5998. <https://doi.org/10.1109/TIE.2017.2774777>
- Widodo, A., & Yang, B.-S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical Systems and Signal Processing*, 21(6), 2560–2574. <https://doi.org/10.1016/j.ymssp.2006.12.007>
- Wu, H., & Zheng, H. (2023). Single-machine scheduling with periodic maintenance and learning effect. *Scientific Reports*, 13(1), 9309.
- Zhang, W., Yang, D., & Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal*, 13(3), 2213–2227. <https://doi.org/10.1109/JSYST.2019.2905565>
- Zhao, R., Wang, D., Yan, R., Mao, K., Shen, F., & Wang, J. (2017). Machine health monitoring using local feature-based gated recurrent unit networks. *IEEE Transactions on Industrial Electronics*, 65(2), 1539–1548. <https://doi.org/10.1109/TIE.2017.2733438>
- Zonta, T., Da Costa, C.A., da Rosa Righi, R., de Lima, M. J., da Trindade, E.S., & Li, G.P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering*, 150, 106889.