

Otonom Robotlar için Pekİştİrmeli Öğrenme Tabanlı Dağıtık Arıza Teşhis Sistemi

Mahmut Kasap

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Mayıs 2024

Reinforcement Learning Based Distributed Fault Diagnosis System for
Autonomous Robots

Mahmut Kasap

DOCTORAL DISSERTATION

Department of Computer Engineering

May 2024

Otonom Robotlar için Pekiştirmeli Öğrenme Tabanlı Dağıtık Arıza Teşhis Sistemi

Mahmut Kasap

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Eğitim ve Öğretim Yönetmeliği Uyarınca
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Bilimleri Bilim Dalında
DOKTORA TEZİ
olarak hazırlanmıştır

Danışman: Prof. Dr. Ahmet Yazıcı
İkinci Danışman: Doç. Dr. Eyüp Çınar

Bu Tez TÜBİTAK tarafından "2232 Uluslararası Lider Araştırmacılar Programı
118C252" no'lu proje ve "2211/A Yurt İçi Genel Doktora Burs Programı"
çerçevesinde desteklenmiştir.

Mayıs 2024

ONAY

Bilgisayar Mühendisliği Anabilim Dalı Doktora öğrencisi **Mahmut Kasap**'ın DOKTORA tezi olarak hazırladığı "**Otonom Robotlar için Pekiştirmeli Öğrenme Tabanlı Dağıtık Arıza Teşhis Sistemi**" başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğin ilgili maddeleri uyarınca değerlendirilerek oybirliği ile kabul edilmiştir.

Danışman : Prof. Dr. Ahmet Yazıcı

İkinci Danışman : Doç. Dr. Eyüp Çınar

Doktora Tez Savunma Jürisi:

Üye: Prof. Dr. Ahmet Yazıcı

Üye: Prof. Dr. Rifat Edizkan

Üye: Prof. Dr. Kemal Özkan

Üye: Prof. Dr. Bünyamin Tamyürek

Üye: Doç. Dr. Mehmet Koç

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Fatma Tümsek
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Ahmet Yazıcı ve Doç. Dr. Eyüp Çınar danışmanlığında hazırlamış olduğum **“Otonom Robotlar için Pekiştirmeli Öğrenme Tabanlı Dağıtık Arıza Teşhis Sistemi”** başlıklı Doktora tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim.

28/05/2024

Mahmut Kasap

ÖZET

Otonom mobil robotlar (AMR'ler), endüstri 4.0 için en önemli siber-fiziksel sistemlerden biridir. Bu robotların arızaları, üretimde kazalara, maliyetli gecikmelere ve kesintilere neden olabilir. Arıza tespitinde veriye dayalı yapay zekâ yöntemleri başarılıdır. Fakat başarılı yapay zekâ modellerinin eğitimi, farklı sistemleri temsil eden yoğun veri gerektirir. Ham sensör verilerinin merkezi sisteme gönderimi hız, güvenlik ve bant genişliği sorunları ortaya çıkarır. Diğer yandan, yalnızca uç sistemlerde eğitilen modeller tüm ajanları ve durum uzayını temsil etmemektedir. Akıllı fabrikalar gibi gerçek ve dinamik ortamlarda birden fazla mobil robot ajan için merkezi ve eşzamanlı eğitim zordur. Her ajan bilinmeyen zor durumlarla karşılaşır ve arızalar nadir görülür, bu durum modelin dengesiz koşullarla eğitilmesi sorununu beraberinde getirir. Bu tez, öngörü ve sağlık yönetimi amaçları doğrultusunda, akıllı fabrikalarda filo düzeninde faaliyet gösteren AMR'ler için çok ajanlı pekiştirmeli öğrenmeye dayalı bir arıza tespit yöntemi önermektedir. Yöntem, ham verileri uç sistemlerden merkezi sisteme aktarmak yerine, model parametrelerinin eşzamansız olarak sistemler arası paylaşılmasına dayanır. Model eğitiminde, insan deneyiminin öğrenilmesini sağlayan taklit öğrenme kullanılmıştır. Çalışma, bilinmeyen ortamlarda birden fazla ajana yönelik eğitimde dengesiz veriler için parametrelendirilmiş orantılı ödül mekanizması önermektedir. Modeller uçta sensör tabanlı aykırılık tespiti gerçekleştirir. Arıza tespiti aşamasında tek sensör verisinde görülebilen ve yanlış alarmı sebep olan gürültüye karşı karar seviyesi füzyonu uygulanmaktadır. Çalışma, Eskişehir Osmangazi Üniversitesi Akıllı Fabrika ve Robotik Laboratuvarı'nda yürütülmüştür. Sonuçlar önerilen yöntemin normal koşullar için tüm yanlış alarmları ortadan kaldırdığını göstermektedir. Ayrıca arızalı koşullar %100 oranında, arızalı pencereler ise yaklaşık %78 oranında tespit edilmiştir. Önerilen yöntem, arıza anını yüksek doğrulukta tespit ederek doğru bakım planlamasında kullanılabilir.

Anahtar Kelimeler: Öngörü ve sağlık yönetimi, otonom mobil robotlar, çok ajanlı, eşzamansız pekiştirmeli öğrenme, arıza tespiti, füzyon

SUMMARY

Autonomous mobile robots (AMRs) are one of the most essential cyber-physical systems for industry 4.0. Faults of these robots can cause accidents, delays, and interruptions in production. Data-driven artificial intelligence methods are successful in detecting faults. However, training successful artificial intelligence models requires extensive data representing different systems. Sending raw sensor data to the central system poses speed, security, and bandwidth issues. On the other hand, models trained only on edge systems do not represent all agents and state space. Centralized and synchronized training for multiple mobile robot agents is difficult in real and dynamic environments such as intelligent factories. Every agent faces unknown difficult situations, and faults are rare, which brings the problem of training the model under unbalanced conditions. This thesis proposes a fault detection method based on multi-agent reinforcement learning for AMRs operating in fleet order on intelligent factory floors for prognostics and health management. The method is based on asynchronously sharing model parameters between systems instead of transferring raw data from edge systems to the central system. In model training, imitation learning was used, which allows learning about human experience. The study proposes a parameterized proportional reward mechanism for unbalanced data in training multiple agents in unknown environments. The models perform sensor-based anomaly detection at the edge. During the fault detection phase, decision-level fusion is applied against noise that can be seen in a single sensor data set and causes false alarms. The study was conducted at Eskişehir Osmangazi University Intelligent Factory and Robotics Laboratory. The results show that the proposed method eliminates all false alarms for normal runs. In addition, faulty runs were detected at a rate of 100%, and faulty windows were detected at approximately 78%. The proposed method can be used in accurate maintenance planning by detecting the moment of fault with high accuracy.

Keywords : Prognostics and health management, autonomous mobile robots, multi-agent, asynchronous reinforcement learning, fault detection, fusion

TEŞEKKÜR

Doktora eğitimim, proje çalışmalarım ve tez dönemim süresince bana yol gösteren, bilgisi, tecrübesi ve disipliniyle örnek aldığım kıymetli hocalarım Prof. Dr. Ahmet Yazıcı ve Doç. Dr. Eyüp Çınar'a destekleri için sonsuz saygılarımı ve teşekkürlerimi sunarım.

Çalışmalarımın kalitesini arttırmak için proje ve tez izleme sürecinde beni değerli yorumlarıyla yönlendiren, saygıdeğer hocalarım Prof. Dr. Rifat Edizkan ve Prof. Dr. Kemal Özkan'a teşekkürlerimi sunarım.

Proje döneminde Eskişehir Osmangazi Üniversitesi Akıllı Fabrika ve Robotik Laboratuvarı'nda beraber çalışma fırsatı bulduğum saygıdeğer hocalarım, Prof. Dr. İnci Sarıçiçek ve Prof. Dr. Abdurrahman Ünsal'a, çalışma arkadaşlarım sayın Metin Yılmaz, Özgür Gültekin, Eyüp Irgat ve Sena Kalay'a teşekkürlerimi sunarım.

2232 Uluslararası Lider Araştırmacılar Programı 118C252 no'lu proje kapsamında ve 2211/A Yurt İçi Genel Doktora Burs Programı kapsamında destekleri için TÜBİTAK'a teşekkürler.

Her zaman bana destek olan anneme, babama, kardeşlerime ve biricik sevgili oğlum Ali Erol Kasap'a sonsuz teşekkürler.

Aileme ve oğluma ithaf ediyorum iyi ki varsınız...

Mahmut Kasap

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	7
2.1. Arıza Tespit Çalışmaları	7
2.1.1. Rulmanlarda arıza tespit çalışmaları	7
2.1.2. Rüzgâr türbinlerinde arıza tespit çalışmaları	7
2.1.3. Güneş enerjisi sistemlerinde arıza tespit çalışmaları	8
2.1.4. Elektrik motorlarında arıza tespit çalışmaları	8
2.1.5. Kablosuz sensör ağlarında arıza tespit çalışmaları	9
2.1.6. Batarya sistemlerinde arıza tespit çalışmaları	10
2.1.7. Elektrikli araçlarda arıza tespit çalışmaları	12
2.2. Robot Arıza Tespit Çalışmaları	12
2.3. Pekiştirmeli Öğrenme Temelli Çalışmalar	16
2.3.1. Pekiştirmeli öğrenme (RL) ve Markov karar süreçleri (MDP) .	16
2.3.2. Pekiştirmeli öğrenme ile aykırılık ve arıza tespit çalışmaları .	19
3. MATERYAL VE YÖNTEM	23
3.1. Materyal	23
3.1.1. Otonom mobil robot (AMR)	23
3.1.2. Test ortamı ve test yatağı	25
3.1.3. Veri parametreleri	26
3.1.4. Durum izleme ve arıza tespit sistem mimarisi	29
3.2. Önerilen Yöntem Mimarisi	31

İÇİNDEKİLER

3.2.1. Önışlemler ve uzman davranışı edinme	33
3.2.2. Durum ve eylem	33
3.2.3. Ödül	35
3.2.4. Eğitim	36
3.2.5. Arıza tespiti için karar seviyesi füzyon	37
3.2.6. Yöntem bulgularında başarı değerdendirmesi ölçütleri	38
4. BULGULAR VE TARTIŞMA	39
4.1. Deney Senaryoları ve Test Verisi	39
4.2. Pekiştirmeli Öğrenme Tabanlı Aykırılık Tespitinde Karar Modeli Bulguları	41
4.3. Karar Seviyesi Füzyon ile Arıza Tespit Bulguları	49
5. SONUÇ VE ÖNERİLER	57
KAYNAKLAR DİZİNİ	59

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
1.1. Endüstri 4.0 ile ilişkili çeşitli teknolojiler	1
1.2. Bakım politikaları	2
1.3. PHM sistemlerinde veri aşamaları	3
1.4. Otonom mobil robotlarda aykırılık ve arıza ilişkisi (Chirayil Nandakumar vd., 2024)	5
1.5. Füzyon a) Sensör seviyesi b) Öznitelik seviyesi ve c) Karar seviyesi . . .	6
2.1. Genel motor sistem bileşenleri	8
2.2. WSN arıza taksonomisi (Muhammed ve Shaikh, 2017)	10
2.3. Lityum iyon batarya genel yapısı	11
2.4. Lityum iyon batarya arıza taksonomisi (Zou vd., 2023)	11
2.5. Robot arızaları ve arıza tespit yöntemleri sınıflandırması	13
2.6. MRS a) Hiyerarşik mimari b) Merkezi mimari ve c) Dağıtık mimari . . .	15
2.7. RL için ajan ortam etkileşimi	17
2.8. Robotlar için MARL uygulama alanları (Orr ve Dutta, 2023)	22
3.1. AMR	24
3.2. Farklı açılardan AMR boyutları	24
3.3. Harici sensörler	25
3.4. AMR harici sensör kutusu	25
3.5. AMR deney düzeneği ve laboratuvar test ortamı	26
3.6. AMR test yatağı	26
3.7. Sistem mimarisi	29
3.8. A3C mimarisi	31
3.9. Önerilen aktör kritik mimarisi	32
3.10. Uzman davranışı edinme	33
3.11. Yöntem çoklu robot mimarisi	36
3.12. Önerilen yöntem için eğitim süreci	37
3.13. Füzyon	37
4.1. Normal ve arızalı koşullar için örnek veri toplama ortamı	40
4.2. Önerilen yöntem a) Akım b) Ses ve c) Titreşim	41
4.3. DNN a) Akım b) Ses ve c) Titreşim	42
4.4. A2C a) Akım b) Ses ve c) Titreşim	42
4.5. A3C (TP=1 TN=1 FP=-1 FN=-1) a) Akım b) Ses ve c) Titreşim	43

ŞEKİLLER DİZİNİ

4.6. A3C (TP=5 TN=1 FP=-1 FN=-5) a) Akım b) Ses ve c) Titreşim	43
4.7. A3C (TP=1 TN=1 FP=0 FN=0) a) Akım b) Ses ve c) Titreşim	44
4.8. Logistic Regression a) Akım b) Ses ve c) Titreşim	44
4.9. Ridge Regression a) Akım b) Ses ve c) Titreşim	45
4.10. kNN a) Akım b) Ses ve c) Titreşim	45
4.11. Bagging a) Akım b) Ses ve c) Titreşim	46
4.12. Random Forest a) Akım b) Ses ve c) Titreşim	46
4.13. SVM a) Akım b) Ses ve c) Titreşim	47
4.14. 1-8. normal koşullar için sonuçlar	51
4.15. 9-16. normal koşullar sonuçlar	52
4.16. 1-8. arızalı koşullar için oy birliği füzyon sonuçları	53
4.17. 9-16. arızalı koşullar için oy birliği füzyon sonuçları	54
4.18. 1-8. arızalı koşullar için oy çokluğu füzyon sonuçları	55
4.19. 9-16. arızalı koşullar için oy çokluğu füzyon sonuçları	56

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
3.1. Öngörü ve sağlık yönetimi için veri parametreleri (Cheng vd., 2010) . . .	27
3.2. AMR sisteminden toplanan veriler	28
3.2. AMR sisteminden toplanan veriler (devamı)	29
3.3. Karmaşıklık matrisi	38
4.1. A3C, A2C ve DNN ortak eğitim parametre değerleri	41
4.2. Akım aykırılık tespit sonuçları	47
4.3. Ses aykırılık tespit sonuçları	48
4.4. Titreşim aykırılık tespit sonuçları	48
4.5. Sensör odaklı arıza tespit sonuçları	50
4.6. Füzyon odaklı arıza tespitinde oy birliği sonuçları	50

SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler</u>	<u>Açıklama</u>
S	Durumlar Kümesi
A	Eylemler Kümesi
$R(.)$	Ödül Fonksiyonu
$T(.)$	Geçiş Fonksiyonu
s	Durum
a	Eylem
π	Politika
$V(.)$	Değer Fonksiyonu
$P(.)$	Geçiş Olasılık Fonksiyonu
$Q(.)$	Q Değerleri
α	Öğrenme Katsayısı
γ	İndirim Faktörü
r	Ödül
$A(.)$	Avantaj Fonksiyonu
L	Kayıp
$H(.)$	Entropi
β	Entropi Etki Katsayısı
d	Normal Sınıf Üyelerinin Sayısı
y	Arızalı Sınıf Üyelerinin Sayısı
δc	Toplam Sınıf Üyelerinin Sayısı
m	Sınıf Oranı
τ	Oransal Ödül Katsayısı
μ	Ödül Fark Parametresi
ψ	Ödül Çarpan Parametresi
η	Ceza Fark Parametresi
ζ	Ceza Çarpan Parametresi

<u>Kısaltmalar</u>	<u>Açıklama</u>
A3C	Eşzamansız Avantaj Aktör Kritik (Asynchronous Advantage Actor-Critic)
AE	Otomatik Kodlayıcı (Auto-Encoder)

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
AGV	Otomatik Yönlendirmeli Araç (Automated Guided Vehicle)
AMR	Otonom Mobil Robot (Autonomous Mobile Robot)
ANN	Yapay Sinir Ağı (Artificial Neural Network)
BD	Büyük Veri (Big Data)
CBM	Durum Temelli Bakım (Condition Based Maintenance)
CC	Bulut Bilişim (Cloud Computing)
CISAR	Akıllı Sistemler Uygulama ve Araştırma Merkezi (Center of Intelligent Systems Applications Research)
CM	Durum İzlemesi (Condition Monitoring)
CNN	Evrişimli Sinir Ağı (Convolutional Neural Network)
CPS	Siber Fiziksel Sistem (Cyber-Physical System)
CUSUM	Kümülatif Toplam (Cumulative Sum)
DDPG	Derin Deterministik Politika Gradyan (Deep Deterministic Policy Gradient)
DDQN	Çift Derin Q-Ağı (Double Deep Q-Network)
Dec-POMDP	Dağıtık Kısmi Gözlemlenebilir Markov Karar Süreci (Decentralized Partially Observable Markov Decision Process)
DIH	Dijital İnovasyon Merkezi (Digital Innovation Hub)
DL	Derin Öğrenme (Deep Learning)

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
DNN	Derin Sinir Ağı (Deep Neural Network)
DQN	Derin Q-Ağı (Deep Q-Network)
DRL	Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning)
DT	Karar Ağaçları (Decision Tree)
DTW	Dinamik Zaman Bükme (Dynamic Time Warping)
ERT	Son Derece Rassal Ağaçlar (Extremely Randomized Trees)
EV	Elektrikli Araç (Electric Vehicle)
EWMA	Üstel Ağırlıklı Hareketli Ortalama (Exponentially Weighted Moving Average)
FIFO	İlk Giren, İlk Çıkar (First In, First Out)
FL	Federe Öğrenme (Federated Learning)
FN	Yanlış Negatif (False Negative)
FP	Yanlış Pozitif (False Positive)
FT	Fonksiyonel Ağaçlar (Functional Trees)
GAN	Üretken Çekişmeli Ağ (Generative Adversarial Network)
I4.0	Endüstri 4.0 (Industry 4.0)
IF	Akıllı Fabrika (Intelligent Factory)

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
IFARLAB	Akıllı Fabrika ve Robotik Laboratuvarı (Intelligent Factory and Robotics Laboratory)
IFRPR	Uluslararası Robotik Federasyonu Basın Odası (International Federation of Robotics Press Room)
IL	Taklit Öğrenme (Imitation Learning)
IoT	Nesnelerin İnterneti (Internet of Things)
IRL	Ters Pekiştirmeli Öğrenme (Inverse Reinforcement Learning)
kNN	K En Yakın Komşu (K-Nearest Neighbors)
LDA	Doğrusal Diskriminant Analizi (Linear Discriminant Analysis)
LIB	Lityum İyon Batarya (Lithium Ion Battery)
LSTM	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
MARL	Çok Ajanlı Pekiştirmeli Öğrenme (Multi-Agent Reinforcement Learning)
MDP	Markov Karar Süreçleri (Markov Decision Processes)
ML	Makine Öğrenmesi (Machine Learning)
MRS	Çoklu Robot Sistemleri (Multi-Robot Systems)
PCA	Temel Bileşen Analizi (Principal Component Analysis)
PdM	Kestirimci Bakım (Predictive Maintenance)
PG	Politika Gradyan (Policy Gradient)


SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
PHM	Öngörü ve Sağlık Yönetimi (Prognostics and Health Management)
POMDP	Kısmi Gözlemlenebilir Markov Karar Süreçleri (Partially Observable Markov Decision Process)
Res-CNN	Artık-Evrişimsel Sinir Ağı (Residual–Convolutional Neural Network)
RL	Pekiştirmeli Öğrenme (Reinforcement Learning)
RNN	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
ROS	Robot İşletim Sistemi (Robot Operating System)
SA	Sağkalım Analizi (Survival Analysis)
SAE DNN	Yığılmış Otokodlayıcı Derin Sinir Ağları (Stacked Autoencoder Deep Neural Network)
SARL	Tek Ajanlı Pekiştirmeli Öğrenme (Single-Agent Reinforcement Learning)
SRS	Sürü Robot Sistemleri (Swarm Robotic Systems)
SVM	Destek Vektör Makinesi (Support Vector Machine)
TD	Zamansal Fark (Temporal Difference)
TDNN	Zaman Gecikmeli Sinir Ağı (Time-Delay Neural Network)
TN	Doğru Negatif (True Negative)
TP	Doğru Pozitif (True Positive)
UGV	İnsansız Kara Araçları (Unmanned Ground Vehicle)
WSN	Kablosuz Sensör Ağı (Wireless Sensor Network)

1. GİRİŞ VE AMAÇ

Bu tez çalışmasında, akıllı fabrikalarda filo şeklinde çalışan otonom mobil robotların (AMR), öngörü ve sağlık yönetimi (PHM) için, pekiştirmeli öğrenme (RL) tabanlı çok ajanlı bir arıza tespit yöntemi önerilmektedir. Yöntem, yerel ajanda öğrenilen modellere ait parametrelerin küresel sistem ile ajanlar arası paylaşılması temelinde eğitilmektedir, model taklit öğrenme ile yerel ajanda farklı sensörler için aykırılık tespiti gerçekleştirir sonrasında karar seviyesi füzyonu ile arıza tespiti yapılmaktadır.


Üretimde geleneksel yaklaşımlar, günümüz yüksek rekabet ortamında artık yetersiz kalmaktadır. Yüksek maliyetlere karşı verimlilik için endüstri 4.0 (I4.0) ile siber fiziksel sistemler (CPS), nesnelerin interneti (IoT), bulut bilişim (CC) ve büyük veri (BD) benzeri çok sayıda önemli teknolojinin üretimde kullanılması önerilmektedir (Ryalat vd., 2023). Bu yeni yaklaşım ile amaç, üretimin, akıllı fabrikalarda insan müdahalesinden uzak gerçekleştirilmesidir (Erol vd., 2016). Şekil 1.1.'de bu amaçla kullanılan çeşitli teknolojiler görülmektedir. Bu teknolojiler içerisinde, AMR'ler en önemli aktörlerinden biridir. AMR'ler, fabrika içi lojistikte veya üretimle bütünleşmiş montaj hattında görev alabilirler (Zhao ve Chidambareswaran, 2023). AMR'lerin beklenmeyen arızaları üretimde yüksek maliyetli sonuçlar ortaya çıkarabilir (Kasap vd., 2023). Dahası bu arızalar ciddi kazalara neden olabilir. Bu sistemlerin uzun dönem sağlıklı çalışması için etkili arıza tespit mekanizmasının sağlanması gereklidir (Ozkan vd., 2010).



Şekil 1.1. Endüstri 4.0 ile ilişkili çeşitli teknolojiler

Etkili arıza tespit mekanizması bakım maliyetlerini ve riskleri azaltır. AMR'ler için verimli çalışma ve düşük risk, doğru bakım planlama ile mümkündür. Geleneksel yöntemler genellikle reaktif bakımı yani arıza sonrası bakımı önerir. Akıllı fabrikalar için arıza sonrası bakım oldukça riskli bir yaklaşımdır ve istenmeyen maliyetli sonuçlar doğurabilir. Arıza öncesi bakım


önleyici bakım ile yapılabilir fakat cihazın gerçek durumu değerlendirilmez ve bakım aralıkları optimize edilirken gereksiz maliyetler ortaya çıkabilir (Patil vd., 2022). Şekil 1.2.'de çeşitli bakım politikaları görülebilir. Cihazın gerçek durumuna odaklanan bakım stratejisi ise kestirimci bakım (PdM) stratejileri altında konumlanan durum temelli bakım (CBM)'dir. CBM ile bakım kararı cihazın sürekli izlenen gerçek durumuna göre verilir. CBM günümüzde, başarısızlık mekanizmaları ve yaşam döngüsü yönetimi çalışmalarını birbirine bağlayan daha üst bir bakışa sahip disiplin olan PHM haline gelmiştir (Hess vd., 2008; Javed vd., 2017; Uckun vd., 2008).



Şekil 1.2. Bakım politikaları

PHM sistemleri için veri toplama, analiz, sorgulama ve depolama gibi veri işleminin farklı aşamalarında büyük veri işleme hattına ihtiyaç vardır (Sahal vd., 2020). Şekil 1.3.'te PHM sistemlerinde veri aşamaları görülmektedir. PHM temelde makineler kurulu sensörler ve IoT aracılığıyla sistemlerin durum izlemesini (CM) içerir (Polverino vd., 2023). Hedef donanım türüne göre kamera, mesafe belirleme, titreşim, ses, akım, gerilim, basınç, ısı, nem ve benzeri farklı parametreler izlenebilir. İzlenen yoğun sensör verileri bant genişliği el verdiği sürece merkezi sistemlere aktarılabilir veya uç sistemlerde işleme tabi tutulabilir.

AMR'lerde merkezi sistemlere aktarım, tarihsel veri depolama ve genel model eğitiminde kullanma için faydalı bir tercihtir. Fakat AMR benzeri mobil cihazlar için güvenlik ve sistem sayısı arttıkça kısıtlı bant genişliğinin yoğun kullanımı riskini beraberinde getirir (H. Yang vd., 2021). Uç düğümlerin kullanımı bahsedilen bu risklere bir çözüm olarak sunulabilir (Z. Zhou vd., 2019). Bunun yanında merkezi sisteme veri aktarımı için geçen süre de arıza tespiti için



Şekil 1.3. PHM sistemlerinde veri aşamaları

kıymetlidir. Bir çalışmada tek bir robota ait sensörler için ham verinin merkezi sisteme aktarımı yerine, algoritma çıkarım sonucunun aktarımının bant genişliği kullanımını 43 kata kadar azalttığı, veri aktarımı için geçen sürenin ise bu sayede 37 kata kadar düştüğü tespit edilmiştir (Gültekin vd., 2022b). Bu durum, çoğunlukla filo halinde çalışan otonom robotlar için ölçeklendiğinde uç düğümlerin etkin kullanımı gerekir.


Uç düğümlerde normal çalışma durumundaki olağan dışı değişim, arıza belirtisi olabilir. Arızalar ise tamamen başarısızlığa neden olabilir. Bir cihazın kritik duruşlarını engellemek, sağlıklı ömrünü artırmak ve uygun bakım planlamak için bu aykırı durumların başarıyla belirlenmesi gerekir. Fakat arızalar nadir görülen durumlardır ve veri elde edilmesi zorlu bir süreçtir (Azzalini vd., 2020). Veriye dayalı metotların eğitimi için veri kümesinin çok sayıdaki sistemi temsil yeteneğine güvenilmektedir. Bu, özellikle tüm çalışma koşullarıyla birlikte uzun ve tutarlı veri kümelerinin genellikle mevcut olmadığı kritik sistemlerde PHM için bir zorluktur (Michau vd., 2018). Sadece uç sistemlerde yapılan durum izleme, belirsizlik ortamlarında benzer sistemlerin karşılaşılabileceği durumların birbirleri adına değerlendirilmesini ve genel bir model eğitimi engeller. Buna karşın çoklu sistemler için merkezi eğitim ve kontrol, gecikmelere neden olabilir bu tür sistemlerde küresel en uygun değer ve hızlı cevap arasında denge kurulmalıdır (Bahrpeyma ve Reichelt, 2022). Bu dengenin sağlanmasında, ham sensör verilerinin aktarımı yerine, çoklu ajanların kendi ortamlarından elde ettikleri çıkarımları aralarında paylaşmaları etkin olabilir. Bu şekilde bir yaklaşım durum uzayında küresel en iyiye ulaşma ihtimali artırılacaktır. Aynı zamanda model eğitimi için gerekli hesaplama yükü paylaştırılacaktır. Bunun yanında arıza tespit çıkarımları yerel ajan tarafında yapılacağı için cevap gecikmesi dezavantajı da ortadan kaldırılabilir.

AMR'ler için arıza tespit yaklaşımları, model tabanlı, bilgi temelli ve veriye dayalı yaklaşımlar olarak gruplanabilir (Khalastchi ve Kalech, 2018). Khalastchi ve Kalech'e (2018) göre model tabanlı yaklaşımlar dinamik ortamlar ve karmaşık robotik sistemler için model oluşturmaya gerektirir, bilgi temelli sistemler ise bilinmeyen arızaların tespitinde zorluklar içerir. Buna karşın veriye dayalı yaklaşımlar bu zorluklara çözüm sunarken çevrim içi ve hızlı arıza tespiti için zorluk yaşamaktadır (Khalastchi ve Kalech, 2018). Veriye dayalı yaklaşımlarda makine öğrenmesi (ML) teknikleri yardımıyla aykırılık ve arıza tespiti çok sayıda kullanım alanıyla önemli bir çıktıdır. ML temelde üç gruba ayrılır, bunlar; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme (RL)'dir. Denetimli öğrenme veri seti için çıktıya ihtiyaç duyarken, denetimsiz öğrenme veri içerisindeki gizli desenleri ve grupları bulmaya odaklanır. Buna karşın RL için ajan, bulunduğu ortam ile etkileşime girerek geri bildirimler üzerinden eğitilmektedir (Sutton ve Barto, 1998). Fakat karmaşık verilerde ve görevlerde, etkili sistem oluşturma süreci hala büyük ölçüde insan uzmanlığı gerektirir (Y. Li vd., 2022). Taklit öğrenme (IL) ise, bir ajanın, bir görevi, uzman öğretmeni gözlemleyerek başarması ve onun beceri veya davranışlarını kazanması anlamına gelir, taklit öğrenme bir uzmanın örnek gösterimlerin alınmasıyla başlar, sonrasında bu gösterimler durum eylem çiftleri olarak kodlanır ve eğitim için kullanılır (Hussein vd., 2017). RL uzman davranışlarının politika olarak öğrenilmesini sağlayan taklit öğrenme için etkili bir tekniktir.

RL, robotik ve video oyunlar gibi birçok alanda etkileyici performans sergilemiştir. Fakat insan başarısını geçen bu başarılar yüksek maliyetli hesaplamalar gerektirir. Akıllı fabrikaların dağıtık doğası ve çoklu karar verme bileşenlerinin varlığı nedeniyle, tek ajanlı pekiştirmeli öğrenme (SARL) yerine çok ajanlı pekiştirmeli öğrenme (MARL) benimsenebilir (Bahrpeyma ve Reichelt, 2022). Çok ajanlı öğrenmenin eşzamanlı gerçekleştirilmesi zorlu bir süreçtir. Fabrikalarda iletişim kopmaları gecikmeler ve beklenmeyen durumlar sıklıkla görülebilir. Modern eşzamanlı pekiştirmeli öğrenme algoritmalarında eğitim için tüm durum, eylem ve ödül bilgilerinin merkezi sistemlere aktarılması gerekir (Espeholt vd., 2018). Bant genişliği kullanımı kısıtlı ortamlar için yoğun veri gönderimi benimseyen yaklaşımlar yüksek maliyetlidir. Aynı zamanda eğitimin merkezi sistemde gerçekleşmesi, hem hesaplama işlem yükünü artırır hem de eğitim sonucunun ajana aktarımında yaşanan gecikme politikadan ayrılmaya neden olur. RL için eşzamansız eğitime uygun farklı yöntemler bulunmaktadır, eşzamansız avantaj aktör kritik (A3C) bu yöntemlerin en başarılılarından biridir (Mnih vd., 2016). A3C çok ajanlı sistemler için çoklu makinelerle ölçeklendirilebilir (Mehanna,

2019). Benzer yapıda algoritmalarla karşı A3C eşzamansız yapısı ve paralelleştirme ile doğrusal hızlanma sağlar (Shen vd., 2023).


Literatürde A3C ile aykırılık tespiti için bazı çalışmalar mevcuttur (Yu ve S. Sun, 2020; K. Zhou vd., 2021) fakat arıza ve aykırılık arasındaki ilişki farklı şekillerde değerlendirilmektedir. Aykırılık beklenen bir durumdan sapma olarak ifade edilebilir, arızalar ise başarısızlığa neden olabilen ve aykırı belirtiler gösterebilen durumlardır. Bilinen ve bilinmeyen tüm arızalar aykırı durum sebebi olabilir. Aykırılık ve arıza arasındaki ilişki Chirayil Nandakumar vd., (2024)'te açıklanmış ve Şekil 1.4.'teki sınıflandırma ile gösterilmiştir. Aykırılıklar AMR gibi dinamik ortamlarda çalışan karmaşık cihazlar için görevleri esnasında sıklıkla görülebilir. Aykırı durumların tamamı arıza ve başarısızlık nedeni olacak kadar tehlikeli değildir. Burada önemli olan ortaya çıkan aykırılığın bir arıza nedeniyle olup olmadığının tespit edilebilmesidir.



Şekil 1.4. Otonom mobil robotlarda aykırılık ve arıza ilişkisi (Chirayil Nandakumar vd., 2024)

Arıza tespit sistemleri sensör ölçümlerine ciddi anlamda duyarlıdır ve doğru girdiler ile hatasız kararlar oluşturabilir. Sensörler için mükemmel ayarlama ve ölçümleme yapılsa dahi tek bir sensöre dayanan arıza tespiti çeşitli riskler içermektedir. Bu riskler, AMR'nin dinamik çalışma ortamından veya doğrudan çalışma şeklinden ortaya çıkabilir. Örneğin sadece ses sensöründen gelen değerlerin arıza tespiti için kullanılması cihazın gürültülü ortamlardan geçişi esnasında yanlış alarmların verilmesine neden olabilir (Kasap vd., 2023). Sensör füzyonu bahsedilen bu risklere karşı kullanışlıdır. Füzyon üç farklı seviyede uygulanabilir bunlar; sensör seviyesi: farklı kaynaklardan elde edilen ham

verilerin tek bir vektör haline getirilmesi, öznitelik seviyesi: farklı kaynaklardan elde edilen öznitelik vektörlerinin birleştirilmesi, karar seviyesi: modellerin çıktılarının nihai bir karar olarak birleştirilmesi şeklinde özetlenebilir (Debie vd., 2021). Sensör seviyesi füzyon yaklaşımı gürültüye duyarlıdır ve sensör ayarlama ve ölçümleme ihtiyacı duyar, öznitelik seviyesinde füzyon için uygun özniteliklerin belirlenmesi zordur fakat karar seviyesi füzyonu sağlamlığı artırırken farklı türde bilgilerin birleştirilmesi için kullanışlıdır (Saeedi vd., 2014). Şekil 1.5.'te Füzyon seviyeleri görülmektedir.



Şekil 1.5. Füzyon a) Sensör seviyesi b) Öznitelik seviyesi ve c) Karar seviyesi

Çalışmada yukarıda bahsedilen isterler dikkate alınmış ve I4.0'da PHM sistemi olarak filo çalışan AMR'ler için eşzamansız eğitilen bir arıza tespit yöntemi önerilmiştir. Eşzamansız eğitim merkezi sisteme ham veri aktarımı yerine model parametrelerinin paylaşımı ile yürütülür. Bunun yanında model eğitiminde uzman davranışlarının taklit öğrenme ile anlaşılması sağlanmaktadır. Yöntem yerel ajanlarda arıza tespiti yaparken aykırılık tespiti sonuçlarına göre karar seviyesi füzyon kullanır. Elde edilen sonuçlar yöntemin aynı eğitim verisi ile eğitilen benzer sistemlere göre üstün olduğunu göstermektedir.

Tez raporu şu şekilde organize edilmiştir. İkinci bölümde tez çalışması ile ilgili literatür araştırması verilmektedir. Üçüncü bölümde önerilen yöntemin detayları açıklanmaktadır. Dördüncü bölümde önerilen yöntem ile elde edilen bulgular ve bu bulgular ile ilgili yorum ve öneriler verilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Literatür araştırması üç başlık halinde kurgulanmıştır. İlk bölüm çeşitli sistemler için arıza tespit çalışmalarını içermektedir. İkinci bölümde robotlar için yapılan arıza tespit çalışmaları incelenmiştir. Literatür araştırmasının son bölümünde RL ile yapılan aykırılık ve arıza tespit çalışmaları incelenmiştir.

2.1. Arıza Tespit Çalışmaları

Arıza tespiti için akıllı çözümler üretmek, araştırmacıların ilgisini çeken önemli bir konu başlığıdır. Yaygın olarak kullanılan rulmanlar, bataryalar ve çeşitli sensör sistemleri yanında, elektrik motorları, rüzgâr türbinleri, güneş enerjisi sistemleri ve elektrikli arabalar benzeri karmaşık cihazlar için çalışmalar yapılmaktadır. Literatür araştırmasının ilk kısmında bu bileşenler ve sistemler için yapılmış olan arıza tespit çalışmaları incelenmiştir.

2.1.1. Rulmanlarda arıza tespit çalışmaları

Rulmanlar dönüş hareketi sergileyen pek çok cihazın en temel bileşenidir. W. Huang ve G. Zhang'a (2023) göre, dönen makine arızalarının %30'u rulmanlar nedeniyle ortaya çıkmaktadır. Korozyon, aşınma, kırılmalar, ısınma ve yanlış hizalama, rulman arızalarının potansiyel nedenleridir. Bu deformasyonlar iç veya dış halkalarda, kafeslerde veya bilyelerde görülebilir. Rulman arıza tespiti için yaygın olarak, ML algoritmaları, yapay sinir ağları (ANN), evrişimli sinir ağları (CNN), derin sinir ağları (DNN), otomatik kodlayıcılar (AE) ve tekrarlayan sinir ağları (RNN) kullanılmaktadır. Rulman arıza tespiti için ayrıntılı bir literatür incelemesi Sahu vd., (2023)'te görülebilir.

2.1.2. Rüzgâr türbinlerinde arıza tespit çalışmaları


Rüzgâr türbinleri yenilenebilir, temiz enerji sağlamakta kullanılan önemli cihazlardır. Çoğunlukla zorlu koşullarda filo düzeninde birden çok sistem şeklinde çalışırlar. Bu sistemler için gerçek zamanlı durum izleme gereklidir. Makine öğrenimi teknikleri yaygın olarak rüzgâr türbini arızalarını tespit etmekte kullanılmaktadır. ML ve derin öğrenmeyi (DL) kullanarak rüzgâr türbini arızalarını tespit etmeye yönelik literatür çalışmaları, Khan ve Byun (2024) ve F. Zhang vd., (2023)'te görülebilir.

2.1.3. Güneş enerjisi sistemlerinde arıza tespit çalışmaları

Güneş enerjisi sistemleri, düşük maliyetli ve çevreci elektrik üretimi amacının önem kazanması nedeniyle giderek yaygınlaşmaktadır. Yüksek verimlilik ve öngörülebilirlik elde etmek için bu sistemlerin arızalarının tespit edilmesi gerekir. Bu sistemlerde diyotlar, gölgeleme, sıcak noktalar, açık/kısa devreler veya aşınma, arızalara neden olabilir. Arıza tespiti için model veya veriye dayalı yöntemler kullanılabilir. Veriye dayalı yöntemlerde üretken çekişmeli ağlar (GAN), uzun kısa süreli bellek (LSTM) ve CNN yaygın olarak uygulanan algoritmalar. Güneş enerjisi sistemleri için arıza tespit yöntemleri El-Banby vd., (2023) ve Osmani vd., (2023)'te özetlenmiştir.

2.1.4. Elektrik motorlarında arıza tespit çalışmaları

Elektrik motorları farklı endüstrilerde yaygın olarak kullanılmaktadır, sürüş ve hareket sağladıkları için hayati sistem bileşenleridir. Motor sistemleri, sürüş sistemi yanında güç elektroniği bileşenleri, kontrol ünitesi ve sensörler gibi bileşenleri içerir. Motor içyapısında rotora bağlı bir şaft bulunmaktadır. Bu şaft ve motor kasası arasında dönmeyi sağlayan rulman bulunur. Stator ise motor kasasına sabit bir vaziyettedir. Stator ve rotor arasında hava boşluğu vardır. Bu sistemler için arızalar üç grupta sınıflandırılabilir bunlar; elektriksel, mekanik ve sensör arızalarıdır (Bellini vd., 2008; X. Wang vd., 2019). Elektrik motorlarında en sık rastlanan arıza nedenleri, mekanik, elektriksel veya termal yüküdür (Moosavi vd., 2015). Genel olarak motor sistem bileşenleri Şekil 2.1.'de görülmektedir.



Şekil 2.1. Genel motor sistem bileşenleri

Motorlarda görülen mekanik arızalar çoğunlukla rulman, rotor veya statorda meydana gelir. Mekanik arızalar için çalışmalar Vaniya ve Chudasama (2023)'te incelenmiştir. Elektrik arızaları ise, motorda görülebileceği gibi motora bağlı sistem bileşenlerinde de kısa devre veya açık devre gibi nedenlerle ortaya çıkabilir. Sensör arızaları elektronik bileşen arızasıdır çalışma limit değerlerinin

dışına çıkılması, kötü ölçümleme ve çevre şartları gibi nedenlerle meydana gelebilir bu arızalar motor kontrolü için kritik bilgilerin doğru şekilde elde edilmesini engeller. Motorlarda elektrik ve sensör arızaları için X. Wang vd., (2019) incelenebilir. Elektrik motoru arızaları ısı oluşması, titreşim artışı, dengesiz çalışma, verim düşüşü benzeri aykırılıklar gösterir ve bunların erken tespiti I4.0 ve AMR'ler için oldukça önemli bir konu başlığıdır.


Elektrik motoru arızaları farklı veriler analiz edilerek tespit edilebilir. Yakhni vd., (2023), motor akım imza analizi ile arıza tespiti için çalışmaları incelemiştir. Titreşim analizi mekanik arızaları tespit etmek için etkin görülmektedir (Gundewar ve Kane, 2021). Bunun yanında ses ve akustik emisyon ile arıza tespiti de literatürdeki çalışmalar değerlendirildiğinde başarılı sonuçlar vermektedir (AlShorman vd., 2021). Motor arıza tespitinde voltaj, manyetik parametreler, hız, dönme kuvveti ve güç verileri de kullanılmaktadır.

Motor arıza tespit çalışmalarında kullanılan teknikler üç ana kategoride sınıflandırılabilir bunlar, istatistiksel yöntemler, ML tabanlı yöntemler ve DL tabanlı yöntemlerdir (Gultekin ve Bazzi, 2023). Das vd., (2023), rulman, dişli, rotor, stator, şaft vb. dönen makinelerin arıza tespitinde kullanılan makine öğrenimi teknikleri hakkında detaylı bir inceleme sunmuşlardır. Elektrik motorlarında arıza tespiti için son dönem yapılan literatür çalışmalarında da derin pekiştirmeli öğrenmenin (DRL) kabiliyetlerinin faydalı olacağı vurgulanmaktadır (Lang vd., 2022).

Motor arıza tespit çalışmalarının yanında elektrik motorları için CM çalışmaları da literatürde önemli yer tutmaktadır. Sinyal temelli CM otomasyonları ile elektrik motorları için elektrikselsel ve mekanik arıza tespit çalışmalarının incelendiği çeşitli çalışmalar mevcuttur (Gangsar ve Tiwari, 2020; Gundewar ve Kane, 2021).

2.1.5. Kablosuz sensör ağlarında arıza tespit çalışmaları

Mobil sistemlerin izlenebilmesinde kablosuz sensör ağları (WSN) gereklidir ve CM için bu sensörlerden elde edilen verilerin doğruluğunun büyük önemi vardır. WSN'lerdeki arızalar için detaylı bir literatür çalışmasında arızalar zaman aralığı ve konumuna göre sınıflandırılmış ve Şekil 2.2.'deki taksonomi ile gösterilmiştir (Muhammed ve Shaikh, 2017).



Şekil 2.2. WSN arıza taksonomisi (Muhammed ve Shaikh, 2017)


Muhammed ve Shaikh (2017)'de, veri merkezli arızalar açıklanmış olup, araştırmacılara göre fark arızası, beklenen sensör değerlerinde sabit farkla gerçekleşir ve kötü ölçümleme ile meydana gelebilir. Sabit bir değerle ölçüm değerinin toplanması ile modellenenir. Artış arızası ise algılanan veri değişim hızının beklenenden farklı olmasıdır. Sabit bir çarpanla normal ölçümün çarpılması ile modellenenir. Sıkışma arızaları, sensör verisinin sabit bir değerde kalmasıdır. Taşma arızaları verinin beklenen aralığın dışına çıkmasıdır. Sivrilme arızası sensörlerden ölçülen verilerin, beklenen ve kabul edilebilir değerlerden, değişim eğiliminin fazla olması durumudur. Veri kaybı aktarımda veya algılamada eksik veri anlamına gelmektedir. Füzyon arızaları ise füzyon kaynaklı arızalar olarak açıklanabilir.

WSN için arıza teşhisi merkezi olarak tüm düğümler için yapılabilir fakat bu ağdaki trafiği artırır, dağıtık yaklaşımlar ise düğümler arasında yapılır, merkezi ve dağıtık hibrit yaklaşımlar da kullanılmaktadır, arıza teşhisi çalışmalarında ise genellikle ML, komşu temelli yöntemler, istatistiksel ve oransal yöntemler kullanılmaktadır (Muhammed ve Shaikh, 2017).

2.1.6. Batarya sistemlerinde arıza tespit çalışmaları


Lityum iyon batarya (LIB) sistemleri AMR'ler gibi sistemlerde yüksek güç ve enerji yoğunlukları, uzun ömürleri ve hafif olmaları nedeniyle yaygın olarak tercih edilmektedir fakat tasarımları nedeniyle çok riskli bileşenlerdir (L.-S. Zhang vd., 2022; Zou vd., 2023). Dolayısıyla bu batarya sistemlerinin güvenli ve sağlıklı çalışması için doğru arıza tespit sistemleri önemlidir. Fiziksel hasar, aşırı şarj deşarj veya aşırı termal yük gibi uç kullanımlarda yüksek güvenlik riskleri ortaya çıkarabilirler. Bunun yanında performansları da ciddi düşüş gösterebilir. Lityum iyon bataryalar çok sayıda hücrenin seri ve/veya paralel birleştirilmesi ile farklı güç ihtiyaçlarını karşılayacak şekilde gruplanarak özelleştirilebilirler. Bu yaklaşım

bu sistemlerinin daha da karmaşık hale gelmesine neden olur (Zou vd., 2023). Şekil 2.3.'te lityum iyon batarya hücresinin genel yapısı görülmektedir.



Şekil 2.3. Lityum iyon batarya genel yapısı

Batarya sistemleri, şarj deşarj ve durum yönetim sistemleri, hücre grupları ve hücrelerden oluşur. Tüm bu sistemlerin temelinde bataryayı oluşturan materyal düzeyi bileşenlerin önemi büyüktür. Zou vd., (2023), detaylı literatür araştırmasında lityum iyon batarya arızalarını sistem ve hücre arızaları olarak sınıflandırılmış ve Şekil 2.4.'teki taksonomi ile göstermiştir.



Şekil 2.4. Lityum iyon batarya arıza taksonomisi (Zou vd., 2023)

Batarya arıza tespit çalışmalarında, laboratuvar ortamlarında materyal, hücre ve hücre gruplarından, AMR veya sabit sistemler benzeri gerçek sistemlerden veya benzetimlerden elde edilen veriler kullanılabilir. Farklı senaryolarda çeşitli yükler kullanılarak deşarj ve şarj senaryoları kurgulanmalıdır. Arıza tespit çalışmalarında akım, voltaj ve ısı parametreleri yaygın olarak kullanılmaktadır (Hu vd., 2020).

Lityum iyon bataryalarda arıza tespiti için Hu vd., (2020), tarafından yapılan detaylı bir literatür çalışmasında, model temelli, bilgi temelli ve veriye dayalı yöntemlerin kullanıldığı belirtilmiştir. Hu vd., (2020)'de yüksek hesaplama maliyetinin yapılan çalışmalarda uygulama için ciddi bir kısıtlama olduğu ve

füzyon yaklaşımı ile yüksek sağlamlık ve hassasiyet elde edildiği bunun yanında birçok çalışmada gürültünün dezavantaj yarattığı görülmektedir.

2.1.7. Elektrikli araçlarda arıza tespit çalışmaları


AMR sistemleri ele alındığında benzer bileşenlere sahip sistemler olarak Elektrikli Araçlar (EV) ön plana çıkmaktadır. EV'ler, elektrik motorları, motor kontrol üniteleri, sensör sistemleri ve batarya sistemleri içerir. EV'ler için bu bileşenlerde oluşabilecek arızaların nedenleri ve çeşitli arıza tespit çalışmaları Khaneghah vd., (2023)'te detaylı olarak incelenmiş ve çalışmalar model, sinyal ve veriye dayalı olarak sınıflandırılmıştır. Khaneghah vd., 'ne (2023) göre model temelli sistemler hızlı olsalar da iyi bir sistem modeline ihtiyaç duyarlar. Bu da karmaşık sistemler için önemli bir zorluktur. Sinyal temelli yaklaşımlar model kullanmaz bunun yerine sağlıklı duruma ait veriler ile arıza kontrolü yapılan veriler karşılaştırılır. Referans değer veya eşik karşılaştırması ile arıza tespiti yapılır. Fakat tespit hızı veya donanım maliyeti dezavantajı vardır. Veriye dayalı EV arıza tespiti için arızalı ve sağlıklı çalışma koşullarında yoğun veri toplanır. Sonrasında yapay zekâ yöntemleri ile bu veriler üzerinde öğrenme gerçekleştirilerek arıza tespiti yapılmaktadır.

2.2. Robot Arıza Tespit Çalışmaları

Küresel çapta kullanılan robotların sayısı 2024'te yaklaşık 3,9 milyona ulaşarak rekor kırmıştır (IFRPR, 2024). Otonomi gerektiren robotların kullanımının bu denli artması, bu cihazlar için akıllı arıza tespit yöntemlerinin önemini ortaya koymaktadır. AMR benzeri sistemlerin görevleri parçalar halinde ele alınmaktadır. Bu alt görev parçacıklarının ardışık gerçekleştirilmesi esnasında ortam sensörler ile algılanır, algılanan duruma uygun kararlar, akıllı algoritmalar ile belirlenir ve eyleyiciler yardımıyla gerçekleştirilir. Bu süreç döngüsel olarak tekrarlanmaktadır. Birçok alt sistemin etkileşim halinde yerine getirdiği bu görevler esnasında arızalar oluşabilir ve görev başarısızlığına neden olabilir.

Carlson ve Murphy, çalışmalarında insansız kara araçlarının (UGV'ler) sahada nasıl başarısız olduğuna dair kapsamlı bir analiz sunmuşlardır (Carlson ve Murphy, 2005). Carlson ve Murphy (2005)'te UGV arıza taksonomisi, etki, onarılabilirlik ve neden (fiziksel veya insan) olarak ifade edilmektedir. Steinbauer, RoboCup'ta kullanılan otonom robotların arızalarını incelemiştir (Steinbauer, 2013). Steinbauer (2013)'te robot arızalarının nedenleri donanım, yazılım, algoritma ve etkileşim şeklinde sınıflandırılmıştır. Literatürde robot arızalarının tespitinde

modeller, veriye dayalı yöntemler ve bilgi temelli yöntemlerin kullanılabileceği belirtilmiştir (Khalastchi ve Kalech, 2018; Pan vd., 2023). Model tabanlı ve bilgi temelli yöntemlerin dezavantajlarına karşı veriye dayalı yöntemler kullanışlıdır. Veriye dayalı yöntemlerde ise robot arıza tespiti için makine öğrenmesi uygulanabilir. Makine öğrenmesi yöntemleri, denetimli, denetimsiz ve pekiştirmeli öğrenme olarak sınıflandırılmaktadır. Robot arızaları ve arıza tespit yöntemlerinin genel bir sınıflandırması Şekil 2.5.'te görülebilir.



Şekil 2.5. Robot arızaları ve arıza tespit yöntemleri sınıflandırması


Literatürde robotlara yönelik veriye dayalı arıza tespitinde farklı yöntemler kullanılmıştır. Kalman ve parçacık filtreleri robot, sensör veya eyleyici arıza tespitinde sıklıkla kullanılmaktadır (Amoozgar vd., 2013; Roumeliotis vd., 1998; Y.-s. Sun vd., 2016; Van vd., 2018; Verma vd., 2004). Diğer taraftan robot arıza tespiti için literatürde derin öğrenme ve sinir ağlarına da rastlanmaktadır (Christensen vd., 2008; Gültekin vd., 2022a; Jäger vd., 2014; Van ve Kang, 2015). Christensen vd. çalışmalarında, otonom mobil robotlar için zaman gecikmeli sinir ağı (TDNN) ve arıza enjeksiyonu ile arıza tespiti önermişlerdir (Christensen vd., 2008). Jäger vd., (2014)'te sensör arıza tespitinde TDNN modeline giriş için, ortalama, standart sapma, sapma, sinyal-gürültü oranı, korelasyon katsayısı öz nitelikleri kullanılmıştır. Y. Oh vd., (2022)'de çok eksenli endüstriyel robotlarda dişli kutularının arıza tespiti için derin, transfer edilebilir ve harekete uyarlanabilir bir yöntem önerilmektedir. Y. Oh vd., çalışmalarında, artık evrişimsel sinir ağı (Res-CNN) modeli kullanmıştır ve Res-CNN modeli için iki boyut görüntü dönüştürme işlemi yerine az örnekleme hızına sahip dönme kuvveti sinyalleri için tek boyut Res-CNN mimarisi önermiştir (Y. Oh vd., 2022).

Bu yöntemlerin yanı sıra yarı denetimli (Hornung vd., 2014) ve denetimsiz öğrenme arıza tespit çalışmaları (Chen vd., 2020; Kasap vd., 2023; Khalastchi vd.,

2013; Khalastchi vd., 2015) görülebilir. Diğer yandan denetimsiz öğrenme ile arıza tespit başarısını artırmak için hibrit bir yöntem çalışması da yapılmıştır (Khalastchi vd., 2017). Literatürdeki bazı çalışmalarda makine öğrenmesi ile arıza tespiti için farklı yöntemler uygulanmıştır (Pinto ve Cerquitelli, 2019; Soualhi vd., 2020). Pinto ve Cerquitelli (2019)'da gerçek endüstriyel robot arıza tespiti için, son derece rassal ağaçlar (ERT), sağkalım analizi (SA), k en yakın komşu (kNN), CNN ve temel bileşen analizi (PCA) uygulanmıştır. Soualhi vd., (2020)'de ise kNN, destek vektör makinesi (SVM), doğrusal diskriminant analizi (LDA) ve fonksiyonel ağaçlar (FT) endüstriyel robot için sapma kaynağının tespitinde uygulanmıştır. Robot arıza tespiti için detaylı bir literatür araştırması Khalastchi ve Kalech (2018)'de görülebilir.

Çoklu robot sistemleri (MRS) ise tek bir amaç için birden fazla robotun ortak çalışmasını ifade eder. Diğer taraftan algı, planlama ve eylemin çok robota dağıtık olduğu sistemler şeklinde de özetlenebilir. MRS mimarileri, görev tahsisi, dağıtılmış kaynak paylaşımı ve yönetimi veya koordinasyon mekanizmalarına sahiptir. Yerel sistemlerin doğruluğu, küresel sistemlere bilgi aktarımı ve çoklu sistemler arası paylaşım ciddi anlamda mimariyi karmaşılaştırır. Burada küresel amaç için yerel kaynakların kullanımı söz konusudur. Ortak bir planlama için haberleşme ve koordinasyon mekanizması sağlanmalıdır. Fakat dinamik çalışma ortamı bu çalışma şekli için her zaman uygun değildir. MRS için arızalar uç sistemde olabileceği gibi haberleşme, planlama ve koordinasyon aşamalarında da ortaya çıkabilir. Güvenilir sistemler için bunun göz önünde bulundurulması gerekir. MRS sistemlerinde robotlar ortaklaşa takım şeklinde çalışarak birlikte sorun çözebilirler, ortak hedef için tekil hareket edebilirler veya her iki yaklaşımı da oransal olarak hibrit şekilde benimseyebilirler. Örneğin robotların ortam temizliği yapması veya ortam haritasını oluşturması takım sürü davranışıdır. Bir diğer örnek ise ortamda aranan bir hedefin bulunması için ortamın çok sayıda robot ile taranması da MRS çalışma şeklidir. MRS sistemlerinde kullanılan farklı mimari yapılar Şekil 2.6.'da görülebilir. Bu mimari topolojilerde arızalar, düğümlerde veya bağlantılarda gerçekleşebilir. Bu arızalar görev veya koordinasyon başarısızlıklarına neden olabilir.

MRS için plan arızalarının teşhisine yönelik bazı çalışmalar mevcuttur. Model tabanlı plan teşhis çalışmaları Roos ve Witteveen (2009) ve de Jonge vd., (2009)'da incelenmiştir. Roberto Micalizio (2009) otonom plan onarımında dağıtık bir yaklaşım önermiştir. MRS plan arızalarının tespitinde eşzamansız bir yöntem Roberto Micalizio ve Torasso (2014)'te görülebilir. İlgili çalışmada yöntemin eşzamansız olması, ajanların sonraki eylemi gerçekleştirebilmesi için tüm ajanların



Şekil 2.6. MRS a) Hiyerarşik mimari b) Merkezi mimari ve c) Dağıtık mimari

eylemleri ile eşzamanlı olmasına gerek olmadığı şeklinde vurgulanmıştır. Stancliff vd. plan arızalarının gerçekleşmesinden önce arızalı durumlar için ön planlama yapılması gerektiğini savunmuştur (Stancliff vd., 2009). MRS koordinasyon arızaları için yapılan çeşitli çalışmalar literatürde görülebilir. Çoklu ajan sistemlerin arıza tespitinde merkezi sistem kullanımı ile gerçekleştirilen model tabanlı çalışma R. Micalizio vd., (2004)'te görülebilir. Çoklu ajanlar için bir başka model tabanlı çalışma Roos vd., (2003), tarafından gerçekleştirilmiş olup, araştırmacılar çalışmalarında iletişim karmaşıklığını çözmek için her bir ajanın farklı bir alt sistemin teşhisinden sorumlu olduğu bir yöntem önermektedir. Çizgeye dayalı model tabanlı koordinasyon arızası tespiti için dağıtılmış bir yöntem çalışması Kalech vd., (2006)'da görülebilir, çalışmada testler simüle edilmiş ve gerçek Sony Aibo robotlar ile gerçekleştirilmiştir. MRS'lerde arıza tespiti için detaylı bir literatür çalışması Khalastchi ve Kalech (2019)'da görülebilir.

Literatürde karşılaşılan diğer bir kavram ise sürü robot sistemleridir (SRS). SRS kavramı, nispeten basit ve çoğunlukla aynı donanım yapısında çok sayıda robotun oluşturduğu ortak karmaşık görevler gerçekleştiren robotlar için kullanılmaktadır (Carminati vd., 2024; Hamann, 2018). SRS sistemlerinde arıza tespiti içsel, dışsal veya hibrit gerçekleştirilebilir. İçsel arıza tespiti robotun kendi arızalarını tespit etmesini ifade ederken dışsal arıza tespiti robotun diğer robotların arızalarını tespit etmesi anlamına gelir. SRS sistemlerinde model tabanlı veya veriye dayalı arıza tespiti yapılabilir. Model tabanlı dışsal SRS arıza tespit çalışması olarak Millard (2016) incelenebilir. Diğer yandan veriye dayalı çalışmalar da sürü robot sistemleri için uygulanmaktadır. Lau vd., (2011)'de içsel arızalar için istatistiksel arıza tespitine dayalı bir yöntem önerilmektedir. Khadidos vd., (2015)'te dışsal arıza tespiti için sürüdeki robotlar kendi sistemleri için topladıkları veriler ile diğer robotların topladığı verileri karşılaştırır tutarlılık durumu arızasız olarak belirlenir tutarsızlık durumunda başka bir robot tarafından değerlendirme

yapılır. Khaldi vd., (2017)'de sürü robotlarda veriye dayalı dışsal arıza tespit yöntemi olarak, PCA, üstel ağırlıklı hareketli ortalama (EWMA) ve kümülatif toplam (CUSUM) kontrol grafikleri önerilmektedir. Christensen vd., (2008)'de SRS için dışsal arıza tespit yöntemi önermektedir.

Filo sistemler ise özdeş çok sayıda sistemin bireysel amaç için çalıştığı sistemler olarak açıklanabilir, filo sistemler de sürü özellikleri sergileyebilir. Bu çalışma biçimine örnek olarak farklı rotalarda yük taşıyan özdeş AMR filoları verilebilir. Filo tabanlı operasyonlar günümüzün akıllı fabrikaları için vazgeçilmezdir. Deneyimlerin birden fazla temsilci arasında paylaşılması durum alanındaki başarıyı artırabilir. Son çalışmalar, otomatik yönlendirmeli araçlar (AGV'ler) tarafından kazanılan deneyimlerin paylaşılmasını içeren federe öğrenme (FL) yaklaşımıyla sinyal tahmininin geliştirilebileceğini göstermektedir (Shubyn vd., 2023).


Literatürde incelenen çalışmalar özgün değerlere sahip olsa da, robot arıza tespiti için veriye dayalı yöntemlerde makine öğrenmesi için genellikle SVM, karar ağaçları (DT) ve kNN kullanılmaktadır. Bunlar haricinde derin öğrenme çalışmalarında ise DNN, CNN, LSTM kullanımı görülmektedir. Fakat robotlar için arıza tespitinde RL uygulayan az sayıda çalışma bulunmaktadır. Sonraki bölümde RL temelli çalışmalar incelenmektedir.

2.3. Pekiştirmeli Öğrenme Temelli Çalışmalar

Bu bölümde RL ve RL temelli aykırılık ve arıza tespit çalışmaları iki başlık altında incelenecektir. İlk bölümde temel RL yaklaşımı ve ilgili önemli kavramlar özetlenmektedir. İkinci kısımda ise RL ile yapılmış aykırılık tespit çalışmaları incelenecektir.

2.3.1. Pekiştirmeli öğrenme (RL) ve Markov karar süreçleri (MDP)

Pekiştirmeli öğrenme ajanın ortamda eylemlerinin sonuçlarından elde ettiği dönütlere göre davranış geliştirdiği bir makine öğrenme tekniğidir. Her iyi eylem için ajan motive edici şekilde olumlu bildirim alırken kötü eylemler için ise ceza benzeri olumsuz geri bildirimler alarak davranış politikası oluşturulmaya çalışılır. Ajan çevre ile etkileşime girerek onu keşfeder. RL için detaylı kaynak olarak Kaelbling vd., (1996) ve Sutton ve Barto (1998) tercih edilebilir. Şekil 2.7.'de RL için ajan ortam etkileşimi görülmektedir.



Şekil 2.7. RL için ajan ortam etkileşimi

Ajan öğrenim sürecinde ortamı algılar, eylem yapar ve eyleme geri bildirimini değerlendirir. Burada ajan, çevreyi algılayan ve eylem yapabilen varlıktır. Çevre, ajan eylem gerçekleştirirken içinde bulunduğu ve etkileşime girdiği ortamdır. Eylem, ajanın problemi çözebilmek için gerçekleştirebileceği aktivitedir. Durum, çevrenin eylem esnasında bulunduğu haldir. Ödül, ortamdan ajana döndürülen geri bildirimdir. Politika ise ajanın mevcut duruma uygun seçeceği eylem stratejisidir.

RL metotları model tabanlı ve model bağımsız olarak sınıflandırılabilir, bu kategoriler içerisinde değer ve politika tabanlı RL metotları vardır (Arulkumaran vd., 2017; Hua vd., 2021).

- Model tabanlı RL, belirli bir ortam için sanal bir model oluşturur ajan bu sınırlamalara uygun çalışmayı öğrenir.
- Değer tabanlı RL, bir değer fonksiyonunu maksimize etmeye çalışır.
- Politika tabanlı RL, birikmiş ödülü en üst düzeye çıkaran bir politika veya deterministik strateji öğrenir.

RL ile eğitimde ajanın en uygun politikayı oluşturması için keşif ve ödül arasında uygun denge sağlanmalıdır (Ishii vd., 2002). Ajan anlık en iyi ödüle odaklanırsa yeni durumları keşfetme şansı kalmaz ve politika yerel en iyide takılabilir. Bu dengenin sağlanmasında amaç sadece anlık ödüle değil, eğitim süreci sonunda küresel en iyiye ulaşmaktır (M. Li vd., 2021). Buna, keşif-sömürü dengesi veya takası denilmektedir.

RL ajanlarının ortamları bir Markov karar süreci (MDP) olarak tanımlanmaktadır. Kısmen gözlemlenebilir ortamlarda tek ajanlı karar oluşturma, kısmi gözlemlenebilir Markov karar süreci (POMDP) olarak, dağıtık kısmi gözlemlenebilir Markov karar süreci (DEC-POMDP) ise çok ajanlı koordinasyon ile karar oluşturma modeli olarak ifade edilebilir (Bernstein vd., 2002).

SARSA ve Q-öğrenme MDP öğrenmede yaygın kullanılan RL algoritmalarıdır (Y.-H. Wang vd., 2013). Diğer yandan diğer bir RL algoritması olarak aktör kritik kullanımı da yaygındır (Grondman vd., 2012). Bellman denklemi (Bellman, 1957), RL kontrol uygulamalarında ayrık zaman eniyilemesinde yaygın olarak kullanılan dinamik programlama denklemidir (Y. Yang ve Whinston, 2023).

Ajan için mevcut olan tüm durum (S) ve eylem (A) bileşenleri için, ($R: S \times A \rightarrow \mathbb{R}$) ajanın S durumlarındaki bir s durumunda A eylemlerinden a eylemi için ödül fonksiyonunu göstermektedir. T bir geçiş fonksiyonudur. Deterministik bir ortam için ajanın eylemleri, ($T: S \times A \rightarrow S$) deterministiktir. Stokastik dünyada ise ajanın eylemleri olasılıksal ($T: S \times A \rightarrow \text{prob}(S)$) olabilir. Böyle bir ortamı modellemek için $\langle S, A, T, R \rangle$ çiftleri ile MDP kullanılabilir. Bu yaklaşımda amaç toplam ödülü maksimum seviyeye çıkaracak optimal bir politika ($\pi: S \rightarrow A$) oluşturmaktır. Anlık ödüllere gelecek ödüllerden daha fazla değer vermek için indirim katsayısı (γ) uygulanmaktadır. İndirimli ödüllerin toplamına değer (V) adı verilmektedir. Bir MDP çözümünde olası tüm durum dizilerinde beklenen değeri maksimuma çıkarmak için Denklem 2.1'de verilen Bellman denklemi kullanılmaktadır.

$$V(s) = R(s, a) + \gamma \max_{a' \in A} \sum_{s'} P(s' | s, a) V(s') \quad (2.1)$$

Denklemde $P(s' | s, a)$, s durumundan a eylemi ile s' durumuna geçişin olasılığıdır ve $R(s, a)$ ödül fonksiyonudur. Bir MDP çözmek için politika veya değer yineleme algoritmaları kullanılabilir.

Model bağımsız RL'de ajanın T ve R fonksiyonlarına erişimi yoktur. R ve T fonksiyonlarının bilinmediği durumlarda, ajanın, hangi durumda hangi eylemin faydalı olduğunu öğrenmesi için farklı eylemleri denemesi gerekir. Bu ajanın eylemine karşın ortamdan ödül sinyali aldığı bir yapı ile sağlanabilir. Ajan eylemleri deneyerek en uygun politikaya zamanla ulaşacaktır. Model tabanlı

RL'de, ajan, tahmini geiş ve ödöl fonksiyonlarını kullanarak deneysel bir MDP öęrenir. Bu fonksiyonlara yakınsama da ortam etkileşimi aracılığıyla gerçekleştirilir. Daha sonra, MDP modelini çözmek için deęer veya politika yineleme algoritması kullanılabilir.

Model bağımsız RL yöntemleri ajan eğitiminde R ve T fonksiyonlarına erişim olmayan gerçek dünya ve robotik uygulamalarında daha yaygın görölmektedir. Q-öęrenme popüler model bağımsız RL yöntemlerinden biridir. Bu teknikte (s, a) çifti için Q deęeri Denklem 2.2 ile belirlenir.

$$Q(s, a) = (1 - \alpha)Q(s, a) + \alpha \left(R(s, a) + \gamma \max_{a' \in A} Q(s', a') \right) \quad (2.2)$$

Bu denklemde α öęrenme katsayısıdır. Bu politika dışı bir öęrenmedir ve politika π^* Denklem 2.3 ile belirlenir.

$$\pi^*(s) = \arg \max_{a \in A} Q(s, a) \quad (2.3)$$

Tüm durum ve eylem çiftleri için Q deęerini tutmak sonsuz olasılıklı olabilen gerçek hayat problemlerinde uygun deęildir. Son yıllarda Q deęerlerinin tabloda tutulması yerine ANN kullanılarak başarılı çalışmalar gerçekleştirilmektedir. Bu yaklaşım DRL olarak adlandırılmaktadır.

2.3.2. Pekiştirmeli öęrenme ile aykırılık ve arıza tespit çalışmaları

Aykırılıklar temel olarak nokta, bağlamsal ve toplu aykırılıklar şeklinde üç grupta deęerlendirilebilir (Ahmed ve A. N. Mahmood, 2015). Nokta aykırılıklarda verinin geri kalanından sapan deęerler söz konusudur. Örnek olarak bir elektrik motorunun normal sabit hız ve yükte çalışması esnasında çektięi akım deęerinin anlık olarak artışı veya azalışı verilebilir. Bağlamsal aykırılıklarda ise bir bağlam için normal fakat başka bir bağlamda aykırı deęerler görölür. Burada örnek olarak kış mevsiminde mevsim normalinden yüksek çıkan sıcaklık deęeri verilebilir bu durum yaz aylarında normal olarak karşılanmaktadır (Audibert vd., 2022). Toplu aykırılıklar, tek tek deęerlendirildiğinde veri içerisinde normal kabul edilebilecek fakat toplu deęerlendirildiğinde aykırı deęerlerdir. Burada örnek olarak borsada bir şirketin hisse deęerlerinin uzun süre sabit kalması verilebilir. Aykırılık tespiti genellikle normal ve aykırı deęer olarak sınıflandırma problemleri şeklinde ele

alınmaktadır ve çeşitli teknikler uygulanmaktadır. Bu teknikler denetimli, yarı denetimli ve denetimsiz şeklinde sınıflandırılabilir (Dogan ve Birant, 2020). Denetimli öğrenme için eğitimde kullanılacak tüm verilerin etiketli olması gereklidir. Yarı denetimli öğrenmede eğitimde kullanılacak verilerin sadece bir kısmı etiketlenir. Denetimsiz öğrenme tekniklerinde ise etiketsiz verinin normal ve aykırı olarak iki sınıfa gruplanması amaçlanır. RL, çevre geri bildirimleri ile eğitilir, eğer eğitimde veri seti kullanılıyor ise denetimli öğrenmeye benzer bir yaklaşım söz konusudur. RL temelli aykırılık tespit çalışmalarına literatürde rastlanmaktadır. Bu bölümde ilgili çalışmalarda araştırma hedefleri ve kullanılan metotlar incelenmektedir.

Aykırılık tespitinde Q-öğrenme kullanılan çeşitli çalışmalar mevcuttur. İnsansız hava araçlarının aykırı motor ısısı durumunda ısı eşik değerine göre güvenli inişi için Q-öğrenme kullanılmıştır (Lu vd., 2018). Servin (2009)'da değiştirilmiş Q-öğrenme ile hiyerarşik çok ajanlı ağ saldırı tespit sistemi önerilmiştir. Çok ajanlı Q-öğrenme temelli başka bir çalışma aykırılıkları da dikkate alarak akıllı şebekelerde yük tahminine odaklanmıştır (Marinescu vd., 2017). Zaman serilerinde aykırılık tespitinde RNN ve Q-öğrenme öneren bir çalışma için C. Huang vd., (2018) görülebilir. D. Zhang vd., (2018), doğru akım motorlar için veri setindeki gürültülü sinyal oranını aza indirerek Q-öğrenme temelli bir arıza tespit yaklaşımı önermiştir. Zhong vd., (2019)'da bilinmeyen sayıda işlemin aynı anda normal veya aykırı durumlarda olabileceği aykırılık tespiti için ardışık testler yapılmıştır, çalışmada POMDP'ye dayalı sensör seçiminde güven düzeyini artırmak ve talep gecikmesini azaltmak amaçlı sinir ağları ve aktör kritik mimarisi kullanılmıştır. Ajanın davranışını tetikleyen fonksiyonu bulmaya yönelik RL için ters pekiştirmeli öğrenme (IRL) terimi kullanılmaktadır. Aykırılık tespiti için IRL önerilen bir çalışmada araştırmacılar ödül fonksiyonu olarak sinir ağı kullanmıştır (M.-h. Oh ve Iyengar, 2019). Wu ve Ortiz (2019)'da binalar için derin deterministik politika gradyan (DDPG) algoritması ile aykırılık tespiti yapılmıştır, çalışmada iki aktör ve iki kritik DNN modeli kullanılmıştır. Rulman ve hidrolik pompalara ait veri setlerinde arıza tespiti için DRL öneren başka bir çalışmada yığılmış otokodlayıcı derin sinir ağları (SAE DNN) kullanılmaktadır (Ding vd., 2019). Bir diğer çalışma zaman serisi verilerinde aykırılık tespiti için A3C temelli genel bir yöntem önermektedir, çalışmada aktör ve kritik için LSTM mimarisi ile sabit ödül mekanizması kullanılmıştır ve zaman serisi verileri çoklu iş parçacığı olarak değerlendirilmektedir (Yu ve S. Sun, 2020). Zha vd., (2020), uygun sorgu seçimine yönelik bir meta politika ile aykırılık tespiti için RL önermektedir, çalışmada yüksek yanlış alarm oranının aykırılık tespiti için önemli bir problem olduğuna vurgu yapılmıştır. Hsu ve Matsuoka (2020), ağ saldırı tespiti için DRL temelli bir


sistem önermektedir, çalışmada önerilen yöntem derin Q-öğrenme temelli modele dayanmaktadır ve başarı karşılaştırması için kesinlik, duyarlılık ve doğruluk metrikleri kullanılmıştır. Kardani-Moghaddam vd., (2021), bulut kaynaklarının dinamik olarak ölçeklendirilmesi için hibrit aykırılığa duyarlı derin Q-öğrenme önermiştir. K. Zhou vd., (2021), görüntü aykırılığı tespiti için CNN ve dikkat mekanizması içeren A3C temelli sabit ödül ile eğitilen bir yöntem önermektedir. Belhadi vd., (2021a), dağıtılmış heterojen enerji ortamındaki aykırılıkların tespiti için DRL temelli güvenlik odaklı bir yöntem önermiştir, çalışmada yerelde veri madenciliği ile tespit edilen aykırılık kalıpları ile küresel karmaşık aykırılık kalıplarının birleştirme işleminde güvenlik için blok zincir teknolojisi kullanılmıştır. Belhadi vd., (2021b), mikro servislerde arıza tespiti için çok ajanlı bir sistem önermektedir, çalışmada yerel ajanlarda sabit ödül ve RL ile öğrenilen aykırılık kalıpları, benzerlikleri ve kNN ile yoğunluklarına göre küresel aykırılık kalıbı olarak değerlendirilmektedir. Dang ve Vo (2021)'de saldırı tespiti için xgboost, derin Q-ağları (DQN), çift derin Q-ağları (DDQN), politika gradyan (PG) ve aktör kritik algoritmaları performans karşılaştırması için kullanmıştır. T. Mahmood vd., (2022), düşük uçtan uca gecikmeyle en uygun rotayı bulmak için Q-öğrenme temelli, akıllı arıza tespiti, enerji verimliliği ve hizmet kalitesi için yönlendirme tekniği önermektedir. H. Wang vd., (2022), dişli kutusu arızalarının tespiti için zaman-frekans gösterimi ve DRL temelli sabit ödül uygulanan bir yaklaşım önermektedir.

DRL temelli aykırılık tespit çalışmaları detaylı olarak Arshad vd., (2022)'de incelenmiştir, çalışmada DRL ile aykırılık tespitinin genellikle ağ trafiği ve ağ güvenliğine odaklandığı görülmektedir.

RL, robotlardaki farklı problemleri çözmek için sıklıkla kullanılır. Karada konuşlu robotlar için yönlendirme ve engellerden kaçınma, üretim, nesneleri alıp yerleştirme, kontrol, zekâ, tehlikelerden korunma, afet yönetimi, insan-robot etkileşimi, taklit öğrenme, kalabalık alanlardan güvenli geçiş, en uygun kontrol, görüntü temelli görevler ve bilişsel amaçlar için RL tabanlı çalışmalar bulunmaktadır (Singh vd., 2022). Bunun yanında RL, mobil robotlar için arızaya dayanıklı kontrol amacıyla kullanılabilir. Bu yaklaşım, cihazlarda arıza olsa bile en uygun kontrolün elde edilmesini sağlar. Bir çalışmada, mobil robotlar için arızaya dayanıklı haritasız bir hareket politikası açıklanmaktadır (Aznar vd., 2019). Robot kolları gibi sabit yer sistemleri için RL tabanlı bazı çalışmalar mevcuttur. Bir çalışma ile yazarlar, aktör kritik mekanizması ile RL'yi temel alan çok eklemli Baxter manipülatörü için uyarlanabilir ve arızaya dayanıklı bir kontrol tekniği önermiştir (Zhu vd., 2023). Son dönemde yapılan başka bir çalışmada, Q-öğrenme

ve robot dinamiği kullanılarak esnek üretim için robot manipülatörü eklem arızası tespit yöntemi önerilmiştir (S. Wang vd., 2024). Literatür incelendiğinde robotlar için RL temelli aykırılık ve arıza tespiti çalışmalarının az sayıda olduğu görülmektedir.

Tüm bunların yanında MARL mimarisi robotların çoklu çalışma düzeni için çok kullanışlıdır. Orr ve Dutta (2023), tarafından robotlar için MARL çalışmaları literatürde detaylı olarak incelenmiştir. İlgili çalışmada uygulama alanları incelendiğinde aykırılık ve arıza tespiti için çalışmaların kategorize edilmediği görülmektedir. Şekil 2.8.'de Orr ve Dutta'nın robotlar için MARL uygulama alanları sınıflandırması görülebilir.



Şekil 2.8. Robotlar için MARL uygulama alanları (Orr ve Dutta, 2023)

AMR'lerin arıza tespit probleminin önemi ve MARL uygulamalarının avantajlarının literatüre katkı sağlayacağı görülmektedir. Bunun yanında öngörü ve sağlık yönetimi mimarileri için eşzamansız yöntemlerin verimli kullanılması otonom sistemlerin sağlıklı ve uzun dönem kullanımı için faydalı olacaktır.

3. MATERYAL VE YÖNTEM

Veriye dayalı öngörü ve sağlık yönetimi için çeşitli aşamaların tamamlanması gereklidir. Bu aşamalar; veri toplama, ön işlemler, analiz ve model eğitimi, karar oluşturma, veri depolama, sorgulama ve görselleştirmedir. Bu bölümde tezimizde otonom mobil robotlar için öngörü ve sağlık yönetimi amacıyla yapılan çalışmalarda kullanılan materyaller ve önerilen yöntem iki bölüm halinde izah edilecektir.

3.1. Materyal

Çalışmalar Eskişehir Osmangazi Üniversitesi Akıllı Fabrika ve Robotik Laboratuvarı'nda (ESOGÜ - IFARLAB) yürütülmüştür. IFARLAB, ESOĞÜ kampüsünde Akıllı Sistemler Uygulama ve Araştırma Merkezi'nde (CISAR) yer almaktadır. IFARLAB'da otonom sistemler fabrika ortamlarında incelenebilmektedir. IFARLAB bir Dijital İnovasyon Merkezi (DIH) olarak dijital yetkinlik gelişimi ve teknoloji transferine katkı sağlamaktadır (IFARLAB, 2022). Bu ilk bölümde öngörü ve sağlık yönetimi sistemi için veri toplama, test sistemi ve test yatağının tasarımının yanında veri aktarım sistemi açıklanmıştır.

3.1.1. Otonom mobil robot (AMR)

Tez çalışmasında kullanılan otonom mobil robot (AMR), belirlenen konumlara otonom olarak yük taşıyabilmektedir. AMR sisteminde robot işletim sistemi (ROS) ve planlama algoritmaları kullanılmaktadır. ROS, robot uygulamaları için algoritmalar, kütüphaneler ve araçlar içeren açık kaynak kodlu bir platform sunmaktadır. AMR'nin farklı açılardan görünümü Şekil 3.1.'de görülmektedir. AMR, orta ölçekli bir otonom mobil robottur, 100 kg'a kadar ağırlık taşıma kapasitesine sahiptir. Robot üzerinde lazer tarayıcı, CANBUS haberleşme sistemi, konum hesaplamada kullanılan enkoderler ve motorlara ait sensör grupları mevcuttur. AMR, ROS Kinetic sürümü ile kontrol edilmektedir. Robotta diferansiyel tahrikli sürüş için hareket sağlayan iki adet tahrik tekerleği ve denge için ön ve arkada ikişer adet olmak üzere toplam dört adet sarhoş tekerlek bulunmaktadır. AMR görevleri uzak bilgisayardan başlatılabilir ve beklenmeyen tehlikeli durumlar için acil durdurma şalterleri bulunmaktadır. Aracın boyutları ve farklı açılardan ölçüleri Şekil 3.2.'de gösterilmektedir.



(a) Isı sensörü




(b) Ses sensörü



(c) Titreşim sensörü

Şekil 3.3. Harici sensörler

Veri toplama için kullanılan harici sensörlerin robotun sağ ve sol tahrik motorlarının üstüne montajı için Şekil 3.4.'te görülen sensör kutusu kullanılmıştır.




Şekil 3.4. AMR harici sensör kutusu

3.1.2. Test ortamı ve test yatağı

AMR test sistemi, aracın büyük fabrika ortamlarında karşılaşılabileceği durumları benzetmek için test yatağı, daha gerçekçi konumlandırma ölçümleri ve fabrika benzetimi amaçlı test laboratuvar ortamı ile tüm deneylerin gerçekleştirilmesine ve görselleştirilmesine olanak sağlayan yazılımları içerir. Şekil 3.5.'te deney düzeneği ve laboratuvar test ortamı görülmektedir. Şekil 3.6.'da AMR test yatağı görülmektedir.



Şekil 3.5. AMR deney düzeneği ve laboratuvar test ortamı



Şekil 3.6. AMR test yatağı

3.1.3. Veri parametreleri

Öngörü ve sağlık yönetimi için sistemlerde farklı veri parametreleri incelenebilir. Sistemlerin farklı doğaları nedeniyle bu parametreleri standart olarak belirlemek mümkün değildir. İzlenecek sistemin mimarisinin yanında arıza türlerine göre de veri parametreleri farklılık gösterebilir. Literatürde öngörü ve sağlık yönetimi amaçlı kullanılabilecek veri parametrelerinin incelendiği çalışmalar mevcuttur. Çizelge 3.1.'de Cheng ve arkadaşlarının özetlediği veri parametreleri görülmektedir (Cheng vd., 2010).

Çizelge 3.1. Öngörü ve sağlık yönetimi için veri parametreleri (Cheng vd., 2010)

Kategori	Parametreler
Mekanik	Uzunluk, alan, hacim, hız veya ivme, kütle akışı, kuvvet, tork, stres, şok, titreşim, zorlanma, yoğunluk, sertlik, mukavemet, açısal, yön, basınç, akustik yoğunluk veya güç, akustik spektral dağılım
Elektrik	Gerilim, akım, direnç, endüktans, kapasitans, dielektrik sabiti, yük, polarizasyon, elektrik alanı, frekans, güç, gürültü seviyesi, empedans
Isı	Sıcaklık (aralıklar, çevrimler, eğim, artış oranları), ısı akımı, ısı dağılımı
Kimyasal	Kimyasal, tür yoğunlaşması, eğim, tepkime, karışıklık, moleküler ağırlık
Nem	Bağıl nem, mutlak nem
Biyolojik	pH, biyolojik moleküllerin yoğunluğu, mikroorganizmalar
Elektromanyetik radyasyon ve iyonize radyasyon	Yoğunluk, faz, dalga boyu (frekans), polarizasyon, yansıtma, geçirgenlik, kırılma indisi, mesafe, maruz kalma dozu, doz oranı
Manyetik	Manyetik alan, akı yoğunluğu, geçirgenlik, yön, mesafe, konum, akış

Bu parametrelerin yanında I4.0'da kullanılan CPS'ler için yazılım da bir kategori olarak düşünülebilir. Yazılımlar için girdi parametreleri, dönüş değerleri ve algoritmalar da izlenebilecek veri parametreleri olarak kabul edilebilir.

Donanım arızaları mekanik bileşenlerin yanında, haberleşme sistemleri, eyleyiciler, sensörler, güç sistemleri, elektronik bileşenler nedeniyle ortaya çıkabilir. Yazılım arızaları ise programlamadan veya algoritmadan kaynaklanabilir. Yazılım arızaları, hatalı kararlara, davranışsal bozukluklara, zamanlama, algılama ve eyleme hatalarına neden olabilir. Bunun yanında AMR benzeri robotik sistemler akıllı fabrikalar gibi dinamik ortamlarda insanlarla ve diğer cihaz ve robotlarla etkileşim halinde çalışır. Etkileşim arızaları tüm bu aktörlerin ortak çalışmaları esnasında çok farklı şekillerde ortaya çıkabilir. Mekanik, ısı, ses ve elektrik parametrelerinin yanında konum verileri de AMR arızaları için takip edilebilir. Tez çalışması için AMR'den Çizelge 3.2.'de belirtilen veriler toplanmıştır.

Çizelge 3.2. AMR sisteminden toplanan veriler

Veri	Tanım	Açıklama	Frekans
Zaman	Sistem çalışma zamanı gün-ay-yıl_saat-dakika-saniye-mili saniye şeklindedir.	Tüm veri istenilen frekansta eşzamanlı olarak bu zaman damgasına göre alınmaktadır.	100 Hz
Teker hızı (m/s)	Sağ ve sol tekerlerin yarıçap/saniye biriminde dönüş hızlarıdır.	Enkoderlerden alınan değerler ile hesaplanmaktadır.	100 Hz
Motor Akımı (A)	Anlık motorların çektiği akım değeridir ve amper biriminde elde edilir.	Motor sürüş sisteminden elde edilmektedir.	100 Hz
Güç (W)	Her bir motor için anlık güç tüketimidir watt biriminde elde edilir.	Motor sürüş sisteminden elde edilmektedir.	100 Hz
Voltaj (V)	Her bir motor için anlık voltaj değeridir volt biriminde elde edilir.	Motor sürüş sisteminden elde edilmektedir.	100 Hz
Robot Baş Açısı	ROS değeridir	Mevcut konumlandırma sistemleri tarafından hesaplanan konum bilgisi robot odometri mesajlarından elde edilmektedir.	100 Hz
Pozisyon (x ve y) (mm)	Robot konumu (bu bilgi yer testlerinde kullanılmaktadır.)	Motor enkoderlerinden düzenleme yapılmadan, gerçek ortamdaki SLAM bilgilerinden ise düzeltmeli olarak alınır.	100 Hz
Isı (°C)	Motorların dış yüzey sıcaklıkları ve ortam sıcaklığı	Motor ısısı motorun üst kısmından ölçülmektedir.	100 Hz


(Çizelge devam ediyor.)

Çizelge 3.2. AMR sisteminden toplanan veriler (devamı)

Veri	Tanım	Açıklama	Frekans
Ses (dB)	Her tekerlek motor Grubu için anlık ses bilgisi.	Her genel örnekleme frekansında 16500 ses seviyesi bilgisi alınır.	16500 Hz
3 eksen titreşim (m/s ²)	Her bir tekerlek motor Grubu için	Her genel örnekleme frekansında 1200 titreşim seviyesi bilgisi bir frekansta alınır.	1200 Hz

3.1.4. Durum izleme ve arıza tespit sistem mimarisi

Öngörü ve sağlık yönetimi için gerçek zamanlı durum izleme ve arıza tespit mimarisi Şekil 3.7.'de görülmektedir. Bu başlıkta mimaride kullanılan teknolojiler özetlenmektedir.



Şekil 3.7. Sistem mimarisi

AMR'de uç sistem hesaplama bileşeni olarak NVIDIA Jetson TX2 kullanılmaktadır. Bu donanım hızlı, güç kullanımında verimli yerleşik yapay zekâ bilgi işlem cihazıdır, üzerinde 7,5 watt tüketimi olan süper bilgisayar bulunur, 256 çekirdek NVIDIA Pascal ailesi GPU üzerine kurulu mimarisi vardır ve 8 GB 128-bit LPDDR4 bellek ve 59,7 GB/s bellek bant genişliğine sahiptir (NVIDIA, 2024). Merkezi sistemde ise Ubuntu 20.04 işletim sistemi kuruludur, donanım olarak 40 çekirdekli iki Intel Xeon Gold 5218R CPU ve 64 GB DDR4 RAM bulunmaktadır.

AMR üzerinde kurulu sistemde, Robot İşletim Sistemi (ROS) bulunmaktadır. ROS robot uygulamaları için yazılım kitaplıkları ve çeşitli araçlar içermektedir. ROS donanımlar için sürücüler, çeşitli algoritmalar ve geliştirici

araçları da sağlamaktadır ve açık kaynaklıdır (OpenRobotics, 2024). Bunun yanında haberleşme, algılama, görselleştirme, hareket planlama, benzetim, kayıt tutma, makine öğrenmesi, bilgisayar görüşü gibi robotik konusunda kullanımı yaygın işlemler için detaylı çözümler içermektedir.

Bağlam yöneticisi olarak Fiware Orion Context Broker kullanılmıştır. Orion Context Broker güncellemeler, sorgular, kayıtlar ve abonelikler için bağlam bilgilerinin yaşam döngüsü yönetiminde kullanılır ve bir NGSIv2 sunucu uygulamasıdır (Fiware, 2024b). FIROS, bulut robot arası iki yönlü çevirmenlik yapar, robot verilerini yayınlama ve dinleme amacıyla ROS ve FIWARE Context Broker kullanır (Fiware, 2024a).

Elastic Stack (ELK Stack), Elasticsearch, Logstash ve Kibana adında üç popüler projeden oluşan bir yapıyı tanımlamak için kullanılan bir kısaltmadır. Elasticsearch, dağıtılmış, RESTful arama ve analiz motorudur, analiz için verileri merkezi olarak depolar (Elasticsearch, 2024c). Logstash, format veya şemadan bağımsız olarak tüm verileri toplama, birleştirme gibi işlemler için Elastic Stack'de kullanılan veri akışı motorudur (Elasticsearch, 2024b). Kibana, Elastic Stack ve Elastic Search için kullanıcı arayüzüdür. Kibana ile veriler görselleştirilebilir bunun yanında Elastic Stack yönetimi ve izleme işlemleri yapılabilir (Elasticsearch, 2024a).


AMR'ler için uzman verilerini kalıcı olarak depolama amaçlı veritabanı sistemi olarak PostgreSQL kullanılmaktadır. PostgreSQL, açık kaynaklı ilişkisel veritabanı sistemidir, sorgulama için SQL dili kullanılmaktadır ve farklı işletim sistemlerinde çalışabilir (PostgreSQL, 2024).

Apache Spark, büyük ölçekli veri işlemeye yönelik birleşik bir analiz motorudur, Java, Scala, Python ve R'de üst düzey uygulama geliştirme arayüzü (API) sağlar, ayrıca SQL için Spark SQL, pandas ile işlemler için Spark üzerinde pandas API, makine öğrenimi için MLlib, grafik işleme için GraphX gibi çok sayıda araç içermektedir (Apache, 2024). Küresel ağ ve eğitim için gerekli parametrelerin çoklu ajan arasında paylaşımı amacıyla kullanılmaktadır.

Grafana farklı kaynaklarda bulunan veriler için görselleştirme araçları sağlamaktadır, Grafana ile kontrol panelleri ve alarmlar oluşturulabilmektedir (Grafana, 2024). AMR arıza ve aykırılık durumlarını görselleştirmek ve alarm oluşturmak için Grafana kullanılmaktadır.

3.2. Önerilen Yöntem Mimarisi

Önerilen yaklaşım eşzamansız avantaj aktör kritik (A3C) algoritmasına dayanmaktadır (Mnih vd., 2016). A3C, birden fazla paralel modelin etkili şekilde eğitime imkan veren mimari sunmaktadır. Küresel ağ, çalışanlar için model parametrelerinin merkezi olarak paylaşılmasını sağlar. Şekil 3.8.'de genel A3C mimarisi görülmektedir.



Şekil 3.8. A3C mimarisi

Bu çalışmada kullanılan mimaride, aktör (politika) $\pi(a_t | s_t; \theta)$ modeli softmax ile eylem çıktısı, değer (kritik) $V(s_t; \theta_v)$ modeli ise durum için linear değer çıktısı üretir. Terminal durum veya t_{max} adımda hem aktör hem kritik modeli güncellenir. Modeller için parametreler θ ile gösterilmektedir. A3C için formal tanım Mnih vd., (2016)'da verilmiştir. Buna göre indirimli ödüller Denklem 3.1'de verilmektedir.

$$R_t = \sum_{i=0}^{k-1} \gamma^i r_{t+i} + \gamma^k V(s_{t+k}; \theta_v) \quad (3.1)$$

Bu denklemde γ indirim faktörü ve r ödülü ifade eder, k değeri t_{max} içerisinde değişebilir. s_t durumunda a_t eylemi için avantaj tanımı Denklem 3.2'de verilmiştir.

$$A(s_t, a_t; \theta, \theta_v) = R_t - V(s_t; \theta_v) \quad (3.2)$$

Değer kaybı ve Entropi düzenlemesi ile birlikte politika kaybı sırasıyla Denklem 3.3 ve 3.4'te verilmiştir.


$$L_v = (A(s_t, a_t; \theta, \theta_v))^2 \quad (3.3)$$

$$L_\pi = \log \pi(a_t | s_t; \theta') (R_t - V(s_t; \theta_v)) + \beta H(\pi(s_t; \theta')) \quad (3.4)$$

Denklemde β Entropi etki katsayısıdır. Toplam model kaybı Denklem 3.5'te verilmektedir.

$$L_M = \frac{1}{2} L_v + L_\pi \quad (3.5)$$

Önerilen aktör kritik modelinde, durum girdisi için 14 düğüm, ReLU aktivasyon fonksiyonu ile bağlı 3 gizli katmanın her birinde 100 düğüm, çıktı katmanında ise aktör için 2 düğüm kritik için ise tek düğüm bulunmaktadır. Önerilen model için ayrıntılı aktör kritik mimarisi Şekil 3.9.'da gösterilmektedir.



Şekil 3.9. Önerilen aktör kritik mimarisi


Yöntem ile arıza tespiti öncesinde veri için ön işlemlerin yapılması gerekmektedir. Sonrasında ajan için ortam oluşturulur ve ajan ortamdan bir durum için politikaya uygun eylem seçimi yapar ve RL algoritması ile eylemin değeri

değerlendirilir ve kayıp hesabı yapılarak parametre güncellemeleri sağlanır. Bu aşamalar detaylı olarak açıklanmaktadır.

3.2.1. Önişlemler ve uzman davranışı edinme

Çalışmada uzman davranışı edinme ve veri önişleme Şekil 3.10.'da gösterilmiştir ve aşağıda verilen önişlemler yapılmıştır.

- Robot verisi için akım (100 Hz) titreşim ortalama (1200 Hz->12 örnek için) ve ses ortalama (16500 Hz->165 örnek için) değerleri eğitim ve test için seçilmiştir.
- Veri test alanından elde edilen değerlerin alınması için konum bilgisine göre 2 ve 5 metre aralığında filtrelenmiştir.
- Filtrelenen veri eşit uzunlukta dosyalar elde edilmesi amacıyla her bir koşu için 700 örnek olacak şekilde sondan budanmıştır.
- Veri üzerinde engel noktalarına denk gelen bölgeler için uzman tarafından manuel etiketleme yapılmıştır. Bu yaklaşım taklit öğrenme amacıyla uygulanmaktadır.
- Veri, her biri 50 örnek içeren ve kesişmeyen ardışık pencerelere bölünmüştür. Bu pencerelerde 10 adetten fazla örnek aykırılık etiketine sahip ise pencere özniteliği aykırı olarak etiketlenmiştir.



Şekil 3.10. Uzman davranışı edinme

3.2.2. Durum ve eylem

Zaman serisi veriler için arıza tespitinde kullanılabilecek farklı öznitelikler bulunmaktadır. Motor arıza tespiti için yapılan önceki çalışmada kullanılan ve aşağıda listelenen 14 öznitelik (Denklem 3.6-3.19) çalışmada kullanılmıştır (Kasap vd., 2021). Pencere örnek sayısı N , zaman serisi örneği ise x ile gösterilmektedir. Bu

öznitelikler, önişlemlerde elde edilen her pencere için hesaplanarak ajanın durum bilgisini (s_t) oluşturmak için kullanılmaktadır. Her durum için atanan etiket doğru eylemdir (a_t). Aykırı durum için 1, normal durum için 0 kullanılmıştır.

$$\text{Kare ortalama karekök} = \sqrt{\frac{\sum_{n=1}^N x_n^2}{N}} \quad (3.6)$$

$$\text{Mutlak maksimum} = \max |x_n| \quad (3.7)$$

$$\text{Çarpıklık} = \frac{\sum_{n=1}^N (x_n - \text{Ortalama})^3}{(N - 1)(\text{Standart sapma})^3} \quad (3.8)$$

$$\text{Basıklık} = \frac{\sum_{n=1}^N (x_n - \text{Ortalama})^4}{(N - 1)(\text{Standart sapma})^4} \quad (3.9)$$

$$\text{Tepe faktörü} = \frac{\text{Mutlak maksimum}}{\text{Kare ortalama karekök}} \quad (3.10)$$

$$\text{Dürtü faktörü} = \frac{\text{Mutlak maksimum}}{\frac{1}{N} \sum_{n=1}^N |x_n|} \quad (3.11)$$

$$\text{Maksimum} = \max(x_n) \quad (3.12)$$

$$\text{Minimum} = \min(x_n) \quad (3.13)$$

$$\text{Tepeden tepeye} = \max(x_n) - \min(x_n) \quad (3.14)$$

$$\text{Ortalama} = \frac{\sum_{n=1}^N x_n}{N} \quad (3.15)$$

$$\text{Medyan} = \frac{x\left(\frac{N}{2}\right)^{nth} + x\left(\frac{N+1}{2}\right)^{nth}}{2} \quad (3.16)$$

$$\text{Varyans} = \frac{\sum_{n=1}^N (x_n - \text{Ortalama})^2}{N - 1} \quad (3.17)$$

$$\text{Mutlak ortalama} = \frac{\sum_{n=1}^N |x_n|}{N} \quad (3.18)$$

$$\text{Standart sapma} = \sqrt{\frac{\sum_{n=1}^N (x_n - \text{Ortalama})^2}{N - 1}} \quad (3.19)$$

Her ajan, ortam bilgisi olarak eşit sayıda eğitim verisi almaktadır. Ajan, ortamından rastgele seçilen bir durum ile eğitime başlar. Her eğitim bölümünün sonunda, durum ajanın eğitim ortamından rastgele olacak şekilde değişir.

3.2.3. Ödül

RL'de ödül (veya ceza) mekanizması, ajanın eylem seçimi konusundaki motivasyonunu belirler. Eyleme karşılık gelen ödül, avantaj ve kayıp hesaplaması için kullanılmaktadır. Arızalar ise nadiren meydana gelir. Ajanın, keşif sömürü dengesini sağlarken bu nadir durumlara doğru eylemle yanıt vermesi daha önemli olmalıdır. Literatürde zaman serisi aykırılık tespiti için sıklıkla sabit ödüller önerilmektedir. Çalışmamızda eşzamansız çalışan çok ajanlı sistemler için çevrimiçi dengeli ve parametrik ödül yaklaşımı öneriyoruz. Bu yaklaşım, bilinmeyen ortamlardan kaynaklanan dengesizlik durumunda ajanların motivasyonunun ne zaman artması gerektiğini dengelemeyi amaçlamaktadır.

Adım t 'deki aykırı sınıf üyelerinin sayısı y ile gösterilmektedir. t adımındaki normal sınıf üyelerinin sayısı ise d ile gösterilmiştir. δ_c , t adımındaki tüm sınıf üyelerinin toplam sayısını ifade eder. t adımındaki a eylemi a_t ile gösterilmiştir, son durum için ödül 0 olarak belirlenmiştir ve r ödül işlevi için tanım şu şekildedir;


$$m = \frac{1}{\delta_c} \quad (3.20)$$

$$\tau = \begin{cases} ym & \text{eğer } a_t = d \\ dm & \text{eğer } a_t = y \end{cases} \quad (3.21)$$


Dinamik zaman bükme (DTW) zaman serisi verilerinde uzaklık hesaplama için kullanılan bir algoritmadır (Berndt ve Clifford, 1994). DTW çalışmada uzman davranışının benzer durumda nasıl olduğunun bulunması amacıyla kullanılmıştır. AMR'nin karşılaştığı duruma en yakın durumun bulunması için uzman verilerinde durum bilgisi için elde edilen 14 öznitelik için DTW mesafesi minimum olan durum bulunur ve uzman eylemi bu durum için belirlenir. Eğer AMR eylemi benzer durum için uzman eylemine uygunsa ödül için, $r = \mu + \psi\tau$ uygulanır, eğer AMR eylemi uzman eylemine uygun değilse ödül $r = -\eta - \zeta\tau$ şeklinde belirlenir.

3.2.4. Eğitim

Uzman verileri, küresel sınıf sayıları, küresel model ağırlıkları eğitim başında merkezi sistemden AMR'ye aktarılır. Eğitim başında tüm AMR çalışanları küresel ağ ağırlıkları ile yerel modelini günceller. AMR çalışanı konuma göre belirlenen test alanı geçişinde t_{max} adım durum bilgisi için eylem gerçekleştirir. Her adım için karşılaşılan uzman davranışı sınıfı yerel sayaç ile tutulur. Her eylem için küresel ve yerel toplam sınıf oranları, uzman davranışlarına uygunluk ile ödül elde edilir. Aktör kritik ağ çıktıları ve ödül bilgisi ile avantaj ve kayıp hesapları gerçekleştirilerek yerel çalışan gradyanları küresel ağ güncellemesi için, yerel sınıf sayıları da küresel sayaç güncellemesi için merkezi sisteme aktarılır. Güncellenen küresel ağ ağırlıkları ve sınıf sayıları AMR çalışanına ilk giren, ilk çıkar (FIFO) kuyruk sıralamasıyla aktarılır. Bu işlemler eşzamansız olarak gerçekleştirilmektedir. Yöntem çoklu mimarisi Şekil 3.11.'de görülmektedir. Yöntem için AMR çalışanı eğitim süreci Şekil 3.12.'de gösterilmiştir.




Şekil 3.11. Yöntem çoklu robot mimarisi



Şekil 3.12. Önerilen yöntem için eğitim süreci

3.2.5. Arıza tespiti için karar seviyesi füzyon

AMR'nin konum bilgisine göre test alanından geçişte ses, akım ve titreşim verileri filtrelenerek eşit örnek kesişmeyen pencerelere ayrılmaktadır. Bu pencerelerden önışlemlerde bahsedilen 14 öz nitelik her bir veri türü için hesaplanır. Ve her bir veri türü için eğitilmiş modellerin aktörlerine girdi vektörü olarak gönderilir. Aktör modelleri pencere için arıza veya normal çıkışını ayrı ayrı üretir. Bu ayrı türdeki veriler için elde edilmiş sonuçların birleştirilmesi için karar seviyesi füzyonu kullanılmıştır. Bir pencere için akım, ses ve titreşim aktör modellerinin çıktıları değerlendirilir. Modellerin çoğunluğu veya tamamını arıza çıktısı üretiyorsa bu pencere için nihai karar olarak arıza alarmı verilebilir. Füzyon yaklaşımı Şekil 3.13.'te gösterilmiştir.



Şekil 3.13. Füzyon

Önerilen yöntem ile öğrenme süreci ve en son elde edilen başarılı modeller ile de arıza tespiti eşzamanlı olarak paralel devam edebilir.

3.2.6. Yöntem bulgularında başarı değerlendirme ölçütleri

Yöntem başarı değerlendirmesinde karmaşıklık matrisleri (Çizelge 3.3.) ve aşağıda tanımları verilmiş olan, Kesinlik (Precision), Duyarlılık (Recall), F1 Skoru (F1 Score) ve Doğruluk (Accuracy) metrikleri (Denklem 3.22-3.25) raporlanmıştır. Karmaşıklık matrisi, yöntem tarafından tahmin edilen değerlerin gerçek değerlerle ne kadar örtüştüğünü görselleştirmektedir.

Kullanılan başarı değerlendirme ölçütlerindeki ifadeler; doğru negatif (TN) modelin normal çalışma koşulunu normal olarak değerlendirmesi, yanlış pozitif (FP) modelin normal çalışma koşulunu arızalı olarak değerlendirmesi, yanlış negatif (FN) modelin arızalı çalışma koşulunu normal olarak değerlendirmesi, doğru pozitif (TP) modelin arızalı çalışma koşulunu arızalı olarak değerlendirmesi şeklindedir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.22)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.23)$$

$$\text{F1 Skoru} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.24)$$

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.25)$$

Çizelge 3.3. Karmaşıklık matrisi

		Tahmin Edilen Değer	
		Normal (0)	Arızalı (1)
Gerçek Değer	Normal (0)	TN	FP
	Arızalı (1)	FN	TP

Sonraki bölümde gerçek AMR arıza senaryosunda önerilen yöntem ile elde edilen sonuçlar sunulmuş ve literatürde kullanılan yöntem ve parametreler ile karşılaştırılmıştır.

4. BULGULAR VE TARTIŞMA

Çalışmada önerilen RL tabanlı aykırılık ve arıza tespit mekanizması AMR için uygulanmıştır. AMR'nin fabrika ortamında görevini yerine getirirken, konum bilgisine göre belirli bir test alanından geçişi koşu olarak adlandırılmıştır. Koşudan elde edilen veriler pencere olarak adlandırılan parçalara bölünür. Arıza tespitinde nihai amaç, koşu esnasında metal levhalara çarpışma pencerelerini tespit etmektir. Yöntemin başarısı hem arızalı koşunun doğru belirlenmesi hem de arızalı pencerenin doğru belirlenmesi ile ölçülmektedir.

Bu bölümde öncelikle deney senaryoları ve çalışmada kullanılan deney verisi açıklanacaktır. Sonrasında aykırılık tespit sonuçları ve füzyon tabanlı arıza tespit yaklaşımı sonuçları iki başlık halinde sunulmaktadır.

4.1. Deney Senaryoları ve Test Verisi

Öngörü ve sağlık yönetim sisteminin test edilmesi amaçlı AMR'ler için çeşitli arıza senaryoları oluşturulmuştur. Bu senaryolar şu şekildedir:

- AMR tekerlerine veya yol yüzeyine farklı parçalar ekleyerek, tekerdeki veya yol yüzeyindeki şekil bozukluklarının değerlendirilmesi.
- AMR motor teker bağlantı flanşının farklı eğimlerde tasarlanması ve bağlantıdaki açı bozulmasının değerlendirilmesi.
- Motor ve şase arasına motor açısını farklı eksenlerde değiştirecek parça ekleyerek eğik şase benzetiminin irdelenmesi.
- Motor redüktör dişlilerine aşındırma veya tam diş eksiltme uygulanarak redüktör arızalarının incelenmesi.
- AMR için hasarlı veya sıkışmış rulmanların etkisinin değerlendirilmesi.
- Ezik veya hasarlı sarhoş tekerlerin benzetimi ile arıza tespiti.

Arıza senaryoları değerlendirildiğinde AMR için en uygulanabilir senaryonun yol yüzeyindeki bozuklukların tespiti olduğu değerlendirilmiştir. Laboratuvar ortamında bozuk zemin geçişlerinin benzetimi için dört adet, 5 mm x

2 cm x 1 m ebatlarında, belirli koordinatlarda yere sabitlenmiş metal levha kullanılmıştır.

Yöntem testlerinde kullanılan veri setinde gerçek bir AMR'ye ait 80 koşu için normal, 80 koşu için de bozuk zemin arıza senaryosu için yüksüz düz rota verisi bulunmaktadır. Şekil 4.1.'de normal ve arızalı senaryo için örnek veri toplama ortamı görülmektedir.

Yöntem testleri için ilk olarak önışlemler ve öznitelik çıkarma adımları tamamlanmıştır. Pencereleere ait öznitelik verileri min-max uygulanarak 0 ile 1 arasında normalleştirilmiştir. Veri setinin %80'i (128 koşu) eğitim için %20'si (32 koşu) ise test için kullanılmıştır. Her yöntem testi için bölünmüş veriler, doğru karşılaştırabılme amacıyla sabit tutulmuştur. Eğitimde 64 normal koşu ve 64 arıza koşusu verisi, testte 16 normal koşu ve 16 arıza koşu verisi bulunmaktadır. Tüm koşular birbirinden bağımsızdır ve farklı özdeş robotlardan elde edildiği varsayılmıştır.



Şekil 4.1. Normal ve arızalı koşular için örnek veri toplama ortamı


4.2. Pekiştirmeli Öğrenme Tabanlı Aykırılık Tespitinde Karar Modeli Bulguları

Önerilen yöntemin aykırılık tespitinde literatür ile karşılaştırılması için A3C, A2C, DNN, Logistic Regression, Ridge Regression, kNN, Bagging, Random Forest ve SVM algoritmaları kullanılmıştır. A3C, A2C ve DNN için Adam optimizasyon algoritması (Kingma ve Ba, 2014) kullanılmıştır, bu algoritmaların ortak eğitim parametre değerleri Çizelge 4.1.'de verilmiştir. Bu parametreler dışında A3C algoritması sabit ödül parametreleri ve önerilen ödül ile test edilmiştir. Detaylı karmaşıklık matrisleri yöntemler ile elde edilen en başarılı sonuçlar için karşılaştırma amaçlı sunulmuştur.

Çizelge 4.1. A3C, A2C ve DNN ortak eğitim parametre değerleri


Parametre	A2C	A3C	DNN
Çalışan sayısı	1	8	-
t_{max}	5	5	-
γ	0,99	0,99	-
β	0,01	0,01	-
Öğrenme katsayısı	0,0001	0,0001	0,0001
Epok	720	720	150

Önerilen yöntemin sırasıyla akım, ses ve titreşim verilerindeki aykırılık tespit karmaşıklık matrisleri Şekil 4.2.'de gösterilmektedir. Önerilen yöntemde ödül için, $\mu = 1 + m$, $\psi = m$, $\eta = 1 - m$, $\zeta = m$ parametre değerleri uygulanmıştır.




Şekil 4.2. Önerilen yöntem a) Akım b) Ses ve c) Titreşim

DNN için önerilen yöntemin aktör mimarisi kullanılmıştır. Durum girdisi için 14 düğüm, ReLU aktivasyon fonksiyonu ile bağlı 3 gizli katmanın her birinde 100 düğüm, çıktı katmanında ise 2 düğüm bulunmaktadır. Kayıp için ayırık kategorik çapraz entropi uygulanmıştır. DNN ile aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.3.'te verilmiştir. Akım, ses ve titreşim verisi için önerilen yöntem ile daha doğru sınıflandırma yapıldığı görülmektedir. Buna karşın DNN modeli aykırı pencereleri düşük bir farkla daha doğru tespit etmiştir.




Şekil 4.3. DNN a) Akım b) Ses ve c) Titreşim

A2C algoritması A3C algoritmasının eşzamanlı versiyonudur. A2C testlerinde önerilen yöntem aktör kritik modeli (TP=1 TN=1 FP=-1 FN=-1) ödül parametresi ile kullanılmıştır. A2C ile aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.4.'te sunulmuştur. Sonuçlar incelendiğinde akım, ses ve titreşim verilerinde önerilen yöntemle göre FP oranının yüksek olduğu görülmektedir. Bu verilerde A2C için TP değerleri yüksek olsa da model doğruluk skoru düşük görülmüştür.




Şekil 4.4. A2C a) Akım b) Ses ve c) Titreşim

A3C ile önerilen mimaride sabit ödül (TP=1 TN=1 FP=-1 FN=-1) kullanılarak elde edilen aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.5.'te görülmektedir. Akım verisi için önerilen yöntem ile daha yüksek doğrulukta sınıflandırma yapıldığı görülmektedir. Ses verisi için aykırılık tespitinde sabit ödül 2 pencere için başarılı görünse de yanlış alarm verilen pencere sayısı önerilen yöntemde 5 pencere daha düşüktür. Titreşim verisinde ise önerilen yöntem TP için 4 pencere daha doğru TN için 2 pencerede daha yanlış sınıflandırma yapmıştır.




Şekil 4.5. A3C (TP=1 TN=1 FP=-1 FN=-1) a) Akım b) Ses ve c) Titreşim

A3C ile önerilen mimaride sabit ödül (TP=5 TN=1 FP=-1 FN=-5) kullanılarak elde edilen aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.6.'da görülmektedir. Akım ses ve titreşim verisi için önerilen yöntem ile daha yüksek doğrulukta sınıflandırma yapıldığı görülmektedir. Akım ve ses verisinde önerilen yöntem daha az FP çıktısı üretmiştir ses verisinde ise daha az FN görülmektedir. Sabit ödül işlevinde aykırı ve normal durum tespitine yüksek ödül verilmesinin akım ve ses için yüksek yanlış alarm titreşim için ise yüksek FN çıktısına neden olduğu değerlendirilebilir.



Şekil 4.6. A3C (TP=5 TN=1 FP=-1 FN=-5) a) Akım b) Ses ve c) Titreşim


A3C ile önerilen mimaride sabit ödül (TP=1 TN=1 FP=0 FN=0) kullanılarak elde edilen aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.7.'de görülmektedir. Akım ses ve titreşim verisi için daha çok FN sınıflandırma yapıldığı gözlemlenmiştir. Normal sınıfa ait pencere sayısının fazla olması nedeniyle bu ödül parametresinin normal pencere olarak sınıflandırma ihtimalini artırdığı değerlendirilebilir.



Şekil 4.7. A3C (TP=1 TN=1 FP=0 FN=0) a) Akım b) Ses ve c) Titreşim


Logistic Regression, Ridge Regression, kNN, Bagging, Random Forest ve SVM testlerinde, Kasap vd., (2021)'de önerilen aşamalar uygulanarak sonuçlar sunulmuştur.

Logistic Regression ile aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.8.'de görülmektedir. Akım verisi için önerilen yöntem ile 5 pencere için daha az FP sınıflandırma yaptığı görülmektedir. Ses verisinde Logistic Regression ile 4 pencere için daha başarılı aykırılık tespit edildiği görülmektedir. Titreşim verisi için önerilen yöntemle aykırı ve normal pencerelerde daha başarılı sınıflandırma sonucu elde edildiği görülmektedir.




Şekil 4.8. Logistic Regression a) Akım b) Ses ve c) Titreşim

Ridge Regression ile aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.9.'da verilmiştir. Akım verisi için önerilen yöntemle daha doğru alarm verildiği görülmektedir. Ses verisinde ise Ridge Regression ile daha başarılı sınıflandırma yapılmıştır. Titreşim için önerilen yöntemle daha başarılı aykırı durum tespiti gerçekleştirilmiştir.



Şekil 4.9. Ridge Regression a) Akım b) Ses ve c) Titreşim


kNN ile aykırılık tespiti karmaşıklık matrisleri akım, ses ve titreşim verileri için sırasıyla Şekil 4.10.'da görülmektedir. Akım verisi için önerilen yöntem ile daha doğru sınıflandırma yapıldığı görülmektedir. Ses verisinde aykırı ve normal pencerelerin kNN ile daha başarılı tespit edildiği görülmektedir. Titreşim için ise önerilen yöntemle daha başarılı normal ve aykırı durum tespiti gerçekleştirilmiştir. kNN arıza tespiti için literatürde sıklıkla kullanılmaktadır. Karşılaştırma sonuçları önerilen yöntemin iki farklı sensör verisinde daha başarılı sonuçlar üretebileceğini göstermektedir.



Şekil 4.10. kNN a) Akım b) Ses ve c) Titreşim


Bagging ile aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.11.'de verilmiştir. Akım verisi için önerilen yöntem ile

daha başarılı aykırılık tespiti yapıldığı görülmektedir. Ses verisinde Bagging ile aykırı durumların daha doğru tespit edildiği görülmektedir. Titreşim için ise önerilen yöntemle daha başarılı sınıflandırma gerçekleştirilmiştir.




Şekil 4.11. Bagging a) Akım b) Ses ve c) Titreşim

Random Forest literatürde yaygın olarak kullanılan arıza tespit algoritmalarından biridir. Karşılaştırma için random forest ile aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.12.'de verilmiştir. Akım verisi için önerilen yöntem ile daha başarılı aykırılık tespiti yapıldığı görülmektedir. Ses verisinde Random Forest ile daha doğru sınıflandırma sonucu elde edilmiştir. Titreşim verisinde arızalı pencerelerin belirlenmesinde eşit başarı görülürken önerilen yöntem normal durumları daha doğru belirlemiştir.



Şekil 4.12. Random Forest a) Akım b) Ses ve c) Titreşim

Literatürde SVM ile yapılan arıza tespit çalışmalarına rastlanmaktadır. SVM ile aykırılık tespiti karmaşıklık matrisleri sırasıyla akım, ses ve titreşim verileri için Şekil 4.13.'te verilmiştir. Akım verisi için önerilen yöntem ile normal pencereler az farkla daha başarılı tespit edilmiştir. Ses verisinde SVM daha başarılıdır. Titreşim için ise önerilen yöntemle daha başarılı sınıflandırma gerçekleştirilmiştir.



Şekil 4.13. SVM a) Akım b) Ses ve c) Titreşim

Çizelge 4.2., Çizelge 4.3. ve Çizelge 4.4.'te sırasıyla akım, ses ve titreşim için, A3C, DNN, A2C, Logistic Regression, Ridge Regression, kNN, Bagging, Random Forest ve SVM algoritmaları ile elde edilen kesinlik, duyarlılık, F1 ve doğruluk skorları gösterilmektedir.

Çizelge 4.2. Akım aykırılık tespit sonuçları

Metot	Kesinlik	Duyarlılık	F1	Doğruluk
A3C (Önerilen)	0,797	0,724	0,759	0,922
DNN	0,760	0,750	0,755	0,917
A2C	0,667	0,842	0,744	0,902
A3C (TP=1 TN=1 FP=-1 FN=-1)	0,917	0,289	0,440	0,875
A3C (TP=5 TN=1 FP=-1 FN=-5)	0,287	1	0,446	0,578
A3C (TP=1 TN=1 FP=0 FN=0)	0,913	0,553	0,689	0,915
Logistic Regression	0,743	0,724	0,733	0,911
Ridge Regression	0,778	0,645	0,705	0,908
KNN	0,690	0,763	0,725	0,902
Bagging	0,596	0,697	0,642	0,868
Random Forest	0,635	0,711	0,671	0,882
SVM	0,786	0,724	0,753	0,920

Çizelge 4.3. Ses aykırılık tespit sonuçları

Metot	Kesinlik	Duyarlılık	F1	Doğruluk
A3C (Önerilen)	0,921	0,946	0,933	0,967
DNN	0,863	0,964	0,911	0,953
A2C	0,833	0,991	0,905	0,949
A3C (TP=1 TN=1 FP=-1 FN=-1)	0,884	0,964	0,922	0,960
A3C (TP=5 TN=1 FP=-1 FN=-5)	0,665	1	0,799	0,875
A3C (TP=1 TN=1 FP=0 FN=0)	1	0,405	0,577	0,853
Logistic Regression	0,924	0,982	0,952	0,975
Ridge Regression	0,939	0,964	0,951	0,975
KNN	0,939	0,964	0,951	0,975
Bagging	0,923	0,973	0,947	0,973
Random Forest	0,932	0,982	0,956	0,978
SVM	0,939	0,973	0,956	0,978

Çizelge 4.4. Titreşim aykırılık tespit sonuçları

Metot	Kesinlik	Duyarlılık	F1	Doğruluk
A3C (Önerilen)	0,841	0,892	0,865	0,949
DNN	0,806	0,904	0,852	0,942
A2C	0,776	0,916	0,840	0,935
A3C (TP=1 TN=1 FP=-1 FN=-1)	0,854	0,843	0,848	0,944
A3C (TP=5 TN=1 FP=-1 FN=-5)	0,869	0,639	0,736	0,915
A3C (TP=1 TN=1 FP=0 FN=0)	0,958	0,277	0,430	0,864
Logistic Regression	0,828	0,867	0,847	0,942
Ridge Regression	0,844	0,783	0,813	0,933
KNN	0,789	0,855	0,821	0,931
Bagging	0,814	0,843	0,828	0,935
Random Forest	0,813	0,892	0,851	0,942
SVM	0,828	0,867	0,847	0,942

4.3. Karar Seviyesi Füzyon ile Arıza Tespit Bulguları

Eşzamansız yöntemler ile elde edilen sonuçlar ödül işlevinin sınıf dengesizliğinde önemini göstermiştir. Test edilen yöntemlerin önemli bir bölümü aykırılık tespiti için iyi sonuçlar verse de aykırılık ve arıza farklı kavramlardır. Aykırılık, beklenen davranıştan sapma olarak tanımlanabilir fakat arızalar, aykırılık gösterebilen ve başarısızlıkla sonuçlanabilen durumlardır. Test senaryosunda arıza, AMR'nin metal levhalara çarpmasıdır. Ağır AMR'lerin çalışması sırasında, alt görevleri gerçekleştirmek için yüksek akım çeken ani hızlanmalar yapılabilir veya çalışma ortamındaki yüksek gürültü, ses sensörleri tarafından algılanabilir. Arıza kararı için tek bir sensörün kullanılması, doğru şekilde ölçümlemesi gerçekleştirilse dahi çeşitli riskler taşımaktadır. Üretimde istenmeyen, gereksiz, bakım onarım kesintilerini engellemek için yanlış alarmlar oluşturulmamalıdır. Son dönemde yapılan araştırmalar, füzyonunun arıza tespitinde daha sağlam sonuçlar ürettiğini göstermektedir (Gültekin vd., 2022a; Kasap vd., 2023). Çalışmamızda, AMR'lerde yüksek doğrulukta arıza tespiti için karar seviyesinde füzyon kullanılmaktadır.

Şekil 4.14. ve 4.15.'te normal yol yüzeyinde koşular için sensör temelli ve füzyon ile elde edilen aykırı ve arızalı pencereler gösterilmiştir. Şekil 4.16. ve 4.17., arıza senaryosunda koşular için pencerelerde sensör temelli aykırılık için gerçek durumu ve önerilen yöntem için karar seviyesi oy birliğine dayanan füzyon ile arıza tespit sonuçlarını göstermektedir. Şekil 4.18. ve 4.19. ise arıza senaryosunda koşular için pencerelerde sensör temelli aykırılık için gerçek durumu ve önerilen yöntem için karar seviyesi oy çokluğuna dayanan füzyon ile arıza tespit sonuçlarını göstermektedir.

Önerilen yöntem ile sensör temelli arıza tespitinde normal koşu pencerelerine bakıldığında (Şekil 4.14. ve 4.15.), koşu 4 (Şekil 4.14.d), koşu 6 (Şekil 4.14.f), koşu 10 (Şekil 4.15.b), koşu 11 (Şekil 4.15.c) ve koşu 16'da (Şekil 4.15.h) akım bilgisi için yanlış alarm verildiği görülmektedir. Bu durum akım için sensör temelli arıza tespitinde verilen 14 alarmın 6 tanesinin normal koşularda gerçekleştiğini göstermektedir.

Çizelge 4.5. tek bir sensör için aykırılık tespit sonucuna göre arıza alarmı verilmesi durumunda elde edilen sonuçları göstermektedir. Bu yaklaşımla verilen

alarm sayısı arıza senaryosu koşullarında bulunan dört metal levhaya çarpma sayısından fazladır. Metal engelin olmadığı koşullarda dahi gereksiz alarmlar oluşturulduğu görülmektedir.


Çizelge 4.5. Sensör odaklı arıza tespit sonuçları

AMR Test Koşusu	Normal Pen.	Arızalı Pen.	Alarm Pen.	Alarm Koşu
Normal	16	224	0	5
Arızalı	16	160	64	16


Yanlış alarmlara karşı karar seviyesi füzyonu oy birliği ile arıza alarmı verilmesi, belirlenen metal levha konumlarına karşılık gelen kısımlarda daha doğru arıza alarmı oluşturulmasını sağlamıştır. Çizelge 4.6., karar seviyesi füzyonunda oy birliği ile arıza alarmı oluşturulması sonuçlarını göstermektedir. Bu sonuçlar incelendiğinde normal koşullarda yanlış alarmların oluşturulmadığı görülmektedir. Arızalı koşullarda ise referans doğru olarak 3 ve 9 numaralı pencerelerin arasında kalan 64 metal levha konumunun 50'si tespit edilerek arızalı pencereler %78,125 doğrulukla tespit edilmiştir.

Çizelge 4.6. Füzyon odaklı arıza tespitinde oy birliği sonuçları


AMR Test Koşusu	Normal Pen.	Arızalı Pen.	Alarm Pen.	Alarm Koşu
Normal	16	224	0	0
Arızalı	16	160	64	16




(a) Normal koşu 1




(b) Normal koşu 2




(c) Normal koşu 3




(d) Normal koşu 4




(e) Normal koşu 5



(f) Normal koşu 6




(g) Normal koşu 7




(h) Normal koşu 8


Şekil 4.14. 1-8. normal koşular için sonuçlar




(a) Normal koşu 9




(b) Normal koşu 10




(c) Normal koşu 11




(d) Normal koşu 12




(e) Normal koşu 13



(f) Normal koşu 14




(g) Normal koşu 15




(h) Normal koşu 16


Şekil 4.15. 9-16. normal koşular sonuçlar




(a) Arızalı koşu 1




(b) Arızalı koşu 2




(c) Arızalı koşu 3




(d) Arızalı koşu 4




(e) Arızalı koşu 5



(f) Arızalı koşu 6




(g) Arızalı koşu 7




(h) Arızalı koşu 8


Şekil 4.16. 1-8. arızalı koşular için oy birliği füzyon sonuçları




(a) Arızalı koşu 9




(b) Arızalı koşu 10




(c) Arızalı koşu 11




(d) Arızalı koşu 12




(e) Arızalı koşu 13



(f) Arızalı koşu 14




(g) Arızalı koşu 15




(h) Arızalı koşu 16


Şekil 4.17. 9-16. arızalı koşular için oy birliği füzyon sonuçları




(a) Arızalı koşu 1




(b) Arızalı koşu 2




(c) Arızalı koşu 3




(d) Arızalı koşu 4




(e) Arızalı koşu 5



(f) Arızalı koşu 6




(g) Arızalı koşu 7




(h) Arızalı koşu 8


Şekil 4.18. 1-8. arızalı koşular için oy çokluğu füzyon sonuçları




(a) Arızalı koşu 9




(b) Arızalı koşu 10




(c) Arızalı koşu 11




(d) Arızalı koşu 12




(e) Arızalı koşu 13



(f) Arızalı koşu 14



(g) Arızalı koşu 15



(h) Arızalı koşu 16

Şekil 4.19. 9-16. arızalı koşular için oy çokluğu füzyon sonuçları

5. SONUÇ VE ÖNERİLER

Otonom mobil robotların dinamik ortamlarda güvenle çalışabilmeleri için etkili arıza tespit mekanizmalarına ihtiyaç vardır. Gelişen teknoloji, arızalara erken müdahale için robotların gerçek zamanlı olarak izlenebileceği durum izleme araçlarına erişimi kolaylaştırmıştır. Akıllı fabrikalarda insan gereksinimini en aza indirecek iyi uygulamalar sunmak için bu teknolojilerin akıllı algoritmalarla desteklenmesi gerekmektedir. Bu amaçla robot çalışma koşullarının da dikkate alındığı gerçekçi senaryolar ile araştırmaların yürütülmesi alana önemli katkı sağlayacaktır.

Çalışmanın sonuçları, AMR'ler için aykırılık tespitinin eşzamansız MARL kullanılarak başarıyla gerçekleştirilebileceğini ortaya koymaktadır. Bununla birlikte eşzamansız MARL, diğer yöntemlere göre aykırılık tespitinde çeşitli avantajlar sunar. Bu avantajlar arasında dağıtılmış kaynak kullanımı, farklı AMR'leri temsil eden ortak öğrenme ile kesinti ve belirsizlik sırasında dahi devam edebilen eğitim yer almaktadır.

Önerilen yöntemle elde edilen sonuçlar, birden fazla ajan arasında dengeli ve parametrik ödül mekanizmasının etkili olduğunu göstermektedir. Diğer merkezi algoritmalarla karşılaştırıldığında önerilen yöntem, aykırılıkları yüksek doğrulukla tespit edebilmektedir.

Her ne kadar aykırılık tespiti literatürde başarıyla kullanılan diğer yöntemler kadar etkili olsa da AMR'ler çalışma koşulları nedeniyle aykırılığa neden olan gürültülü durumlardan etkilenmektedir. Bu tek bir kaynak ile gerçekleştirilen arıza tespiti için yanlış alarmlara neden olmaktadır. Bu durum normal çalışma şartlarında bile maliyetli kesintilere neden olabileceken füzyon mekanizması bunu engellemektedir.

Oy birliği ile yapılan arıza tespitinde arızalı koşullarda bazı arızalı pencerelerin atlandığı görülmektedir. Buna karşı oy çokluğuyla yapılan arıza tespitinde sadece arızalı koşullarda olmakla beraber ek alarmlar üretmiştir. Bu durum robotun engellere çarpan birden fazla sırada tekerinin olmasından kaynaklanmaktadır.

Arıza alarmı verilmesinde arızanın geçici mi yoksa kalıcı mı olduğu da değerlendirilebilir. Bunun için kısa dönem bir tampon bellekte arıza alarmları tutularak ardışık belirli bir pencere limiti sonrası kalıcı arıza alarmı verilebilir. Fakat AMR benzeri ağır hizmet robotlarının arızalarının hızlı tespiti ciddi kazaların önüne geçecektir.

Füzyon mekanizmasının karar seviyesinde gerçekleştirilmesi farklı veri tiplerini bir araya getirmesi nedeniyle kullanışlıdır. Fakat bu durum her sensör verisi aykırılığı için ayrı bir model eğitimi ve küresel ağ güncellemesi nedeniyle ağ yükü oluşturur. Ek olarak arıza tipine göre model seçimi gerekir. Alternatif olarak sensör düzeyi füzyonu seçilebilir fakat böyle bir yaklaşım sensör okumalarına çok bağımlı olduğu için gürültüden ve ölçümlemeden etkilenebilir. Öznitelik düzeyi füzyon ise farklı bir tercih olarak değerlendirilebilir. Bu seçim için arıza tiplerine uygun öznitelik belirleme gerekir.

Çalışmamızda AMR filoları için merkezi bir mimari kullanılmıştır. Bu ortak ağ kullanan çoklu ajan sistemler için kullanışlıdır. Fakat bu mimarinin merkezi sistemin kaynaklarına bağımlı olmasının risk oluşturması nedeniyle dağıtık bir mimari kullanılabilir. Dağıtık mimarinin dezavantajı ise politika güncelleme gecikmeleridir. Bu risk ağır AMR sistemleri için tehlikeli olabilir. Buna bir çözüm olarak hibrit bir mimarinin kullanımı uygun olacaktır.

Uzman davranışlarının öğrenilmesi uzman bilgisi gerektirmektedir. Bu şekilde tecrübelerin elde edilmesi her zaman mümkün değildir. Son çalışmalar benzerlik tabanlı denetimsiz öğrenmenin filolar için kullanışlı olduğunu göstermiştir. Gelecek çalışmalarda denetimsiz öğrenme ile ödül mekanizmasının iyileştirilmesi ve tamamen otonom asenkron öğrenmenin hibrit mimaride sağlanması planlanmaktadır. Bununla birlikte sistem kaynaklarının yük karşılaştırmalarının farklı füzyon düzeylerinde yapılması üzerine çalışmalar yapılacaktır.

KAYNAKLAR DİZİNİ

- Ahmed, M., & Mahmood, A. N. (2015). Novel Approach for Network Traffic Pattern Analysis using Clustering-based Collective Anomaly Detection. *Annals of Data Science*, 2(1), 111–130. <https://doi.org/10.1007/s40745-015-0035-y>
- AlShorman, O., Alkahatni, F., Masadeh, M., Irfan, M., Glowacz, A., Althobiani, F., Kozik, J., & Glowacz, W. (2021). Sounds and acoustic emission-based early fault diagnosis of induction motor: A review study. *Advances in Mechanical Engineering*, 13(2), 1687814021996915. <https://doi.org/10.1177/1687814021996915>
- Amoozgar, M., Chamseddine, A., & Zhang, Y. (2013). Experimental Test of a Two-Stage Kalman Filter for Actuator Fault Detection and Diagnosis of an Unmanned Quadrotor Helicopter. *Journal of Intelligent & Robotic Systems*, 70, 107–117. <https://doi.org/10.1007/s10846-012-9757-7>
- Apache. (2024). Apache Spark - A Unified engine for large-scale data analytics [Erişim tarihi: 30.04.2024]. <https://spark.apache.org/docs/latest/>
- Arshad, K., Ali, R. F., Muneer, A., Aziz, I. A., Naseer, S., Khan, N. S., & Taib, S. M. (2022). Deep Reinforcement Learning for Anomaly Detection: A Systematic Review. *IEEE Access*, 10, 124017–124035. <https://doi.org/10.1109/ACCESS.2022.3224023>
- Arulkumaran, K., Deisenroth, M. P., Brundage, M., & Bharath, A. A. (2017). Deep Reinforcement Learning: A Brief Survey. *IEEE Signal Processing Magazine*, 34(6), 26–38. <https://doi.org/10.1109/MSP.2017.2743240>
- Audibert, J., Michiardi, P., Guyard, F., Marti, S., & Zuluaga, M. A. (2022). Do deep neural networks contribute to multivariate time series anomaly detection? *Pattern Recognition*, 132, 108945. <https://doi.org/10.1016/j.patcog.2022.108945>
- Aznar, F., Pujol, M., & Rizo, R. (2019). Obtaining fault tolerance avoidance behavior using deep reinforcement learning [Deep Learning for Intelligent Sensing,

KAYNAKLAR DİZİNİ

- Decision-Making and Control]. *Neurocomputing*, 345, 77–91. <https://doi.org/10.1016/j.neucom.2018.11.090>
- Azzalini, D., Castellini, A., Luperto, M., Farinelli, A., & Amigoni, F. (2020). HMMs for Anomaly Detection in Autonomous Robots. *Proceedings of the 19th International Conference on Autonomous Agents and MultiAgent Systems*, 105–113.
- Bahrpeyma, F., & Reichelt, D. (2022). A review of the applications of multi-agent reinforcement learning in smart factories. *Frontiers in Robotics and AI*, 9, 1027340. <https://doi.org/10.3389/frobt.2022.1027340>
- Belhadi, A., Djenouri, Y., Srivastava, G., Jolfaei, A., & Lin, J. C.-W. (2021a). Privacy reinforcement learning for faults detection in the smart grid. *Ad Hoc Networks*, 119, 102541. <https://doi.org/10.1016/j.adhoc.2021.102541>
- Belhadi, A., Djenouri, Y., Srivastava, G., & Lin, J. C.-W. (2021b). Reinforcement learning multi-agent system for faults diagnosis of mircoservices in industrial settings. *Computer Communications*, 177, 213–219. <https://doi.org/10.1016/j.comcom.2021.07.010>
- Bellini, A., Filippetti, F., Tassoni, C., & Capolino, G.-A. (2008). Advances in Diagnostic Techniques for Induction Machines. *IEEE Transactions on Industrial Electronics*, 55(12), 4109–4126. <https://doi.org/10.1109/TIE.2008.2007527>
- Bellman, R. E. (1957). *Dynamic Programming*. Princeton University Press.
- Berndt, D. J., & Clifford, J. (1994). Using dynamic time warping to find patterns in time series. *Proceedings of the 3rd International Conference on Knowledge Discovery and Data Mining*, 359–370.
- Bernstein, D. S., Givan, R., Immerman, N., & Zilberstein, S. (2002). The Complexity of Decentralized Control of Markov Decision Processes. *Mathematics of Operations Research*, 27(4), 819–840. <https://doi.org/10.1287/moor.27.4.819.297>

KAYNAKLAR DİZİNİ

- Carlson, J., & Murphy, R. (2005). How UGVs physically fail in the field. *IEEE Transactions on Robotics*, 21(3), 423–437. <https://doi.org/10.1109/TRO.2004.838027>
- Carminati, A., Azzalini, D., Vantini, S., & Amigoni, F. (2024). A Distributed Approach for Fault Detection in Swarms of Robots. *Proceedings of the 23rd International Conference on Autonomous Agents and Multiagent Systems*, 253–261.
- Chen, T., Liu, X., Xia, B., Wang, W., & Lai, Y. (2020). Unsupervised Anomaly Detection of Industrial Robots Using Sliding-Window Convolutional Variational Autoencoder. *IEEE Access*, 8, 47072–47081. <https://doi.org/10.1109/ACCESS.2020.2977892>
- Cheng, S., Azarian, M. H., & Pecht, M. G. (2010). Sensor Systems for Prognostics and Health Management. *Sensors*, 10(6), 5774–5797. <https://doi.org/10.3390/s100605774>
- Chirayil Nandakumar, S., Mitchell, D., Erden, M. S., Flynn, D., & Lim, T. (2024). Anomaly Detection Methods in Autonomous Robotic Missions. *Sensors*, 24(4), Article e1330. <https://doi.org/10.3390/s24041330>
- Christensen, A. L., O’Grady, R., Birattari, M., & Dorigo, M. (2008). Fault detection in autonomous robots based on fault injection and learning. *Autonomous Robots*, 24, 49–67. <https://doi.org/10.1007/s10514-007-9060-9>
- Dang, Q.-V., & Vo, T.-H. (2021). Studying the Reinforcement Learning techniques for the problem of intrusion detection. *2021 4th International Conference on Artificial Intelligence and Big Data (ICAIBD)*, 87–91. <https://doi.org/10.1109/ICAIBD51990.2021.9459006>
- Das, O., Bagci Das, D., & Birant, D. (2023). Machine learning for fault analysis in rotating machinery: A comprehensive review. *Heliyon*, 9(6), e17584. <https://doi.org/10.1016/j.heliyon.2023.e17584>

KAYNAKLAR DİZİNİ

- Debie, E., Fernandez Rojas, R., Fidock, J., Barlow, M., Kasmarik, K., Anavatti, S., Garratt, M., & Abbass, H. A. (2021). Multimodal Fusion for Objective Assessment of Cognitive Workload: A Review. *IEEE Transactions on Cybernetics*, 51(3), 1542–1555. <https://doi.org/10.1109/TCYB.2019.2939399>
- de Jonge, F., Roos, N., & Witteveen, C. (2009). Primary and secondary diagnosis of multi-agent plan execution. *Autonomous Agents and Multi-Agent Systems*, 18(2), 267–294. <https://doi.org/10.1007/s10458-008-9045-x>
- Ding, Y., Ma, L., Ma, J., Suo, M., Tao, L., Cheng, Y., & Lu, C. (2019). Intelligent fault diagnosis for rotating machinery using deep Q-network based health state classification: A deep reinforcement learning approach. *Advanced Engineering Informatics*, 42, 100977. <https://doi.org/10.1016/j.aei.2019.100977>
- Dogan, A., & Birant, D. (2020). A Two-Level Approach based on Integration of Bagging and Voting for Outlier Detection. *Journal of Data and Information Science*, 5(2), 111–135. <https://doi.org/doi:10.2478/jdis-2020-0014>
- Elasticsearch. (2024a). Getting Started with Kibana [Erişim tarihi: 30.04.2024]. <https://www.elastic.co/virtual-events/getting-started-kibana>
- Elasticsearch. (2024b). Getting Started with Logstash [Erişim tarihi: 30.04.2024]. <https://www.elastic.co/webinars/getting-started-logstash>
- Elasticsearch. (2024c). The heart of the free and open Elastic Stack [Erişim tarihi: 30.04.2024]. <https://www.elastic.co/elasticsearch>
- El-Banby, G. M., Moawad, N. M., Abouzalm, B. A., Abouzaid, W. F., & Ramadan, E. (2023). Photovoltaic system fault detection techniques: a review. *Neural Computing and Applications*, 35(35), 24829–24842. <https://doi.org/10.1007/s00521-023-09041-7>
- Erol, S., Jäger, A., Hold, P., Ott, K., & Sihn, W. (2016). Tangible Industry 4.0: A Scenario-Based Approach to Learning for the Future of Production [6th

KAYNAKLAR DİZİNİ

- CIRP Conference on Learning Factories]. *Procedia CIRP*, 54, 13–18. <https://doi.org/10.1016/j.procir.2016.03.162>
- Espeholt, L., Soyer, H., Munos, R., Simonyan, K., Mnih, V., Ward, T., Doron, Y., Firoiu, V., Harley, T., Dunning, I., Legg, S., & Kavukcuoglu, K. (2018). IMPALA: Scalable Distributed Deep-RL with Importance Weighted Actor-Learner Architectures. In J. Dy & A. Krause (Eds.), *Proceedings of the 35th International Conference on Machine Learning* (pp. 1407–1416, Vol. 80). PMLR. <https://proceedings.mlr.press/v80/espeholt18a.html>
- Fiware. (2024a). Welcome To FIROS [Erişim tarihi: 30.04.2024]. <https://firos.readthedocs.io/en/latest/>
- Fiware. (2024b). Welcome To Orion Context Broker. [Erişim tarihi: 30.04.2024]. <https://fiware-orion.readthedocs.io/en/master/>
- Gangsar, P., & Tiwari, R. (2020). Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mechanical Systems and Signal Processing*, 144, 106908. <https://doi.org/10.1016/j.ymssp.2020.106908>
- Grafana. (2024). Dashboard anything. Observe everything. [Erişim tarihi: 30.04.2024]. <https://grafana.com/grafana/>
- Grondman, I., Busoniu, L., Lopes, G. A. D., & Babuska, R. (2012). A Survey of Actor-Critic Reinforcement Learning: Standard and Natural Policy Gradients. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 42(6), 1291–1307. <https://doi.org/10.1109/TSMCC.2012.2218595>
- Gultekin, M. A., & Bazzi, A. (2023). Review of Fault Detection and Diagnosis Techniques for AC Motor Drives. *Energies*, 16(15), Article e5602. <https://doi.org/10.3390/en16155602>
- Gundewar, S. K., & Kane, P. V. (2021). Condition Monitoring and Fault Diagnosis of Induction Motor. *Journal of Vibration Engineering & Technologies*, 9(4), 643–674. <https://doi.org/10.1007/s42417-020-00253-y>

KAYNAKLAR DİZİNİ

- Gültekin, Ö., Cinar, E., Özkan, K., & Yazıcı, A. (2022a). Multisensory data fusion-based deep learning approach for fault diagnosis of an industrial autonomous transfer vehicle. *Expert Systems with Applications*, 200, 117055. <https://doi.org/https://doi.org/10.1016/j.eswa.2022.117055>
- Gültekin, Ö., Cinar, E., Özkan, K., & Yazıcı, A. (2022b). Real-Time Fault Detection and Condition Monitoring for Industrial Autonomous Transfer Vehicles Utilizing Edge Artificial Intelligence. *Sensors*, 22(9), Article e3208. <https://doi.org/10.3390/s22093208>
- Hamann, H. (2018). *Swarm robotics: A formal approach*. Springer. <https://doi.org/10.1007/978-3-319-74528-2>
- Hess, A., Stecki, J. S., & Rudov-Clark, S. D. (2008). The maintenance aware design environment: Development of an aerospace phm software tool. *Proc. PHM08*, 1–9.
- Hornung, R., Urbanek, H., Klodmann, J., Osendorfer, C., & van der Smagt, P. (2014). Model-free robot anomaly detection. *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 3676–3683. <https://doi.org/10.1109/IROS.2014.6943078>
- Hsu, Y.-F., & Matsuoka, M. (2020). A Deep Reinforcement Learning Approach for Anomaly Network Intrusion Detection System. *2020 IEEE 9th International Conference on Cloud Networking (CloudNet)*, 1–6. <https://doi.org/10.1109/CloudNet51028.2020.9335796>
- Hu, X., Zhang, K., Liu, K., Lin, X., Dey, S., & Onori, S. (2020). Advanced Fault Diagnosis for Lithium-Ion Battery Systems: A Review of Fault Mechanisms, Fault Features, and Diagnosis Procedures. *IEEE Industrial Electronics Magazine*, 14(3), 65–91. <https://doi.org/10.1109/MIE.2020.2964814>
- Hua, J., Zeng, L., Li, G., & Ju, Z. (2021). Learning for a Robot: Deep Reinforcement Learning, Imitation Learning, Transfer Learning. *Sensors*, 21(4), Article e1278. <https://doi.org/10.3390/s21041278>

KAYNAKLAR DİZİNİ

- Huang, C., Wu, Y., Zuo, Y., Pei, K., & Min, G. (2018). Towards experienced anomaly detector through reinforcement learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 32(1). <https://doi.org/10.1609/aaai.v32i1.12130>
- Huang, W., & Zhang, G. (2023). Bearing Fault-Detection Method Based on Improved Grey Wolf Algorithm to Optimize Parameters of Multistable Stochastic Resonance. *Sensors*, 23(14), Article e6529. <https://doi.org/10.3390/s23146529>
- Hussein, A., Gaber, M. M., Elyan, E., & Jayne, C. (2017). Imitation Learning: A Survey of Learning Methods. *ACM Comput. Surv.*, 50(2), Article e21. <https://doi.org/10.1145/3054912>
- IFARLAB. (2022). Eskisehir Osmangazi University Intelligent Factory and Robotics Laboratory [Erişim tarihi: 06.04.2024]. <https://ifarlab.ogu.edu.tr/>
- IFRPR. (2024). Top 5 Robot Trends 2024 [Erişim tarihi: 04.04.2024]. <https://ifr.org/ifr-press-releases/news/top-5-robot-trends-2024>
- Ishii, S., Yoshida, W., & Yoshimoto, J. (2002). Control of exploitation–exploration meta-parameter in reinforcement learning. *Neural Networks*, 15(4), 665–687. [https://doi.org/10.1016/S0893-6080\(02\)00056-4](https://doi.org/10.1016/S0893-6080(02)00056-4)
- Jäger, G., Zug, S., Brade, T., Dietrich, A., Steup, C., Moewes, C., & Cretu, A.-M. (2014). Assessing neural networks for sensor fault detection. *2014 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, 70–75. <https://doi.org/10.1109/CIVEMSA.2014.6841441>
- Javed, K., Gouriveau, R., & Zerhouni, N. (2017). State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels. *Mechanical Systems and Signal Processing*, 94, 214–236. <https://doi.org/10.1016/j.ymssp.2017.01.050>

KAYNAKLAR DİZİNİ

- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237–285. <https://doi.org/10.1613/jair.301>
- Kalech, M., Kaminka, G. A., Meisels, A., & Elmaliach, Y. (2006). Diagnosis of multi-robot coordination failures using distributed CSP algorithms. *Proceedings of the 21st National Conference on Artificial Intelligence - Volume 1*, 970–975.
- Kardani-Moghaddam, S., Buyya, R., & Ramamohanarao, K. (2021). ADRL: A Hybrid Anomaly-Aware Deep Reinforcement Learning-Based Resource Scaling in Clouds. *IEEE Transactions on Parallel and Distributed Systems*, 32(3), 514–526. <https://doi.org/10.1109/TPDS.2020.3025914>
- Kasap, M., Çinar, E., Yazici, A., & Özkan, K. (2021). AN EXPERIMENTAL EVALUATION OF INTELLIGENT FAULT DETECTION AND CLASSIFICATION FOR INDUCTION MOTORS UTILIZING MACHINE LEARNING APPROACHES. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 29(2), 126–136. <https://doi.org/10.31796/ogummf.853090>
- Kasap, M., Yılmaz, M., Çinar, E., & Yazıcı, A. (2023). Unsupervised dissimilarity-based fault detection method for autonomous mobile robots. *Autonomous Robots*, 47(8), 1503–1518. <https://doi.org/10.1007/s10514-023-10144-2>
- Khadidos, A., Crowder, R. M., & Chappell, P. H. (2015). Exogenous Fault Detection and Recovery for Swarm Robotics [15th IFAC Symposium on Information Control Problems in Manufacturing]. *IFAC-PapersOnLine*, 48(3), 2405–2410. <https://doi.org/10.1016/j.ifacol.2015.06.448>
- Khalastchi, E., & Kalech, M. (2018). On Fault Detection and Diagnosis in Robotic Systems. *ACM Comput. Surv.*, 51(1), Article e9. <https://doi.org/10.1145/3146389>

KAYNAKLAR DİZİNİ

- Khalastchi, E., & Kalech, M. (2019). Fault Detection and Diagnosis in Multi-Robot Systems: A Survey. *Sensors*, 19(18), Article e4019. <https://doi.org/10.3390/s19184019>
- Khalastchi, E., Kalech, M., Kaminka, G. A., & Lin, R. (2015). Online data-driven anomaly detection in autonomous robots. *Knowledge and Information Systems*, 43, 657–688. <https://doi.org/10.1007/s10115-014-0754-y>
- Khalastchi, E., Kalech, M., & Rokach, L. (2013). Sensor fault detection and diagnosis for autonomous systems. *Proceedings of the 2013 International Conference on Autonomous Agents and Multi-Agent Systems*, 15–22.
- Khalastchi, E., Kalech, M., & Rokach, L. (2017). A hybrid approach for improving unsupervised fault detection for robotic systems. *Expert Systems with Applications*, 81, 372–383. <https://doi.org/10.1016/j.eswa.2017.03.058>
- Khalidi, B., Harrou, F., Cherif, F., & Sun, Y. (2017). Monitoring a robot swarm using a data-driven fault detection approach. *Robotics and Autonomous Systems*, 97, 193–203. <https://doi.org/10.1016/j.robot.2017.06.002>
- Khan, P. W., & Byun, Y.-C. (2024). A Review of machine learning techniques for wind turbine's fault detection, diagnosis, and prognosis. *International Journal of Green Energy*, 21(4), 771–786. <https://doi.org/10.1080/15435075.2023.2217901>
- Khaneghah, M. Z., Alzayed, M., & Chaoui, H. (2023). Fault Detection and Diagnosis of the Electric Motor Drive and Battery System of Electric Vehicles. *Machines*, 11(7), Article e713. <https://doi.org/10.3390/machines11070713>
- Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. *arXiv preprint arXiv:1412.6980*. <https://arxiv.org/abs/1412.6980>
- Lang, W., Hu, Y., Gong, C., Zhang, X., Xu, H., & Deng, J. (2022). Artificial Intelligence-Based Technique for Fault Detection and Diagnosis of EV

KAYNAKLAR DİZİNİ

- Motors: A Review. *IEEE Transactions on Transportation Electrification*, 8(1), 384–406. <https://doi.org/10.1109/TTE.2021.3110318>
- Lau, H., Bate, I., Cairns, P., & Timmis, J. (2011). Adaptive data-driven error detection in swarm robotics with statistical classifiers. *Robotics and Autonomous Systems*, 59(12), 1021–1035. <https://doi.org/10.1016/j.robot.2011.08.008>
- Li, M., Huang, T., & Zhu, W. (2021). Adaptive exploration policy for exploration–exploitation tradeoff in continuous action control optimization. *International Journal of Machine Learning and Cybernetics*, 12(12), 3491–3501. <https://doi.org/10.1007/s13042-021-01387-5>
- Li, Y., Chen, Z., Zha, D., Zhou, K., Jin, H., Chen, H., & Hu, X. (2022). Automated Anomaly Detection via Curiosity-Guided Search and Self-Imitation Learning. *IEEE Transactions on Neural Networks and Learning Systems*, 33(6), 2365–2377. <https://doi.org/10.1109/TNNLS.2021.3105636>
- Lu, H., Li, Y., Mu, S., Wang, D., Kim, H., & Serikawa, S. (2018). Motor Anomaly Detection for Unmanned Aerial Vehicles Using Reinforcement Learning. *IEEE Internet of Things Journal*, 5(4), 2315–2322. <https://doi.org/10.1109/JIOT.2017.2737479>
- Mahmood, T., Li, J., Pei, Y., Akhtar, F., Butt, S. A., Ditta, A., & Qureshi, S. (2022). An intelligent fault detection approach based on reinforcement learning system in wireless sensor network. *J. Supercomput.*, 78(3), 3646–3675. <https://doi.org/10.1007/s11227-021-04001-1>
- Marinescu, A., Dusparic, I., & Clarke, S. (2017). Prediction-Based Multi-Agent Reinforcement Learning in Inherently Non-Stationary Environments. *ACM Trans. Auton. Adapt. Syst.*, 12(2). <https://doi.org/10.1145/3070861>
- Mehanna, N. (2019). Scaling the A3C algorithm to multiple machines with Tensorflow.JS [Erişim tarihi: 04.04.2024]. <https://naifmehanna.com/2019-02-27-scaling-a3c-multiple-machines-tensorflowjs/>

KAYNAKLAR DİZİNİ

- Micalizio, R. [R.], Torasso, P., & Torta, G. (2004). On-line monitoring and diagnosis of multi-agent systems: a model based approach. *Proceedings of the 16th European Conference on Artificial Intelligence*, 848–852.
- Micalizio, R. [Roberto]. (2009). A distributed control loop for autonomous recovery in a multi-agent plan. *Proceedings of the 21st International Joint Conference on Artificial Intelligence*, 1760–1765.
- Micalizio, R. [Roberto], & Torasso, P. (2014). Cooperative monitoring to diagnose multiagent plans. *Journal of Artificial Intelligence Research*, 51(1), 1–70. <https://doi.org/10.1613/jair.4339>
- Michau, G., Palmé, T., & Fink, O. (2018). Fleet PHM for critical systems: bi-level deep learning approach for fault detection. *Proceedings of the European Conference of the PHM Society 2018*, 4(1). <https://doi.org/10.36001/phme.2018.v4i1.403>
- Millard, A. G. (2016). *Exogenous fault detection in swarm robotic systems* [Doctoral dissertation, University of York]. University of York. <https://etheses.whiterose.ac.uk/15533/>
- Mnih, V., Badia, A. P., Mirza, M., Graves, A., Lillicrap, T., Harley, T., Silver, D., & Kavukcuoglu, K. (2016). Asynchronous Methods for Deep Reinforcement Learning. In M. F. Balcan & K. Q. Weinberger (Eds.), *Proceedings of The 33rd International Conference on Machine Learning* (pp. 1928–1937, Vol. 48). PMLR. <https://proceedings.mlr.press/v48/mniha16.html>
- Moosavi, S., Djerdir, A., Ait-Amirat, Y., & Khaburi, D. (2015). ANN based fault diagnosis of permanent magnet synchronous motor under stator winding shorted turn. *Electric Power Systems Research*, 125, 67–82. <https://doi.org/10.1016/j.epsr.2015.03.024>
- Muhammed, T., & Shaikh, R. A. (2017). An analysis of fault detection strategies in wireless sensor networks. *Journal of Network and Computer Applications*, 78, 267–287. <https://doi.org/10.1016/j.jnca.2016.10.019>

KAYNAKLAR DİZİNİ

- NVIDIA. (2024). Jetson TX2 Module [Erişim tarihi: 30.04.2024]. <https://developer.nvidia.com/embedded/jetson-tx2>
- Oh, M.-h., & Iyengar, G. (2019). Sequential Anomaly Detection using Inverse Reinforcement Learning. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 1480–1490. <https://doi.org/10.1145/3292500.3330932>
- Oh, Y., Kim, Y., Na, K., & Youn, B. D. (2022). A deep transferable motion-adaptive fault detection method for industrial robots using a residual-convolutional neural network. *ISA Transactions*, 128, 521–534. <https://doi.org/10.1016/j.isatra.2021.11.019>
- OpenRobotics. (2024). ROS - Robot Operating System [Erişim tarihi: 30.04.2024]. <https://www.ros.org/>
- Orr, J., & Dutta, A. (2023). Multi-Agent Deep Reinforcement Learning for Multi-Robot Applications: A Survey. *Sensors*, 23(7), Article e3625. <https://doi.org/10.3390/s23073625>
- Osmani, K., Haddad, A., Lemenand, T., Castanier, B., Alkhedher, M., & Ramadan, M. (2023). A critical review of PV systems' faults with the relevant detection methods. *Energy Nexus*, 12, 100257. <https://doi.org/10.1016/j.nexus.2023.100257>
- Ozkan, M., Kirlik, G., Parlaktuna, O., Yufka, A., & Yazici, A. (2010). A Multi-Robot Control Architecture for Fault-Tolerant Sensor-Based Coverage. *International Journal of Advanced Robotic Systems*, 7(1), 67–74. <https://doi.org/10.5772/7252>
- Pan, J., Qu, L., & Peng, K. (2023). Research on robotic manipulator fault detection and diagnosis technology based on machine vision in complex environments. *Journal of Field Robotics*, 40(2), 231–242. <https://doi.org/10.1002/rob.22125>
- Patil, A., Soni, G., Prakash, A., & Karwasra, K. (2022). Maintenance strategy selection: a comprehensive review of current paradigms and solution

KAYNAKLAR DİZİNİ

- approaches. *International Journal of Quality & Reliability Management*, 39(3), 675–703. <https://doi.org/10.1108/IJQRM-04-2021-0105>
- Pinto, R., & Cerquitelli, T. (2019). Robot fault detection and remaining life estimation for predictive maintenance [The 10th International Conference on Ambient Systems, Networks and Technologies (ANT 2019) / The 2nd International Conference on Emerging Data and Industry 4.0 (EDI40 2019) / Affiliated Workshops]. *Procedia Computer Science*, 151, 709–716. <https://doi.org/10.1016/j.procs.2019.04.094>
- Polverino, L., Abbate, R., Manco, P., Perfetto, D., Caputo, F., Macchiaroli, R., & Caterino, M. (2023). Machine learning for prognostics and health management of industrial mechanical systems and equipment: A systematic literature review. *International Journal of Engineering Business Management*, 15, 18479790231186848. <https://doi.org/10.1177/18479790231186848>
- PostgreSQL. (2024). What is PostgreSQL? [Erişim tarihi: 30.04.2024]. <https://www.postgresql.org/about/>
- Roos, N., ten Teije, A., & Witteveen, C. (2003). A protocol for multi-agent diagnosis with spatially distributed knowledge. *Proceedings of the Second International Joint Conference on Autonomous Agents and Multiagent Systems*, 655–661. <https://doi.org/10.1145/860575.860681>
- Roos, N., & Witteveen, C. (2009). Models and methods for plan diagnosis. *Autonomous Agents and Multi-Agent Systems*, 19(1), 30–52. <https://doi.org/10.1007/s10458-007-9017-6>
- Roumeliotis, S., Sukhatme, G., & Bekey, G. (1998). Sensor fault detection and identification in a mobile robot. *Proceedings. 1998 IEEE/RSJ International Conference on Intelligent Robots and Systems. Innovations in Theory, Practice and Applications (Cat. No.98CH36190)*, 3, 1383–1388. <https://doi.org/10.1109/IROS.1998.724781>

KAYNAKLAR DİZİNİ

- Ryalat, M., ElMoaqet, H., & AlFaouri, M. (2023). Design of a Smart Factory Based on Cyber-Physical Systems and Internet of Things towards Industry 4.0. *Applied Sciences*, 13(4), Article e2156. <https://doi.org/10.3390/app13042156>
- Saeedi, S., Moussa, A., & El-Sheimy, N. (2014). Context-Aware Personal Navigation Using Embedded Sensor Fusion in Smartphones. *Sensors*, 14(4), 5742–5767. <https://doi.org/10.3390/s140405742>
- Sahal, R., Breslin, J. G., & Ali, M. I. (2020). Big data and stream processing platforms for Industry 4.0 requirements mapping for a predictive maintenance use case. *Journal of Manufacturing Systems*, 54, 138–151. <https://doi.org/10.1016/j.jmsy.2019.11.004>
- Sahu, D., Dewangan, R. K., & Matharu, S. P. S. (2023). An Investigation of Fault Detection Techniques in Rolling Element Bearing. *Journal of Vibration Engineering & Technologies*, 2523–3939. <https://doi.org/10.1007/s42417-023-01202-1>
- Servin, A. L. (2009). *Multi-Agent Reinforcement Learning for Intrusion Detection* [Doctoral dissertation, University of York]. University of York. <https://etheses.whiterose.ac.uk/690/>
- Shen, H., Zhang, K., Hong, M., & Chen, T. (2023). Towards Understanding Asynchronous Advantage Actor-Critic: Convergence and Linear Speedup. *IEEE Transactions on Signal Processing*, 71, 2579–2594. <https://doi.org/10.1109/TSP.2023.3268475>
- Shubyn, B., Kostrzewa, D., Grzesik, P., Benecki, P., Maksymyuk, T., Sunderam, V., Syu, J.-H., Lin, J. C.-W., & Mrozek, D. (2023). Federated Learning for improved prediction of failures in Autonomous Guided Vehicles. *Journal of Computational Science*, 68, 101956. <https://doi.org/10.1016/j.jocs.2023.101956>
- Singh, B., Kumar, R., & Singh, V. P. (2022). Reinforcement learning in robotic applications: a comprehensive survey. *Artif. Intell. Rev.*, 55(2), 945–990. <https://doi.org/10.1007/s10462-021-09997-9>

KAYNAKLAR DİZİNİ

- Soualhi, M., Nguyen, K., Medjaher, K., Lebel, D., & Cazaban, D. (2020). Data-driven diagnostics of positioning deviations in multi-axis robots for smart manufacturing [21st IFAC World Congress]. *IFAC-PapersOnLine*, 53(2), 10330–10335. <https://doi.org/10.1016/j.ifacol.2020.12.2769>
- Stancliff, S. B., Dolan, J., & Trebi-Ollennu, A. (2009). Planning to fail — Reliability needs to be considered a priori in multirobot task allocation. *2009 IEEE International Conference on Systems, Man and Cybernetics*, 2362–2367. <https://doi.org/10.1109/ICSMC.2009.5346359>
- Steinbauer, G. (2013). A Survey about Faults of Robots Used in RoboCup. In X. Chen, P. Stone, L. E. Sucar, & T. van der Zant (Eds.), *RoboCup 2012: Robot Soccer World Cup XVI* (pp. 344–355). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-39250-4_31
- Sun, Y.-s., Ran, X.-r., Li, Y.-m., Zhang, G.-c., & Zhang, Y.-h. (2016). Thruster fault diagnosis method based on Gaussian particle filter for autonomous underwater vehicles. *International Journal of Naval Architecture and Ocean Engineering*, 8(3), 243–251. <https://doi.org/10.1016/j.ijnaoe.2016.03.003>
- Sutton, R. S., & Barto, A. G. (1998). *Reinforcement learning: An introduction*. MIT press.
- Uckun, S., Goebel, K., & Lucas, P. J. (2008). Standardizing research methods for prognostics. *2008 International Conference on Prognostics and Health Management*, 1–10. <https://doi.org/10.1109/PHM.2008.4711437>
- Van, M., Ge, S. S., & Ceglarek, D. (2018). Fault Estimation and Accommodation For Virtual Sensor Bias Fault in Image-Based Visual Servoing Using Particle Filter. *IEEE Transactions on Industrial Informatics*, 14(4), 1312–1322. <https://doi.org/10.1109/TII.2017.2723930>
- Van, M., & Kang, H.-J. (2015). Robust fault-tolerant control for uncertain robot manipulators based on adaptive quasi-continuous high-order sliding mode and neural network. *Proceedings of the Institution of Mechanical Engineers, Part*

KAYNAKLAR DİZİNİ

- C: *Journal of Mechanical Engineering Science*, 229(8), 1425–1446.
<https://doi.org/10.1177/0954406214544311>
- Vaniya, V., & Chudasama, K. (2023). Induction motor stator, rotor and bearing faults: A review. *AIP Conference Proceedings*, 2855(1), 070006. <https://doi.org/10.1063/5.0168725>
- Verma, V., Gordon, G., Simmons, R., & Thrun, S. (2004). Real-time fault diagnosis [robot fault diagnosis]. *IEEE Robotics & Automation Magazine*, 11(2), 56–66. <https://doi.org/10.1109/MRA.2004.1310942>
- Wang, H., Xu, J., Sun, C., Yan, R., & Chen, X. (2022). Intelligent Fault Diagnosis for Planetary Gearbox Using Time-Frequency Representation and Deep Reinforcement Learning. *IEEE/ASME Transactions on Mechatronics*, 27(2), 985–998. <https://doi.org/10.1109/TMECH.2021.3076775>
- Wang, S., Tao, J., Jiang, Q., Chen, W., & Liu, C. (2024). Manipulator joint fault localization for intelligent flexible manufacturing based on reinforcement learning and robot dynamics. *Robotics and Computer-Integrated Manufacturing*, 86, 102684. <https://doi.org/10.1016/j.rcim.2023.102684>
- Wang, X., Wang, Z., Xu, Z., Cheng, M., Wang, W., & Hu, Y. (2019). Comprehensive Diagnosis and Tolerance Strategies for Electrical Faults and Sensor Faults in Dual Three-Phase PMSM Drives. *IEEE Transactions on Power Electronics*, 34(7), 6669–6684. <https://doi.org/10.1109/TPEL.2018.2876400>
- Wang, Y.-H., Li, T.-H. S., & Lin, C.-J. (2013). Backward Q-learning: The combination of Sarsa algorithm and Q-learning. *Engineering Applications of Artificial Intelligence*, 26(9), 2184–2193. <https://doi.org/10.1016/j.engappai.2013.06.016>
- Wu, T., & Ortiz, J. (2019). Towards Adaptive Anomaly Detection in Buildings with Deep Reinforcement Learning. *Proceedings of the 6th ACM International Conference on Systems for Energy-Efficient Buildings, Cities, and Transportation*, 380–382. <https://doi.org/10.1145/3360322.3361011>

KAYNAKLAR DİZİNİ

- Yakhni, M. F., Cauet, S., Sakout, A., Assoum, H., Etien, E., Rambault, L., & El-Gohary, M. (2023). Variable speed induction motors' fault detection based on transient motor current signatures analysis: A review. *Mechanical Systems and Signal Processing*, 184, 109737. <https://doi.org/10.1016/j.ymssp.2022.109737>
- Yang, H., Zhao, J., Xiong, Z., Lam, K.-Y., Sun, S., & Xiao, L. (2021). Privacy-Preserving Federated Learning for UAV-Enabled Networks: Learning-Based Joint Scheduling and Resource Management. *IEEE Journal on Selected Areas in Communications*, 39(10), 3144–3159. <https://doi.org/10.1109/JSAC.2021.3088655>
- Yang, Y., & Whinston, A. (2023). A Survey on Reinforcement Learning for Combinatorial Optimization. *2023 IEEE World Conference on Applied Intelligence and Computing (AIC)*, 131–136. <https://doi.org/10.1109/AIC57670.2023.10263956>
- Yu, M., & Sun, S. (2020). Policy-based reinforcement learning for time series anomaly detection. *Engineering Applications of Artificial Intelligence*, 95, 103919. <https://doi.org/10.1016/j.engappai.2020.103919>
- Zha, D., Lai, K.-H., Wan, M., & Hu, X. (2020). Meta-AAD: Active Anomaly Detection with Deep Reinforcement Learning. *2020 IEEE International Conference on Data Mining (ICDM)*, 771–780. <https://doi.org/10.1109/ICDM50108.2020.00086>
- Zhang, D., Lin, Z., & Gao, Z. (2018). A Novel Fault Detection with Minimizing the Noise-Signal Ratio Using Reinforcement Learning. *Sensors*, 18(9), Article e3087. <https://doi.org/10.3390/s18093087>
- Zhang, F., Chen, M., Zhu, Y., Zhang, K., & Li, Q. (2023). A Review of Fault Diagnosis, Status Prediction, and Evaluation Technology for Wind Turbines. *Energies*, 16(3), Article e1125. <https://doi.org/10.3390/en16031125>
- Zhang, L.-S., Gao, X.-L., Liu, X.-H., Zhang, Z.-J., Cao, R., Cheng, H.-C., Wang, M.-Y., Yan, X.-Y., & Yang, S.-C. (2022). CHAIN: unlocking

KAYNAKLAR DİZİNİ

- informatics-aided design of Li metal anode from materials to applications. *Rare Metals*, 41(5), 1477–1489. <https://doi.org/10.1007/s12598-021-01925-8>
- Zhao, X., & Chidambareswaran, T. (2023). Autonomous Mobile Robots in Manufacturing Operations. *2023 IEEE 19th International Conference on Automation Science and Engineering (CASE)*, 1–7. <https://doi.org/10.1109/CASE56687.2023.10260631>
- Zhong, C., Gursay, M. C., & Velipasalar, S. (2019). Deep Actor-Critic Reinforcement Learning for Anomaly Detection. *2019 IEEE Global Communications Conference (GLOBECOM)*, 1–6. <https://doi.org/10.1109/GLOBECOM38437.2019.9013223>
- Zhou, K., Wang, W., Hu, T., & Deng, K. (2021). Application of Improved Asynchronous Advantage Actor Critic Reinforcement Learning Model on Anomaly Detection. *Entropy*, 23(3), Article e274. <https://doi.org/10.3390/e23030274>
- Zhou, Z., Chen, X., Li, E., Zeng, L., Luo, K., & Zhang, J. (2019). Edge Intelligence: Paving the Last Mile of Artificial Intelligence With Edge Computing. *Proceedings of the IEEE*, 107(8), 1738–1762. <https://doi.org/10.1109/JPROC.2019.2918951>
- Zhu, J.-W., Dong, Z.-Y., Yang, Z.-J., & Wang, X. (2023). A New Reinforcement Learning Fault-Tolerant Tracking Control Method With Application to Baxter Robot. *IEEE/ASME Transactions on Mechatronics*, 1–11. <https://doi.org/10.1109/TMECH.2023.3309888>
- Zou, B., Zhang, L., Xue, X., Tan, R., Jiang, P., Ma, B., Song, Z., & Hua, W. (2023). A Review on the Fault and Defect Diagnosis of Lithium-Ion Battery for Electric Vehicles. *Energies*, 16(14), Article e5507. <https://doi.org/10.3390/en16145507>