

Mobil Manipulatörler için Derin Öğrenme Tabanlı Arıza Teşhis Sistemi

Zekican YILMAZ^{1*}, Tolga YÜKSEL¹⁺

¹Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi Elektrik Elektronik Mühendisliği

*İlgili Yazar: zekican.yilmaz@tedu.edu.tr

*Konuşmacı: zekican.yilmaz@tedu.edu.tr

+ tolga.yuksel@bilecik.edu.tr

Özetçe - Mobil manipulatörler, çeşitli endüstrilerde önemli bir rol oynamakta olup, üretim ve lojistikten sağlık hizmetleri ve felaket müdahalesine kadar birçok göreve katkı sağlamaktadır. Bu nedenle dünya genelinde çeşitli endüstriler büyüdükçe mobil manipulatörlerin de büyümesi gerekmektedir ve bu da güvenilir çalışmalarının büyük bir öneme sahip olmasını gerektirmektedir. Bu makale, mobil manipulatörler için derin öğrenme tekniklerini kullanarak arıza teşhis sisteminin geliştirilmesine yönelik yeni bir yaklaşım sunmaktadır. Geleneksel arıza teşhis yöntemleri, karmaşık kurallara dayalı bir sistem ve uzman bilgisi gerektirir ki bu da sürdürme ve geliştirme açısından zorlayıcı olabilir. Bu çalışmada robot mobil manipulatörün her bir eklemi modellenerek, modellenen eklemlere belirli hareketler yaptırılmıştır ve veriler kayda alınmıştır. Sonrasında elde edilen verilere belli oranlarda eklem arızası verilmiştir ve eklem arızaları her bir eklem için aynı zamanda verilmiştir. Arıza verilen eklemlerde derin öğrenme yöntemi kullanılarak, gerçeğe en yakın sonuç elde edilmeye çalışılmıştır, önerilen sistemde, özellikle evrimsel sinir ağları gibi derin öğrenme algoritmalarından yararlanarak, eklemlerine dayalı olarak arızaları otomatik olarak öğrenmiştir ve Kuka Youbot'un dinamikleri arıza teşhisi için kullanılmıştır. Arıza, eklemlerinden elde edilen verilerden tespit edilmiştir ve bu veriler, Yapay Sinir Ağı (YSA) kullanılarak bir karar yapısı aracılığıyla işlenerek karar verilmiştir.

Abstract – Mobile manipulators play a significant role in various industries, contributing to a wide range of tasks from production and logistics to health care and disaster response. As various industries grow globally, there's a corresponding need for the growth of mobile manipulators, emphasizing the importance of their reliable operation. This paper presents a novel approach to developing a fault diagnosis system for mobile manipulators using deep learning techniques. Traditional fault diagnosis methods rely on a complex rule-based system and expert knowledge, which can be challenging to maintain and develop. In this study, each joint of the robotic mobile manipulator was modeled, subjected to specific movements, and the data were recorded. Subsequently, joint failures were introduced to the collected data at certain ratios, and these failures were simultaneously applied for each joint. Using deep learning techniques on the joints with induced faults, efforts were made to obtain results closest to reality. The proposed system, deep learning algorithms like convolutional neural networks, automatically learns faults based on their joints. The dynamics of the Kuka Youbot were used for fault diagnosis. Faults were detected from the data obtained from its joints, and this data was processed through a decision structure using Artificial Neural Networks (ANN) to make a determination.

Keywords – hata teşhisi; yapay sinir ağı; mobil manipulatör

I. GİRİŞ

Mobil manipulatörler, mobil platformların hareketliliğini kullanarak robot kol ile birleşmiş robotik sistemlerdir. İmalat uygulamaları bulunan büyük endüstrilerde çalışma alanına sahiptirler. Mobil manipulatörlerin yetenekleri olan, navigasyon ve hareketlilik kullanarak karmaşık görevleri yerine getirme özellikleri olduğu kabul edilmiştir, bu nedenle güvenli ve verimli işlem için hareket planlama tekniklerine ihtiyaç duyarlar. Birçok araştırmacı, bu teknikler için birçok yaklaşım bulmuşlardır ve bu tekniklerden bazıları şunlardır: mobil manipulatörün tüm eklemleri için ters kinematik öğrenme çerçevesi, bu teknikte fazla veri sorununu çözmek için, kolun ve mobilin her ikisinin de eklem açılarını bulmak gereklidir; bu, son hareketinin istenilen bir son yolunu takip etmesini sağlayacaktır [1], fakat veriler arttıkça yani hareket arttıkça mobil robotun önceki hareketi bulması ve açıları takip etmesi zorlaşacaktır. Bir diğer yöntem ise; Hareket Eden Bir Manipulatör için Kendi Kendine Çarpışma Önleme, kendi kendine çarpışma tespitini, proprioseptif veya eksteroseptif sensörler kullanarak algılaması ve reaktif olarak sensör tabanlı kaçınma hareketi üretmesi [2], fakat bu yöntemde de dikkat

çeken konu ise maliyet olacaktır, çünkü sensör maliyeti mobil robotun maliyetini arttıracaktır, öteki taraftan ise sensörlerde arıza meydana geldiğinde veya dış etmen kaynaklı problem görüldüğünde ekstra bakım gerektirmektedir. "İstatistiksel modelleme, makine öğrenimi ve hibrit gradyan artırma kullanarak robot kollarında arıza tespiti" çalışmasında belirtilen, Algoritma modelleme kültürü, genellikle en öngörücü modeli bulmaya odaklanmaktadır. Burada "kara kutu model" olarak adlandırılan bu model, karmaşık bir yapıya sahip olabilir ve birçok değişkeni kullanabilir. [3] tüm makine öğrenimini otomatikleştirmeyi amaçlar, özel gereksinimler eklendikçe Otomatik Makine Öğrenimi'ni zorlaştırır. Bu, ağı tahmin edilen çıkışları ile istenen çıkışlar arasındaki hata miktarını en aza indirmeyi amaçlayan tekrarlı bir algoritmadır [4]. Bu yaklaşım, çeşitli dizi-diziyi dönüştürme görevlerine uygulanabilen sinir ağları kullanarak dizi öğrenme için genel bir yaklaşım sunar. Bu yaklaşım, dizinin yapısı hakkında minimal varsayımlar yapılacak şekilde tasarlanmıştır. Günümüzde popüler olan ve uygulanan ise derin öğrenme tekniğidir, sistem davranışını inceleyerek hatayı erken tespit edebilir, maliyet bakımından da ekstra bakım gerektirmez,

aynı zamanda derin öğrenme yeni hata örgülerini tespit edebilir.

Veri analizi yapılırken, teknik bazlı model seçimi çalışma için önemlidir, bir durum bilgisinin sağlanması için Kalman filtresi kullanılır, Kalman filtresi giriş-çıkış bilgisine dayanan gerçek çıkış ve tahmini çıkışı karşılayıp durum bilgisi sağlar ve bu şekilde yorum yapılabilecek duruma gelinmiş olunur.

Bu çalışmada Kuka Youbot'un dinamikleri arıza teşhisi için kullanılmıştır. Kuka Youbot 5 serbestlik derecesinde ekleme sahiptir ve 4 adet mecanum tekerleği 45 derecelik açıyla hareket etmesine sağlar. Denavit Hartenberg parametreleri Kuka Youbot'un Matlab üzerinden modellenmesini sağlamaktadır.

Bu çalışmada, Kuka Youbot 5 serbestlik derecesine sahip eksenli mobil robot sisteminin veriye dayalı arıza teşhisi için LTSM ve NNT Levenberg-Marquardt algoritması arıza teşhis sistemi için kullanılmıştır.

İzleyen bölümde, 5 Eksenli mobil manipülatör modeli açıklanmaktadır, sonrasında modellenen mobil manipülatörün Bölüm B'de YSA ve Derin Öğrenme Kullanılarak Arıza Teşhisi'nin nasıl olacağı açıklanmaktadır. III. Bölüm'de sonuçlar, IV. Bölümde tartışma ve son olarak da V. Bölüm'de Özet bulunmaktadır.


II. 5 EKSENLİ MOBİL MANİPÜLATÖR MODELİ

Bu çalışmada model olarak MATLAB'ta Denavit Hartenberg (DH) İleri (Forwards) ve Ters (Inverse) kinematik denklemleri kullanılarak Kuka Youtbot 5 eksenli mobil robot manipülatör modeli kullanılmıştır. Bu model 5 ekleme sahipken aynı zamanda 4 adet mecanium tekerleğe sahiptir, bu da modele hareketlilikte çeşitliliği sağlar. Bu modelde 5 eksenin ve 4 tekerleğin hareketleri ayrı ayrı dinamikleri ve çevresel etkileri de incelenebilir. Modelde 5 eklem ve 4 tekerlek, farklı durumlarda konumlandırılmış ve konumlandırılma esnasında yaptığı hareketlerden iki konfigürasyon arasındaki ortak uzay yörüngesi hesaplanmıştır. Yapılan çalışmada her bir eklem için PID kontrolcüsü kullanılmıştır. Şekil 1'de Kuka Youbot görünümü, Şekil 2'de ise koordinat yerleşimleri gösterilmiştir


Mobil robota dair DH parametreleri Tablo 1'de verilmiştir;

Tablo. 1 Kuka Youbot DH parametreleri

Eklem	a (mm)	α (rad)	d (mm)	θ (rad)
1	33	$\frac{\pi}{2}$	147	θ_1
2	155	0	0	θ_2
3	135	0	0	θ_3
4	0	$\frac{\pi}{2}$	0	θ_4
5	0	0	217,5	θ_5



Şekil 1. Kuka Youbot Görünümü



Şekil 2. Koordinat Yerleşimi

Daha sonra da aşağıda gösterilen (1), (2), (3), (4) ve (5) DH tablosu kullanılarak, manipülatörün kinematik modeli bulunur.

$${}^0T_1(\theta_1) = \begin{bmatrix} \cos(\theta_1) & 0 & \sin(\theta_1) & 0.033\cos(\theta_1) \\ \sin(\theta_1) & 0 & -\cos(\theta_1) & 0.33(\sin(\theta_1)) \\ 0 & 1 & 0 & 0.147 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (1)$$

$${}^1T_2(\theta_2) = \begin{bmatrix} \cos(\theta_2) & -\sin(\theta_2) & 0 & 0.155\cos(\theta_2) \\ \sin(\theta_2) & \cos(\theta_2) & 0 & 0.155(\sin(\theta_2)) \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2)$$

$${}^2T_3(\theta_3) = \begin{bmatrix} \cos(\theta_3) & -\sin(\theta_3) & 0 & 0.135\cos(\theta_3) \\ \sin(\theta_3) & \cos(\theta_3) & 0 & 0.135(\sin(\theta_3)) \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3)$$

$${}^3T_4(\theta_4) = \begin{bmatrix} \cos(\theta_4) & 0 & \sin(\theta_4) & 0 \\ \sin(\theta_4) & 0 & -\cos(\theta_4) & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4)$$

$${}^4T_5(\theta_5) = \begin{bmatrix} \cos(\theta_5) & -\sin(\theta_5) & 0 & 0 \\ \sin(\theta_5) & \cos(\theta_5) & 0 & 0 \\ 0 & 0 & 1 & 0.2175 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (5)$$

mT_e aşağıdaki (6) şekilde tanımlanır:

$${}^mT_e = {}^0T_1(\theta_1) {}^1T_2(\theta_2) {}^2T_3(\theta_3) {}^3T_4(\theta_4) {}^4T_5(\theta_5) \quad (6)$$

Robot değişkeni q mobil manipülatörler için (7) şeklindedir:

$$q = [x_b \ y_b \ \theta_b \ \theta_1 \ \theta_2 \ \theta_3 \ \theta_4 \ \theta_5]^T \quad (7)$$

Eklem θ_1 - θ_5 değerleri, manipülatörün eklem konfigürasyonudur, $x_b \ y_b \ \theta_b$ mobil platformun sırasıyla konum ve yönelim değişkenleridir,


Bu denklem robotun anlık koordinatlarını verir ve robot eklem hareket yolları robotun her bir eklem için zaman içinde izlediği yolu tanımlamaktadır. Robot eklem hareket yollarının matematiksel ifade edilmesi için kuadratik polinom fonksiyonları kullanılmaktadır. Diğer çalışmalarda şu şekilde açıklanabilir; Endüstriyel robotun her eklem yörüngesi genellikle ikinci dereceden bir polinom fonksiyonu ile ifade edilecektir, dolayısıyla bu optimizasyon probleminde eklem sarsıntısı kısıtlaması dikkate alınacaktır [5]. Kuadratik polinom fonksiyonlarının kullanılıp robotun A noktasından B noktasına gittiği hareketin zamana bağlı değişimini verir ve endüstriyel robotların verimle ve güvenli bir biçimde çalışmasını sağlar, fakat bu çalışmada kuadratik polinom fonksiyonu veri almak amacıyla kullanılmıştır. Hareketin zamana bağlı değişimi kuadratik polinom ile (8)'deki şekilde ifade edilir:

$$P(x) = ax^2 + bx + c \quad (8)$$

Bu fonksiyon, robotun hareket edebileceği yolu temsil eder. Bu fonksiyonda x ile temsil edilen zaman veya başka bağımsız değişken olabilir, ama bu çalışmada $P(x)$ robotun hızını ve konumunu temsil eder.

A. Manipülatör Eklemelerinin SIMULINK'te Modellenmesi ve Arıza Verisi Toplama

Modellenen manipülatör eklemelerinin Simulink gösterilimi Şekil 3'te verilmiştir,



Şekil 3. Simulink Eklem Modeli

Hazırlanan PID modelinde, PID kullanılarak mevcut hata oranıyla üretilen çıkışları geri besleme yaparak sisteme tekrardan gönderir ve integral ve türevinden faydalanarak biriken hataların zaman içindeki değişim oranına bağlı olarak sonraki gelecek hatayı tahmin eder bu sayede sistemde süreklilik sağlanır. Sürekliliğin sağlanmasında transfer fonksiyonda kullanılan J ve B verilerinin önemi büyüktür, modelleme esnasında mekanik terimleri temsil eder. J eylemsizlik momenti yani yapılan dönme hareketine karşı gösterilen dirençtir, bu direnç cismin kütlesine ve malzemesine bağlı olarak değişir, sistemin başlaması veya durması için ne kadar tork gerektiğinin hesabı yapılır. B ise viskoz sönüm katsayısıdır, bu da dönme hareketinin hızıyla birlikte olan enerji kaybını temsil eder. J ve B değeri modellenen sistemin gerçek tepkisinin nasıl olacağını tahmini için önemlidir. Aşağıdaki Tablo 2'de bu sistem için kullanılan her eklem için J ve B değerleri gösterilmiştir

Tablo 2. kullanılan sistemdeki eklem için J ve B değerleri


Eklem Adı	J Değeri	B Değeri
1. Eklem	0.006	40
2. Eklem	0.006	40
3. Eklem	0.006	20
4. Eklem	0.0814	8
5. Eklem	0.0734	20
6. Eklem (Sol ön tekerlek)	0.006	40
7. Eklem (Sol arka tekerlek)	0.006	40
8. Eklem (Sağ ön tekerlek)	0.006	40
9. Eklem (Sağ arka tekerlek)	0.006	40

PID kontrolü, manuel üretime ve PID'siz sistemlere kıyasla üretim hızını önemli ölçüde artırır. PID kontroller için tuning (ayarlar), kontrolcünün performansı açısından çok önemlidir. MATLAB tuning ayarını kendi fonksiyonu ile en iyi değeri otomatik olarak ayarlar. PID Tuning ile ayarlanmış eklemeler için PID katsayıları Tablo 3'te verilmiştir;

Tablo 3. Eklemelerin PID katsayıları

Eklem Adı	P Katsayısı	I Katsayısı	D Katsayısı
1. Eklem	53.503	712947.324	-0.00029
2. Eklem	53.503	712947.324	-0.00029
3. Eklem	26.751	178236.831	-0.00029
4. Eklem	10.700	2102.05599	-0.00395
5. Eklem	26.751	14569.768	-0.00356
6. Eklem (Sol ön tekerlek)	53.503	712947.324	-0.00029
7. Eklem (Sol arka tekerlek)	53.503	712947.324	-0.00029
8. Eklem (Sağ ön tekerlek)	53.503	712947.324	-0.00029
9. Eklem (Sağ arka tekerlek)	53.503	712947.324	-0.00029

Örnek; beşinci eklem için PID tuning sonrası grafiği Şekil 4'te gösterilmiştir;



Şekil 4. Beşinci eklem için Tuning sonrası basamak cevabı

PID parametreleri uygulandıktan sonra, her bir eklem için %30, %40, %50, %60 ve %70 oranında $T=0.5$ anında arıza verilmiştir. Bu sayede arıza teşhis sisteminin test edilmesi için gereken temel hazırlanmıştır. Arızalar verildikten sonra, simulink'teki elde edilen veriler tek bir matris üzerinde oluşturulur ve oluşturulan matris şunları içerir; ilk satırda eklemdeki hareketin zamana bağlı değişimi, ikinci satırda PID sonrası tuning edilmiş veriler, üçüncü satırda transfer fonksiyonu bloğunun çıkışındaki veriler, dördüncü satırda $1/s$ integratörü eklenir integratör, eklem için dinamik hareketini (konumunu, hızını ve ivmesini) simüle etmek için

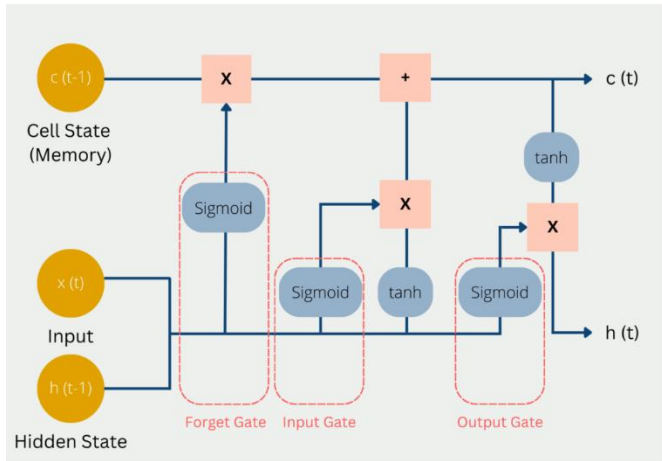
gereklidir ve son olarak 5. Satırda zaman bulunmaktadır. Böylece her bir eklem için 5×7379 boyutlu veriler elde edilmiş ve uygulanmıştır.

III. BENZETİM ÇALIŞMALARI

Bu çalışmada arıza teşhisi için neural network (NN) ve Long Short-Term Memory (LSTM) kullanılmıştır. Giriş verisi olarak PID çıkışlarından elde edilen 5×7379 veriler her bir eklem için verilmiştir, çıkış olarak ise olması beklenen $T=0.5$ anında arıza verilmeyen hareket verilmiştir, verilen giriş bilgileriyle doğru çıkışın tahmin edilmesi ve gerçek veriler ile arasındaki uyumun ölçülmesi buradaki amaç olarak tanımlanır. Özetle, amaç sistemin normal çalışma koşullarını öğrenerek ardından arızaları tespit veya tahmin etmek için LSTM veya NN modeli oluşturmak ve kullanmaktır. Daha sonra arızalı verilerin girişi modele verilir ve çıkış olarak tahminler üretilir. İlgili çalışmada da belirtildiği gibi; Burada arıza tespiti bir zaman serisi tahmin problemi olarak ele alınır [6]. Öğrenme algoritmalarının dikkatli seçilmesi için arızalı ve eğitilmiş eklem çıkışı başka eklemelerin çıkışına verilir benzerlik de tespit edilmiş olunur bu şekilde hem model genişlemiş olur hem de algoritma seçimi önem kazanmış olur.

Araç olarak, NN kullanılmıştır. YSA'da 3 katmanlı eğitim metodu olan Levenberh-Marguardt çalışılmıştır, aktivasyon fonksiyon tipi TANSIG olarak alınmıştır, nöron sayıları ilk iki katmanda 10 olarak seçilmiştir, bu da 10 adet giriş değişkeni olduğunu belirtir, ikinci katman ise gizli katmandır ağız öğrenme yeteneğini destekler bu katmanda da 10 nöron bulunur. Üçüncü katman ise ağız çıkış veren katmandır.

LSTM, YSA'da öğrenme zorluklarını aşmak için kullanılır, içinde ise tam bağlantılı katman ve regresyon katmanlarından oluşmuştur, Bu kapama birimlerinin tanıtılması, tüm zincir boyunca kolay bilgi akışını mümkün kılar, bu nedenle gradyanın kaybolma sorunu ortadan kaldırılabilir ve uzun süreli bağımlılıkları öğrenme yeteneğine sahip olabilir [7]. Giriş kapısı, yeni bilgiyi hafızaya almayacağını kararını verir, unutma kapısı; hafızada bulunan eski verilerden hangilerinin unutulacağına karar verir ve son olarak da çıkış kapısı hafızanın mevcut durumunu değerlendirerek hangi bilginin üretileceğine karar verir. Bir karar mekanizması olması gürültünün azaltılmasında da etki gösterir. Şekil 5'te LSTM yapısı basit olarak gösterilmiştir;




Şekil 5. LSTM Yapısı

Bu ağların eğitim sonucunda elde edilen MSE değerleri Tablo 4'te verilmiştir:


Tablo 4. MSE Değerleri

Eklem No:	NN MSE Değeri	LSTM MSE Değeri
1.Eklem	0.0078	0.0081
2.Eklem	0.0065	0.0112
3.Eklem	0.0075	0.0073
4.Eklem	0.0063	0.0784
5.Eklem	0.0069	0.0066
6.Eklem	0.0034	0.0021
7.Eklem	0.0092	0.0016
8.Eklem	0.0038	0.0021
9.Eklem	0.0057	0.0023


Arıza durumuna göre YSA veya LSTM kullanımı MSE değerlerinin yanında eğitim başarımı deneme yanılma ile de belirlenmiştir. Özellikle her iterasyonda ya da epoch'ta elde edilen MSE değerlerinin yakınsamasına da bakılmaktadır. Eğer MSE değeri her iterasyonda azalıyor, bu modelin eğitim verisine yakınsadığını gösterir. NN ile yakınsama örnekleri Şekil 6'da gösterilmiştir, grafikteki mavi çizgi gerçek durumu, kırmızı ise yakınsamayı göstermektedir;




Şekil 6.a. 1. Eklem yakınsama örneği




Şekil 6.a. 2. Eklem yakınsama örneği




Şekil 6.a. 3. Eklem yakınsama örneği




Şekil 6.a. 4. Eklem yakınsama örneği




Şekil 6.a. 5. Eklem yakınsama örneği




Şekil 6.a. 6. Eklem yakınsama örneği



Şekil 6.a. 7. Eklem yakınsama örneği



Şekil 6.a. 8. Eklem yakınsama örneği



Şekil 6.a. 9. Eklem yakınsama örneği

Önerilen arıza tespit sisteminin nasıl çalıştığını göstermek için robotun her bir eklemine 5 farklı hareket ve %70, %60, %50, %40 ve %30 oranında arıza verilmiştir aynı zamanda tekerleklerine de verilmiştir. Bu arızalar $T=0.5$ anında verilmiştir, bu da 0.5 anında tekabül ettiği yerde bozulmaya başlamıştır.

IV. SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada Mobil Manipülatörler için Derin Öğrenme Tabanlı Arıza Teşhis Sistemi üzerine odaklanılmıştır. Önerilen yöntem, modellenen mobil manipülatörün hareket verilerini derinlemesine analiz ederek arıza teşhisini gerçekleştirmektedir. Bu analiz süreci, manipülatörün eklemlerinde oluşan bozulmalara odaklanarak, $T=0.5$ saniyede farklı oranlarda (%30, %40, %50, %60 ve %70) bozulma gösteren durumları kapsamaktadır. Bu çalışmada, toplamda 9 eklem için bu oranlardaki bozulmalar ayrı ayrı ele alınmıştır. Elde edilen veriler, derin öğrenme algoritmalarından olan NN ve LSTM ile işlenmiş, bu yöntemlerin manipülatör eklemlerinde oluşan arızaları teşhis etmedeki başarısı değerlendirilmiştir. Sağlıklı kabul edilen veriler ile arızalı veri setleri karşılaştırıldığında, NN ve LSTM'nin eğitim süreçleri sonucunda belirli bir eşik değeri üzerinden arıza teşhisinde bulunduğu gözlemlenmiştir.

Sonuç olarak, bu çalışma mobil manipülatörlerin arıza teşhis süreçlerinde derin öğrenme yöntemlerinin potansiyelini ortaya koymaktadır. Gelecekte, bu alandaki çalışmaların daha geniş veri setleri ve farklı derin öğrenme modelleri ile genişletilmesi, arıza teşhis süreçlerinin daha da optimize edilmesine katkıda bulunabilir.

KAYNAKLAR

- [1] R. Raja, A. Dutta, & B. DasGupta, "Learning framework for inverse kinematics of a highly redundant mobile manipulator", *Robotics and Autonomous Systems*, vol. 120, p. 103245, 2019
- [2] K. Jang, S. Kim, & J. Park, "Reactive self-collision avoidance for a differentially driven mobile manipulator", *Sensors*, vol. 21, no. 3, p. 890, 2021
- [3] Costa, M. A., Wullt, B., Norrlöf, M., & Gunnarsson, S., "Failure detection in robotic arms using statistical modeling, machine learning and hybrid gradient boosting.", *Measurement*, 146, 425-436, 2019.
- [4] I. Sutskever, O. Vinyals, Q. Le, "Sequence to sequence learning with neural networks", In *Proceedings of NIPS*, pages 3104–3112, 2014.
- [5] G. Xiaoqing, W. Jidong, "Trajectory planning theory and method of industrial robot," 2011 3rd International Conference on Computer Research and Development, Shanghai, China, pp. 340-343, 2011
- [6] T. Wang, L. Zhang and X. Wang, "Fault Detection for Motor Drive Control System of Industrial Robots Using CNN-LSTM-based Observers," in *CES Transactions on Electrical Machines and Systems*, vol. 7, no. 2, pp. 144-152, June 2023.
- [7] Han, P., Ellefsen, A. L., Li, G., Holmeset, F. T., & Zhang, H.. Fault detection with LSTM-based variational autoencoder for maritime components. *IEEE Sensors Journal*, 21(19), 21903-21912, 2021