

Araştırma Makalesi

Yapay Zekâ Kullanımıyla Peron Ayırıcı Kapı Sisteminin Sağlığını İzleme ve Kestirimci BakımŞükrü Görgülü^{1,4,*}, İsa Koç^{1,2}, Necim Kırımça¹, Mehmet Karaköse³, Mehmet Tankut Özgen⁴¹ Ar-Ge Birimi, Albayrak Makine Elektronik San. Tic. A.Ş., Eskişehir, Türkiye² Elektrik-Elektronik Mühendisliği Bölümü, Osmangazi Üniversitesi, Eskişehir, Türkiye³ Bilgisayar Mühendisliği Bölümü, Fırat Üniversitesi, Elâzığ, Türkiye⁴ Elektrik-Elektronik Mühendisliği Bölümü, Eskişehir Teknik Üniversitesi, Eskişehir, Türkiye*Correspondence: sgorgulu@ogr.eskisehir.edu.tr

DOI: 10.51513/jitsa.1311985

Özet: Peron Ayırıcı Kapı Sistemleri (PAKS), modern metro ve hızlı transit otobüs istasyonlarında yolcu ve araç/ray arasında bir bariyer olarak kullanılan kayar kapı sistemleridir. PAKS sistemi, sadece platform ve raylar arasında bir bariyer olmakla kalmaz, aynı zamanda araçlara emniyetli iniş ve biniş imkânı da sağlar. Bu nedenle, PAKS sistemi kullanımı metro istasyonlarında hızla yaygınlaşmaktadır. Son yıllarda, PAKS sistemi ile ilgili birçok çalışma yapılmıştır. Bu çalışmalar, istasyon çevresi koşullarından, enerji tüketimine, yolcu bekleme sürelerine, acil tahliye prosedürlerine, emniyet bütünlüğü seviyesi prosedürlerine ve PAKS sisteminin kontrol ve izleme yaklaşımlarına kadar geniş bir yelpazeyi kapsamaktadır. PAKS sistemi, yolcu emniyeti için kritik bir önem taşımakta ve modern metro istasyonlarının vazgeçilmez bir özelliği haline gelmiştir. Bu nedenle, PAKS sistemi üzerine yapılan araştırmaların devam etmesi ve bu sistemlerin sürekli olarak geliştirilmesi gereklidir. Makine öğrenimi algoritmaları, hata teşhisinde önemli bir katkı sağlamakta ve bu algoritmalar sayesinde sistemin sürekli olarak geliştirilmesi hedeflenmektedir. Hata teşhisinde makine öğrenmesi yaklaşımları kullanılarak gerçekleştirilen çalışmaların sonuçları, sistemin gerçek zamanlı olarak izlenerek hataların tespit edilmesine ve giderilmesine yardımcı olmaktadır. Yapay zekâ tabanlı öngörülü bakım yaklaşımı, özellikle demiryolu sektöründe hem yolcu emniyetini hem de işletme performansını artırmak için önemlidir. Bu çalışma, makine öğrenmesi tabanlı sınıflandırma için Destek Vektör Makinesi (DVM), K-En Yakın Komşuluğu (KYK) ve Lojistik Regresyon (LR) modelleri kullanılarak tam boy PAKS sistemindeki mekanik arızaların teşhisini içermektedir. Modellerin eğitimi için PAKS sistemi tarafından sağlanan akım, gerilim, titreşim, ses, kapı pozisyonu ve kapı hızı gibi veriler kullanılmıştır. Bu verilerin istatistiksel öznitelikleri çıkarılmış ve bu öznitelikler makine öğrenimi algoritmalarında kullanılarak, eğitilmiş algoritmaların arıza tespitindeki performansları gözlenmiştir.

Anahtar Kelimeler: Akıllı Ulaşım Sistemleri, Peron Ayırıcı Kapı Sistemleri, Kestirimci Bakım, Yapay Zekâ, Makine Öğrenmesi, Durum İzleme

Health Monitoring and Predictive Maintenance of Platform Screen Door Systems Using Artificial Intelligence

Abstract: The Platform Screen Door System (PSD) is a sliding door system used as a barrier between passengers and the vehicle/rail in modern metro and Rapid Bus Transit (RBT) stations. The PSD system not only serves as a barrier between the platform and tracks but also provides safe boarding and alighting opportunities for passengers, making it a critical component of modern metro stations. Consequently, PSD systems have rapidly gained popularity and are widely used. In recent years, numerous research studies have been conducted on PSD systems, covering a broad range of topics such as station environment conditions, energy consumption, passenger waiting times, emergency evacuation procedures, safety-integrity-level (SIL) procedures, and control and monitoring approaches for PSD systems. Continued research and development of PSD systems is necessary due to their critical importance for passenger safety and their indispensable role in modern metro stations. Machine learning algorithms have played a significant role in fault diagnosis, and these algorithms can be used to improve the reliability of PSD systems. The results of studies conducted using these fault diagnosis methods could help in real-time detection and rectification of errors by monitoring system performance. Artificial intelligence-based predictive maintenance approaches are important, particularly in the railway sector, for enhancing both passenger safety and operational performance. This study focuses on the application of artificial intelligence models, such as Support Vector Machine (SVM), K-Nearest Neighbors (KNN), and Logistic Regression (LR), for the diagnosis of mechanical failures in full-scale PSD systems. The information (such as current, voltage, vibration, sound, door position, and door speed) provided by the system are processed for training the models. The features of these data were extracted and used in machine learning algorithms to diagnose faults that could occur in the system.

Keywords: Intelligent Transportation Systems, Platform Screen Door, Predictive Maintenance, Artificial Intelligence, Machine Learning, Condition Monitoring

1. Giriş

Büyük şehirlerdeki kentleşme, hava kirliliği ve trafik sıkışıklığına sebep olurken, metrolar ve trenler bu durumun azaltılması için önemli bir rol oynamaktadır. Peron Ayırıcı Kapı Sistemleri (PAKS) ise modern metro ve hızlı transit otobüs istasyonlarında yolcu ve araç/ray arasında bariyer olarak kullanılan kayar kapı sistemleridir. PAKS sistemleri, yolcuları tren raylarına erişimden korurken, istasyon enerji tüketiminin optimizasyonu, hava kalitesi kontrolü, intiharı önleme ve emniyet gibi birçok işleve hizmet etmektedir. PAKS sistemleri, sadece platform ve raylar arasında bir bariyer olmayıp aynı zamanda araçlara emniyetli iniş/biniş imkânı sağlamaktadır. PAKS kullanımının yaygınlaşmasıyla birlikte, PAKS ile ilgili yapılan araştırmalar, matematiksel modelleme ve simülasyon çalışmaları da önemli hale gelmiştir. PAKS ile ilgili yapılan çalışmalar, istasyon çevresinin koşullarından, enerji tüketimine, yapay zekâ ile hata teşhisine, yolcu bekleme sürelerine, acil tahliye prosedürlerine ve emniyet bütünlüğü seviyesi (SIL: Safety Integrity Level) prosedürlerine ve PAKS kontrolü ve izleme yaklaşımlarına kadar geniş bir yelpazeyi kapsamaktadır. PAKS ile ilintili makine öğrenmesi tabanlı çalışmalar da yelpazenin içerisinde önemli bir yer tutmaktadır (Koç vd., 2022; Li vd., 2018; Zhou vd., 2010; Abdurrahman vd., 2018; Qu vd., 2012; Lindfeldt, 2017; Su vd., 2022; Gabay, 2004; Aarnio vd., 2005; He vd., 2018; Koç vd., 2023).

Fiziksel sistemlerden elde edilen veriler makine öğrenimi (MÖ) algoritmaları ile sınıflandırılarak sistemdeki arızaların teşhisi yapılabilmektedir. Verilerin MÖ yapısına girilmeden önce çeşitli teknikler kullanılarak birtakım ön işlemlerden geçirilmesi teşhis performansını olumlu yönde etkilemektedir. Söz konusu tekniklerden biri veri özniteliklerinin çıkarılmasıdır. Ayrıca veri kalitesinin önemi konusunda da birçok çalışma yapıldığı bilinmektedir. Endüstriyel arıza teşhisi için yapay zekâ (YZ) modellerinin kullanımında zorluklarla karşılaşılsa da veri kalitesinin artırılması ve verilerin doğru şekilde işlenmesiyle birlikte YZ-tabanlı yaklaşımların kullanımı artmaktadır. Veri kalitesinin artırılması ve uygun örnekleme yöntemlerinin kullanımı, YZ modellerinin doğruluğunun artırılmasında önemlidir (Başaran vd., 2020; Ham vd., 2019; Jimenez vd., 2021; Sun vd., 2018).

Demiryolu sektöründe YZ-tabanlı hata teşhisine yönelik yaklaşımlar modele ve veriye dayalı yöntemler olmak üzere iki kategoride değerlendirilebilir. Model tabanlı yaklaşım cebirsel modellemeyle ifade edilirken, veriye dayalı yaklaşımlarda gerçek zamanlı arıza teşhisi amaçlanmaktadır. Çalışmalar, tren ve tramvay kapıları gibi belirli sistemlere ve asansör kapılarına yoğunlaşmıştır. Veri kalitesinin artırılması ve uygun işleme yöntemlerinin kullanımı, YZ modellerinin doğruluğunu arttırmak için önemlidir ve literatürde birçok çalışma bu konuya odaklanmaktadır (Li vd., 2017) (Shuai vd., 2014).


PAKS sistemleri, yolcu güvenliği için kritik önem taşımakta ve modern metro istasyonlarında yaygın bir şekilde kullanılmaktadır. Sistemin sürekli olarak geliştirilmesinde hata teşhisi çalışmaları önem arz etmektedir. Albayrak Makine Elektronik San. ve Tic. A. Ş. tarafından üretilen PAKS setleri, hata teşhisi çalışmalarına katkı sağlamaktadır ve bu bilgiler ışığında PAKS için hataların erken tespiti ve izolasyonu mümkün olmaktadır (Min vd., 2012; Koç vd., 2023). Bu çalışmada, metro istasyonlarında kullanılan tam boy PAKS sistemlerinde meydana gelebilecek mekanik arızaların teşhisinde makine öğrenmesi modellerinden yararlanılarak hata teşhisi yapıldı. Bu modellerin kullanımında PAKS sisteminden elde edilen, akım, gerilim, kapı hızı, kapı pozisyonu, ses ve titreşim verileri kullanılmıştır.

2. Peron Ayırıcı Kapı Sisteminin Yapısı

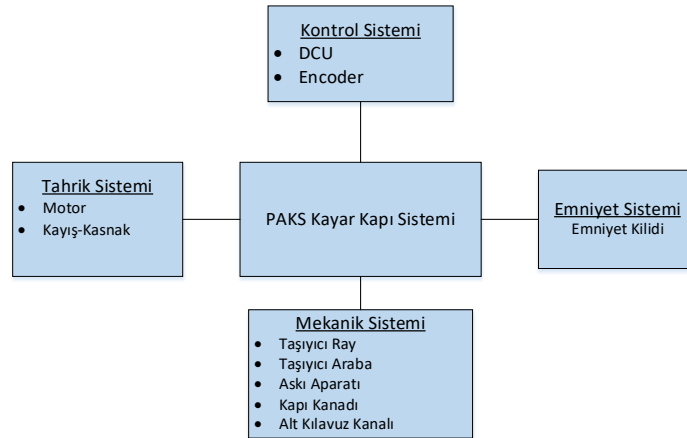
PAKS sistemi, önemli rolleri olan birçok alt bileşenden meydana gelir. Örnek bir PAKS görseli Şekil-1'de gösterilmiştir. Motor, elektronik kontrol ünitesi, kayış-kasnak ünitesi, taşıma rayı, kapı kanatları, askı aparatları ve taşıyıcı araba grubu gibi bileşenler (Şekil-2), Albayrak firması tarafından üretilen ALPSD-1000 serisindeki PAKS kayar kapı düzeneğini oluşturmaktadır. PAKS sisteminde, tahrik ünitesi, taşıma ünitesi, hareket mekanizması, kontrol ünitesi ve kapı kanadı gibi alt sistemlerin bir araya gelerek güvenli ve etkili bir şekilde çalışması sağlanmaktadır (Şekil-3). Bu alt bileşenlerin kusursuz iş birliği, PAKS sisteminin modern metro istasyonlarının vazgeçilmez bir parçası haline gelmesini sağlamaktadır (Min vd., 2012).



Şekil 1. PAKS Görseli



Şekil 2. PAKS kayar kapı sistemi görseli (Koç vd., 2023)



Şekil 3. PAKS Kayar kapısı sistem mimarisi

2.1. PAKS Sisteminden Veri Toplama Metodu


Çalışmada, metotların belirlenmesinde ve süreçlerin tanımlanmasında ISO-13379-1, ISO-13374-1 ve ISO-13380 (Makinelerin durumunun izlenmesi ve teşhisi- Veri yorumlama ve teşhis teknikleri, Veri işleme, iletişim ve sunum, Performans parametrelerinin kullanımına ilişkin genel kurallar) standartlarından yararlanıldı.

PAKS kayar kapı sistemi için ‘Arıza Modu Etkileri ve Kritiklik Analizi’ (FMECA: Failure mode effects and criticality analysis) yapılarak mekanik yapıya ait olası hata durumları belirlendi ve uygulanabilir yirmi iki farklı hata durumunu içeren bir hata kütüphanesi oluşturuldu. Hata kütüphanesi, hata türlerini, sistem üzerinde uygulanacak hata noktalarını, hatalı sistem bileşenlerini ve bu hataların oluşturulmasında uygulanacak yöntemleri tanımlamaktadır. Uygulama süreçlerinde kontrollü hata senaryolarının oluşturulması ve bu senaryoların tekrar edilebilir olması amaçlandı.

Uygulanan hatalara işaret edecek belirtilerin yakalanacağı veri türlerinin (akım, gerilim, hız, vb.) ve bu belirtileri ayırt edilebilir hale getirecek tanımlayıcıların (öznitelikler) belirlenmesi için bir veri toplama planı hazırlandı. Veri türlerinin ölçülebilmesi için kullanılacak sensörler, ölçüm alma yöntemlerinin ve düzeneğin belirlenmesi (sıklık, kullanılan donanımlar vb.) veri toplama planına dahil edildi. Oluşturulan hata kütüphanesine ve veri toplama planına göre veri toplanabilmesi için gerçek bir PAKS sistemi içeren bir deney düzeneği (Şekil-5) oluşturuldu. Bu deney düzeneğinde sistem bileşenleri, belirlenen tekil hataların ortaya çıkacağı şekilde değiştirilerek veriler alındı. Toplanan veriler, elektronik kapı kontrol ünitesinden ve sisteme yerleştirilen haricî sensörlerden alındı. Sensörlerin yerleştirildiği noktalar Şekil-5'te gösterilmektedir.



Şekil 4. PAKS Veri Toplama Deney Düzeneği Görseli



Şekil 5. PAKS Kayar Kapı Sisteminde Yer Alan Harici Sensörlerin Yerleşimi

MÖ modellerinin eğitimi için kullanılan 23 farklı duruma ait etiketler ve kullanılan veri sayıları Tablo-1’de verilmiştir. Hata durumları için alınan veriler, sistem üzerinde kontrollü olarak oluşturulan hatalara ilişkin verilerdir. MÖ modellerinin eğitiminde kullanılan veriler, motor akımının yanı sıra motor gerilimi, kapı pozisyonu, ses verileri, kapı hızı ve titreşim verileri gibi eş zamanlı olarak örneklenen farklı veri türlerini içermektedir. Analizler için Tablo-2’de formülleri verilen istatistiksel bilgiler kullanılarak, her bir açma-kapama döngüsüne ait örneklem grubu için ve her veri türü için altışar adet öznitelik bilgisi elde edilmiştir. Bu öznitelikler, motor akımı, motor gerilimi ve veri setinde yer alan diğer veri türlerinin özelliklerinin daha iyi anlaşılması ve PAKS kayar kapı sisteminin sağlıklı/hatalı durumlarının belirlenmesi için kullanılmıştır (Deng vd., 2014; Mimaz vd., 2019).

Zaman serisi olarak ölçülen akım, gerilim, ses, titreşim, kapı hızı ve kapı pozisyonu verileri, kapının açma/kapama döngüsü esas alınıp gruplanarak analiz edilmiştir. Bu formüller, her çalışma durumuna ait veriler için ayrı ayrı uygulanarak, 37 açma/kapama döngüsü boyunca öznitelikler hesaplanmıştır. Bu hesaplamalar, her bir döngü için akım, gerilim ve diğer verilerin pencereleme işlemine tabi tutulması ile elde edilmiştir.

Tablo 1. PAKS Kayar Kapı Sisteminin Sağlıklı ve Hatalı Çalışma Durumları

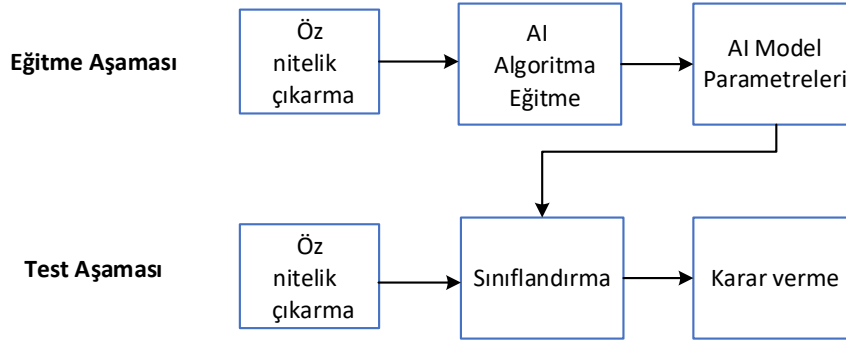
ID	Arıza Türü	Açma/Kapama Sayısı (Yaklaşık 10dk)
f_saglikli	Sağlıklı	37
f1_1	Motor Spot Hatası	37
f3	Motor Mil Eksenel Sapma Hatası	37
f5	Motor Rulman Yağsızlık Hatası	37
f6	Kayış Gerginliği Gevşek Olması G1	37
f7_1	Kayış Gerginliği Gevşek Olması G2	37
f8	Kayış Gerginliğinin Fazla Olması G1	37
f9_1	Kayış Gerginliğinin Fazla Olması G2	37
f10_1	Avare Kasnak Montaj Hatası T1	37
f10_2	Avare Kasnak Montaj Hatası T2	37
f10_3	Avare Kasnak Montaj Hatası T3	37
f11	Avare Kasnak Mil Yamultma Hatası	37
f12	Avare Kasnak Rulman Hatası	37
f13	Avare Kasnak Rulman Yağsızlık Hatası	37
f16_1	Araba Grubu Tekerlek Yüzey Aşınma Hatası_1	37
f16_2	Araba Grubu Tekerlek Yüzey Aşınma Hatası_2	37
f18_1	Teker Rulmanı Yağsızlık Hatası	37
f19	Asma Aparatı Dikey Hizalama Hatası	37
f20	Asma Aparatı Yatay Hizalama Hatası	37
f21	Alt Kılavuz Kanalda Yabancı Madde Tespiti	37
f23	Emniyet Kilit Mekanizması Hatası	37
f24	Yıpranmış Kayış Hatası	37
f25	Kayış Üzerinde Yabancı Madde Oluşması	37

Tablo 2. Kullanılan Öznitelik İsimleri ve Formülleri

#	Öznitelik adı	Denklem
1	Ortalama (mean)	$\mu = \frac{\sum x_i}{N}$
2	Standart Sapma (standard deviation)	$\sigma = \sqrt{\frac{\sum (x_i - \mu)^2}{N - 1}}$
3	Çarpıklık (skewness)	$\gamma_1 := \tilde{\mu}_3 = \frac{\sum (x_i - \mu)^3}{(N - 1) * \sigma^3}$
4	Basıklık (kurtosis)	$\beta_2 = \frac{\sum (x_i - \mu)^4}{(N - 1) * \sigma^4}$
5	Aralık (range)	$\max_i(x_i) - \min_i(x_i)$
6	Karelerin ortalamasının karekökü (Root Mean Square – RMS)	$\sqrt{\frac{\sum x_i^2}{N}}$

3. PAKS Kayar Kapı Sistemi için Makine Öğrenmesi Tabanlı Hata Teşhis Yaklaşımı

MÖ tabanlı hata teşhis yaklaşımları, sistemde oluşabilecek arızaların tespiti için kullanılmaktadır. K-En Yakın Komşuluk (K-nearest Neighboring), Destek Vektör Makineleri (Support Vector Machines) ve Lojistik Regresyon (Logistic Regression) algoritmaları, literatürde sıkça kullanılan örneklerdir. Bu çalışmada, MÖ yapısının bu algoritmalarla uygulanması süreci gösterilmiştir. Her bir algoritmanın kendine özgü avantaj ve dezavantajları vardır (Koç vd., 2023; Zagajewski vd., 2021). Algoritma seçimi, çözülmeye çalışılan probleme ve verilerin özelliklerine bağlıdır. Örneğin, destek vektör makineleri (DVM) algoritmasında iki sınıf arasındaki en geniş aralığın bulunması için bir hiper-düzlem oluşturulur ve sınıfların en iyi şekilde ayrılmasını sağlamaya yönelik bir yaklaşım kullanılır (Zoppis vd., 2019). Bu çalışmada, MÖ yapısının tüm algoritmalarla uygulanması süreci Şekil-5'te olduğu gibi gerçekleştirilmiştir.



Şekil 6. Çalışmada kullanılan MÖ yapısı

4. Materyal ve Metot

Çalışma kapsamında, PAKS'tan Tablo-1'de belirtilen tüm durumlarda veri toplama işlemi gerçekleştirildi. Örneğin; “f5: Motor Rulman Yağsızlık Hatası” (Tablo-1) senaryosu, yağlı temizlenmiş motor rulmanı kullanılarak oluşturuldu ve deney düzeneği periyodik açılma-kapanma modunda çalıştırıldı. Düzenek çalışırken kapı kontrol ünitesinden ve haricî algılayıcılardan veriler toplanarak eş-zamanlı olarak kaydedildi.

Sağlıklı durumu da dahil olmak üzere yirmi üç farklı durumdan (Tablo-1) saniyede 17 veri örneklem paketi (Akım, gerilim, vd.) alınarak 10'ar dakika boyunca kayıt yapıldı. Elde edilen veriler Python ortamında işlenerek Tablo-2'de listelenen denklemlerle öznitelikler çıkartıldı ve bu öznitelikler etiketlenerek veri seti oluşturuldu. Oluşturulan veri seti ile MATLAB'da Sınıflandırma Öğrenici Araç-kutusunda (Classification Learner Toolbox) bulunan onlarca makine öğrenmesi algoritması eğitildi ve test edildi. Bu testler sonucunda literatürde sık kullanılan DVM, KYK ve LR modellerinin en iyi sonuçları veren sürümleri seçilerek çalışmada raporlandı.

Çalışmadaki temel amaç, durum/koşul izlemeye dayalı olarak hataların tespit edilme sürecinin gerçekleştirilmesidir. Bu süreç, makine ve ekipmanların sağlık ve performansının izlenmesi, değerlendirilmesi ve sınıflandırılması açısından kritik öneme sahiptir, çünkü makine arızalarının önlenmesi, bakım stratejilerinin optimize edilmesi ve makine ömrünün uzatılması hedeflenmektedir. Bu çalışmanın amacı, hedeflenen durum/koşul izleme sürecinde kullanılacak en iyi makine öğrenimi algoritmalarının belirlenmesi ve ardından sistemde kontrollü olarak oluşturulan arızaların tespit edilmesidir.

Tablo 3. Raporlanan algoritmalara Ait Ortalama Başarım Oranları

Algoritma Türü	Ortalama Başarım
DVM Model (Doğrusal Destek Vektör Modeli)	%99.4
A-KYK (Ağırlıklı En Yakın Komşuluk Modeli)	%96.5
VLR (Verimli Lojistik Regresyon Modeli)	%81.7

6. Tartışma/Sonuç

Bu çalışmada, PAKS kayar kapı sistemindeki hataların tespiti ve sınıflandırılması, elektronik kontrol ünitesinden ve diğer sensörlerden alınan verilerin analizi ile gerçekleştirilmiştir. Sistem durumunun izlenmesinde yapay zekâ tabanlı algoritmaların kullanımı, öngörülü bakımda arızaların tespiti ve onarımı için gerekli bilgileri sağlayabilir. Yapay zekâ algoritmaları tarafından işlenen veriler, olası arızaların tespit edilmesi ve onarımı için yüksek başarı oranıyla kullanılabilirliğini göstermektedir.

Şekil-7, 8 ve 9'da gösterilen hata matrislerine göre, PAKS kayar kapı sistemindeki hataların tespit edilmesi ve sınıflandırılması için farklı algoritmaların kullanımının başarılı olduğu görülmüştür. Bu matrisler, her bir sınıflandırma modelinin performansını değerlendirmek için kullanılan tablolardır ve doğruluk/kesinlik sonuçları Tablo-3'te sunulmuştur ve bu tablodan anlaşılacağı üzere, Verimli Lojistik Regresyon Modeli dışındaki algoritmalarda ortalama %96'lık bir doğruluk elde edilmiştir.

Tablo-4. Eğitilmiş DDVM Modeline Ait Örnek Tahmin Sonuçları

Sisteme Verilen Hata	Sağlıklı	f1_1	f10_1	f3	f7_1	f9_1	f12	f10_2	f10_3
		f11	f16_1	f16_2	f19	f20	f21	f6	f8
		f13	f23	f24	f25	f5			
F1_1	0.0	0.9	0.0	0.0	0.0	0.0	0.0	0.0	0.0
		0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
		0.0	0.0	0.0	0.1	0.0			
F24	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
		0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
		0.0	0.0	1.0	0.0	0.0			
Sağlıklı	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
		0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
		0.0	0.0	0.0	0.0	0.0			

Eğitilmiş DDVM modeli kullanılarak kontrol edilen (eğitim sırasında kullanılmamış) rastgele üç girdiye ait tahmin sonuçları Tablo-4'te gösterilmiştir. Eğitilen model, verilen girdilerin hangi hata sınıfına ait olabileceğine dair ihtimal listesi üretmektedir. Gerçek hata sınıfı 'F1_1' olan girdiler, model tarafından da %90 ihtimalle aynı sınıfa dahil edilmiştir. Aynı şekilde gerçek hata sınıfı 'F24' olan girdi tam olarak kendi sınıfına, gerçek etiketi 'sağlıklı' olan girdi de tam olarak kendi sınıfına dahil edilmiştir. Bu sonuçlar, modelin Tablo-3'te gösterilen ortalama başarımla performansını da örtüşmektedir. Özetle, PAKS sistemlerinin bakımını yapmak için önceden planlama yapmak, işletmelerin sistemin kesintisiz çalışmasını sağlamanın yanı sıra işletme maliyetlerini düşürecek ve sistem güvenilirliğini artıracaktır. Ayrıca, gerçekleştirilen çalışmanın peron ayırıcı kapı sistemi ile benzer alt bileşenleri içeren asansör kapısı ve tren kapısı gibi sistemlere de uygulanabilecek olması, yapılan çalışmanın önemini bir kez daha göz önüne sermektedir.

Araştırmacıların Katkı Oranı Beyanı

Sorumlu yazar ve ikinci yazar tarafından araştırmanın ilk versiyonu hazırlanmış, tüm yazarlar tarafından düzenlenerek gözden geçirilmiştir.

Destek ve teşekkür beyanı

Bu çalışma, ECOMAI PENTA-EURIPIDES (Hibe No. 2021028) çatı projesi kapsamında TÜBİTAK (Hibe No. 9210043) tarafından desteklenmektedir.

Çıkar Çatışması Beyanı

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

Kaynakça

Koç, İ., Mermer, Ö., Kırımça, N., Çakır, F.H., ve Karaköse, M. (2022). Modeling and Simulation of Platform Screen Door (PSD) System using MATLAB-Simulink. *International Conference on Data Analytics for Business and Industry (ICDABI), Sakir – Kingdom of Bahrain*, 629-633.

Li, X., ve Wang, Y., (2018). Simulation study on air leakage of platform screen doors in subway stations. *Sustainable Cities and Society*, c. 43, 350-356.

Zhou, C., Su, Z., ve Zhou, J. (2010). Design and Implementation of the Platform Screen Doors System for BRT, 2540-2552. doi: 10.1061/41127(382)271.

Abdurrahman, U.T., Jack, A., ve Schmid, F. (2018). Effects of Platform Screen Doors on the Overall Railway System. *8th International Conference on Railway Engineering, London, UK*. doi: 10.1049/cp.2018.0053.

Roh, J. S., Ryou, H.S., ve Yoon, S.W. (2010). The effect of PSD on life safety in subway station fire. *J Mech Sci Technol*, 24(4), 937-942. doi: 10.1007/s12206-010-0217-7.

Qu, L., ve Chow, W. K., (2012). Platform siren doors on emergency evacuation in underground railway stations. *Tunnelling and Underground Space Technology*, 30(1), 1-9. doi: 10.1016/j.tust.2011.09.003.

Lindfeldt, O., (2017). The impact of platform screen doors on rail capacity, *Int. J. TDI*, 1(3), 601-610. doi: 10.2495/TDI-V1-N3-601-610

Su, Z., ve Li, X., (2022). Energy benchmarking analysis of subway station with platform screen door system in China. *Tunnelling and Underground Space Technology*, 128, 104655. doi: 10.1016/j.tust.2022.104655.

Gabay, D., (2004) Compared fire safety features for metro tunnels, *Safe & Reliable Tunnels. Innovative European Achievements First International Symposium*, 4-6 February, Prague.

Aarnio, P., Yli-Tuomi, T., Kousa, A., Mäkelä, T., Hirsikko, A., Hämeri, K., Räisänen, M., Hillamo, R., Koskentalo, T., Jantunen, M., (2005). The concentrations and composition of and exposure to fine particle in the Helsinki subway system. *Atmos. Environ.* 39(28), 5059–5066.

Ampofo, F., Maidment, G., Missenden, J., 2004. Underground railway environment in the UK Part 1: *Review of thermal comfort. Appl. Therm. Eng.* 24 (5), 611–631.

He, S., Jin, L., Le, T., Zhang, C., Liu, X., ve Ming, X., (2018). Commuter health risk and the protective effect of three typical metro environmental control systems in Beijing, China. *Transportation Research Part D: Transport and Environment*, c. 62, 633-645.

- Min, L., Zhaoyong, C., ve Jin, Z.,** (2012). Study on PSD system control strategy for safety. *3rd International Conference on System Science, Engineering Design and Manufacturing Informatization, Chengdu*, 154-159. doi: 10.1109/ICSSEM.2012.6340789.
- Koç, İ., Mermer, Ö., Kırımça, N., ve Karaköse, M.** (2023). Raylı Sistemlerde Peron Ayırıcı Kapı Sistemi İçin Yapay Sinir Ağı Tabanlı Hata Teşhis Yaklaşımı. *Emo Bilimsel Dergi*, 13(1), 13-22.
- Li, C., Luo, S., Cole, C., ve Spiriyagin, M.,** (2017). An overview: modern techniques for railway vehicle on-board health monitoring systems, *Vehicle System Dynamics*, c. 55(7), 1045-1070.
- Gonzalez-Jimenez, D., Del-Olmo J., Poza, J., Garramiola, F., ve Madina P.,** (2021). Data-Driven Fault Diagnosis for Electric Drives: A Review, *Sensors*, c. 21(12), s. 4024.
- Sun, X., Ling, K. V., Sin, K. K., ve Tay, L.** (2018). Intelligent Fault Detection and Diagnosis of Air Leakage on Train Door. *International Conference on Intelligent Rail Transportation (ICIRT), Singapore*, 1(4).
- Başaran, M., Fidan, M.,** (2020). Gearbox Fault Classification by Using Frequency Based Feature Extraction. *Eskişehir Technical University Journal of Science and Technology*, 21, 101-107.
- Ham, S., Han, S.Y., Kim, S., Park, H. J., Park, K. J., ve Choi J. H.** (2019). A Comparative Study of Fault Diagnosis for Train Door System. Traditional versus Deep Learning Approaches, *Sensors*, c. 19(23) s. 5160.
- Deng, L., ve Yu, D.** (2014). Deep learning: methods and applications. *Foundations and trends® in Signal Processing*, 7(3-4), 197-387.
- Mimaz M. R., Yıldız, K.** (2019). İndüksiyon Motorun Mekanik Arıza Teşhisinde Makine Öğrenme Yöntemlerinin Kullanılması. *Avrupa Bilim ve Teknoloji Dergisi*, Sayı 16, S. 881-904.
- Zagajewski, B., Kluczek, M., Raczko, E., Njegovec, A., Dabija, A., & Kycko, M.** (2021). Comparison of random forest, support vector machines, and neural networks for post-disaster forest species mapping of the krkonoše/karkonosze transboundary biosphere reserve. *Remote Sensing*, 13(13), 2581.
- Zoppis, I., Mauri, G., & Dondi, R.** (2019). Kernel methods: Support vector machines. *In Encyclopedia of Bioinformatics and Computational Biology*. Volume 1 (pp. 503-510). Elsevier.
- Ben-Hur, A., Horn, D., Siegelmann, H. T., & Vapnik, V.** (2001). Support vector clustering. *Journal of Machine Learning Research*, 2(Dec), 125-137.
- Hsieh, C. J., Chang, K. W., Lin, C. J., Keerthi, S. S., & Sundararajan, S.** (2008). A dual coordinate descent method for large-scale linear SVM. *Proceedings of the 25th International Conference on Machine Learning* (pp. 408-415)
- Khan, M. M. R., Arif, R. B., Siddique, M. A. B., & Oishe, M. R.** (2018). Study and observation of the variation of accuracies of KNN, SVM, LMNN, ENN algorithms on eleven different datasets from UCI machine learning repository. *4th International Conference on Electrical Engineering and Information & Communication Technology (iCEEiCT)* (pp. 124-129). IEEE.
- Joshuva, A., Sugumaran, V., & Amarnath, M.** (2015). Selecting kernel function of support vector machine for fault diagnosis of roller bearings using sound signals through histogram features. *International Journal of Applied Engineering Research*, 10(68), 482-487.
- Pandya, D., Upadhyay, S. H., & Harsha, S. P.** (2014). Fault diagnosis of rolling element bearing by using multinomial logistic regression and wavelet packet transform. *Soft Computing*, 18, 255-266.
- Shuai, L., Limin, J., Yong, Q., Bo, Y., & Yanhui, W.** (2014). Research on urban rail train passenger door system fault diagnosis using PCA and rough set. *The Open Mechanical Engineering Journal*, 8(1).

Sun, L., Zhang, J., Ding, W., & Xu, J. (2022). Feature reduction for imbalanced data classification using similarity-based feature clustering with adaptive weighted K-nearest neighbors. *Information Sciences*, 593, 591-613.