

# Raylı Sistemlerde Peron Ayırıcı Kapı Sistemi İçin Yapay Sinir Ağı Tabanlı Hata Teşhis Yaklaşımı

## An Artificial Neural Network Based Fault Detection Approach for Platform Screen Doors in Railway Systems

İsa KOÇ<sup>1,2</sup>, Ömer MERMER<sup>1</sup>, Necim KIRIMÇA<sup>1</sup>, Mehmet KARAKÖSE<sup>3</sup>

<sup>1</sup>Araştırma ve Geliştirme Bölümü

Albayrak Makine Elektronik A.Ş., Eskişehir  
omermer@aldoor.com.tr, necim@aldoor.com.tr

<sup>2</sup>Elektrik Elektronik Mühendisliği Bölümü  
Eskişehir Osmangazi Üniversitesi, Eskişehir  
isakoc@windowslive.com

<sup>3</sup>Bilgisayar Mühendisliği Bölümü  
Fırat Üniversitesi, Elazığ  
mkarakose@firat.edu.tr

### Özet

Günümüzde demiryolu sektöründe tren taşımacılığının önemi göz önüne alındığında endüstriyel Peron Ayırıcı Kapı Sistemi (PAKS) genellikle emniyet açısından kritik sistemler olarak tanımlanmaktadır. PAKS sisteminde meydana gelebilecek arızalar, tren ulaşımının elverişliliğini ciddi şekilde etkileyecektir. PAKS sisteminin emniyetli ve güvenilir bir şekilde çalışmasını sağlamak için bu çalışmada PAKS sistemi üzerinde veriye dayalı hata tespit ve sınıflandırma yöntemi üzerine çalışıldı. Bu yöntemde yapay sinir ağı (YSA) güçlü kabiliyetleri nedeniyle tercih edildi. PAKS sistemi üzerinde yapay olarak farklı çalışma durumları (sağlıklı ve hatalı) oluşturularak, PAKS kapısının çalışmasını sağlayan elektriksel motorun akım ve gerilim sinyalleri veri seti olarak kullanıldı. Toplamda beş farklı çalışma durumu için her biri 1000 açma/kapama döngüsü üzerinden veriler toplandı ve her bir durum için 12 adet öz nitelik değerleri hesaplanarak YSA modelleri için giriş/çıkış veri setleri elde edildi. Bu çalışmada dört farklı YSA yapısı üzerinde çalışıldı ve eğitim/test aşamaları bu yapılaraya uygulandı. Doğruluk, hassasiyet, kesinlik, belirginlik gibi performans parametreleri bu YSA modelleri için karşılaştırmalı olarak hesaplandı. Çalışma kapsamında elde edilen sonuçlara göre, toplamda üç katmanlı (giriş-gizli katman-çıkış) ve nöron sayıları sırasıyla 12-7-5 olan yapının en iyi performansı gösterdiği gözlemlendi. Sonuç olarak YSA yapısının PAKS sistemi üzerindeki oluşabilecek hataları teşhis etmede kullanışlı bir Yapay Zeka (YZ) aracı olduğu söylenebilir.

Anahtar kelimeler: Yapay sinir ağı, peron ayırıcı kapı sistemi (PAKS), hata teşhis, hata sınıflandırma, veriye dayalı yöntem

### Abstract

Considering the importance of train transportation in the railway sector today, the industrial Platform Screen Door System (PSD) is generally defined as safety critical systems. Failures that may occur in the PSD system will seriously

affect the availability of train transportation. In this study, data driven fault detection and classification method was studied on the PSD system in order to ensure the safe and reliable operation of the PSD system. In this method, artificial neural network (ANN) is preferred because of its powerful capabilities. Different operating states (healthy and faulty) were created artificially on the PSD system and the electrical motor current and voltage signals were used as data set. Data set were collected over 1000 on/off cycles for each of five different operating states in total, and input/output data sets for ANN models were obtained by calculating 12 features for each state. Four different ANN structures were studied and training/testing stages were applied to them at this study. Performance parameters such as accuracy, precision, precision, and specificity were calculated comparatively for these ANN models. According to the results, it has been shown that the structure with three layers (input-hidden layer-output) and the number of neurons 12-7-5, respectively, show the best performance. Consequently, it is observed that the ANN structure is a useful AI tool in fault detection on the PSD system.

Keywords: Artificial neural network, platform screen door system (PSD), fault detection, fault classification, data-driven approach

### 1. Giriş

Hızlı kentleşme nedeniyle, dünya çapındaki metropoller sürekli olarak hava kirliliği ve trafik sıkışıklığı ile mücadele etmektedir. Metrolar ve trenler, kolay ve güvenilir ulaşım, trafik sıkışıklığını ve hava kirliliğini azaltmak noktasında çok önemli bir rol oynamaktadır. Yeni nesil tren ve metrolarda ise daha yüksek hızı ve otonom ulaşım sistemleri nedeniyle, Peron Ayırıcı Kapı Sistemi (PAKS) kullanmak son yirmi yılda temel bir gereklilik haline geldiği ve peron ayırıcı kapı sistemlerinin mekatronik modellemesi kapsamında matematiksel modelleme ile simülasyon çalışmaları yapıldığı

anlaşılmaktadır [1]. PAKS yapıları birçok modern metro istasyonunda [1] ve birçok RBT (Hızlı Otobüs Transit) istasyonunda [2] yolcu ile araç arasında bariyer görevi gören kayar kapı sistemi olarak tanımlanmaktadır. PAKS sistemleri üstlendikleri fonksiyonellik açısından emniyet-kritik sistemler olarak adlandırılır ve özellikle raylı sistemlerde yolcuları tren raylarına erişimden koruyarak istasyon enerji tüketiminin optimizasyonu, hava kalitesi kontrolü, intiharı önleme ve emniyet gibi birçok işleve hizmet etmektedir [3].

PAKS sistemi, yalnızca platform ve ray arasında bir bariyer oluşturmakla kalmaz, aynı zamanda araca emniyetli iniş/binişi de sağlamaktadır [1, 3]. Bu nedenle metro istasyonları için PAKS sistemi günümüzde hızla yayılmakta ve kullanılmaktadır. Bundan dolayı özellikle son on yılda, PAKS sistemi üzerine farklı araştırmalar yapılmıştır. Bu araştırmalar çoğunlukla PAKS sisteminin istasyonun çevresel koşullarına [4-6], istasyondaki hava kaçağına [7], istasyonun enerji tüketimine [8], yolcu bekleme süresine [9], yolcunun acil tahliyesine [10,11], fonksiyonel emniyet ve güvenliği [12], ve PAKS sistemi üzerinde kontrol/izleme yaklaşımları konularında olduğu görülmektedir [13].

Mühendislik noktasından bakıldığında, emniyetle ilgili standartların gerekliliklerine uymak ve istenen emniyet seviyesine (Emniyet Bütünlük Seviyesi veya SIL olarak anılır) ulaşmak ve bunu beklenen hazır oluş (availability) seviyesinde sunmak için, yeterli düzeyde durum izleme ve teşhis araçlarının geliştirilmesi gerekmektedir [14, 15]. Durum izleme ve hata teşhisinin temel amacı arızalara sebebiyet verebilecek hataların gerektiği kadar erken tespit etmek, yerini belirlemek ve izole etmektir. Özellikle demiryolu uygulamalarında, sistemlerde oluşabilecek hataları etkin bir şekilde teşhis ederek tanımlayabilmek işletmede yaşanan arıza/aksama sürelerini en aza indirebilir ve hatta önleyebilir.

Raylı sistemlerde hata teşhisine yönelik yaklaşımlar iki kategoriye ayrılır: Bunlar veriye dayalı ve modele dayalı yöntemlerdir [16]. Genel olarak, model tabanlı teşhiste, izlenen sistemin mantıksal ve matematiksel modelleri kullanılırken, veriye dayalı teşhiste ise sağlıklı ve hatalı durumlar için mevcut verilerden öğrenilen yapay zeka modelleri kullanılır [17]. Model tabanlı yaklaşım matematiksel modellemeye dayanmaktadır ve özellikle tren kapı sistemleri üzerinde uygulama çalışmaları yapıldığı gerçekleştirilen literatür çalışmasından anlaşılmaktadır [18, 19]. Bunun yanında tren kapı sisteminde arıza teşhisine yönelik bilgiye dayalı ontolojik yaklaşım geliştirildiği ve [20] son zamanlarda, Cauffriez ve ark. [21] tren kapı sisteminin referans bir modelini oluşturmak için bond grafiği metodolojisini üzerine çalıştıkları görülmektedir. Ek olarak, Yu'nun [22] çalışmasında, genel proses izlemede temel bileşen analizi yapılarak arıza teşhis yöntemi sunulmuştur. Model tabanlı arıza teşhisindeki en önemli kısıtlama, üzerinde çalışılan sistem hakkında iyi bir uzmanlığa ihtiyaç duyulmasıdır. Diğer bir zorluk ise içerisinde birçok mekaniksel ve elektriksel bileşen barındıran sistemleri (tren kapısı, peron ayırıcı kapı, asansör kapısı, vb.) doğru ve kesin matematiksel bir modelle tanımlanmasının oldukça zor olmasıdır.

Diğer taraftan veriye dayalı yöntemler kullanarak gerek tren kapı sistemi üzerinde gerekse farklı sistemler üzerinde literatürde yapılan çalışmalar, model tabanlı arıza teşhis

yaklaşımlarının aksine uygulama daha fazla ön plana çıkmaktadır. Bu çalışmalarda Endüstri 4.0'ın yakın zamanda ortaya çıkışı ve yeni dijital teknolojilerin kullanıma geçmesiyle Yapay Zeka tabanlı sistemlerin kullanımını yaygınlaştı [23]. İlk zamanlarda AI sistemlerinin endüstride veriye dayalı hata teşhisinde kullanılmasındaki temel kısıtlama endüstriyel boyutta veri elde edilememesi olarak belirtilmektedir. Zaman içinde bu verinin kalitesinin artması (gürültüsüz, eksiksiz, uygun değer aralıkları, uygun örnekleme, zaman/frekans alan dönüşümleri) ve hatalı durumları ifade edebilecek verilerin de elde edilmesiyle AI modellerinin veri tabanlı hata teşhisinde kullanımını önemli ölçüde arttı [23]. Sun ve ark. [24], tren kapı sistemindeki hava kaçaklarını algılayabilecek makine öğrenmesi modelleri kullanan bir hata tespiti sistemi yazarlar tarafından önerildi. Başka bir çalışmada, tren kapı sistemindeki araba grubu ve rulman hataları Bayesian ağ olasılıksal makine öğrenmesi sınıflandırma modelleri kullanılarak motor akım verileri üzerinden hata teşhis çalışmaları yapıldığı görülmektedir [25]. Ayrıca diğer bir çalışmada farklı bir tren kapı sistemindeki hataların teşhis edilmesi benzer bir modelle yapıldığı anlaşılmaktadır [26].

Ek olarak, farklı makine öğrenmesi [27-30] ve derin öğrenme [31, 32] algoritmalarının tren kapı sistemlerinde ortaya çıkabilecek çeşitli hataların tespiti noktasında uygulama çalışmaları son zamanlarda artarak devam etmektedir.

Bu çalışmalar arasında son yıllarda, özellikle Yapay Sinir Ağları (YSA) algoritmalarının gerçek sistemlerde oluşabilecek hataların teşhis edilmesinde oldukça etkili olduğu görülmektedir. Farklı YSA yapıları kullanılarak asansör kapısı [33], elektrik motoru [34,35] ve tren kapı sistemleri [31, 32, 36] gibi gerçek uygulamalar üzerinde değişik hataların yüksek doğruluk oranıyla tespit edilmesi çalışmalarını literatürde mevcuttur. Yapılan literatür araştırması sonucunda, PAKS sistemine yönelik herhangi bir hata teşhis yaklaşımının olmadığı görülmektedir. PAKS yapılarının son yıllarda hem metro hem de metrobüs istasyonlarında kullanım oranının hızla artması düşünüldüğünde, bu sistemlerde meydana gelebilecek olası arızaların önceden tespit edilmesi büyük önem taşımaktadır.

Bu çalışmada metro istasyonlarında kullanılan tam boy PAKS sistemlerinde oluşabilecek mekaniksel arızaların YSA modeli kullanılarak teşhis edilmesi gerçekleştirildi. Bunun için motor akım ve gerilim verileri ve farklı istatistiksel yöntemler ile öz nitelikler çıkarılarak PAKS sisteminin sağlıklı ve hatalı durumları teşhis edilerek sınıflandırma işlemi yapıldı.


## 2. PAKS Sisteminin Yapısı

### 2.1. PAKS Sisteminin Mekaniksel ve Elektriksel Üniteleri

Peron Ayırıcı Kapı Sisteminde yer alan sistem bileşenleri (otomatik kayar kapı, acil çıkış kapısı, peron sonu kapısı, sabit panel) ve bir uygulama örneği Şekil 1'de gösterilmektedir. PAKS otomatik kayar kapı sistemi, tren kapı sistemi ile benzer mekanik ve elektriksel ünitelere sahiptir [1, 21, 37]. Tahrik ünitesi, taşıma ünitesi, hareket mekanizması, kontrol ünitesi ve kapı kanadı PAKS kayar kapı sistemini oluşturan alt sistemlerdir. Albayrak firması tarafından üretilen ALPSD-1000 serisine ait tam boy bir PAKS kayar kapı sisteminin görseli Şekil 2'de yer almaktadır.

## 2.2. PAKS Sistemi Arıza Tanımları ve Veri Toplama


Bu çalışmada PAKS kayar kapı sistemi mekanik kısmında dört hata durumu oluşturularak toplamda beş farklı senaryo (sağlıklı çalışma durumu da dahil edilerek) üzerinden YSA tabanlı hata teşhis yöntemi uygulandı. Tablo 1’de verilen bu durumlar, YSA modelinde bu durumlara karşılık gelen etiketler ve çalışmada kullanılan data sayıları gösterilmektedir. Bu hata durumları YSA tabanlı hata teşhis yaklaşımının PAKS kayar kapı sistemi üzerinde uygulanabilirliğini göstermek için yapay olarak kolay oluşturulabilecek arızalardan seçildi ve arızaların uygulamada ortaya çıkma olasılıkları dikkate alınmadı. Ek olarak Tablo 1’te tanımlanan her bir hata durumu PAKS sistemine ayrı ayrı (tekil olarak) uygulandı. Her bir durum için kayar kapı sistemi 1000 açma/kapama olacak şekilde tekrarlı bir şekilde çalıştırılarak arıza koşulları verileri alındı.



Şekil 1. PAKS sistem bileşenleri ve uygulama örneği


Tablo 1: PAKS kayar kapı sisteminin çalışma durumları (sağlıklı ve hatalı)

ID	Arıza Koşulları	Açma/kapama	Etiket
H/S	Sağlıklı	1000	0
K-1	Kayış Gergin	1000	1
K-2	Kayış Gevşek	1000	2
K-3	Kayış Dişleri Aşınma	1000	3
K-4	Kasnak Dişleri Aşınma	1000	4



Şekil 2. PAKS kayar kapı sistemi görseli

PAKS kayar kapı sistemini oluşturan her bir birim, ilgili görevleri yerine getirmek için özel alt bileşenlere sahiptir. Bu bağlamda PAKS kayar kapı sisteminin detay mimari yapısı Şekil 3’de verilmektedir. Burada motor kapı kontrol ünitesi (Door Control Unit-DCU) tarafından kapının istenilen çalışma senaryolarına uygun bir şekilde sürme görevini üstlenmektedir. Motor çıkışı, motor kasnağına bağlı kayış-kasnak ünitesini hareket ettirerek kapının taşıma rayı boyunca hareket etmesini sağlamaktadır. Bu arada kapı kanatları askı aparatları ile taşıyıcı araba grubuna birleştirilerek tek bir parça olarak hareket ederler. Albayrak firması tarafından ALPSD-1000 serisinden üretilen PAKS kayar kapı düzeneği çalışma kapsamında kullanılmıştır.



Şekil 3. PAKS kayar kapı sisteminin mimari yapısı

Literatürde veriye dayalı yöntemlerde özellikle motor akımı sinyali yaygın bir şekilde kullanıldığı görülmektedir. Elektrik motoru [34], asansör kapı [33] ve tren kapı sistemleri [31, 32] gibi gerçek sistemlerde zaman serisi olarak motor akım sinyali belirli bir örnekleme frekansı ile okunduğu anlaşılmaktadır. Bu çalışmada tipik elektriksel imza sinyali olan motor akımı ve gerilim sinyalleri 20Hz örnekleme frekansı ile MODBUS TCP haberleşme protokolü kullanılarak 3 saat boyunca DCU üzerinden alındı. Bu sinyallere ait gerçek zamanlı veri örnek kayıtları Tablo 2’de verilmektedir.

Tablo 2: PAKS kayar kapı sisteminde alınan gerçek zamanlı veri örnek kayıtları

Tarih /Zaman	Akım (mA)	Gerilim (V)
28.09.2021 12:56	0	0
28.09.2021 12:56	3190	30
28.09.2021 12:56	3340	29
28.09.2021 12:56	2180	29
28.09.2021 12:56	2140	30
28.09.2021 12:56	2140	31

## 2.3. Öznitelik Çıkarma

Zaman serisi olarak elde edilen bu sinyallerin özelliklerini daha iyi anlamak ve PAKS kayar kapı sisteminin sağlıklı ve hatalı durumlarında nasıl değişiklik gösterdiklerini daha iyi

ortaya koyabilmek için, Tablo 3’de gösterilen temel istatistiksel yöntemler motor akımı ve gerilimi sinyallerine uygulanmıştır. Bu istatistiksel yöntemler; Ortalama (mean), standart sapma (standard deviation), çarpıklık (skewness), basıklık (kurtosis), aralık (range) ve RMS (Root Mean Square) olup toplamda altı adet öz nitelik bilgisi içermektedir. Akım ve gerilim sinyallerinin her biri için bu yöntemler/formüller kullanılarak toplamda altı adet öz nitelik oluşturulmuş olmakla birlikte Tablo 3’de bu öz niteliklerin isimleri ve formülleri verilmiştir.


Tablo 3: YSA için kullanılan öz-nitelik isimleri ve formülleri

#	Öz-nitelik adı	Denklem
1	Ortalama	$\frac{\sum x_i}{N}$
2	Standart Sapma (SS)	$\frac{\sqrt{\sum(x_i - \bar{x})^2}}{N - 1}$
3	Çarpıklık	$\frac{\sum(x_i - \bar{x})^3 / N}{SS^3}$
4	Basıklık	$\frac{\sum(x_i - \bar{x})^4 / N}{SS^4}$
5	Aralık	$\max(x) - \min(x)$
6	RMS	$\frac{\sqrt{\sum x_i^2}}{N}$

Zaman serisi olarak ölçülen akım ve gerilim sinyalleri üzerinde kapının bir açma/kapama döngüsü esas alınarak pencereleme (windowing) yapılmıştır. Yukarıda verilen bu formüller, her bir çalışma durumu için, pencereleme yapılmış akım ve gerilim verileri üzerinde ayrı ayrı uygulanarak 1000 açma/kapama döngüsü için toplamda 1000 adet akıma ait ve 1000 adet gerilime ait öz-nitelikler hesaplanmıştır.

### 3. PAKS Kayar Kapı Sistemi için YSA Tabanlı Hata Teşhis Yaklaşımı

Şekil 4’de temel yapısı gösterilen Yapay sinir ağı (YSA), beyin hücrelerinin biyolojik yapısından esinlenen bir yapay zekaya yaklaşımıdır [38]. Temel olarak YSA giriş, gizli katman ve çıkış olmak üzere üç katmana sahiptir. Yapay sinir ağı, nöron hücrelerine benzer şekilde, işleme elemanı, giriş ve çıkışlardan oluşan bir yapıdır. Her giriş kendisi ile bağlantılı ağırlıklarla çarpılır ve eşik (bias) ile birlikte işlem elemanı olan nöron gövdesine iletilirler. İlk aşamada çarpılan girişler toplama fonksiyonu ile toplanır ve ikinci adımda transfer fonksiyonu ile çıkışa aktarılır. Eğitim işleminden önce katmanların nöron sayısı, eğitim algoritmaları, iterasyon sayısı, performans değerleri ve doğrulama kontrolleri ayarlanabildiğinden YSA’nın çok esnek ve çok yönlü bir araç olduğu ifade edilebilir. Son yirmi yılda YSA, çoğunlukla sınıflandırma, kümeleme, örüntü tanıma, görüntü işleme, kontrol, optimizasyon ve modelleme gibi farklı görevleri yerine getirmek için kullanılmaktadır [39].



Şekil 4. Çalışmada kullanılan YSA mimari yapısı

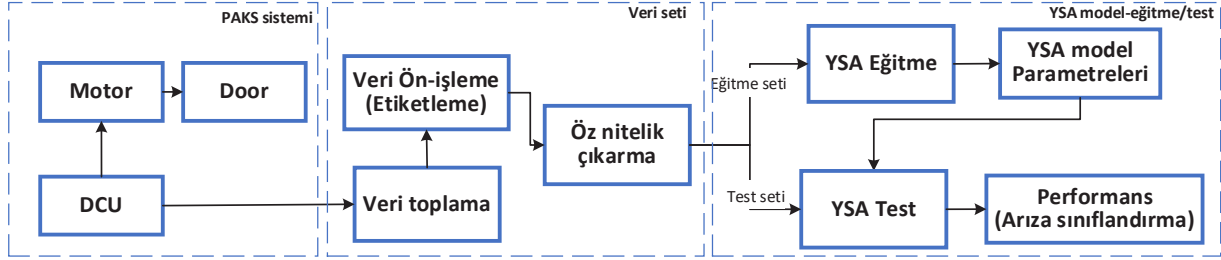
Bu çalışmada kullanılan YSA yapısında tek bir gizli katman seçildi. Giriş olarak akım ve gerilim verilerine ait toplamda 12 adet öz nitelik bulunduğu için giriş katmanındaki nöron sayısı 12 olarak kabul edildi. Aynı şekilde çıkışımızda 5 farklı durum (sağlıklı ve dört arıza durumu) olduğu için çıkış katmanında 5 nöron belirlendi. Ayrıca, gizli katmandaki nöron sayısı da 3, 5, 7 ve 9 alınarak farklı nöron sayısını YSA performansını nasıl etkilediği araştırıldı. Bahsedilen bu YSA yapıları Tablo 4’de yer almaktadır. Ek olarak YSA yapısının öğrenme oranı 0.6 ve momentum katsayısı 0.95 olarak seçildi. Her bir akım ve gerilim verilerine ait 5000 adet öz nitelik değeri (örnek) 80:20 oranında eğitimde (4000 örnek) ve test verisi (1000 örnek) olarak bölünerek ve YSA yapılarının eğitim ve test işlemlerinde kullanıldı. Burada kullanılan veri setleri karıştırılarak ve rastgele bir şekilde eğitim/test veri ayrımı yapıldı.

Tablo 4: Katman Sayısı ve Nöron Dahil YSA Yapısı

YSA Modeli	Nöron sayısı			Momentum katsayısı	Öğrenme katsayısı
	Giriş	Gizli katman	Çıkış		
YSA-1	12	3	5	0.95	0.6
YSA-2	12	5	5	0.95	0.6
YSA-3	12	7	5	0.95	0.6
YSA-4	12	9	5	0.95	0.6

YSA yapılarında artımlı ve toplu eğitim olmak üzere iki farklı yaklaşım mevcuttur [40]. Artımlı eğitim aynı zamanda örnek-örnek modeli olarak da bilinir ve daha çok dinamik yapay sinir ağlarında uygulanmaktadır. Statik ağlarda da uygulanabilen bu yaklaşımda ağırlıklar her iterasyonda güncellenir. Bu yaklaşımda örnekler tek tek alındığı için küçük depolama içermesine rağmen ilk kötü örnek eğitimi yanlış yöne zorlayabilir. Diğer bir yaklaşım olan toplu eğitimde, tüm girişler yapay sinir ağına girdikten sonra ağırlıklar güncellenir. Bu yaklaşım MATLAB ortamı için de daha verimli bir çalışma yöntemidir [41]. Bu çalışmada toplu eğitim yaklaşımı kullanıldı. Eğitim için oluşturulan giriş-çıkış veri setleri kullanılarak YSA modellerinin eğitim işlemi gerçekleştirildi. Bu bölümde iterasyon sayısı 200 ve eğitim hatası 0.001 olarak kabul edildi. Optimize edilen YSA modeli daha sonrasında test verisi ile doğrulanarak ve modele ait performans metrikleri hesaplandı. Bu işlem basamaklarının detaylı olarak görselleştirildiği akış diyagramı Şekil 5’de verilmektedir.





Şekil 5. Uygulama akış diyagramı

## 4. Deneysel Sonuçlar

### 4.1. Performans Kriterleri

Bu çalışmada öncelikle Doğru Pozitif (DP-TP), Yanlış Pozitif (YP-FP), Doğru Negatif (DN-TN) ve Yanlış Negatif (YN-FN) olmak üzere dört indeksten oluşan karmaşıklık matrisi (confusion matrix) kullanılarak YSA yapılarının performansları analiz edildi. Şekil 6'da tipik bir karmaşıklık matrisi ve bu parametrelerinin karşılık geldiği kısımlar gösterilmektedir. Bu kapsamda TP ve TN doğru tahmin edilen veri sayısını, FP ve FN ise yanlış tahmin edilen veri sayısını temsil etmektedir.

	gerçekte pozitif	gerçekte negatif
tahmin pozitif	doğru pozitif	yanlış pozitif
tahmin negatif	yanlış negatif	doğru negatif

Şekil 6. Karmaşıklık matrisi ve uygulama parametreleri

Karmaşıklık matrisine ek olarak, literatürde [42] başka yardımcı performans ölçütleri belirlendi ve aşağıda bunlarla alakalı bilgiler ve formüllere yer verildi. Doğruluk (accuracy) parametresi modelin kapsamlı bir performansı gösterir. Doğru yapılan tahminlerin bütün tahminlere bölümü şeklinde tanımlanır ve denklem (1) deki gibi hesaplanır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

Hassasiyet (sensitivity-recall) parametresi yalnızca pozitif örneklere ve tahminlere odaklanır. Genel olarak hassasiyet, pozitif olarak tahmin edilmesi gereken örneklerin oransal olarak kaçının doğru tahmin edildiğinin göstergesidir. Denklem 2'de verilen ifade ile hesaplanır. Burada  $M$  sınıflandırma sayısını göstermektedir.

$$\text{Hassasiyet} = \frac{\sum_i \frac{TP_i}{TP_i + FN_i}}{M} \quad (2)$$

Son olarak pozitif olarak tahmin ettiğimiz örneklerin kaçının doğru olarak tahmin edildiğini gösteren performans parametresi kesinlik (precision) olarak isimlendirilir ve Denklem 3'de hesaplama formülü yer almaktadır.

$$\text{Kesinlik} = \frac{\sum_i \frac{TP_i}{TP_i + FP_i}}{M} \quad (3)$$

Ayrıca bu performans parametrelerinden kesinlik ve hassasiyet değerlerini kullanarak tek bir değere indirgeyen F1-skor parametresi Denklem 4'deki gibi formüle edilebilir ve birden fazla model arasından en iyisi seçmek için kullanılabilir bir parametredir.

$$F1 - \text{skor} = \frac{2 \times \text{Kesinlik} \times \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} \quad (4)$$

### 4.2. Deneysel sonuçlar

Bu çalışmada kullandığımız data setleri motor akım ve gerilim sinyallerinden hesaplanan toplamda 12 adet öz nitelik değerinin 1000 açma/kapama döngüsü ve 5 farklı çalışma durumları (sağlıklı/arızalı) için elde edilen verilerden oluşmaktadır. Sonuçta, giriş data seti matrisi 5000x12 boyutlarında, çıkış data seti 5000x5 boyutlarında oluşturularak eğitim ve test aşamalarında kullanıldı. Eğitim aşamasında ezber etkisini azaltmak için giriş ve çıkış veri setleri aynı şekilde karıştırılmış ve yine tamamıyla rastgele bir şekilde 80:20 oranında bölünerek eğitim ve test veri setleri oluşturuldu.

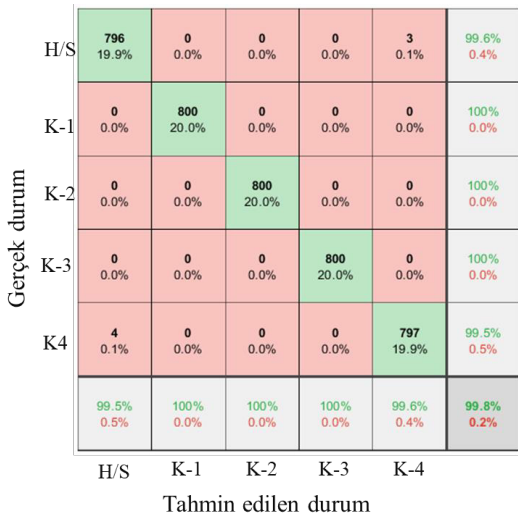
Tablo 4'de verilen dört farklı YSA yapıları öncelikle bu eğitim veri setleri ile eğitilerek sonrasında test veri setleri ve performansları hesaplandı. Tüm YSA için bu performans parametreleri Tablo 5'de özet şeklinde sunuldu. Burada YSA-1 modeli hassasiyet parametresi diğer modellerle kıyaslandığında düşük durmaktadır. Bu modelin yeterli sayıda doğru tahmin edememesinden kaynaklanmaktadır. Burada en iyi performans YSA-3 modelinin gösterdiği anlaşılmaktadır. Gizli katmandaki nöron sayısını artırmak belli dereceye kadar YSA performansını artırırken, bir noktadan sonra YSA'nın performansını düşürmektedir. Literatürde YSA üzerinde yapılan bazı çalışmalarda [43] benzer sonuçları

görmek mümkündür. Burada gizli katmandaki nöron sayılarını belli bir değerden daha fazla artırmak YSA modelini eğitirken “aşırı uyum problemine” neden olabilmektedir. Bu da test aşamasında eğitilen modelin performansında düşüş meydana getirebilmektedir.


Tablo 5. YSA modellerinin performans metriklerinin karşılaştırılması

YSA modeli	Keskinlik (Precision) (%)	Hassasiyet (Sensitivity) (%)	F1-skor (F1-score) (%)	Doğruluk (Accuracy) (%)
YSA-1	98,6	79,8	88,2	78,9
YSA-2	98,3	99,5	98,8	97,8
YSA-3	99,6	99,6	99,6	98,2
YSA-4	98,3	99,5	98,8	97,8

Şekil 7’de ise en iyi performansı gösteren YSA modelinin (YSA-3) eğitime ve test aşamalarından sonra elde edilen karmaşıklık matrisleri gösterilmektedir. Buradan da görüleceği üzere, optimize edilen YSA modeli test aşamasında eğitime aşamasından daha yüksek bir performans göstermektedir.




(a)



(b)

Şekil 7. YSA-SL3 model için (a) eğitime ve (b) test sonucunda elde edilen karmaşıklık matrisi

Ayrıca Şekil 8’de bu optimize edilmiş YSA-3 modelinin eğitime aşamasında ortalama kare hatası (mean squared error) değerinin iterasyon sayısına göre değişimi görülmektedir. YSA-3 modelinin çok hızlı bir şekilde (ilk 20-30 iterasyon)  $1 \times 10^{-3}$  hata değerine ulaştığı ve bu noktadan sonra iterasyona bağlı olarak hata değerinin daha da azalmadığı anlaşılmaktadır. Bu da eğitime aşaması için iterasyon sayısının 200 yerine 20-30 olarak alınabileceğini ve böylece çok daha hızlı bir şekilde eğitimin tamamlanacağını göstermektedir.



Şekil 8. YSA-3 modelin eğitime aşamasında ortalama kareler hata oranının değişimi

Deneylerden elde edilen sonuçlar, PAKS kayar kapı sisteminde hataları da içeren çalışma durumlarının YSA modeli ile oldukça başarılı bir şekilde sınıflandırılabilirliğini göstermektedir. Burada PAKS sistemin ilgili çalışma durumunu belirlemek için problemi çoklu sınıflandırma olarak ele almak YSA modellerinin yüksek bir başarı oranı ortaya çıkarmasını sağlamıştır.

## 5. Sonuçlar

Veri tabanlı arıza tespiti ve sınıflandırma yaklaşımları sistemlerin sürekli olarak izlenmesi ve arızaların daha erken bir aşamada tespit/teşhis edilmesine imkan vermektedir. Bu çalışmada raylı sistemlerde önemi ve kullanımı her geçen gün artan Peron Ayırıcı Kapı Sisteminin (PAKS) ana bileşeni olan kayar kapı sistemi analiz edildi ve olası mekanik arıza türleri çoklu veriye dayalı YSA modelleri kullanılarak incelendi. YSA hakkında yapılan literatür çalışmalarında verimli bir sınıflandırıcı olduğu görülmekte olup bu çalışmada, YSA modelleri üzerinde odaklanılarak, farklı nöron sayıları üzerinden optimize işlemi gerçekleştirildi. Deneyler, dört farklı YSA modeli kullanılarak 5 farklı çalışma durumu için gerçekleştirilerek, daha spesifik bakıldığında, her bir çalışma durumu için 1000 açma/kapama döngüsü üzerinden motor akım ve gerilim elektriksel sinyalleri ölçülerek 12 adet öz-nitelik değeri hesaplandı ve YSA modellerinin eğitim/test davranışları ve performansları araştırıldı. Performans metrikleri (doğruluk, hassasiyet, kesinlik, vb.) dikkate alınarak her bir modelin diğerleriyle karşılaştırılması bu çalışmada gerçekleştirildi. Ayrıca söz konusu bu çalışmada, giriş-gizli katman-çıkış katmanlarındaki nöron sayılarının sırasıyla 12-7-5 olan yapının en iyi performansı gösterdiği görüldü.

Sonuçlarımız, elektriksel motor ve gerilim sinyallerinin istatistiksel yöntemlerle öz-nitelik değerlerini kullanarak, PAKS kayar kapı sistemindeki hataların veriye dayalı bir şekilde tespit ve sınıflandırılmasının yüksek bir başarı oranında verimli bir şekilde uygulanabileceğini göstermektedir. Bu çalışmada yalnızca akım ve gerilim verilerinin kullanılmasına rağmen, gelecekte bu çalışmayı; daha fazla sinyal kullanarak gerçekleştirme, farklı YSA algoritmalarının karşılaştırılmasını yapma ve ayrıca bu YSA modellerinin uç platforma (edge device) yerleştirme ile PAKS kayar kapı sisteminin hata tespitine yönelik sürekli izlenmesi çalışmaları ile genişletmek mümkün olabilecektir.

## 6. Teşekkür

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

## 7. Kaynakça

- [1] İ. Koç, Ö. Mermer, N. Kırımça, F.H. Çakır ve M. Karaköse, "Modeling and Simulation of Platform Screen Door (PSD) System using Matlab-Simulink" *International Conference on Data Analytics for Business and Industry (ICDABI)*, Sakhr – Kingdom of Bahrain, Eki. 2022, ss. 629-633.
- [2] C. Zhou, Z. Su, ve J. Zhou, "Design and Implementation of the Platform Screen Doors System for BRT", içinde *ICCTP 2010*, Beijing, China, Tem. 2010, ss. 2540-2552. doi: 10.1061/41127(382)271.
- [3] U. T. Abdurrahman, A. Jack, ve F. Schmid, "Effects of platform screen doors on the overall railway system", program adı: 8th International Conference on Railway Engineering (ICRE 2018), London, UK, 2018. doi: 10.1049/cp.2018.0053.
- [4] Z. Yang, X. Su, F. Ma, L. Yu, ve H. Wang, "An innovative environmental control system of subway", *Journal of Wind Engineering and Industrial Aerodynamics*, c. 147, ss. 120-131, Ara. 2015, doi: 10.1016/j.jweia.2015.09.015.
- [5] S. He, L. Jin, T. Le, C. Zhang, X. Liu, ve X. Ming, "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, ss. 633-645, Tem. 2018, doi: 10.1016/j.trd.2018.04.015.
- [6] H. Han, J.-Y. Lee, ve K.-J. Jang, "Effect of platform screen doors on the indoor air environment of an underground subway station", *Indoor and Built Environment*, c. 24, sy 5, ss. 672-681, Ağu. 2015, doi: 10.1177/1420326X14528731.
- [7] X. Li ve Y. Wang, "Simulation study on air leakage of platform screen doors in subway stations", *Sustainable Cities and Society*, c. 43, ss. 350-356, Kas. 2018, doi: 10.1016/j.scs.2018.08.035.
- [8] Z. Su ve X. Li, "Energy benchmarking analysis of subway station with platform screen door system in China", *Tunnelling and Underground Space Technology*, c. 128, s. 104655, Eki. 2022, doi: 10.1016/j.tust.2022.104655.
- [9] O. Lindfeldt, "The impact of platform screen doors on rail capacity", *Int. J. TDI*, c. 1, sy 3, ss. 601-610, Oca. 2017, doi: 10.2495/TDI-V1-N3-601-610
- [10] L. Qu ve W. K. Chow, "Platform siren doors on emergency evacuation in underground railway stations", *Tunnelling and Underground Space Technology*, c. 30, ss. 1-9, Tem. 2012, doi: 10.1016/j.tust.2011.09.003.
- [11] J. S. Roh, H. S. Ryou, ve S. W. Yoon, "The effect of PSD on life safety in subway station fire", *J Mech Sci Technol*, c. 24, sy 4, ss. 937-942, Nis. 2010, doi: 10.1007/s12206-010-0217-7.
- [12] L. Min, C. Zhaoyong, ve Z. Jin, "Study on PSD system control strategy for safety", içinde *2012 3rd International Conference on System Science, Engineering Design and Manufacturing Informatization*, Chengdu, China, Eki. 2012, ss. 154-159. doi: 10.1109/ICSSEM.2012.6340789.
- [13] M. Çeçen, N. Kırımça, Ö. Mermer ve M. Karaköse, "Control and Monitoring Approaches of Platform Screen Door Systems in Railway Systems", *Otomatik Kontrol Ulusal Toplantısı, Elazığ, Türkiye*, Eyl. 2022, ss. 592-597.
- [14] Functional Safety of Electrical/Electronic/Programmable Electronic Safety Related Systems, IEC 61508-3, European

- Committee for Electrotechnical Standardization, Brussels, Belgium, 2000.
- [15] M. S. Durmuş, S. Takai, ve M. T. Söylemez, "Fault diagnosis in fixed-block railway signaling systems: a discrete event systems approach: FAULT DIAGNOSIS IN FIXED-BLOCK RAILWAY SIGNALING SYSTEMS", *IEEJ Trans Elec Electron Eng*, c. 9, sy 5, ss. 523-531, Eyl. 2014, doi: 10.1002/tee.22001.
- [16] C. Li, S. Luo, C. Cole, ve M. Spiriyagin, "An overview: modern techniques for railway vehicle on-board health monitoring systems", *Vehicle System Dynamics*, c. 55, sy 7, ss. 1045-1070, Tem. 2017, doi: 10.1080/00423114.2017.1296963.
- [17] K. Tidriri, N. Chatti, S. Verron, ve T. Tiplica, "Bridging data-driven and model-based approaches for process fault diagnosis and health monitoring: A review of researches and future challenges", *Annual Reviews in Control*, c. 42, ss. 63-81, 2016, doi: 10.1016/j.arcontrol.2016.09.008.
- [18] H. Dassanayake, C. Roberts, C. J. Goodman, ve A. M. Tobias, "Use of parameter estimation for the detection and diagnosis of faults on electric train door systems", *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, c. 223, sy 4, ss. 271-278, Ara. 2009, doi: 10.1243/1748006XJRR265.
- [19] L. Shuai, J. Limin, Q. Yong, Y. Bo, ve W. Yanhui, "Research on Urban Rail Train Passenger Door System Fault Diagnosis Using PCA and Rough Set", *TOMEJ*, c. 8, sy 1, ss. 340-348, Eyl. 2014, doi: 10.2174/1874155X01408010340.
- [20] E. Miguelanez, K. E. Brown, R. Lewis, C. Roberts, ve D. M. Lane, "Fault diagnosis of a train door system based on semantic knowledge representation", içinde *4th IET International Conference on Railway Condition Monitoring (RCM 2008)*, Derby, UK, 2008, ss. 27-27. doi: 10.1049/ic:20080333.
- [21] L. Cauffriez, S. Grondel, P. Loslever, ve C. Aubrun, "Bond Graph modeling for fault detection and isolation of a train door mechatronic system", *Control Engineering Practice*, c. 49, ss. 212-224, Nis. 2016, doi: 10.1016/j.conengprac.2015.12.019.
- [22] J. Yu, "Local and global principal component analysis for process monitoring", *Journal of Process Control*, c. 22, sy 7, ss. 1358-1373, Ağu. 2012, doi: 10.1016/j.jprocont.2012.06.008.
- [23] D. Gonzalez-Jimenez, J. del-Olmo, J. Poza, F. Garramiola, ve P. Madina, "Data-Driven Fault Diagnosis for Electric Drives: A Review", *Sensors*, c. 21, sy 12, s. 4024, Haz. 2021, doi: 10.3390/s21124024.
- [24] X. Sun, K. V. Ling, K. K. Sin, ve L. Tay, "Intelligent Fault Detection and Diagnosis of Air Leakage on Train Door", içinde *2018 International Conference on Intelligent Rail Transportation (ICIRT)*, Singapore, Ara. 2018, ss. 1-4. doi: 10.1109/ICIRT.2018.8641662.
- [25] S. Kim, N. H. Kim, ve J.-H. Choi, "Information Value-Based Fault Diagnosis of Train Door System under Multiple Operating Conditions", *Sensors*, c. 20, sy 14, s. 3952, Tem. 2020, doi: 10.3390/s20143952.
- [26] R. Chen, S. Zhu, F. Hao, B. Zhu, Z. Zhao, ve Y. Xu, "Railway Vehicle Door Fault Diagnosis Method with Bayesian Network", içinde *2019 4th International Conference on Control and Robotics Engineering (ICCRE)*, Nanjing, China, Nis. 2019, ss. 70-74. doi: 10.1109/ICCRE.2019.8724211.
- [27] Y. Sun, Y. Cao, ve L. Ma, "A Fault Diagnosis Method for Train Plug Doors via Sound Signals", *IEEE Intell. Transport. Syst. Mag.*, c. 13, sy 3, ss. 107-117, 2021, doi: 10.1109/MITS.2019.2926366.
- [28] H. Chen, B. Jiang, S. X. Ding, ve B. Huang, "Data-Driven Fault Diagnosis for Traction Systems in High-Speed Trains: A Survey, Challenges, and Perspectives", *IEEE Trans. Intell. Transport. Syst.*, c. 23, sy 3, ss. 1700-1716, Mar. 2022, doi: 10.1109/TITS.2020.3029946.
- [29] G. W. Han vd., "Incipient anomaly detection for railway vehicle door system based on adaptive mean shift clustering", içinde *2017 Chinese Automation Congress (CAC)*, Jinan, Eki. 2017, ss. 1297-1302. doi: 10.1109/CAC.2017.8242967.
- [30] X. Heng, Q. Jiang, D. Liu, L. Xie, T. Zhan, ve N. Jin, "Fault Diagnosis of Subway Plug Door Based on KPCA and CS-LSSVM", içinde *2020 15th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, Kristiansand, Norway, Kas. 2020, ss. 100-105. doi: 10.1109/ICIEA48937.2020.9248245.
- [31] S. Ham, S.-Y. Han, S. Kim, H. J. Park, K.-J. Park, ve J.-H. Choi, "A Comparative Study of Fault Diagnosis for Train Door System: Traditional versus Deep Learning Approaches", *Sensors*, c. 19, sy 23, s. 5160, Kas. 2019, doi: 10.3390/s19235160.
- [32] N. Lehrasab, H. P. B. Dassanayake, C. Roberts, S. Fararooy, ve C. J. Goodman, "Industrial fault diagnosis: Pneumatic train door case study", *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, c. 216, sy 3, ss. 175-183, May. 2002, doi: 10.1243/095440902760213602.
- [33] P. Wen, M. Zhi, G. Zhang, ve S. Li, "Fault Prediction of Elevator Door System Based on PSO-BP Neural Network", *ENG*, c. 08, sy 11, ss. 761-766, 2016, doi: 10.4236/eng.2016.811068.
- [34] T. Ince, S. Kiranyaz, L. Eren, M. Askar, ve M. Gabbouj, "Real-Time Motor Fault Detection by 1-D



- Convolutional Neural Networks”, *IEEE Trans. Ind. Electron.*, c. 63, sy 11, ss. 7067-7075, Kas. 2016, doi: 10.1109/TIE.2016.2582729.
- [35] Chow, M.-Y., “Methodologies of using neural network and fuzzy logic technologies for motor incipient fault detection”, Singapore: World Scientific, 1997.
- [36] B. Bagheri, H. Ahmadi, ve R. Labbafi, “Application of data mining and feature extraction on intelligent fault diagnosis by Artificial Neural Network and k-nearest neighbor”, içinde *The XIX International Conference on Electrical Machines - ICEM 2010*, Rome, Italy, Eyl. 2010, ss. 1-7. doi: 10.1109/ICELMACH.2010.5607984.
- [37] A. Boussif ve M. Ghazel, “Model-Based Monitoring of a Train Passenger Access System”, *IEEE Access*, c. 6, ss. 41619-41632, 2018, doi: 10.1109/ACCESS.2018.2860966.
- [38] B. Yegnanarayana, “Artificial neural networks”, PHI Learning Pvt. Ltd., 2009
- [39] I. N. da Silva, R. Andrade Flauzino, S. F. dos Reis Alves, D. Hernane Spatti, ve L. H. B. Liboni, *Artificial Neural Networks: A Practical Course*, 1st ed. 2017. Cham: Springer International Publishing : Imprint: Springer, 2017. doi: 10.1007/978-3-319-43162-8.
- [40] I. A. Basheer, and M. Hajmeer, “Artificial neural networks: fundamentals, computing, design, and application,” *Journal of Microbiological Methods* vol. 43(1), ss.3–31, 2000.
- [41] ]H. Demuth, M. Beale, and M. Hagan, “Neural Network Toolbox TM 6 User’s Guide”. Network, the MathWorks, Inc.P, 2010.
- [42] Z. Comert, A.F. Kocamaz, “A study of artificial neural network training algorithms for classification of cardiocography signals,” *Bitlis Eren University Journal Of Science And Technology* vol. 7(2), ss 93–103, 2017.
- [43] Y. Liu, J. Starzyk, Z. Zhu, “Optimizing number of hidden neurons in neural networks.. *IASTED International Conference on Artificial Intelligence and Applications* ss.138-143, Austria, 2007.

## Özgeçmişler



**İsa Koç**, 1989'da Beypazarı'nda doğdu. Lisans derecesini Atatürk Üniversitesi Elektrik- Elektronik Mühendisliği ve yüksek lisans derecesini Eskişehir Osmangazi Üniversitesi Elektrik-Elektronik Mühendisliği alanında sırasıyla 2013 ve 2017 yıllarında almıştır. Halen aynı üniversitede doktora çalışmalarına devam etmektedir. Aynı zamanda Albayrak Makine Elektronik A.Ş. firmasında Ar-Ge mühendisi olarak görev yapmaktadır. Güncel araştırma alanları arasında veri analizi, AI tabanlı hata sınıflandırma, Matlab/Simulink tabanlı sistem modelleme, akustik ve elektromanyetik dalgalar yer almaktadır.



**Ömer Mermer**, lisans ve yüksek lisans derecesini Ege Üniversitesi Elektrik ve Elektronik Mühendisliği alanında sırasıyla 1998 ve 2001 yıllarında almıştır. 2006 yılında Iowa Üniversitesi'nden (ABD) Fizik Doktora derecesini almıştır. 2016 yılında Üniversiteler Arası Kurul tarafından Doçent unvanını almıştır. Halen Albayrak Makine Elektronik A.Ş. firmasında Ar-Ge bölümünde RAMS Yöneticisi olarak görev yapmaktadır. Güncel araştırma alanları arasında AI tabanlı hata sınıflandırma, kestirimci bakım, fonksiyonel emniyet, sistem modelleme ve optoelektronik aygıt ve sensör uygulamaları yer almaktadır.



**Necim Kırımça**, lisans derecesini İstanbul Teknik Üniversitesi Elektrik Mühendisliği alanında 1988 yılında almıştır. Halen Albayrak Makine Elektronik A.Ş. firmasında Kalite ve Ar-Ge Yöneticisi görev yapmaktadır. Güncel araştırma alanları arasında kalite yönetimi, fonksiyonel emniyet, hata sınıflandırma yer almaktadır.



**Prof. Dr. Mehmet Karaköse**, 1976 yılında Elazığ'da doğdu. Lisans derecesini 1998 yılında Fırat Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden aldı. 2001 yılında Bilgisayar Mühendisliği'nde Yüksek lisansını ve 2005 yılında Elektrik-Elektronik Mühendisliğinde Doktora eğitimini tamamladı. 1999-2005 yılları arasında Bilgisayar Mühendisliği Yazılım Anabilim Dalı'nda araştırma görevlisi, 2005-2014 yılları arasında Yrd.Doç.Dr., 2014-2020 yılları arasında Doç.Dr. olarak çalışmış olup 2020 yılından beri Prof. Dr. olarak aynı bölümde görev almaktadır. Araştırma alanları akıllı sistemler, bulanık sistemler, simülasyon ve modelleme, hesapsal zeka, arıza teşhisi, optimizasyon algoritmaları, görüntü işleme, makine görmesi, beyin-bilgisayar etkileşimi, raylı sistemler ve kuantum hesaplama modelleridir. IEEE kıdemli üyesidir. Çeşitli dergiler ve konferans bildirilerinde yayınlanan birçok makale yazmıştır ve birçok TÜBİTAK projesi tamamlamıştır. Bilgisayar Mühendisliği Bölümü'nde Otomata Teorisi, Algoritma Analizi, Derleyici Tasarımı, Sistem Teorisi, Yapay Zeka, Hesapsal Zeka, Kuramsal Hesaplama ve İnsan-Bilgisayar Etkileşimi derslerini vermektedir.