

ISSN: 1308-9064

Cilt: 36 / Sayı: 2 / Yıl: 2024

# FIRAT ÜNİVERSİTESİ FEN BİLİMLERİ DERGİSİ





Fırat Üniversitesi  
Fen Bilimleri Dergisi (FBD)  
Cilt:36, Sayı:2, Yıl:2024  
ISSN: 1308 - 9064

### İletişim

Fırat Üniversitesi  
Fen Bilimleri Enstitüsü  
23119, ELAZIĞ

Tel: 0 424 212 27 07  
Faks: 0 424 236 99 55  
e-posta: [fenbilim@firat.edu.tr](mailto:fenbilim@firat.edu.tr)

Bu dergi yılda 2 kez ve hakemli olarak yayımlanır.

Derginin Eski Adı: Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi  
Derginin Eski ISSN Numarası: 1300-2708

<http://dergipark.gov.tr/fufbd>



**Fırat Üniversitesi  
Fen Bilimleri Dergisi (FBD)**

**Sahibi**

**Prof. Dr. Fahrettin GÖKTAŞ**  
Fırat Üniversitesi Rektörü

**Genel Yayın Yönetmeni**

**Prof. Dr. Burhan ERGEN**  
F.Ü. Fen Bilimleri Enstitüsü Müdürü

**Baş Editör**

**Doç. Dr. Ferhat Uçar**  
F.Ü. Fen Bilimleri Enstitüsü Müdür Yrd.

**Editör**

**Prof. Dr. Emrah YILMAZ**  
F.Ü. Fen Bilimleri Enstitüsü Müdür Yrd.

**DANIŞMA KURULU**

Ali YAZICI	Atılım Ü., Yazılım Müh.	Turgay SEÇKİN	İnönü Ü., Kimya
Haluk KORALAY	Gazi Ü., Fizik	İbrahim KARATAŞ	Selçuk Ü., Kimya
Mahmut ELP	Kastamonu Ü., Su Ürünleri	Zihni DEMİRBAĞ	K.T.Ü., Biyoloji
Yusuf AYVAZ	S.Demirel Ü., Biyoloji.	Seyfettin ÇAKMAK	S.Demirel Ü., Fizik
Mikail ET	Fırat Ü., Matematik	Orhan ERMAN	Fırat Ü., Biyoloji
Hikmet GEÇKİL	İnönü Ü., Biyoloji	Ömer AKIN	T.O.B.B. Matematik
Kenan GÜLLÜ	Muğla S.K.Ü. Su Ürünleri	Sinan AKPINAR	Fırat Ü., Fizik
Mehmet KAYA	Fırat Ü., Kimya	Ahmet ŞAHİN	Erciyes Ü., Biyoloji
İlhami KİZİROĞLU	Hacettepe Ü., Biyoloji	Kadir DEMİRELLİ	Fırat Ü., Kimya
S.Güneş KÜRKÇÜOĞLU	Osmangazi Ü., Fizik	Kenan GÜLLÜ	Muğla Ü., Su Ürünleri
Dursun ŞEN	Fırat Ü., Su Ürünleri	Vedat ASİL	Fırat Ü., Matematik
Serdar SALMAN	Marmara Ü. Metal. Müh.	Ertan GOKALP	K.T.Ü. Harita. Müh.
İzzet KARA	Pamukkale Ü., Fizik	Ekrem ARTUNÇ	S.Demirel Ü., Fizik



# Fırat Üniversitesi Fen Bilimleri Dergisi (FBD)

## 36-2, 2024

### İÇİNDEKİLER / CONTENTS

1. TuringEQ: Doğrusal Olmayan Problemler Özelinde Yeni bir Yapay Zekâ Mimarisi  
*TuringEQ: A New Artificial Intelligence Architecture for Nonlinear Problems*  
Hüseyin Enes OKUTAN, Muhammet BAYKARA ..... 43-58
2. Martensitic Transformation Thermodynamic and Structure Analysis of CuAlFe High-Temperature Shape Memory Alloy  
*CuAlFe Yüksek Sıcaklık Şekil Hafızalı Alaşımın Martensitik Dönüşüm Termodinamigi ve Yapı Analizi*  
Oktay Karaduman, İskender Özkul, Yakup Aydemir, Canan Aksu Canbay ..... 59-66
3. Gerilim Kaynaklı Eviricinin Faz Akımlarının İzlenmesiyle Açık Devre Arızalarının Teşhisİ  
*Diagnosis of Open Circuit Faults by Monitoring Phase Currents of Voltage Source Inverter*  
Serenay Çelik, Servet Tuncer ..... 67-82
4. SARS CoV-2 (COVID-19) ve Biyolojik Etkileri  
*SARS CoV-2 (COVID-19) and Its Biological Effects*  
Nuray Temizkan, Özlem Gök, Abdullah Aslan ..... 83-94



## TuringEQ: Doğrusal Olmayan Problemler Özeline Yeni bir Yapay Zekâ Mimarisi

Hüseyin Enes OKUTAN<sup>1\*</sup>, Muhammet BAYKARA<sup>2</sup>

<sup>1</sup> Yazılım Mühendisliği Bölümü, Mühendislik Fakültesi, İnönü Üniversitesi, Malatya, Türkiye

<sup>2</sup> Yazılım Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

\*<sup>1</sup> enes.okutan@inonu.edu.tr, <sup>2</sup> mbaykara@firat.edu.tr

(Geliş/Received: 05/06/2024;

Kabul/Accepted: 20/09/2024)

**Öz:** Yapay Zekâ alanındaki gelişmelerle birlikte birçok alanda Yapay Zekâ kullanımını yaygınlaşmış ve bu teknolojinin kullanımı ile önemli başarımlar elde edilmiştir. Elde edilen başarımların büyük bir kısmı, Yapay Zekâ içerisindeki alt alanlardan biri olan Yapay Sinir Ağlarına dayanmaktadır. Bu çalışma kapsamında, Yapay Sinir Ağlarının başarım düzeyini yakalayabilecek yeni bir Yapay Zekâ Mimarisi üzerinde durulmaktadır. Bu çalışmada, doğrusal ve doğrusal olmayan problemler özeline incelemeler yapılarak bu problemlerin karakteristiğinin çözüm üzerindeki etkileri incelenmiş ve bu incelemeler sonucunda temel bir doğrusal olmayan problem üzerinde, başarılı bir şekilde çalışacak yeni bir Yapay Zekâ Mimarisi geliştirilmesi amaçlanmıştır. Yapılan çalışmada öncelikle yeni Yapay Zekâ Mimarisi için temel bir problem belirlenmiştir. Temel problemin belirlenmesinin ardından, Yapay Zekâ Mimarisi ile ilgili çalışmalarla başlanarak teorik temeller üzerinde mimari tasarım yapılmıştır. Mimari kapsamında, problem katmanlara bölünerek, her katmanın kendi içerisinde düzgün bir şekilde öğrenme işlemini gerçekleştirmesi amaçlanmıştır. Başarıma olumsuz olarak etki eden katmanlar içerisindeki ağırlıkların, katman bozukluğunu giderecek şekilde değiştirilmesi ile katman düzeltimi yapılmıştır. Bu katman düzeltmeleri ile mimarinin temeli olarak her katmanın genel mimari başarısını artıracak şekilde kendi hatasını düzeltmesi ile öğrenme işleminin hatasız bir şekilde gerçekleştirilebilmesi amaçlanmıştır. Bütün bu teorik temeller üzerine tasarlanan Yapay Zekâ Mimarisinin, temel bir doğrusal olmayan problem üzerinde test edilmesi sonucunda mimarinin başarılı bir şekilde öğrenme işlemini gerçekleştirdiği görülmüştür.

**Anahtar kelimeler:** Yapay Zekâ, Yapay Öğrenme, Doğrusal Olmayan Problem.

## TuringEQ: A New Artificial Intelligence Architecture for Nonlinear Problems

**Abstract:** With the developments in the field of Artificial Intelligence, the use of Artificial Intelligence has become widespread in many areas and important achievements have been achieved with the use of this technology. Most of the achievements are based on Artificial Neural Networks, which is one of the sub-fields in Artificial Intelligence. In this study, a new Artificial Intelligence Architecture that can achieve the performance level of Artificial Neural Networks is emphasized.

In this study, the effects of the characteristics of these problems on the solution were examined by examining the linear and nonlinear problems, and because of these examinations, it was aimed to develop a new Artificial Intelligence Architecture that would work successfully on a basic nonlinear problem. In the study, first, a basic problem for the new Artificial Intelligence Architecture was determined. After the determination of the basic problem, studies on Artificial Intelligence architecture were started and architectural design was made on theoretical foundations. Within the scope of architecture, it is aimed to divide the problem into layers and each layer to perform the learning process within itself properly. Layer correction was made by changing the weights in the layers, which had a negative effect on the performance, in a way that would eliminate the layer defect. With these layer corrections, as the basis of the architecture, it is aimed to perform the learning process without error by correcting its own error in a way that increases the overall architectural performance of each layer. As a result of testing the Artificial Intelligence architecture, which was designed on all these theoretical foundations, on a basic nonlinear problem, it was seen that the architecture successfully performed the learning process.

**Key words:** Artificial Intelligence, Machine Learning, Nonlinear Problem.

### 1. Giriş

Teknolojinin gelişmesi ve mevcut problemler üzerine uygulanmasıyla birçok probleme etkin ve kalıcı çözümler üretilmeye başlanmıştır. İnsanlar açısından, zamandan ve maliyetten tasarruf sağlamak amacıyla teknolojik gelişmeler doğrudan kullanım alanları bularak, insanların problemlerine çözümler üretilmiştir. Bu kapsamında, kullanım alanı olarak bilimsel problemlerden günlük hayatı karşılaşılan problemlere kadar birçok alanda aktif teknolojik çözümler kullanılmaya başlanmıştır.

İlk zamanlarda temel anlamda komutlar ile çözülebilen problemlerin karmaşık bir yapıya dönüşmesi sonucunda teknolojik gelişmeler bir gereklilik haline gelmiştir. Teknolojinin gelişiminin kaçınılmaz olduğu bu

\* Sorumlu yazar: enes.okutan@inonu.edu.tr. Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-7455-2786, <sup>2</sup> 0000-0001-5223-1343

ilerlemeler sonucunda Yapay Zekâ konusu ortaya çıkmış ve insanların problemlerine en az insanlar kadar etkin çözümler üretebilecek teknolojiler üzerinde durulmuştur.

Makinelerin en az insanlar kadar zeki olabileceği fikri 1950 yılında Mind adlı felsefe dergisinde ünlü bir İngiliz matematikçi ve bilgisayar bilimcisi olan Alan Turing tarafından Turing Testi olarak ortaya atılmıştır [1]. Alan Turing tarafından ortaya atılan Turing Testi, temel olarak belirli üç oda üzerinde durmaktadır. Bu odalardan ilki, içerisinde sorular sormaya hazır olan sorgulayıcı bir insanın olduğu bir odadır. Bu odalardan ikinci oda sorulara cevap vermeyi bekleyen cevap verici bir insanın yer aldığı bir odadır. Bu odalardan sonuncu oda ise içerisinde sorulan sorulara cevap verebilecek bir bilgisayarın bulunduğu odadır. Turing testine göre, ilk odada bulunan sorgulayıcı insan, sorulara cevapların geleceği odalardan hangisinde bilgisayar hangisinde insan olduğunu bilmemektedir. Bu kapsamda Turing testi, sorgulayıcı olan insanın yönelttiği sorulara verilen cevaplardan cevabı veren odada bir bilgisayar mı yoksa bir insan mı olduğunu tahmin edilememesine dayanmaktadır. Eğer sorgulayıcı insan, bilgisayar ve insan tahminini doğru bir şekilde yapamaz ise bu durum Turing testinin başarılı olduğu anlamına gelmekte ve makinelerin düşünebileceği kanıtlanmış olmaktadır.

Alan Turing tarafından, makinelerin düşünebilmesine yönelik ilk fikirlerin ortaya atılmasının ardından gelen teknolojik gelişmeler ile Yapay Zekâ kavramı ortaya çıkmıştır. Alan Turing'in Turing testi ile ortaya çıkarmayı amaçladığı şekilde bir Yapay Zekâ, bir bilgisayarın veya bilgisayar kontrollü robotun akıllı varlıklarla ilişkili görevleri yerine getirme yeteneğidir [2].

Yapay Zekâ kavramının ortaya çıkışının ardından akıllı varlıklarla ilişkili görevleri yerine getirebilmek amacıyla çeşitli akıllı algoritmalar geliştirilmiştir. Geliştirilen akıllı algoritmaların mevcut problemleri akıllı bir varlık kadar iyi bir şekilde çözebilmesi sonucunda Yapay Zekâ alanında hızla artan gelişmeler sağlanmış ve mevcut akıllı algoritmaların insan beynine benzer şekilde çalışabilme kabiliyeti üzerinde durulmuştur.

Akıllı algoritmalarının insan beynine olabildiğince yakın olarak modellenmesini sağlayabilecek bilimsel çalışmaların sürdürülmesinin ardından Yapay Sinir Ağı ortaya çıkmıştır. Yapay Sinir Ağı, insan beyni içerisindeki bilgi akışı ve işlenmesinin yapay olarak bilgisayarlar üzerinde modellenmesini içeren bir Yapay Zekâ alt dalıdır [3]. Yapay Sinir Ağları ile beynin bilgi işlem mimarisine benzer bir şekilde katmanlı bir sinir ağı mimarisi temel almaktadır. Her bir katman kendi içerisinde bilgiyi işleyen düğümlere sahiptir. Ek olarak bu düğümler diğer düğümlere bilginin aktarılmasını sağlayan ve bilgisayarın öğrenme işlemini gerçekleştiren belirli ağırlık değerlerine sahiptir. Bir Yapay Sinir Ağı, temelde bu bağlantılar üzerindeki ağırlıkları ayarlama işlemini gerçekleştirerek bilgisayarın verilen problemi öğrenmesini sağlamayı amaçlamaktadır. Bir Yapay Sinir Ağı üzerinde ağırlıkların güncellenmesini içeren tüm bu işlemler, genel olarak belirli verilerin Yapay Sinir Ağına gösterilmesi ve Yapay Sinir Ağını gösterilen bu verilerden öğrenme işlemi yapmasını sağlamaktadır [4].

Tüm bu gelişmelerden görülebileceği gibi teknolojik olarak Alan Turing testi ile başlayan gelişmeler günümüz teknolojisinde Yapay Sinir Ağları ile kendisini göstermektedir. Yapay Zekâ alanında yaşanan gelişmeler ile çözülebilecek problem uzayı artmaka ve her açıdan insanların yaklaşımına benzer şekilde etkin ve verimli çözümler üretilebilmektedir.

Bu çalışma kapsamında etkin ve verimli çözümler üretilebilmesine olanak tanıyan Yapay Sinir Ağına ek olarak yeni bir alternatif Yapay Zekâ Mimarisinin oluşturulması amaçlanmıştır. Ek olarak oluşturulmuş olan bu Yapay Zekâ Mimarisinin doğrusal olmayan bir problem olan XOR problemi üzerindeki başarımı analiz edilmiştir.

Oluşturulan Yapay Zekâ Mimarisi denklem sistemlerine ve katman mimarisine dayanmaktadır. Bu katman mimarisi sayesinde problem katmanlar düzeyinde çözüme ulaşılırarak, bozuk katmanların genel başarımı maksimuma ulaştracak şekilde kendilerini düzeltmesi işlemi gerçekleştirilmiştir. Elde edilen Yapay Zekâ Mimarisinin doğrusal olmayan bir problem olan XOR problemi üzerinde test edilmesi sonucunda, mimarının tahminleme işlemini düzgün bir şekilde yaptığı görülmüş ve TuringEQ Yapay Zekâ Mimarisinin doğrusal olmayan problemler üzerinde çalıştığı kanıtlanmıştır.

Çalışma kapsamında mevcuttaKİ Yapay Zekâ mimarilerine bağımlılığı azaltmak ve ileriki aşamalarda performans optimizasyonları yapılabilecek denklem sistemlerine dayalı yeni bir Yapay Zekâ sistemi geliştirilmesi amaçlanmıştır. Geliştirilen bu Yapay Zekâ mimarisi ile yeni mimarilerin Yapay Sinir Ağlarının ilk çaglarında çözümlü olduğu doğrusal olmayan bir problem olan XOR problemini çözdüğü kanıtlanarak Yapay Zekâ alanında sadece Yapay Sinir Ağları özelinde değil, farklı yaklaşımlar ile literatürde yeni yaklaşımların getirilebileceği görülmektedir. Ek olarak çalışma kapsamında denklem sistemlerine dayalı yeni bir mimarının geliştirilmesinin sebebi, ileriki çalışmalarda denklem sadeleştirme ve denklem optimizasyonu teknikleri ile TuringEQ mimarisinin hesaplama karmaşıklığını azaltarak Yapay Zekâ sistemlerinin hesaplama maliyetlerini düşürmektedir.

## 2. İlgili Çalışmalar

Yapay Zekâ alanında son yıllarda yapılan çalışmalar, insan zekasına benzer davranışların bilgisayarlarda modellenebilmesine dayanmaktadır. Bu kapsamında, literatürde çeşitli yaklaşımlara dayanan mimari ve konseptler geliştirilmiştir. Bu yeni Yapay Zekâ yaklaşımlarından ilki insan beynindeki sinir hücrelerinin ve bu hücreler

arasındaki bağlantıların modellemesini içeren Yapay Sinir Ağlarıdır. Yapay Sinir Ağları, son zamanlarda karmaşık süreçlerin modellenmesinde bir araç olarak uygulanmaya başlayan veriye dayalı modellerden biridir [5]. Yapay sinir ağları ile son zamanlarda yapılan birçok uygulama mevcuttur. Bu uygulamalardan bazıları doğal dil işleme, görüntü işleme ve makine öğrenmesi gibi alanları kapsamaktadır. Yapay Sinir Ağlarının Yapay Zekâ alanında en çok kullanılan mimari yaklaşım olmasına karşın kullanım alanlarına ve amaçlarına göre sinir ağları bağlamında veya tamamıyla özgün bir mimari olarak geliştirilen farklı Yapay Zekâ yaklaşımları da mevcuttur.

Bu yaklaşımlar Yapay Sinir Ağlarını temel olarak farklılaşan mimari bileşenlerine veya onarım mekanizmalarına dayanan çeşitli yeni sinir ağı tasarımlarını içermektedir. Bu tasarımlardan bazıları Neocognitron [6], LeNet-5 [7], AlexNet [8], VGGNet [9], GoogleNet [10] ve ResNet [11] olarak isimlendirilen sinir ağı mimarileridir. Yapay Zekâ alanında üretilen bu yeni mimariler, farklılaşarak ortaya çıkarken genellikle belirli problemlerin üstesinden gelmek veya mevcut yöntemlerin sınırlamalarını aşmak amacıyla tasarlanmıştır. Geleneksel yapay sinir ağları büyük veri kümelerinde etkili olmasına rağmen, hesaplama karmaşıklığı ve eğitim süreleri gibi zorluklarla karşı karşıya kalmasından kaynaklı olarak sinir ağlarını temel alan yeni mimarilerde geliştirilmiştir. Bu sorunları ele almak için geliştirilen Transformers mimarisi, özellikle doğal dil işleme alanında iyi bir performans sergilerken, EfficientNet gibi modeller, sinir ağlarının boyutlandırılmasındaki verimsizlikleri gidermek amacıyla ölçeklendirme stratejilerini optimize etmektedir. Graph Neural Networks ise, düğümler ve kenarlar arasındaki ilişkileri modelleyerek graf yapılarındaki verileri analiz etmede önemli bir adım atmıştır. Her bir yeni mimari, belirli bir problem veya sınırlamayı hedef olarak var olan yöntemlerden farklılaşan özgün yaklaşımlar sunarak Yapay Zekâ uygulamalarının kapsamını ve etkinliğini genişletmektedir. Yapay Sinir Ağlarından türeyen bu mimarilerin yanı sıra sinir ağı mimarilerinin manuel yapılandırmasından kaynaklanan hatalara odaklanan çalışmalarda mevcuttur. Bu çalışmalardan biri Termrrithikun ve arkadaşları [12] tarafından geliştirilen ve sinir ağı mimarilerinin manuel olarak yapılandırılması problemini çözmeyi amaçlayan bir süper ağ mimarisidir. Çalışma kapsamında SainAS ismi verilen bu süper ağ mimarisi ile belirginlik tahmini problemi için manuel yapılandırmadan kaynaklanan hataların engellenmesi amacıyla dinamik bir evrişim entegrasyonu kullanılarak ağ içerisinde otomatik bir yapılandırma gerçekleştirilmektedir. Literatürde sinir ağları temel alınarak geliştirilen birçok yapay zekâ mimarisi olmasına karşın istatistiksel yöntemler baz alınarak geliştirilen farklı Yapay Zekâ yaklaşımları da mevcuttur. Bu yaklaşımlardan biri sınıflandırma problemlerinde kullanılan ve istatistiksel yöntemlere dayanan Naive Bayes algoritmasıdır. Naive Bayes algoritması, Bayes teoremine dayanarak sınıflandırma yapan olasılık tabanlı bir algoritmadır [13]. İstatistiksel yöntemlere dayanan diğer Yapay Zekâ algoritmaları ise bağımlı ve bağımsız değişkenler arasındaki doğrusal ilişkileri modellemeye dayanan doğrusal regresyon ve belirli bir olayın olma olasılığına tahmin etmeye dayalı olan lojistik regresyon algoritmalarıdır. Yapay Zekâ alanında yaygın olarak kullanımda olan diğer yaklaşımlar ise verilerin komşuluk ilişkilerinin analizine dayanan k-en yakın komşu algoritması ve k ortalamalar algoritmalarıdır.

Literatürde Yapay Zekâ alanı ile ilgili gerçekleştirilen çalışmalar incelendiğinde çalışmaların büyük bir kısmının Yapay Sinir Ağları temelinde gerçekleştirildiği görülmektedir. Son yıllarda yapılan çalışmalar tamamıyla yeni ve özgün Yapay Zekâ mimarileri geliştirilmesinden ziyade mevcutta var olan Yapay Zekâ mimarilerinin iyileştirilmesine yönelik çalışmalardır. MevcuttaKİ Yapay Sinir Ağlarının beyin tümörlerinin sınıflandırılmasını içeren ve Joshi ve arkadaşları [14] tarafından yapılan bir çalışmada parçacık sürü optimizasyonu kullanımını iyileştiren ve Cuckoo arama algoritmasını kullanan PSCS adında yeni bir optimizasyon yaklaşımı önerilmektedir. Önerilen optimizasyon yaklaşımının sinir ağları ile birleştirilmesi sonucunda başarılı sonuçlar elde edilmiştir. Sinir ağı mimarilerinin dışında veri setlerinin mimarilere uygun yapılara dönüştürülmesi için yapılan çalışmalar mevcuttur. Bu çalışmalardan biri Rosso ve arkadaşları [15] tarafından inşaat yapılarının dayanıklılığını ölçmek için sinir ağlarının kullanımında performans iyileştirmesi için veri ön işleme adımda Fourier dönüşümlü ve dönüşümsüz tekniklerin Yapay Sinir Ağının başarısına katkısını incelemektedir. Literatürde Yapay Zekânın eğitilmesi için kullanılacak yeni veri setlerinin üretimine yönelik çalışmalar da mevcuttur. Bu çalışmalardan biri Aslan ve arkadaşları [16] tarafından yalan söyleyen ve söylemeyen insanların beyinlerinden alınan EEG sinyal örneklerinden oluşan büyük bir veri setinin oluşturulmasına ve Yapay Sinir Ağları ile analizine odaklanmaktadır.

Literatürde gerçekleştirilen bu çalışmalara bakıldığına Yapay Zekâ alanında yapılan yoğunlukla sinir ağları temelinde gerçekleştirildiği görülmektedir. Bu kapsamda, Yapay Zekâ alanında yapılan çalışmaların yeni ve özgün mimari ve yaklaşımlarla geliştirilmesi için yapılan bu çalışmanın literatüre önemli bir katkı sunacağı düşünülmektedir.

### 3. Problem Kümeleri

Bir problem, yanıtının bilimsel yöntemlerle bulunması veya kurallarla çözülmesi gereken bir soru olarak tanımlanmaktadır. İnsanlar geçmişten günümüze kadar birçok problem ile karşılaşmış ve bu problemlere o günün mevcut imkanlarını kullanarak çözümler üretmişlerdir. Elde mevcut olan bir durumun problem olarak nitelenebilmesi için şu özelliklere sahip olması gerekmektedir:

- Durumun benzersiz olması
- Çözümünün hali hazırda biliniyor olmaması
- Durumun zihinde karmaşıklığa sebep olması
- Daha önce edinilen bilgi ve tecrübe ile çözülebilir nitelikte olması

Temel olarak bir problemin problem olarak nitelenebilmesi için belirtilen özelliklerini sağlaması gerekmektedir.

Problemlerin ortaya çıkışları, teknolojik geliştirmeleri hızlandırmış ve belirli problem karakteristiklerine ek olarak yeni çözüm yöntemleri ortaya çıkmıştır. Problemlerin karakteristiği çözüme giden yolda önemli bir yer tutmaktadır. Çözümün bilinmesinden ziyade genellenebilir bir çözüm elde edebilmek için üzerinde çalışılan problem karakteristiklerinin doğru bir şekilde analiz edilmesi gerekmektedir. Çalışma kapsamında ele alınacak iki ana problem karakteristiği mevcuttur. Bu problem karakteristiklerinden ilki herhangi bir düzensizlik içermeyen doğrusal problemler iken, ikincisi ise düzensizlikler barındırabilen doğrusal olmayan

### 3.1. Doğrusal Problemler

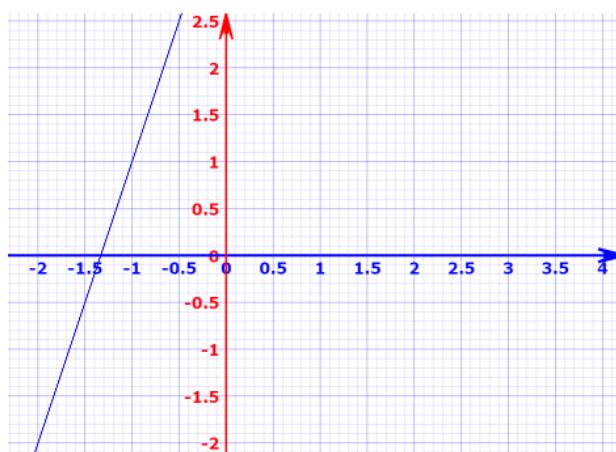
Doğrusal problemler, kendi içerisinde bir doğrusallık içeren ve bu doğrusallığı bozacak herhangi bir düzensizliği barındırmayan problemlerdir. Bu tür problemlerde veriler, doğrusal bir düzlem üzerinde ilerlemektedir.

#### 3.1.1. Doğrusal Problemlerin Karakteristiği

Doğrusal problemler, düzin bir dağılıma sahiptir. Bu problem türüne dahil olan problemler kendi içerisinde düzenliliği bozacak herhangi bir karakteristik taşımaz. Ayrıca doğrusal bir problem düzlemsel olarak bakıldığından doğrusallık taşımaktadır. Verilerin dağılımı, bu doğrusallığı bozacak herhangi bir düzensizlik içermemektedir. Denklem 1'de basit bir doğrusal denklem problemi verilmiştir. Bu problem, denklem tanımından da anlaşılabileceği gibi doğrusal bir yapıya sahip olup, kendi içerisinde herhangi bir düzensizlik barındımadığından doğrusal problem kategorisine girmektedir.

$$y = 3x + 5 \quad (1)$$

Başa bir ifade ile Denklem 1'de verilen denklem Şekil 1'de görüldüğü gibi düzlem üzerinde doğrusal bir dağılıma sahip olduğundan doğrusal bir problem olarak sınıflandırılabilir.



Şekil 1. Doğrusal bir denklem için düzlem üzerinde grafiksel gösterim

### 3.1.2. Doğrusal Problemlerin Çözüm Yöntemleri

Doğrusal problemlerin çözülebilmesi için bir amaç fonksiyonu seçilmelidir. Seçilen amaç fonksiyonunun belirli kısıtlara uyması şartıyla, verilerin doğrusallığından faydalananarak doğrusal problemlerin çözülmesi işlemi gerçekleştirilecektir. Doğrusal problemler çözülürken izlenmesi gereken adımlar sırasıyla şu şekildedir [17]:

- Karar değişkenleri tanımlanır: Amaç fonksiyonunun kontrolü için gerekli olan karar değişkenlerinin tanımlanması işlemi yapılır. Bu adımda tanımlanan karar değişkenleri amaç fonksiyonu üzerinde ayarlamalar yapmak için kullanılmaktadır.
- Amaç fonksiyonu belirlenir: Karar değişkenleri kullanılarak oluşturulan doğrusal denklem sistemine amaç fonksiyonu denir. Doğrusal problemlerin çözümü için amaç fonksiyonunun karar değişkenleri ile ayarlanması sonucunda istenen çözümün elde edilebileceği bir denklem elde edilir.
- Kısıtlama kümesi belirlenir: Karar değişkenlerinin değer aralıkları için belirli kısıtlamalar bulunmaktadır. Çözüm işleminde belirlenen bu kısıtlamalara uyulmalıdır.
- Doğrusal problemi çözme yöntemi belirlenir: Doğrusal problemi çözebilmek için tek yönlü yöntem, R kullanarak sorunu çözme,问题in grafik yöntemi kullanarak çözülmüş ve açık bir çözümü kullanarak sorunu çözme gibi çözüm yöntemlerin biri seçilir.

Bütün bu doğrusal problem çözme adımlarının gerçekleştirilmesinin ardından seçilmiş olan doğrusal problem çözüm teknigine göre, karar değişkenleri üzerindeki kısıtlamalara bağlı kalınarak belirlenmiş olan amaç fonksiyonunun optimum olduğu nokta bulunmaya çalışılır. Çözüm yönteminin kısıtlamalara bağlı kalınarak uygulanması sonucunda elde edilen optimum alan problemin çözümünü içermektedir.

### 3.2. Doğrusal Olmayan Problemler

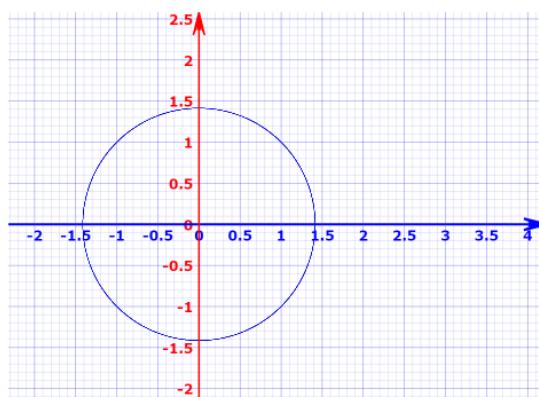
Doğrusal olmayan problemler, kendi içerisinde bir doğrusallık içermeyen ve girdiler ile çıktıların birbirile orantılı olmadığı problemlerdir. Bu tür problemlerde veriler bir düzlem üzerinde doğrusal bir dağılım yerine karmaşık olarak yayılmış halde bulunur.

#### 3.2.1. Doğrusal Olmayan Problemlerin Karakteristiği

Doğrusal olmayan problemler düzgün olmayan bir dağılıma sahiptir. Bu problem türüne dahil olan problemler kendi içerisinde düzenli herhangi bir karakteristik taşımaz. Doğrusal olmayan bir problem düzlemsel olarak bakıldığından doğrusallık yerine rastgele bir dağılıma sahiptir. Verilerin dağılımı, doğrusallığa engel olan düzensizlikler içermektedir. Denklem 2'de basit bir doğrusal olmayan denklem problemi verilmiştir. Bu problem, denklem tanımından da anlaşılabileceği gibi doğrusal bir yapıya sahip olmayıp, kendi içerisinde girdi verilerinden çıktı verilerine düzenliliği bozacak dağılımlara sahip olduğundan doğrusal olmayan problem kategorisine girmektedir.

$$2x^2 + 2y^2 = 4 \quad (2)$$

Başa bir ifade ile Denklem 2'de verilen denklem Şekil 2'de görüldüğü gibi düzlem üzerinde doğrusal bir dağılıma sahip olmadığından doğrusal olmayan bir problem olarak sınıflandırılabilmektedir.



**Şekil 2.** Doğrusal olmayan bir denklem için düzlem üzerinde grafiksel gösterim

### 3.2.2. Doğrusal Olmayan Problemlerin Çözüm Yöntemleri

Doğrusal olmayan problemlerde doğrusal problemlere benzer şekilde amaç fonksiyonu belirlenerek, bu amaç fonksiyonunun seçilen yönteme göre çözülmesi sağlanır. Temel anlamda doğrusal olmayan problem çözüm adımları da doğrusal problem çözüm adımlarına benzerlik göstermekle birlikte üzerinde çalışılan problemlerin karakteristik farklılıklarından dolayı çözüm yöntemleri arasında farklılıklar bulunmaktadır. Doğrusal olmayan problemlerde amaç fonksiyonunun çözümü, bu fonksiyonun yapısına göre yapılmaktadır.

Amaç fonksiyonu içbükey (maksimizasyon problemi) veya dışbükey (minimizasyon problemi) ise ve kısıtlama kümesi dışbükey ise, problem dışbükey olarak adlandırılır ve çoğu durumda dışbükey genel yöntemler kullanılabilir. Amaç fonksiyonu ikinci dereceden ve kısıtlamalar doğrusal ise, ikinci dereceden programlama teknikleri kullanılır. Amaç fonksiyonu bir içbükey ve bir dışbükey fonksiyonun oraniysa (maksimizasyon durumunda) ve kısıtlamalar dışbükey ise, o zaman problem kesirli programlama teknikleri kullanılarak bir dışbükey optimizasyon problemine dönüştürülebilir. Dışbükey olmayan problemleri çözmek için çeşitli yöntemler mevcuttur. Bir yaklaşım, doğrusal programlama problemlerinin özel formülasyonlarını kullanmaktadır. Başka bir yöntem dal ve sınır kullanımını içerir [18].

Doğrusal olmayan problemlerin çözümü, genel olarak bir noktada maliyeti yaklaşık çözümlerden herhangi biri için elde edilen en iyi alt sınıra eşit olacak şekilde gerçek bir çözüm elde edilerek yapılmaktadır. Bu çözüm, benzersiz olmasa da optimaldır.

Doğrusal olmayan problemlerin bu şekilde çözümünde kullanılan algoritma, mümkün olan en iyi çözümün bulunan en iyi noktadan bir tolerans dahilinde olduğu güvencesiyle erken durdurulabilir; bu tür noktalara  $\epsilon$ -optimal denir. Sonlu sonlandırmayı sağlamak için  $\epsilon$ -optimal noktalarda sonlandırma genellikle gereklidir. Bu özellikle büyük türevlenebilirlik ve kısıtlama nitelikleri altında geçerli olan bir durumdur.

Doğrusal olmayan problemlerin, doğrusal problemler gibi kesin çözümlere sahip olmaması ve hata tolere edilebilir yaklaşımlar ile çözüm işleminin gerçekleştirilmesi nedeniyle bu tür problemler Yapay Zekâ ile çözülmesi amaçlanan problemlerdir. Doğrusal olmayan problemler, Yapay Zekâ teknikleri ile ele alınan başlıca problemler arasındadır [19].

## 4. Materyal ve Metot

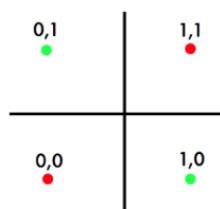
Yapılan çalışmanın temel amacı, Yapay Zekâ tekniklerinden olan ve yaygın olarak her alanda kullanım olanağına sahip olan Yapay Sinir Ağlarına alternatif bir Yapay Zekâ Mimarisi geliştirmektir. Bu amaçla yapılan çalışmanın öncelikli hedefi, geliştirilmiş olan Yapay Zekâ Mimarisinin doğrusal olmayan bir problem olan XOR problemi üzerinde çalışlığının kanıtlanmasıdır.

### 4.1. Materyal

Yapılan çalışmada veri seti olarak XOR verisi kullanılmıştır. Oluşturulan Yapay Zekâ Mimarisi XOR verisi üzerinde test edilerek mimarının doğrusal olmayan bir problem üzerinde çalışıp çalışmadığı test edilmiştir.

#### 4.1.1. XOR Verisi

Doğrusal olmayan bir karakteristiğe sahip olması ve mimarının doğrusal olmayan bir problem üzerinde çalıştığını doğrulanması için XOR problemi kullanılmıştır. XOR problemi, doğrusal olmayan bir problemdir. Bu kapsamında XOR içerisinde girdi verilerinin çıktı verilerine oranı Şekil 3'te görüldüğü gibi düzenli bir dağılım göstermemektedir. Düzenli dağılım göstermeyen XOR verisi, mimarının doğrusal olmayan problemler üzerindeki yeteneğini kanıtlamada iyi bir başlangıç noktası olacaktır.



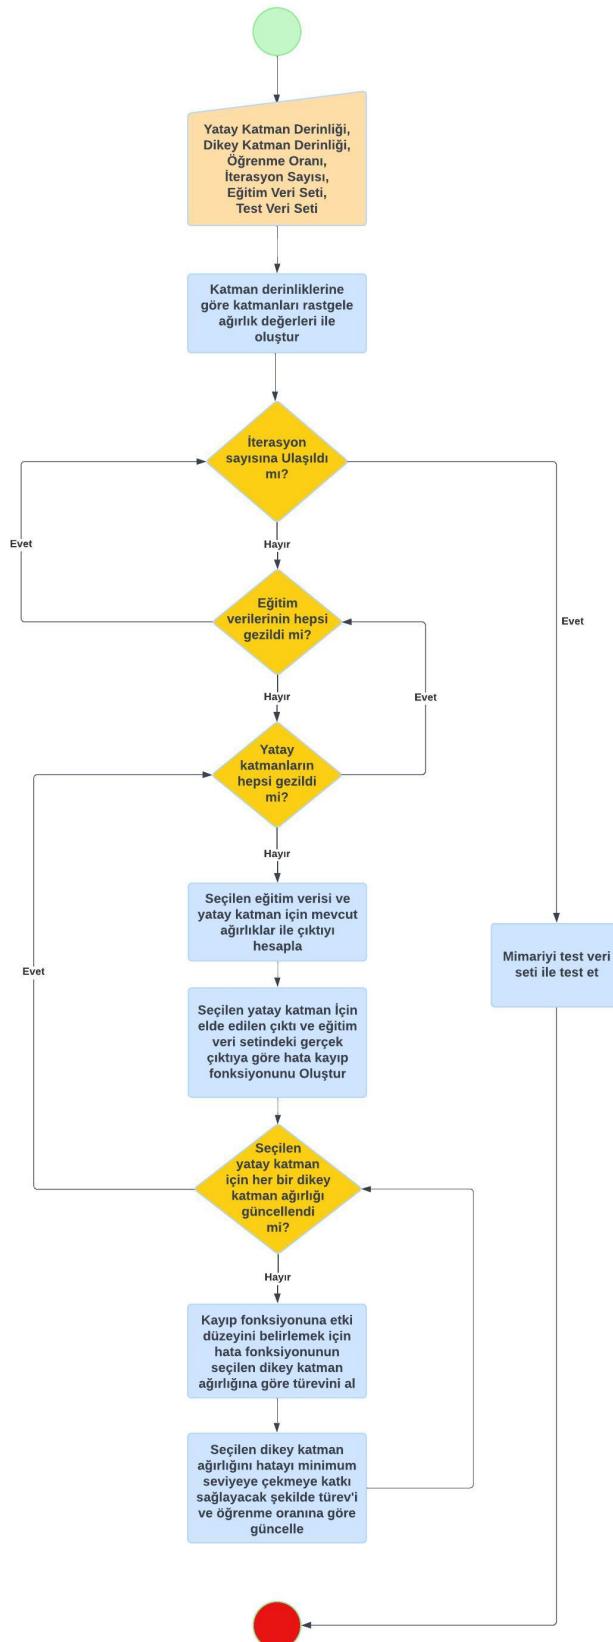
Şekil 3. XOR verisinin düzlem üzerinde gösterimi [20]

## 4.2. Metot

Yapılan çalışmada öncelikle geliştirilecek olan Yapay Zekâ Mimarisi için teorik temeller tasarlanmıştır. Teorik temellerin tasarılanarak doğrulanmasının ardından mimari tasarım yapılarak, yapılan mimari tasarımın hızlı geliştirme imkânı ve OOP (Object Oriented Programming) mimarisinde kodlama yeteneği sunan PYTHON programlama dili kullanılarak kodlanması işlemi yapılmıştır. PYTHON programlama dili ile OOP mimarisine uygun şekilde TuringEQ kütüphanesi olarak kodlanan mimarinin test işlemleri, XOR veri seti üzerinde yapılarak elde edilen sonuçlardan TuringEQ Yapay Zekâ Mimarisinin doğrusal olmayan problemler üzerinde çalışıp çalışmadığı test edilmiştir

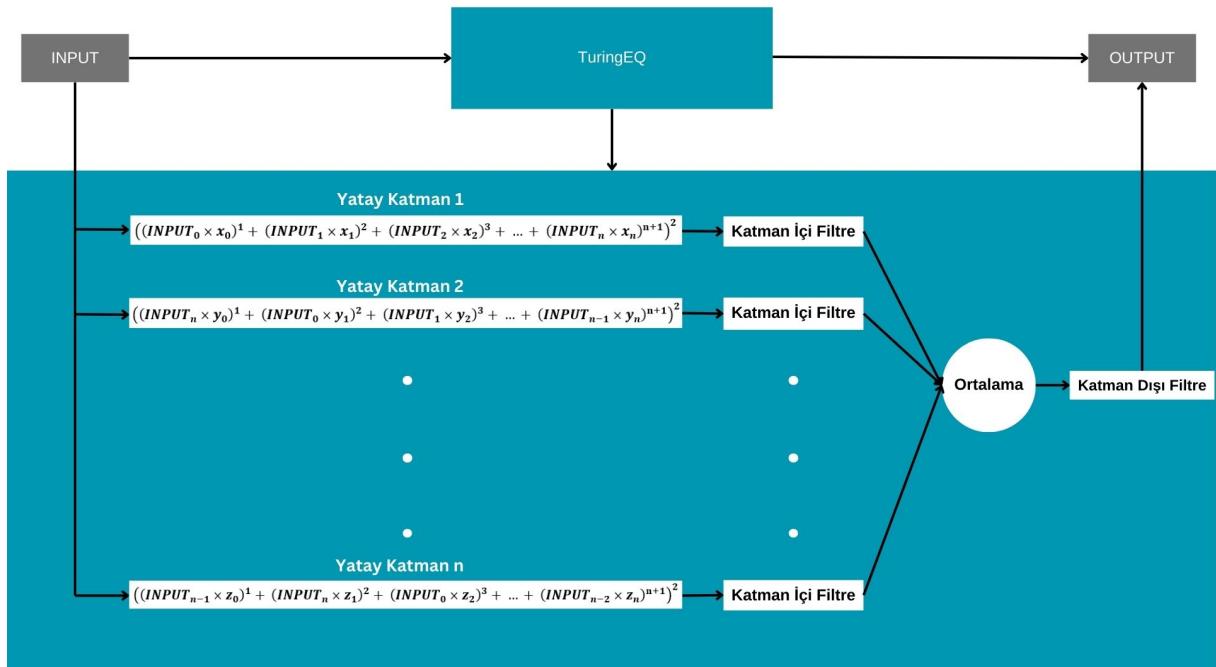
### 4.2.1. TuringEQ Mimarisi

Yapılan çalışma sonucunda TuringEQ Yapay Zekâ Mimarisi oluşturulmuştur. TuringEQ mimarisi, denklem sistemlerinden faydalanan ve katmanlı bir mimariye sahip olan Yapay Zekâ Mimarisidır. Bu mimaride her bir katmanın bir denklem sistemini ifade ettiği yatay katmanlar ve bu yatay katmanlar içerisindeki denklemlerin bilinmeyen değişkenlerini ifade eden dikey katmanlar bulunmaktadır. Mimariye sunulan girdi değerlerinin her bir yatay katmanın farklılaşan dikey katman ağırlıklarına dağıtılması ile girdi verilerinin işlemesi sağlanmaktadır. Mimarinin genel akış şeması Şekil 4'te gösterilmektedir. Mimariye girdi olarak verilen yatay katman derinliği, dikey katman derinliği, öğrenme oranı, iterasyon sayısı, eğitim veri seti ve test veri seti bulunmaktadır. Bu girilen verilerden yatay katman derinliği mimarinin içerisindeki denklem sistemlerinin sayısını ifade ederken dikey katman derinliği ise bu yatay katmanlar içerisindeki denklem sistemlerinin değişken sayılarını ifade etmektedir. Öğrenme oranı, yatay katmanlar içerisindeki dikey katman ağırlıklarının değişim oranını belirlemektedir. Iterasyon sayısı, mimarinin veri seti üzerinde kaç iterasyon da çalıştırılarak öğrenme işleminin gerçekleştirileceğini belirlemektedir. Son olarak eğitim veri seti, mimarinin eğitimi için kullanılırken test veri seti ise eğitilen mimarinin test edilmesi sürecinde başarımı ölçmek için kullanılmaktadır. TuringEQ mimarisi gerekli girdilerin verilmesinin ardından mimari kendi içerisindeki yatay ve dikey katmanları, dikey katman ağırlıkları rastgele başlangıç değerlerine ayarlanacak şekilde oluşturmaktadır. Katmanların oluşturulmasının ardından mimari girilen iterasyon adedince kendi içerisinde eğitim işlemini gerçekleştirilmektedir. TuringEQ mimarisinin eğitim stratejisi, farklılaşan her bir yatay katmanın kendi içerisinde dikey katman ağırlıklarının değiştirilmesi ile onarılmasına dayanmaktadır. Bu kapsamda, seçilen her bir eğitim verisi için her bir yatay katmanın çıktıları hesaplanmakta ve hesaplanan bu çıktılar eğitim veri setindeki gerçek çıktılar ile karşılaştırılarak hata kayıp fonksiyonu oluşturulmaktadır. Belirli bir yatay katmanın hatalı hesaplama durumunu ölçebilmek için oluşturulmuş olan hata kayıp fonksiyonunun oluşturulmasının ardından ilgili yatay katmanın içerisindeki dikey katman ağırlıklarının yatay katmanın hatasına etki düzeyinin belirlenmesi için güncellenmek istenen her bir ağırlığa göre türev alınmaktadır. Alınan türev ile hatayı minimum noktaya yakinsayacak güncellenmek istenen dikey katman ağırlığının değişim yönü belirlenerek, öğrenme oranına göre bu ağırlığın güncellenmesi işlemi yapılmaktadır. TuringEQ mimarisi, her bir eğitim verisi için yatay katmanların her bir dikey katman ağırlıklarını bu stratejiye göre güncelleyerek öğrenme işlemini gerçekleştirilmektedir,



**Sekil 4.** TuringEQ akış şeması

TuringEQ mimaris Şekil 5'te görüldüğü gibi kendi içerisinde katmanlı bir yapıya sahip olmakla birlikte her bir katman kendi içerisindeki başarımı maksimum düzeye çıkarmaktan sorumludur.



Şekil 5. TuringEQ genel mimarisi

TuringEQ mimarisinde her bir katmanın çıktısının mimarinin çıktısına aritmetik ortalaması ile etki etmektedir. Bu şekilde, katmanların genel çıkışına aynı düzeyde etki etmesi sağlanarak katmanlardaki hata düzeltimlerinin genel hatayı minimize etmesi sağlanmaktadır. Denklem 3'te TuringEQ içerisindeki bir yatay katmanın genel yapısı gösterilmektedir. Her bir girdinin bilinmeyen değişkenler ile çarpılarak toplanması sonucunda, denklemi yeterince dağıtık ve türevi alınabilir hale getirebilmek amacıyla sonunda karesi alınmaktadır.

$$((INPUT_0 \times x_0)^1 + (INPUT_1 \times x_1)^2 + (INPUT_2 \times x_2)^3 + \dots + (INPUT_n \times x_n)^{n+1})^2 \quad (3)$$

Şekil 5'te görüldüğü gibi her bir yatay katman kendi içerisinde kendi bilinmeyen değişken değerlerine sahiptir. Bu bilinmeyen değişkenler katman içi hataların onarılması için kullanılmaktadır.

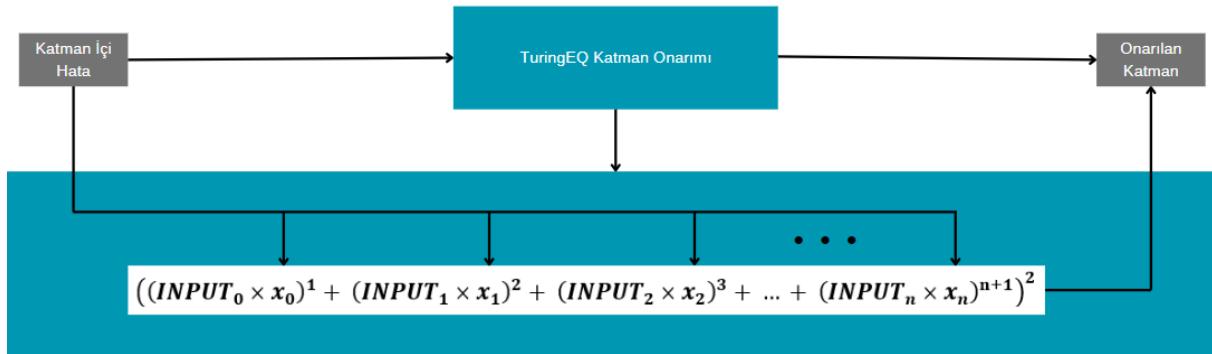
TuringEQ mimarisinde hata onarımının yapılabilmesi için her bir katmandan elde edilen çıktıların gerçek çıktılar ile farkına dayanan ve Denklem 4'te belirtilen bir kayıp fonksiyonu üzerinden hata tespiti gerçekleştirilmektedir.

$$0.5 \times (\text{Tahmin Edilen Değer} - \text{Gerçek Değer})^2 \quad (4)$$

Denklem 5'te gösterildiği gibi kayıp fonksiyonunun her bir yatay katmanın içerisindeki her bir bilinmeyen değişkenin göre türevinin hesaplanması sonucunda bilinmeyen değişkenlerin belirli bir öğrenme oranında değiştirilmesi işlemi gerçekleştirilmektedir.

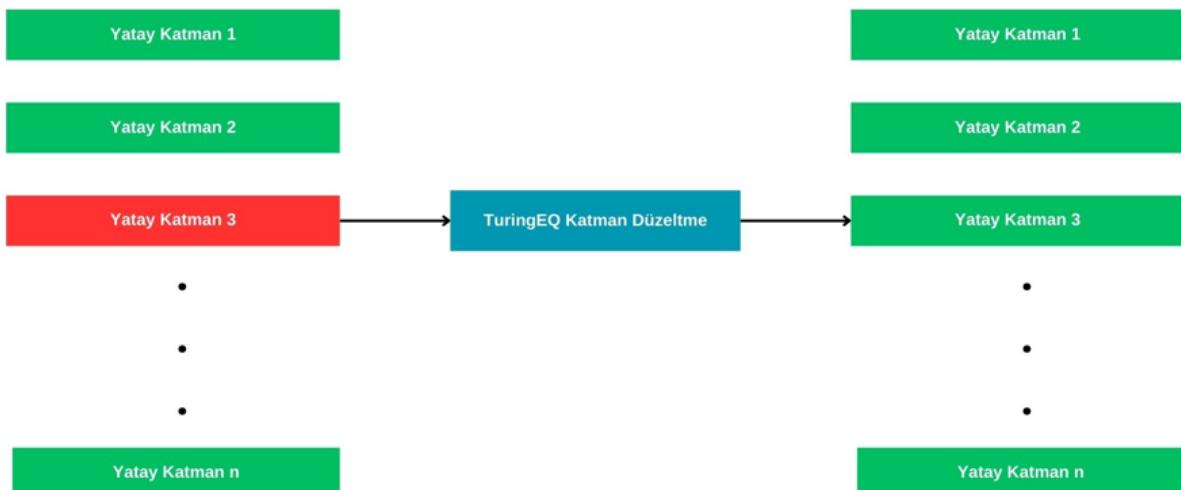
$$\sum_{k=0}^n x_k - \left( \frac{d(0.5 \times (\text{Tahmin Edilen Değer} - \text{Gerçek Değer})^2)}{d(x_k)} \times \text{Öğrenme Katsayısı} \right) \quad (5)$$

Belirtilen hata onarım denklemlerinin kullanılmasıyla Şekil 6'da gösterildiği şekilde yatay katmanlar üzerindeki her bir bilinmeyen değişken için hata onarım işlemi gerçekleştirilmiş olur.



Şekil 6. TuringEQ yatay katman değişkenlerinin düzeltilmesi

TuringEQ içerisindeki her bir yatay katmanın belirtilen şekilde düzenlemesiyle mimari genelinde bozuk katmanların onarım işlemi yapılarak Şekil 7'de görüldüğü gibi genel olarak mimari düzeyinde hata onarımı gerçekleştirilmiş olur.



Şekil 7. TuringEQ bozuk katman onarımı

TuringEQ mimarisinde yatay katmanlara ek olarak dikey katmanlar mevcuttur. Dikey katmanların derinliği her bir yatay katman içerisindeki bilinmeyen değişken sayılarını temsil etmektedir. Yatay katman içerisindeki bilinmeyen değişken sayısı arttıkça dikey katman derinliği artmaktadır. Çok özellikli girdilerde, girdileri her bir katmanda farklı bilinmeyen değişkenler üzerinden ayarlayarak türevlerin çeşitlendirilmesi ve girdiler üzerinden birbirinden farklılaşan denklem sistemleri oluşturulması amaçlanmaktadır. 1. Yatay katmanı temsil eden Denklem 6 ve 2. Yatay katmanı temsil eden Denklem 7'de belirtildiği şekilde TuringEQ mimarisine sunulan girdilerin sıralaması her bir katmanda farklılaşarak birbirinden farklı denklem sistemleri elde edilmektedir.

$$((INPUT_0 \times x_0)^1 + (INPUT_1 \times x_1)^2 + (INPUT_2 \times x_2)^3 + \dots + (INPUT_n \times x_n)^{n+1})^2 \quad (6)$$

$$((INPUT_n \times y_0)^1 + (INPUT_0 \times y_1)^2 + (INPUT_1 \times y_2)^3 + \dots + (INPUT_{n-1} \times y_n)^{n+1})^2 \quad (7)$$

Farklı denklem sistemleri elde etmenin yanı sıra, etkili girdilerin yüksek düzeyli olarak temsil edildiği denklem sistemlerinde girdi karakteristiklerinin net olarak çıkarılması amaçlanmaktadır. Bu kapsamda, yüksek dereceli bilinmeyen değişkenler üzerinden ayarlanan girdilerin etki düzeyleri yüksek olurken, diğer denklemlerde aynı girdinin etki düzeylerinin düşürülmESİ sebebiyle girdiler üzerinde farklı düzeylerin test edilmesi ve en uygun dereceye sahip düzey üzerinde ayarlamaların bulunması sağlanmaktadır.

## 5. Bulgular ve Tartışma

Elde edilen TuringEQ mimarisinin XOR veri seti üzerinde farklı katman derinlikleri ve öğrenme katsayılarındaki değişimlerin mimarinin öğrenme durumuna etkisini görebilmek amacıyla oluşturulan ve farklı yatay katman derinliği, dikey katman derinliği ve öğrenme katsayılarını içeren 2 farklı senaryo için test edilmesi sonucunda elde edilen bulgular üzerinden çeşitli analizler yapılmıştır. Farklı senaryolar için TuringEQ mimarisinin XOR veri seti üzerinde elde etmiş olduğu başarımların incelenmesinin ardından TuringEQ mimarisinin Yapay Sinir Ağları ile aynı problem üzerinde elde etmiş olduğu başarımlar açısından karşılaştırmalar yapılarak, yeni oluşturulan Yapay Zekâ Mimarisinin mevcutta yaygın bir biçimde kullanılan bir Yapay Zekâ Mimarisi olan Yapay Sinir Ağlarına karşı olumlu ve olumsuz tarafları incelemiştir.

### 5.1. TuringEQ Mimarisinin Senaryo 1 için Test Edilmesi

TuringEQ mimarisi ilk senaryoda 2 yatay katman derinliği, 4 dikey katman derinliği ve 0,1 öğrenme katsayısı için XOR problemi üzerinde çalıştırıldığında Tablo 1'de görüldüğü gibi başarıyı yüksek sonuçlar elde edilmiştir.

**Tablo 1.** TuringEQ mimarisi senaryo 1 için sonuçlar

X	Y	Beklenen Sonuç	Tahmin Edilen Sonuç	Hata
0	0	0	0,0	0
0	1	1	1,135508236674183	-0,135508236674183
1	0	1	0,9840631326887465	0,0159368673112535
1	1	0	0,06507361395531353	-0,06507361395531353

TuringEQ mimarisinin senaryo 1 için eğitim öncesi başlangıç tahmin değerleri Tablo 2'de görülmektedir.

**Tablo 2.** TuringEQ mimarisi senaryo 1 için eğitim öncesi tahminleri

X	Y	Beklenen Sonuç	Tahmin Edilen Sonuç	Hata
0	0	0	0,0	0
0	1	1	0,7997997799281024	0,20020022007108976
1	0	1	0,30401244023373786	0,69598755976626214
1	1	0	3,1714671185109644	-3,1714671185109644

TuringEQ mimarisinin senaryo 1 için eğitim öncesi başlangıç ağırlık değerleri Tablo 3'te görülmektedir.

**Tablo 3.** TuringEQ mimarisi senaryo 1 için eğitim öncesi başlangıç ağırlık değerleri

Yatay Katmanlar	1.Dikey Katman Ağırlığı	2.Dikey Katman Ağırlığı	3.Dikey Katman Ağırlığı	4.Dikey Katman Ağırlığı
1.Yatay Katman	0,5535758386896907	0,4251791630662658	0,24124945159930522	0,9140154121540919
2.Yatay Katman	0,8977400944587374	0,7309848405146916	0,22831793153423074	0,13132787610390073

TuringEQ mimarisinin senaryo 1 için eğitim sonrası ağırlık değerleri Tablo 4'te görülmektedir.

**Tablo 4.** TuringEQ mimarisi senaryo 1 için eğitim sonrası ağırlık değerleri

Yatay Katmanlar	1.Dikey Katman Ağırlığı	2.Dikey Katman Ağırlığı	3.Dikey Katman Ağırlığı	4.Dikey Katman Ağırlığı
1.Yatay Katman	-0,992434997994770	0,379327937039821	0,227173207889428	0,856354088385537
2.Yatay Katman	-1,00326665617092	0,99984477281268	0,148377417701089	0,132736814366460

TuringEQ mimarisinin senaryo 1 için XOR problemi üzerinde eğitim işleminin 100 iterasyon tekrarı için gerçekleştirilmemesi sonucunda XOR tahminlemesinin çok yakın düzeylerde gerçekleştiği görülmektedir. Eğitim öncesi ve eğitim sonrasında mimarinin elde ettiği sonuçlar mutlak hataya göre incelendiğinde eğitim öncesinde hata oranı 1,02 iken eğitim sonrasında ise hata oranının 0,05'e gerilediği tespit edilmiştir. Bu kapsamda TuringEQ mimarisinin doğrusal olmayan problemler üzerinde çalışığının kanıtlanması açısından senaryo 1 için elde edilen sonuçların olumlu düzeyde olduğu görülmüştür.

## 5.2. TuringEQ Mimarisinin Senaryo 2 için Test Edilmesi

TuringEQ mimarisi, ikinci senaryoda 2 yatay katman derinliği, 8 dikey katman derinliği ve 0,05 öğrenme katsayısı için XOR problemi üzerinde çalıştırıldığında Tablo 5'te görüldüğü gibi başarıyı yüksek sonuçlar elde edilmiştir.

**Tablo 5.** TuringEQ mimarisi senaryo 2 için sonuçlar

X	Y	Beklenen Sonuç	Tahmin Edilen Sonuç	Hata
0	0	0	0,0	0
0	1	1	1,08214460177223	-0,08214460177223
1	0	1	1,0927197157602675	-0,0927197157602675
1	1	0	0,02014012966719759	-0,02014012966719759

TuringEQ mimarisinin senaryo 2 için eğitim öncesi başlangıç tahmin değerleri Tablo 6'da görülmektedir.

**Tablo 6.** TuringEQ mimarisi senaryo 2 için eğitim öncesi tahminleri

X	Y	Beklenen Sonuç	Tahmin Edilen Sonuç	Hata
0	0	0	0,0	0
0	1	1	0,5714640914273006	0,4285359085726994
1	0	1	0,8905479121079419	0,1094520878920581
1	1	0	5,385353620277009	-5,385353620277009

TuringEQ mimarisinin senaryo 2 için eğitim öncesi başlangıç ağırlık değerleri Tablo 7'de görülmektedir.

**Tablo 7.** TuringEQ mimarisi senaryo 2 için eğitim öncesi başlangıç ağırlık değerleri

Yatay Katmanlar	1.Dikey Katman Ağırlığı	2.Dikey Katman Ağırlığı	3.Dikey Katman Ağırlığı	4.Dikey Katman Ağırlığı	5.Dikey Katman Ağırlığı	6.Dikey Katman Ağırlığı	7.Dikey Katman Ağırlığı	8.Dikey Katman Ağırlığı
1.Yatay Katman	0,53639384	0,14171107	0,81874787	0,18594171	0,31970408	0,93385278	0,11875274	0,2928139
2.Yatay Katman	0,55280375	0,67850139	0,61142288	0,02961601	0,35183227	0,82342399	0,61788556	0,05130254

TuringEQ mimarisinin senaryo 2 için eğitim sonrası ağırlık değerleri Tablo 8'de görülmektedir.

**Tablo 8.** TuringEQ mimarisi senaryo 2 için eğitim sonrası ağırlık değerleri

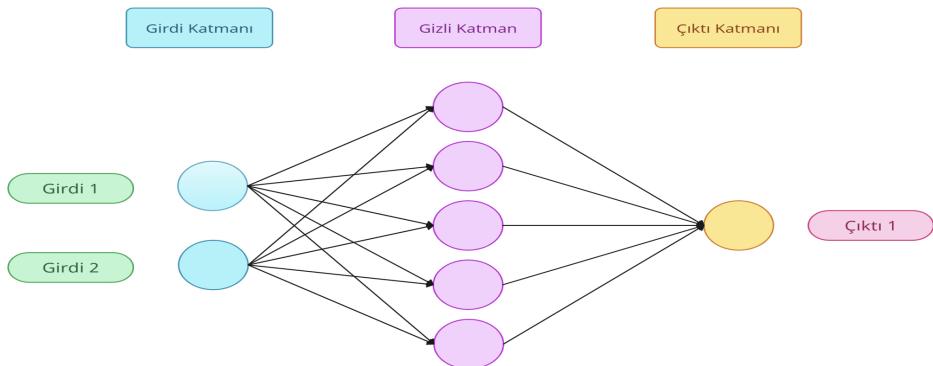
Yatay Katmanlar	1.Dikey Katman Ağırlığı	2.Dikey Katman Ağırlığı	3.Dikey Katman Ağırlığı	4.Dikey Katman Ağırlığı	5.Dikey Katman Ağırlığı	6.Dikey Katman Ağırlığı	7.Dikey Katman Ağırlığı	8.Dikey Katman Ağırlığı
1.Yatay Katman	-1,37037909	0,58164229	0,71769999	0,21688348	0,32124603	0,89375705	0,11875717	0,2928139
2.Yatay Katman	-1,02159386	0,63632502	0,22937971	0,02964162	0,30387616	0,88088905	0,49511525	0,05130254

TuringEQ mimarisinin senaryo 2 için XOR problemi üzerinde eğitim işleminin 100 iterasyon tekrarı için gerçekleştirilmesi sonucunda XOR tahminlemesinin senaryo 1'de görüldüğü gibi çok yakın düzeylerde gerçekleştiği görülmektedir. Eğitim öncesi ve eğitim sonrasında mimarinin elde ettiği sonuçlar mutlak hataya göre incelendiğinde eğitim öncesinde hata oranı 1,48 iken eğitim sonrasında ise hata oranının 0,05'e gerilediği tespit edilmiştir. Bu kapsamda TuringEQ mimarisinin doğrusal olmayan problemler üzerinde çalışığının kanıtlanması açısından senaryo 1'de olduğu gibi senaryo 2 içinde elde edilen sonuçların olumlu düzeyde olduğu görülmüştür.

### 5.3. TuringEQ Mimarisi ve Yapay Sinir Ağlarının Karşılaştırılması

TuringEQ mimarisinin belirlenmiş olan senaryolar üzerinden XOR veri seti üzerindeki başarısının doğrulanmasının ardından Yapay Sinir Ağlarının aynı veri seti üzerinde senaryolarda kullanılan aynı iterasyon sayısı ve öğrenme katsayısına göre göstermiş olduğu başarıma göre iki Yapay Zekâ Mimarisi arasında

karşılaştırmalar yapılmıştır. Karşılaştırmada kullanılan Yapay Sinir Ağrı Şekil 8'de gösterildiği şekilde 2 düğümden oluşan 1 girdi katmanı, 5 düğümden oluşan 1 gizli katman ve 1 düğümden oluşan 1 çıktı katmanından oluşan çok katmanlı bir sinir ağıdır.



**Şekil 8.** Yapay Sinir Ağrı Mimarisi

Yapay Sinir Ağrı mimarisinin senaryo 1 için 0,1 öğrenme katsayısı ve 100 iterasyon eğitim sonucunda mimarinin eğitim sonrası tahminleri Tablo 9'da gösterilmektedir.

**Tablo 9.** Yapay Sinir Ağrı mimarisi senaryo 1 için eğitim sonrası tahminleri

X	Y	Beklenen Sonuç	Tahmin Edilen Sonuç	Hata
0	0	0	0,45077726	-0,45077726
0	1	1	0,44137248	0,55862752
1	0	1	0,55580937	0,44419063
1	1	0	0,5710973	-0,5710973

Yapay Sinir Ağrı mimarisinin senaryo 1 için XOR problemi üzerinde eğitim işleminin 100 iterasyon tekrarı için gerçekleştirilmesi sonucunda XOR tahminlemesinin doğru bir şekilde yapılabilmesi için iterasyon tekrarının yetersiz düzeyde kaldığı görülmektedir. Eğitim sonrasında mimarinin elde ettiği sonuçlar mutlak hataya göre incelendiğinde hata oranının 0,5 olduğu tespit edilmiştir. Bu kapsamda senaryo 1 özeline yapılan karşılaştırmalara göre Yapay Sinir Ağrı mimarisinin TuringEQ mimarisine göre aynı iterasyon ve öğrenme katsayıları ile daha yüksek bir hata orانına sahip olduğu görülmektedir.

Yapay Sinir Ağrı mimarisinin senaryo 2 için 0,05 öğrenme katsayısı ve 100 iterasyon eğitim sonucunda mimarinin eğitim sonrası tahminleri Tablo 10'da gösterilmektedir.

**Tablo 10.** Yapay Sinir Ağrı mimarisi senaryo 2 için eğitim sonrası tahminleri

X	Y	Beklenen Sonuç	Tahmin Edilen Sonuç	Hata
0	0	0	0,4568027	-0,4568027
0	1	1	0,45977562	0,54022438
1	0	1	0,46615469	0,53384531
1	1	0	0,48125098	-0,48125098

Yapay Sinir Ağı mimarisinin senaryo 2 için XOR problemi üzerinde eğitim işleminin 100 iterasyon tekrarı için gerçekleştirilmesi sonucunda XOR tahminlemesinin doğru bir şekilde yapılabilmesi için iterasyon tekrarının yetersiz düzeye kıldığı görülmektedir. Eğitim sonrasında mimarinin elde ettiği sonuçlar mutlak hataya göre incelendiğinde hata oranının 0,5 olduğu tespit edilmiştir. Bu kapsamda senaryo 2 özelinde yapılan karşılaştırmalara göre Yapay Sinir Ağı mimarisinin TuringEQ mimarisine göre aynı iterasyon ve öğrenme katsayıları ile daha yüksek bir hata oranına sahip olduğu görülmektedir.

TuringEQ mimarisinin belirlenmiş olan senaryolar üzerinden XOR veri seti üzerindeki başarımının doğrulanmasının ardından Yapay Sinir Ağlarının aynı veri seti üzerinde göstermiş olduğu başarımlar incelendiğinde iki Yapay Zekâ mimarisi arasında yapılan karşılaştırmalara göre TuringEQ mimarisinin daha düşük iterasyon sayılarında başarılı sonuçlara ulaştığı görülmürken, Yapay Sinir Ağlarının daha yüksek iterasyon sayılarında başarılı sonuçlara ulaştığı görülmüştür. Yapılan analizlerde iki mimari çalışma hızı açısından karşılaştırıldığında TuringEQ mimarisinin, mimari içerisindeki gradyan geri düzeltme mekanizmasından kaynaklı olarak bir iterasyon için Yapay Sinir Ağlarından daha düşük hızlarda çalıştığı görülmüştür.

TuringEQ mimarisinin başlangıç ağırlık değerlerinin veri setinin aralık genişliğine göre belirlenmesi mimarinin başarımını etkileyen önemli unsurlardan biridir. Ağırlık değerlerinin rastgele olarak atanması mimarinin hesaplama karmaşıklığını artırmakta ve bazı durumlarda öğrenmeyi olumsuz olarak etkilemektedir. Bu kapsamında, ağırlıkların belirli bir stratejiye göre atanması mimarinin öğrenmesine katkı sağlayacaktır.

## 6. Sonuç ve Öneriler

Yapılan çalışmada geliştirilen TuringEQ mimarisinin doğrusal olmayan bir problem olan XOR problemi üzerinde test edilmesi sonucunda olumlu sonuçlar elde edilmiştir. Doğrusal olmayan bir problem üzerinde TuringEQ mimarisi, 100 iterasyon sonucunda farklı katman derinlikleri ve öğrenme katsayıları ile olumlu sonuçlar göstererek XOR problemi için gerekli tahminlemeleri doğru bir şekilde gerçekleştirmiştir.

Elde edilen başarı, oluşturulmuş olan mimarinin XOR problemleri üzerinde yüksek bir başarıyla çalıştığını kanıtlamış ve temel düzeye doğrusal olmayan karakteristiğe sahip problemler için temel mimarinin uygun bir tasarıma sahip olduğu görülmüştür.

Çalışma sonucunda elde edilen kazanımlar şu şekilde sıralanabilir:

- Yeni bir Yapay Zekâ Mimarisi olan TuringEQ mimarisi geliştirilmiştir.
- TuringEQ mimarisinin doğrusal olmayan problem karakteristiklerine uygun olduğu kanıtlanmıştır.
- TuringEQ mimarisinin farklı parametrik değişimler için çalıştırılması sonucunda elde edilen başarımlar olumlu düzeydedir.
- TuringEQ mimarisinin ileri düzey çalışmalarında geliştirilebilecek temel tasarımının doğrulaması yapılmıştır.

Yapay Sinir Ağları ile yapılan karşılaştırmalar sonucunda, TuringEQ mimarisinin her ne kadar daha düşük iterasyonlarda başarılı sonuçlara ulaşlığı görülmüş olsa da mimari içerisindeki gradyan geri düzeltme mekanizmasından kaynaklı olarak, iterasyon başına Yapay Sinir Ağlarından daha düşük hızlarda çalıştığı görülmüştür.

Yapılan çalışma sonucunda TuringEQ mimarisi elde edilerek temel bir doğrusal olmayan problem olan XOR problemi üzerinde olumlu sonuçlar alınsa da elde edilen bu mimarinin karmaşık ve büyük doğrusal olmayan problemler üzerindeki başarımı analiz edilmemiştir.

İlerleyen çalışmalarda TuringEQ mimarisinin büyük ve daha karmaşık veri kümeleri üzerinde çalıştırılması sonucunda elde edilen sonuçlar analiz edilerek mimari düzeye iyileştirme çalışmaları yapılması hedeflenmektedir.

Ayrıca yatay katmanlar içerisindeki hata onarımında türev yaklaşımının yanı sıra, yatay katman bilinmeyen değişkenlerinin derecelerinin ve birbirleri ve diğer katman değişkenleri ile ilişkilerinin ele alındığı yeni bir onarım algoritması tasarlanması düşünülmektedir. Ek olarak tasarlanacak olan bu onarım algoritması ile iterasyon başına çalışma hızlarının daha düşük seviyelere indirgenmesi, mevcut algoritmanın hız noktasındaki verimsizliğinin çözülmesi ve mevcutta kullanılan Yapay Sinir Ağ gibi Yapay Zekâ mimarilerine hız olarak avantaj sağlanabilmesi amaçlanmaktadır.

## Teşekkür

H. E. O., fikir sahibi olup çalışmayı gerçekleştirdi, yorumladı ve makaleyi yazdı. M.B., çalışmayı yorumladı.

## Kaynaklar

- [1] Moor JH, Turing test, Encyclopedia of Computer Science, ss. 1801-1802, Oca. 2003, Erişim: 05 Haziran 2024. [Çevrimiçi]. Erişim adresi: [https://dl.acm.org/doi/abs/10.5555/1074100.1074882#pill-authors\\_contentcon](https://dl.acm.org/doi/abs/10.5555/1074100.1074882#pill-authors_contentcon)
- [2] Abitha J. Artificial Intelligence Technology and its Challenges-A Review, Journal of excellence in Computer Science and Engineering, c. 2, sy 1, ss. 11-18, Şub. 2016.
- [3] Abraham. A. H. of measuring system design 2005, “Artificial neural networks”, wsc10.softcomputing.net, Erişim: 05 Haziran 2024. [Çevrimiçi]. Erişim adresi: [http://wsc10.softcomputing.net/ann\\_chapter.pdf](http://wsc10.softcomputing.net/ann_chapter.pdf)
- [4] Silva IN, Spatti DH, Flauzino RA, Liboni LHB, Alves SFR. Artificial Neural Networks: A Practical Course, Illustrated. Springer International Publishing, 2016, 2016.
- [5] Asadollahfardi G. “Artificial Neural Network”, ss. 77-91, 2015.
- [6] Fukushima K. “Biological Cybernetics Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position”, Biol. Cybernetics, c. 36, s. 202, 1980.
- [7] LeCun Y, Bottou L, Bengio Y, Haffner P. “Gradient-based learning applied to document recognition”, Proceedings of the IEEE, 1998, Erişim: 05 Ağustos 2024. [Çevrimiçi]. Erişim adresi: <https://ieeexplore.ieee.org/abstract/document/726791/>
- [8] Krizhevsky A, Sutskever I, Hinton GE., “ImageNet classification with deep convolutional neural networks”, Commun ACM, c. 60, sy 6, ss. 84-90, Haz. 2017.
- [9] Simonyan K, Zisserman A. “Very Deep Convolutional Networks for Large-Scale Image Recognition”, 3rd International Conference on Learning Representations, ICLR 2015- Conference Track Proceedings, Eyl. 2014, Erişim: 05 Ağustos 2024. [Çevrimiçi]. Erişim adresi: <https://arxiv.org/abs/1409.1556v6>
- [10] Szegedy C vd. “Going Deeper with Convolutions”, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, c. 07-12-June-2015, ss. 1-9, Eyl. 2014.
- [11] He K, Zhang X, Ren S, Sun J. “Deep Residual Learning for Image Recognition”, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, c. 2016-December, ss. 770-778, Ara. 2015.
- [12] Termritthikun C, Umer A, Suwanwimolkul S, Xia F, Lee I. “SalNAS: Efficient Saliency-prediction Neural Architecture Search with self-knowledge distillation”, Eng Appl Artif Intell, c. 136, s. 109030, Eki. 2024.
- [13] Yang FJ. “An implementation of naive bayes classifier”, Proceedings - 2018 International Conference on Computational Science and Computational Intelligence, CSCI 2018, ss. 301-306, Ara. 2018.
- [14] Joshi AA, Aziz RM. “Deep learning approach for brain tumor classification using metaheuristic optimization with gene expression data”, Int J Imaging Syst Technol, c. 34, sy 2, s. e23007, Mar. 2024.
- [15] Rosso MM, Aloisio A, Randazzo V, Tanzi L, Cirrincione G, Marano GC. “Comparative deep learning studies for indirect tunnel monitoring with and without Fourier pre-processing”, Integr Comput Aided Eng, c. 31, sy 2, ss. 213-232, Oca. 2024.
- [16] Aslan M, Baykara M, Alakus TB. “LieWaves: dataset for lie detection based on EEG signals and wavelets”, Med Biol Eng Comput, c. 62, sy 5, ss. 1571-1588, May. 2024.
- [17] Steps to Solve a Linear Programming Problem | Superprof. Erişim: 05 Haziran 2024. [Çevrimiçi]. Erişim adresi: [https://www.superprof.co.uk/resources/academic/mathematics/linear-algebra/linear-programming/steps-to-solve-a-linear-programming-problem.html#chapter\\_steps-to-solve-a-linear-programming-problem](https://www.superprof.co.uk/resources/academic/mathematics/linear-algebra/linear-programming/steps-to-solve-a-linear-programming-problem.html#chapter_steps-to-solve-a-linear-programming-problem)
- [18] Nonlinear programming- Wikipedia. Erişim: 05 Haziran 2024. [Çevrimiçi]. Erişim adresi: [https://en.wikipedia.org/wiki/Nonlinear\\_programming](https://en.wikipedia.org/wiki/Nonlinear_programming)
- [19] Benderskaya EN. Nonlinear Trends in Modern Artificial Intelligence: A New Perspective, Beyond Artificial Intelligence, ss. 113-124, 2013.
- [20] Demystifying the XOR problem- DEV Community. Erişim: 05 Haziran 2024. [Çevrimiçi]. Erişim adresi: <https://dev.to/jbahire/demystifying-the-xor-problem-1blk>

## Martensitic Transformation Thermodynamic and Structure Analysis of CuAlFe High-Temperature Shape Memory Alloy

Oktay KARADUMAN<sup>1</sup>, İskender ÖZKUL<sup>2</sup>, Yakup AYDEMİR<sup>3</sup>, Canan Aksu CANBAY<sup>4\*</sup>

<sup>1</sup> Rare Earth Elements Application and Research Center (MUNTEAM), Munzur University, 62000, Tunceli/TURKEY

<sup>2</sup> Department of Mechanical Engineering, Faculty of Engineering, Mersin University, Mersin, TURKEY

<sup>3,4</sup> Physics Department, Faculty of Science, Fırat University, Elazığ/TURKEY

\*<sup>4</sup> caksu@firat.edu.tr

(Geliş/Received: 23/02/2024;

Kabul/Accepted: 26/07/2024)

**Abstract:** The work presented in this paper reports the shape memory effect characteristics of a CuAlFe high-temperature shape memory alloy (HTSMA) with a new composition and new martensitic transformation temperatures. In this context, casting via a vacuum arc melter produced the Cu-rich ternary CuAlFe high-temperature shape memory alloy (HTSMA). Both DSC and DTA measurement thermograms showed excellent martensitic phase transformation peaks while heating the alloy up and cooling it back. The forward and reverse martensitic phase transformation peaks at different DSC heating/cooling rates had high thermal stability, and the temperature range of these transformations was found above 100 °C between 220-340 °C circa. Therefore, this classifies the alloy as a high-temperature shape memory alloy. Moreover, the formation of the martensite phases, i.e. the microstructural base mechanism for the shape memory effect of the alloy, was confirmed by X-ray diffraction (XRD) pattern obtained at room temperature using CuK $\alpha$  radiation. The findings of this study can be helpful in the high-temperature shape memory alloy-related application areas, in which areas different shape memory properties are highly demanded.

**Key words:** High-temperature shape memory alloy, CuAlFe, martensitic transformation, DSC.

## CuAlFe Yüksek Sıcaklık Şekil Hafızalı Alaşımın Martensitik Dönüşüm Termodinamigi ve Yapı Analizi

**Öz:** Bu makalede sunulan çalışma, yeni bir bileşime ve yeni martensitik dönüşüm sıcaklıklarına sahip bir CuAlFe yüksek sıcaklık şekil hafızalı alaşımının (YSŞHA) şekil hafiza etkisi özelliklerini rapor etmektedir. Bu kapsamda, bakırca zengin üçlü CuAlFe yüksek sıcaklık şekil hafızalı alaşımı (YSŞHA) vakumlu bir ark eriticide dökümü yapılarak üretildi. Hem DSC hem de DTA ölçüm termogramları, alaşımın ısıtılması ve akabinde soğutulması sırasında mükemmel martensitik faz dönüşüm pikleri gösterdi. Farklı DSC ısıtma/soğutma hızlarında ileri ve ters martensitik dönüşüm piklerinin yüksek ıslı kararlılığı sahip olduğu ve bu dönüşümlerin sıcaklık aralığı 100 °C'nin üzerinde yaklaşık 220-340 °C arasında oluştuğu görüldü. Bundan dolayı alaşım yüksek sıcaklıkta şekil hafızalı alaşım olarak sınıflandırıldı. Ayrıca, martensit fazlarının oluşumu, yani alaşımın şekil hafiza etkisine yönelik mikroyapısal temel mekanizma, CuKa radyasyonu kullanılarak oda sıcaklığında elde edilen X-işını kırınımı (XRD) deseni ile doğrulandı. Bu çalışmanın bulguları, farklı şekil hafızalı özelliklerin oldukça talep edildiği yüksek sıcaklık şekil hafızalı alaşımalarla ilgili uygulama alanlarında faydalı olabilir.

**Anahtar kelimeler:** Yüksek sıcaklık şekil hafızalı alaşım, CuAlFe, martensitik dönüşüm, DSC.

### 1. Introduction

Nowadays, high-temperature shape memory alloys (HTSMAs), as being valuable functional smart materials, with varied properties such as different martensitic transformation temperatures, hysteresis gap, mechanical or other properties are highly demanded in applications utilizing HTSMAs such as automotive, manufacturing, energy exploration, or aero-space [1]. Since the history of studies on shape memory alloys (SMAs) started in the mid of last century [2] due to their unique and functional shape memory effect (SME) and superelasticity (SE) properties, after then HTSMA studies [1,3,4] have started, too.

Among HTSMAs suitable for high-temperature applications [5], high-cost NiTi-based SMAs or HTSMAs [1,3,5-7] have the best thermomechanical shape memory properties. Thus, they are commercially the most preferred ones. NiTiZr and NiTiHf HTSMAs are relatively cheaper than other NiTi-based or Ti-based HTSMAs, but copper-based SMAs and HTSMAs are nearly ten times cheaper than NiTi-based ones. Therefore, studies on

\* Sorumlu yazar: caksu@firat.edu.tr. Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-6947-7590, <sup>2</sup> 0000-0003-4255-0564, <sup>4</sup> 0000-0002-5151-4576

copper-based SMAs and HTSMAs are continuously carried out to improve or alter these alloys' SE and SME or other properties to enable their use as alternatives to NiTi-based ones.

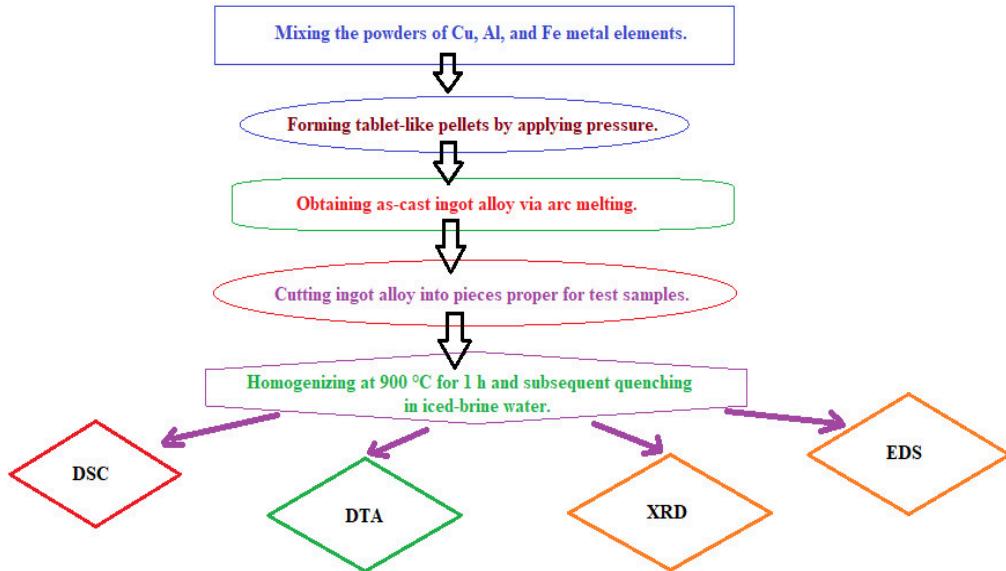
The shape change mechanism of SMAs based on their reversible martensitic transformation occurs fundamentally by change of SMAs temperature. The low temperature martensite phase with low symmetry changes to high temperature austenite phase with high symmetry by increase of temperature or heat intake and this transformation from martensite to austenite is called as reverse transformation. Conversely, when the temperature goes down then austenite converts to martensite and it is called as forward transformation. Martensitic transformation in SMAs occurs isostatically and atomically non-diffusional (atoms move cooperatively and theoretically they do not displace further than atomic lattice parameter or inter-atomic distance) by the effect of internal stresses which are generated by heat intake or release from SMAs. Mostly the austenite unit cell is a cubic phase and for example it transforms to a monoclinic martensite, then a macroscopic shape change can be seen as a sum of all these transformations. This is called as shape memory effect (SME) [8]. The crystallographic SME mechanism of copper-based SMAs is based on a martensitic phase transformation from an austenite (parent) phase with high symmetry cubic  $\beta$ -phase ( $DO_3$  or  $L2_1$ ) to a martensite (product) phase with lower symmetry monoclinic ( $\beta'$ ) or orthorhombic ( $\gamma'$ ) or a mixture ( $\beta' + \gamma'$ ) martensite structure [9]. This structural SME mechanism is susceptible to the alloying composition, thermal treatment, and stress levels of these SMAs. Even a slight variation in the alloy composition can substantially alter the SME characteristics. For this reason i.e. in order to improve or modify shape memory properties and/or reduce the grain size for enhancement of mechanical properties, adding one or more extra elements such as Ti, Mn, Ni, Fe, Co, Be, Sn, Zn, etc., called grain refining elements, to the binary copper-based SMAs is a practical and prevalent method used to improve or modify shape memory parameters of copper-based SMAs.

Among Cu-based SMAs, binary CuAl-based HTSMAs exhibit martensitic transformation (operation) in higher temperature ranges than the other Cu-based ones [10] and also better microstructural stability [1] and electric and thermal conductivity [11]. Especially the foremost CuAlNi (or -based) and the other CuAlMnNi, CuAlMnTi, CuAlNb, CuAlBe, CuAlTa, and CuAlFeMn HTSMAs [1,9,10,12–14] are the most outstanding CuAl-based (or Cu-based) HTSMAs. Ternary CuAlFe HTSMAs with excellent SME [13,15,16] have also distinguished in the last decade. For example, in one of these works, the Cu-xAl-4Fe ( $x = 11, 13, 15\text{wt\%}$ ) alloys were studied and it was reported that the alloy is very sensitive to Al fraction and the  $M_s$  temperature decreased substantially by the increase of Al content (from 11wt% to 15wt% Al, it decreased by up to 217 °C), also the microstructure presented sub-eutectic to hyper-eutectic characteristics with the rise in Al content, and while the shape memory recovery rates of the 13 and 15wt% Al alloys were determined as 100%, the recovery rate of 11wt% Al alloy was determined only as 22.6%, but the lowest ductility (or the highest brittleness) was found in the 15wt% Al alloy. In another work [15], the  $Cu_{84-x}Al_{11+x}Fe_5$  ( $x = 0, 1, 2$ ) alloys were investigated and it was stated that the  $\beta1'$  and  $\gamma1'$  martensites form together for the Al content of 11 and 12 wt%, but in the case of 12 wt% of Al content  $\gamma1'$  forms dominantly, and the ductility of alloy gradually increases with the decrease of Al content. In the other work, the influence of Al content (in the range of 10-13 wt %) on the two groups of Cu-Al-Fe alloys, one with only varying Al contents and the other with only varying Fe contents, were studied and it was observed that the transformation temperatures reduced with increase of Al, but they increased with increase of Fe content, and again the dominancy changing from  $\beta1'$  to  $\gamma1'$  martensite was observed through going from low to high Al content. However, studies on these HTSMAs are still very few, and their thermodynamic transformation parameters were not adequately investigated. Also, not many options for different transformation temperatures have been reported. Therefore, a CuAlFe HTSMA with different transformation temperatures was produced in this study, and its thermodynamic aspects were investigated.

## 2. Experimental Details

The ternary CuAlFe HTSMA was produced by the following steps (as shown in Figure 1): 1- The high %99.9-purity of Cu, Al, and Fe metal elements powders were mixed. 2- The tablet-like pellets were formed from the powder-mixture by applying pressure. 3- Ingot alloy was cast by melting the pellets in a vacuum arc melter. 4- The ingot alloy pieces proper for test samples were cut and for one (1) h the samples were homogenized at 900 °C and quenched immediately in iced-brine water to form martensitic structure mechanism in the HTSMA to have SME property. In order to observe and analyze the heat-induced SME behaviour of the HTSMA, a Shimadzu-60A label DSC equipment was used at varied heating/cooling rates between 10 - 25 °C/min and running between room temperature and 380 °C under a constant flow rate of 100 ml/min of inert (argon) gas. For high-temperature region behaviours of the HTSMA, a Shimadzu DTG-60AH model DTA equipment was used under the same inert gas flow at 25 °C/min of heating/cooling rate between room temperature and 900 °C. The XRD pattern of the produced CuAlFe HTSMA was obtained in the room condition using CuK $\alpha$  wavelength rays in a Rigaku Miniflex 600 model X-ray diffractometer to determine the martensite structures of the SME mechanism formed in the HTSMA matrix.

Using the SEM-Hitachi SU3500 instrument at room temperature, the EDS test was performed to detect the alloying composition of the CuAlFe HTSMA.



**Figure 1.** The flow diagram showing the production and characterization steps of the ternary CuAlFe HTSMA.

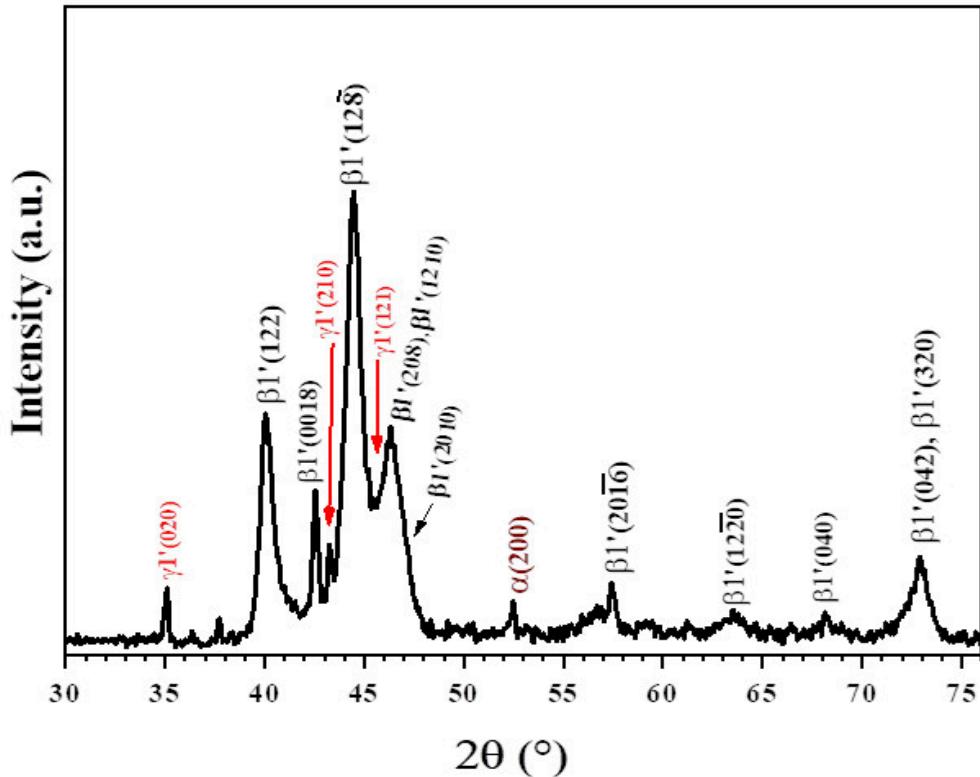
### 3. Results and Discussion

The XRD pattern of the fabricated CuAlFe HTSMA is given in Figure 2 and displays the peaks indicating the formed martensite and other phases in the alloy at room temperature. The observed main or most powerful intensity peak is a monoclinic  $\beta'1$  type martensite with an orientation of (128) Miller indices. This main peak and the other smaller monoclinic  $\beta'1(18R)$  and hexagonal  $\gamma'1(2H)$  martensite peaks [9,13,15–17] mean that a crystallographic structure mechanism for a shape memory effect property of the CuAlFe alloy is formed in the alloy texture by the effect of rapid cooling (quenching) right at the end of homogenization. Lastly, there a small copper-rich  $\alpha$ -phase peak is also seen formed on this XRD pattern. It is seen that both  $\beta'1$  and  $\gamma'1$  types of martensites, with volumetric dominancy of  $\beta'1$  martensite over  $\gamma'1$  martensite, were formed together contextured in the alloy texture and the formation of which martensite types and dominancy over each other depend on the average valence electron concentration per atom ratio ( $e/a$ ) parameter value of the alloy. This  $e/a$  parameter value calculated for the CuAlFe alloy is to be given ahead in the EDS result section.

By using the XRD data of the main martensite peak, the crystallite size of the CuAlFe alloy was also calculated by using the Debye-Scherrer formula [9] as given below;

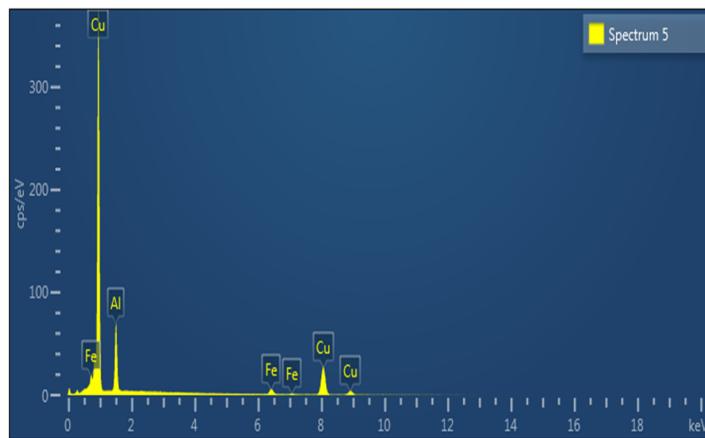
$$D = \frac{0.9\lambda}{B_{1/2} \cos \theta} \quad (1)$$

Where  $\lambda$  stands for the wavelength (CuK $\alpha$  radiation,  $\lambda = 0.15406$  nm) used for X-ray diffraction,  $B_{1/2}$  refers to the full width at half maximum (FWHM) value of the main intensity martensite peak, and  $\theta$  refers to the Bragg diffraction angle of this peak. So, at the  $2\theta$  angle of  $44.418^\circ$  with a corresponding FWHM value of 0.953, the crystallite size  $D$  value of the CuAlFe HTSMA was calculated as 9.01 nm. This value was found as similar to 9.29 nm found for the 73.23Cu-21.93Al-3.36Fe1.48Mn (at.%) alloy aged and quenched in boiling water [18], close to 15.61 nm found for the quinary Cu-24.08Al-2.23Fe-1.34Co-0.97Ti (at%) alloy [19], lower than 20.02 nm found for Cu-22.78Al-2.59Fe-2.44Mn (at%) [9], and than 21.12 nm found for Cu-23.08Al-0.5Mn (at%) [20], previously. When these reported  $D$  values of the alloys with Fe contents are compared, it seems that the crystallite size decreased with increase of Fe content.



**Figure 2.** The XRD pattern of the ternary CuAlFe HTSMA at room temperature.

The EDS pattern of the ternary CuAlFe HTSMA is given in Figure 3. This EDS test detects the alloying composition of the produced CuAlFe HTSMA as 72.28Cu-23.71Al-4.01Fe (at.%).

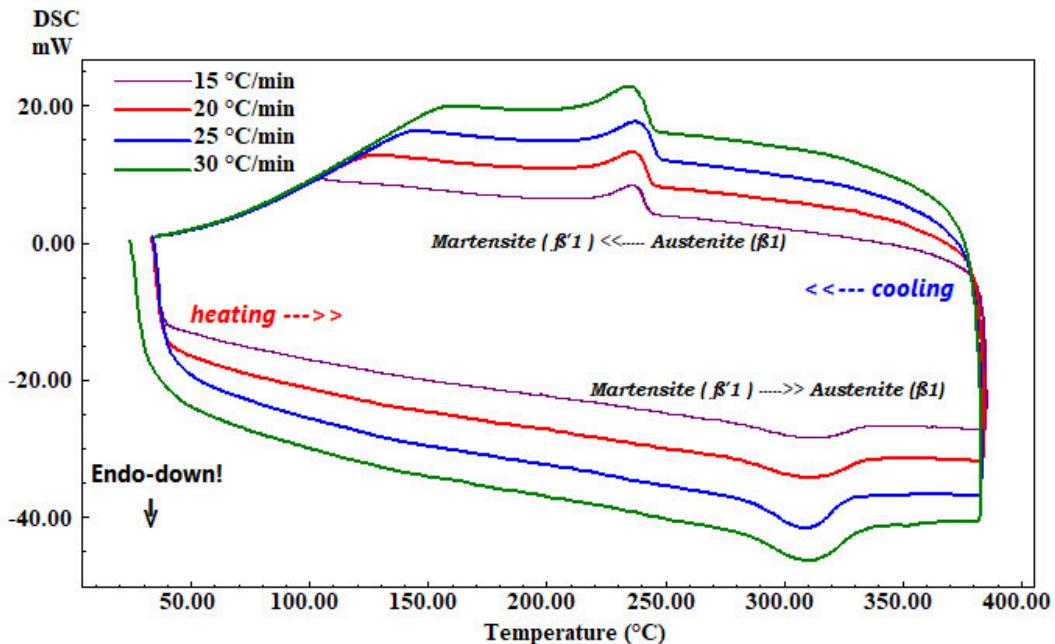


**Figure 3.** The EDS test pattern of the produced CuAlFe HTSMA.

By using atomic at.% percentages (fractions) of the constituent elements of the detected alloy's composition in the formula [9] given as  $e/a = \sum f_i \cdot v_i$ , and in this formula:  $f$  refers to the atomic fractions of the alloying elements and  $v$  stands for the corresponding valence electron numbers of these elements. In this way, the e/a ratio of the average electron concentration ratio (e/a) of the CuAlFe alloy was 1.51. The e/a ratio of CuAlFe alloy is found between the e/a ratio range of 1.45-1.51, which is a theoretical condition for Cu-based alloys to have a shape memory effect [8,9]. Moreover, Cu-based SMAs with e/a ratios in this range can have two different martensite forms ( $\beta_1'$  and  $\gamma_1'$ ) together, and  $\beta_1'$  martensite gains dominancy over  $\gamma_1'$  martensite by going from 1.51 to 1.45.

The XRD result given above confirmed the formation of these two martensite phases in the CuAlFe alloy predicted by the alloy's e/a ratio of the alloy.

The DSC curves of the CuAlFe HTSMA obtained by DSC cycles run at different 15-30 °C/min heating/cooling rates as multi-curves in Figure 4. On each one of these curves, while the downward endothermic peaks indicate the reverse martensite-to-austenite (M→A) phase transformations, the upward exothermic peaks indicate the forward austenite-to-martensite (A→M) phase transformations occurred upon heating and then cooling the DSC test sample piece of CuAlFe HTSMA, respectively [9,11,21].



**Figure 4.** The cycling DSC, heating/cooling curves, taken at different 15, 20, 25 and 30 °C/min heating/cooling rates, show the reverse martensite to austenite (M→A) transformation peaks on heating fragments of these curves and the forward austenite to martensite (A→M) transformation peaks on cooling fragments of these curves.

The characteristic operation (martensitic transformation) temperatures and other thermokinetic parameter values of the CuAlFe HTSMA determined from the DSC peak analyses data and based calculations were all presented in Table 1. In this table, values of the thermal equilibrium temperature ( $T_0$ ) parameter; at this temperature, there is no driving force for a martensitic transformation to occur because no difference between the Gibbs (chemical) free energies of austenite and martensite phases exists at an equilibrium temperature, were determined by  $T_0=(A_f+M_s)\times 0.5$  formula [9,11]. Also, the entropy change ( $\Delta S$ ) parameter value for each M→A transformation reaction was determined by using the enthalpy change ( $\Delta H$ ) values in  $\Delta S_{M \rightarrow A}=\Delta H_{M \rightarrow A}/T_0$  formula [9,11]. As a result, the high enthalpy change amounts of these martensitic transformations, reached its maximum 12.03 J/g value at the 30 °C/min heating/cooling rate, indicate the potent suitable shape memory effect property of the CuAlFe HTSMA.

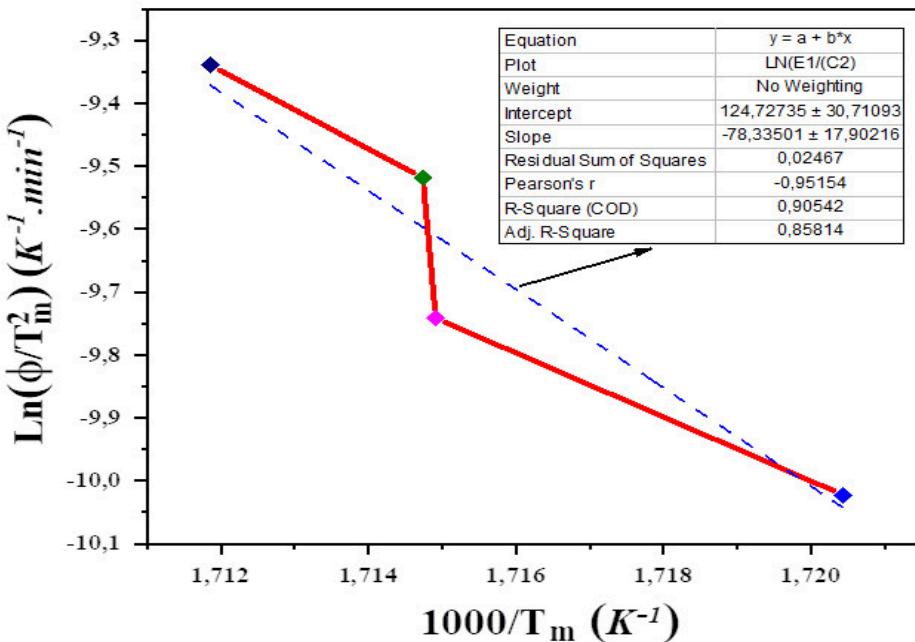
Another important reaction kinetic parameter is activation energy ( $E_a$ ), which is proper for a martensitic transformation; it plays a critical role in the occurrence of martensitic phase transformations and determines the crystallization behaviour of the alloy. Also, to determine this energy parameter is important in the industrial productions and applications of shape memory alloys. Here, the formula of Kissinger [9,22] relevant for martensitic transformation was used to compute the  $E_a$  value of the M→A transformation of CuAlFe alloy;

$$\frac{d\left[\ln\left(\frac{\phi}{T_m^2}\right)\right]}{d\left(\frac{1}{T_m}\right)} = -\frac{E_a}{R} \quad (2)$$

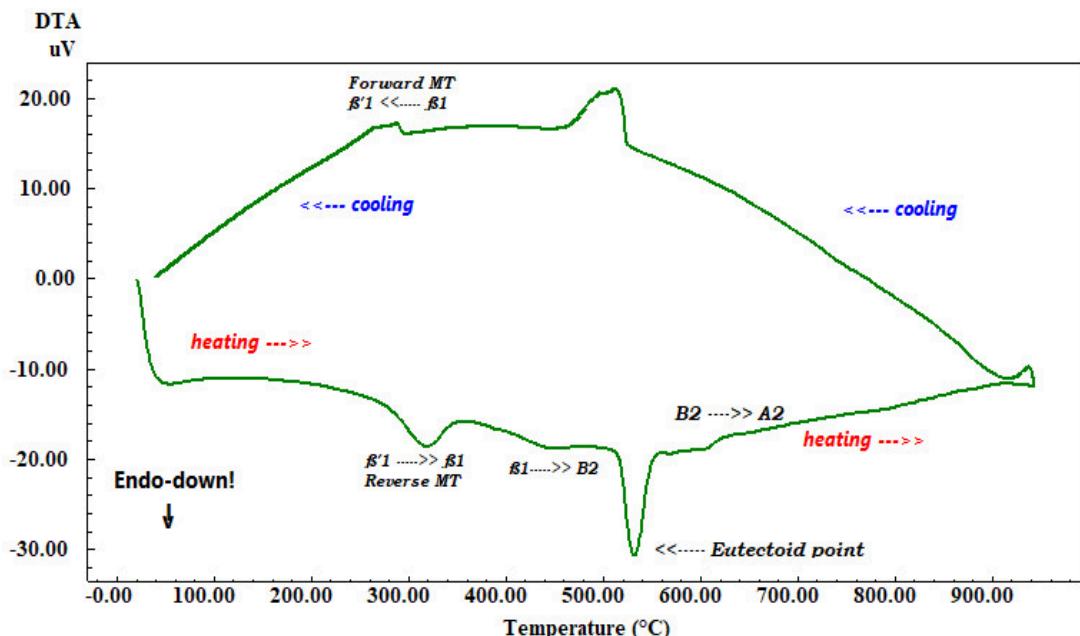
**Table 1.** The characteristic martensitic transformation temperatures and other related thermodynamic parameters of the fabricated CuAlFe HTSMA.

Heating/cooling rate (°C/min)	$A_s$ (°C)	$A_f$ (°C)	$A_{max}$ (°C)	$M_s$ (°C)	$M_f$ (°C)	$A_s - M_f$ (°C)	$T_0$ (°C)	$\Delta H_{M \rightarrow A}$ (J/g)	$\Delta S_{M \rightarrow A}$ (J/g°C)
15	286.65	331.97	308.10	243.72	221.04	65.61	287.85	9.90	0.0344
20	283.80	334.90	309.97	244.88	217.87	65.93	289.89	11.37	0.0392
25	288.14	326.56	310.03	247.92	217.54	70.60	287.24	11.43	0.0398
30	285.61	333.01	311.01	245.37	214.80	70.81	289.19	12.03	0.0416
Avg.	286.05	331.61	309.78	245.47	217.81	68.24	288.54	11.18	0.0388

Where  $T_m$  refers to the peak maximum temperature ( $A_{max}$ ) of  $M \rightarrow A$  transformation,  $\phi$  stands for heating/cooling rate, and  $R$  is ( $=8.314 \text{ J/mol.K}$ ) the universal gas constant. A plot showing the activation energy change of the reverse  $M \rightarrow A$  transformation of the CuAlFe HTSMA was drawn and presented in Figure 5. By taking linear fitting on this plot, obtaining its slope value (seen in the inset fitting dataset in this graphic), and substituting it instead of the left term in Eq.2, the activation energy for the reverse martensitic phase transition reaction of the CuAlFe HTSMA can be found. Thus, the  $E_a$  activation energy value of the CuAlFe HTSMA was  $651.28 \text{ kJ/mol}$ . This value was found close to those reported in some previous works [9,23].

**Figure 5.** Activation energy change plot of the CuAlFe HTSMA with linear fitting line and inset dataset.

DTA high-temperature thermogram curve of the alloy obtained at a single  $25 \text{ }^\circ\text{C}/\text{min}$  heating/cooling rate is given in Figure 6. On the up fragment of this DTA curve representing the cooling of the CuAlFe alloy sample back to room temperature, there is a series of multiple sequential phase transition steps of  $A_2 \rightarrow B_2 \rightarrow B_1(\text{DO}_3 \text{ or L}2_1) \rightarrow \beta'1$  as commonly seen in the other Cu-based SMAs and HTSMAs [8,9,11,24–26]. The DTA curve of the CuAlFe alloy also shows its forward and reverse martensite transformation peaks. The sharp and deep eutectoid point peak indicates how well the CuAlFe HTSMA is alloyed.



**Figure 6.** The cycling DTA heating/cooling curve of the fabricated CuAlFe HTSMA taken at a single 25 °C/min heating/cooling rate shows the multiple-phase transition chain on heating as follows: martensite ( $\beta'1$ ) → austenite ( $\beta1$ , L21) → B2 (metastable cubic) → precipitating → eutectoid dissolution → B2 (ordered cubic) → A2 (disordered cubic).

#### 4. Conclusions

The CuAlFe HTSMA was produced successfully by arc melting method. The homogenization and quenching led martensitic structures to be formed in the alloy to have a shape memory property. The XRD pattern of the alloy confirmed the formed martensite structures in the alloy. Also, it confirmed the supportive prediction of the formation of these martensite structures made upon the alloy's calculated average valence electron concentration ratio. The DSC and DTA results showed the powerful forward and reverse martensitic transformations that happened upon heating and cooling the alloy. The determined operation temperatures of the alloy showed that the alloy is a high-temperature shape memory alloy and they are different than those in the literature. Also, the enthalpy and entropy change amounts were found as the highest reached ever in the literature, showing the powerful shape memory capacity of the produced alloy. The determined high activation energy of the reverse transformation of the alloy is related to its polycrystallinity and small crystallite size which enlarged the total surface area of martensite crystallites to transform to austenite thus increase the activation energy needed for this transformation. The determined crystallite size of the alloy was found mostly smaller than those reported in the literature, due to the high Fe content use. All findings of this study indicate that the fabricated CuAlFe HTSMA with new martensitic transformation temperatures may be useful in HTSMA-related smart material applications.

#### Acknowledgments

This research work is a part of thesis works of Yakup AYDEMİR mastering in general physics in Physics Department, Science Faculty, Firat University. Firat University Scientific Research Projects (FUBAP) financially supports this research work: FF.23.17 project number.

#### References

- [1] Ma J, Karaman I, Noebe RD. High temperature shape memory alloys. International Materials Reviews 2010;55:257–315.
- [2] Kauffman GB. The Story of Nitinol: The Serendipitous Discovery of the Memory Metal and Its Applications. The Chemical Educator 1997;2:1–21.
- [3] Firstov GS, Van Humbeeck J, Koval YN. High-temperature shape memory alloys. Materials Science and Engineering: A 2004;378:2–10.
- [4] Duerig TW, Albrecht J, Gessinger GH. A Shape-Memory Alloy for High-Temperature Applications. JOM 1982;34:14–20.

- [5] Van Humbeeck J. Shape memory alloys with high transformation temperatures. *Mater Res Bull* 2012;47:2966–8.
- [6] Hite N, Sharar DJ, Treherne W, Umale T, Atlı KC, Wilson AA, et al. NiTiHf shape memory alloys as phase change thermal storage materials.
- [7] Ley NA, Wheeler RW, Benafan O, Young ML. Characterization of Thermomechanically Processed High-Temperature Ni-Lean NiTi–20 at.% Hf Shape Memory Wires. *Shape Memory and Superelasticity* 2019;5.
- [8] Otsuka K, Wayman CM. Shape memory materials. Cambridge University Press; 1999.
- [9] Canbay CA, Karaduman O, Ünlü N, Baiz SA, Özkul İ. Heat treatment and quenching media effects on the thermodynamical, thermoelastical and structural characteristics of a new Cu-based quaternary shape memory alloy. *Compos B Eng* 2019;174:106940.
- [10] Mazzer EM, Da Silva MR, Gargarella P. Revisiting Cu-based shape memory alloys: Recent developments and new perspectives. *J Mater Res* 2022;37:162–82.
- [11] Canbay CA, Karaduman O. The photo response properties of shape memory alloy thin film based photodiode. *J Mol Struct* 2021;1235:130263.
- [12] Canbay CA, Karaduman O, Özkul İ. Investigation of varied quenching media effects on the thermodynamical and structural features of a thermally aged CuAlFeMn HTSMA. *Physica B Condens Matter* 2019;557:117–25.
- [13] Wang H, Huang J, Chen S, Yuan X, Zhu J, Xu D, et al. Microstructure and shape memory properties of Cu-Al-Fe alloys with different Al contents made by additive manufacturing technology. *Mater Res Express* 2022;9:095701.
- [14] Najah Saud Al-Humairi S. Cu-Based Shape Memory Alloys: Modified Structures and Their Related Properties. Recent Advancements in the Metallurgical Engineering and Electrodeposition, IntechOpen; 2020, p. 25.
- [15] Yang S, Su Y, Wang C, Liu X. Microstructure and properties of Cu-Al-Fe high-temperature shape memory alloys. *Mater Sci Eng B Solid State Mater Adv Technol* 2014;185:67–73.
- [16] Raju TN, Sampath V. Influence of aluminium and iron contents on the transformation temperatures of Cu-Al-Fe shape memory alloys. *Transactions of the Indian Institute of Metals* 2011;64:165–8.
- [17] Saud SN, Hamzah E, Abubakar T, Bakhsheshi-Rad HR. Thermal aging behavior in Cu-Al-Ni-xCo shape memory alloys. *J Therm Anal Calorim* 2015;119:1273–84.
- [18] Canbay CA, Karaduman O, Özkul İ, Ünlü N. Modifying Thermal and Structural Characteristics of CuAlFeMn Shape Memory Alloy and a Hypothetical Analysis to Optimize Surface-Diffusion Annealing Temperature. *J Mater Eng Perform* 2020;29:7993–8005.
- [19] Karaduman O, Özkul İ, Altın S, Altın E, Bağlayan, Canbay CA. New Cu-Al based quaternary and quinary high temperature shape memory alloy composition systems. *AIP Conf Proc*, vol. 2042, American Institute of Physics Inc.; 2018.
- [20] Karaduman O, Aksu Canbay C, Özkul İ, Aziz Baiz S., Ünlü N. Production and Characterization of Ternary Heusler Shape Memory Alloy with A New Composition. *Journal of Materials and Electronic Devices* 2018;1:9–16.
- [21] Canbay CA, Karaduman O, Özkul İ. Lagging temperature problem in DTA/DSC measurement on investigation of NiTi SMA. *Journal of Materials Science: Materials in Electronics* 2020;31:13284–91.
- [22] Kissinger HE. Reaction Kinetics in Differential Thermal Analysis. *Anal Chem* 1957;29:1702–6.
- [23] Canbay CA, Karaduman O, Ünlü N, Özkul İ, Çiçek MA. Energetic Behavior Study in Phase Transformations of High Temperature Cu–Al–X (X: Mn, Te, Sn, Hf) Shape Memory Alloys. *Transactions of the Indian Institute of Metals* 2021.
- [24] Prado MO, Decorte PM, Lovey F. Martensitic transformation in Cu-Mn-Al alloys. *Scripta Metallurgica et Materialia* 1995;33.
- [25] Chentouf SM, Bouabdallah M, Gachon JC, Pattoor E, Sari A. Microstructural and thermodynamic study of hypoeutectoidal Cu-Al-Ni shape memory alloys. *J Alloys Compd* 2009;470:507–14.
- [26] Grgurić TH, Manasijević D, Kožuh S, Ivanić I, Anžel I, Kosec B, et al. The effect of the processing parameters on the martensitic transformation of Cu-Al-Mn shape memory alloy. *J Alloys Compd* 2018;765:664–76.

## Gerilim Kaynaklı Eviricinin Faz Akımlarının İzlenmesiyle Açık Devre Arızalarının Teşhisİ

Serenay ÇELİK<sup>1\*</sup>, Servet TUNCER<sup>2</sup>

<sup>1,2</sup> Elektrik Elektronik Mühendisliği, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

\*<sup>1</sup> serenay.celik@firat.edu.tr, <sup>2</sup> stuncer@firat.edu.tr

(Geliş/Received: 11/07/2024;

Kabul/Accepted: 25/09/2024)

**Öz:** Gerilim kaynaklı eviricilerin endüstriyel uygulamalarda yaygın olarak kullanılmasıyla, meydana gelen arızaların tanımlanması önemli bir araştırma konusu haline gelmiştir. Bu çalışmada, üç-fazlı iki-seviyeli eviricideki 24 farklı tekli ve çoklu açık anahtar devre arızaları incelenmiş, arızanın bulunduğu kol ve arızalı anahtarın tespiti yapılmıştır. Matlab/Simulink ortamında benzetimi yapılan eviricinin çıkış faz akımlarının ortalama, rms (etkin) değerlerinin yanı sıra ortalama/rms oranları da kullanılarak yük bağımlılığı problemi giderilmiştir. Çalışmada, destek vektör makineleri (SVM: Support Vector Machines), K-en yakın komşular (KNN: K-Nearest Neighbours), yapay sinir ağı (ANN: Artificial Neural Network) ve uzun kısa süreli bellek (LSTM: Long Short Term Memory) gibi dört farklı sınıflandırma modeli kullanılmış olup her bir modelin başarısını ayrı ayrı değerlendirilmiştir. Benzetim sonuçlarından, önerilen arıza teşhis ve sınıflandırma tekniklerinin tekli, çiftli ve üçlü anahtar arıza durumlarındaki tahmin başarısı yüksek doğrulukla sağlanmıştır.

**Anahtar kelimeler:** Açık devre arızası, makine öğrenmesi, derin öğrenme, faz akımları.

### Diagnosis of Open Circuit Faults by Monitoring Phase Currents of Voltage Source Inverter

**Abstract:** With the widespread use of voltage source inverters in industrial applications, the identification of faults has become an important research topic. In this study, 24 different single and multiple open switch circuit faults in a three-phase two-level inverter were examined, and the branch where the fault was located and the faulty switch were identified. The load dependency problem was eliminated by using the average, rms (effective) values of the output phase currents of the inverter simulated in the Matlab/Simulink environment as well as the average/rms ratios. In the study, four different classification models such as Support Vector Machines (SVM), K-nearest Neighbors (KNN), Artificial Neural Network (ANN) and Long Short Term Memory (LSTM) were used and the performance of each model was evaluated separately. From the simulation results, the prediction success of the proposed fault diagnosis and classification techniques in single, double and triple switch fault cases was achieved with high accuracy.

**Key words:** Open circuit fault, machine learning, deep learning, phase currents.

### 1. Giriş

Gerilim kaynaklı eviriciler; ayarlanabilir hız sürücü uygulamaları, yenilenebilir enerji sistemleri gibi değişken gerilimlerin ihtiyaç duyulduğu vb. endüstriyel alanlarda önemli bir rol oynamaktadır [1]. Eviricilerin güç devresinde anahtarlama elemanı olarak yüksek performans özelliklerine sahip kapıdan yalıtımlı bipolar transistörler (IGBT: Insulated Gate Bipolar Transistor) yaygın olarak kullanılmaktadır [2]. Bununla birlikte IGBT'ler, evirici devre yapılarındaki arızaların %38'ini oluşturan en hassas bileşenlerdir [3]. Güç anahtarı arızaları kısa devre ve açık devre arızaları olmak üzere iki sınıfta incelenmektedir. Aşırı ısınma, aşırı gerilim veya yanlış tetikleme sinyallerinden kaynaklanan kısa devre arızaları sistem üzerinde ciddi hasarlara sebep olmaktadır. Açık devre arızaları ise sistem çıkışındaki performansı düşüren, diğer devre bileşenlerinde ikincil arızalara sebep olan yumuşak arızalardır. Bu nedenle açık devre arızalarının tespiti ve sınıflandırılması son zamanlarda en çok araştırılan konularından biri olmuştur [3-6]. Arızaları kısa sürede tanımlamak ve doğru sınıflandırmak sistem sağlamlığı ve güvenirliği açısından önemli görülmektedir.

Güç anahtarlarının açık devre durumunda sistem performansını iyileştirmek için birçok yöntem geliştirilmiştir [3,7]. Açık devre arızaları; kapı sürücüsü arızaları, açık anahtar arızaları, açık diyon arızaları ve açık faz bacağı arızaları olarak sınıflandırılabilir [8,9]. Kapı sürücüsü arızası güç anahtarına gönderilen tetikleme sinyalinin kesilmesiyle IGBT anahtarında açık devre arızasına sebep olmaktadır. IGBT anahtarlarına bağlı anti-paralel diyonların devreyle bağlantısının kesilmesi ise açık diyon arızalarını meydana getirmektedir. IGBT anahtarlarının açılması ve böylece içerisindeki akımın herhangi bir sebeple kesilmesi ile doğrudan açık devre arızaları meydana gelmektedir [8-11].

\* Sorumlu yazar: serenay.celik@firat.edu.tr. Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-4774-2381, <sup>2</sup> 0000-0002-7435-0906

Eviricilerde arıza tespit yöntemleri: model tabanlı yöntemler, sinyal tabanlı yöntemler ve veriye dayalı yöntemler olmak üzere üç kategoride incelenmektedir [12]. Model tabanlı yöntemler, sensör bilgileri veya ölçüm donanım bileşenleri gerektirmeksiz matematiksel model ve analitik bilgiye dayanmaktadır [2,13]. Gözlemeviye dayalı yöntemler [14,15], eşlik denklemlerine dayalı yöntemler [16,17] ve parametre tahmin denklemlerine dayalı yöntemler [18-20] yaygın olarak kullanılan model tabanlı yöntemlerdir. Model tabanlı yöntemlerde matematiksel modelden hesaplanan değerler ile elde edilen veriler arasında oluşan farkların izlenmesiyle arızalar tespit edilebilmektedir. Ancak model belirsizlikleri veya parametrelere duyarlılığına bağlı olarak sistem performansının etkilenmesi ve çoklu anahtar arıza tespitlerindeki eksiklik bu yöntemin en önemli dezavantajını oluşturmaktadır [2,4,21].

Sinyal tabanlı yöntemler, arıza tespiti için akım ve gerilim sinyallerini veya her iki sinyalin birleşimini kullanırlar. Gerilim tabanlı yöntemlerde sinyal bilgilerini almak için ek sensörlerle ihtiyaç duyulmaktadır. Bu durum yöntemin karmaşıklığını ve maliyeti artırmaktadır [22,23]. Akım tabanlı yöntemler daha yaygın olarak kullanılmaktadır. Bunun sebebi evirici parametrelerine bağlı olmamasıdır [24-29]. Sinyal işleme tekniklerinin hesaplama yükü fazlalarını ve uzun tespit sürelerinin bulunması sinyal tabanlı yaklaşımların eksiklikleri olarak görülmektedir [2,4,5,21,30].

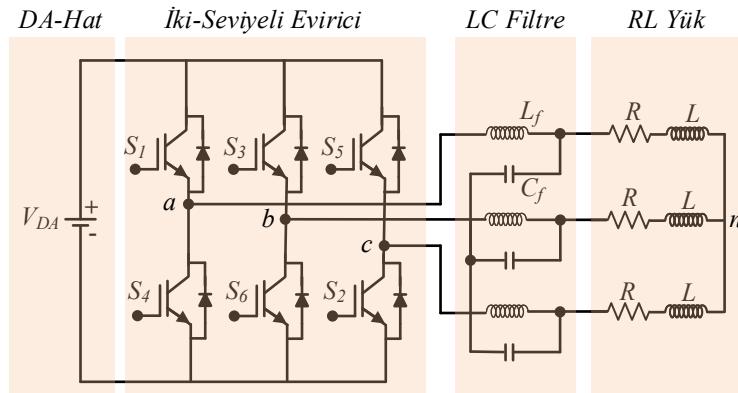
Veri tabanlı yöntemlerde mevcut verilerden arıza özelliklerini elde edilerek arıza etiketleri ile eşleştirilmektedir [31-36]. Model tabanlı ve sinyal tabanlı yöntemlerden farklı olarak veri tabanlı yöntemler modelden ve yük durumundan bağımsız olduğundan değişken sistem durumları için daha esnek, karmaşık arıza durumları için ise daha sağlam performans göstermektedirler. Veriye dayalı yöntemler arasında uzman sistemler, bulanık mantık, karar ağaçları, yapay sinir ağları, destek vektör makineleri vb. yapay zekâ yaklaşımları bulunmaktadır [2,5,21]. Algoritmaların eğitiminin ve doğrulanmasının sağlanması için büyük veri kümelerinin gerekliliği bu yöntemin temel problemidir [4].

Eviricilerdeki arıza durumlarının tespitine yönelik literatürde yapılan çalışmalar incelendiğinde, kapı sürme arızaları üzerinde açık anahtar arızalarından daha çok çalışıldığı görülmektedir. Evirici anahtarlarındaki arızaları tanımlamak ve sınıflandırmak tüm sistemin güvenliği ve olası risklerin azaltılması açısından önemli bir konu olarak görülmektedir. Bu çalışmada; üç-fazlı iki-seviyeli eviricinin açık anahtar arıza durumları incelenmiş, arıza teşhis ve sınıflandırılması için SVM, KNN gibi makine öğrenmesi algoritmaları, ANN ve LSTM gibi derin öğrenme modelleri kullanılmıştır. Veri kümесini elde etmek için evirici üzerinde oluşturulan açık anahtar arıza durumuna ilişkin faz akımlarının ortalama ve rms değerleri ölçülmüştür. Mevcut yöntemlerden farklı olarak veri kümese ortalama ve rms akımları ile birlikte ortalama/rms değerlerinin oranları eklenmiştir. Bu teknik sayesinde ortalama akımdan kaynaklı yük bağımlılığı problemi giderilmiştir [4]. Böylelikle tekli ve çoklu anahtar arızalarını tanımlayan ve sınıflandıran yöntemler elde edilmiş, sonuçları değerlendirilmiş ve önerilen yöntemlerin performansları karşılaştırılmıştır.

Bölüm II'de iki-seviyeli evirici modeli ele alınmış ve arıza davranışları incelenmiştir. Benzetim modeli ile makine öğrenmesi ve derin öğrenme esaslı arıza tespit ve sınıflandırma teknikleri Bölüm III'de sunulmuştur. Benzetim sonuçları ve performans değerlendirilmeleri Bölüm IV'de tartışılmıştır.

## 2. İki-Seviyeli Evirici Modeli ve Arıza Davranışları

Üç-fazlı iki-seviyeli gerilim kaynaklı eviriciler; kesintisiz güç kaynakları, değişken-hızlı AA motor sürücüler, şebekeye bağlı fotovoltaik sistemler ve diğer yenilenebilir enerji üretimleri ile endüstriyel otomasyon gibi uygulamalarda yaygın olarak kullanılan güç elektroniki devreleridir [36-38]. Bu çalışmada, Şekil 1'de gösterilen IGBT anahtarlarından oluşan ve anahtarların denetimi için sinüzoidal darbe genişlik modülasyonu (SPWM)技术ini kullanan üç-fazlı iki-seviyeli eviricinin açık anahtar arıza durumları incelenmiştir. Sistemin parametreleri Tablo 1'de verilmiştir. Yapılan çalışmada yük olarak dengeli yıldız bağlı iki farklı yük kullanılmıştır.

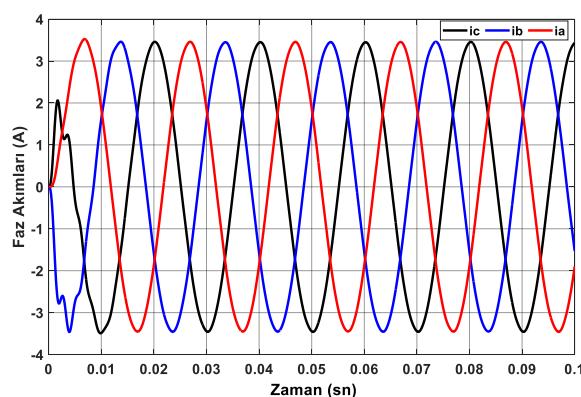


Şekil 1. Üç-fazlı iki-seviyeli evirici.

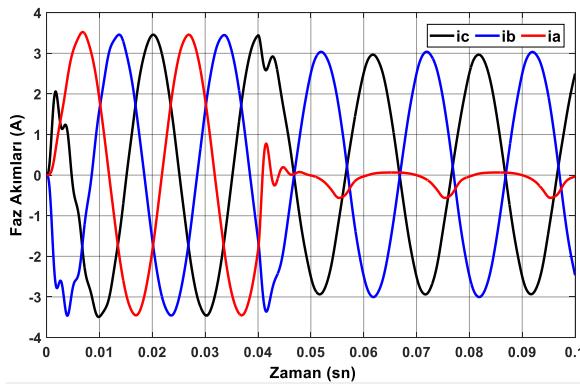
Tablo 1. Devre parametreleri.

Parametre	Değeri
Doğru Akım Kaynağı	100V
Temel Frekans	50Hz
Taşıyıcı Frekans	10kHz
Yük-1	10Ω, 10mH
Yük-2	40Ω, 20mH
Modülasyon İndeksi	0,8
LC Filtre	L=10mH, C=25μF

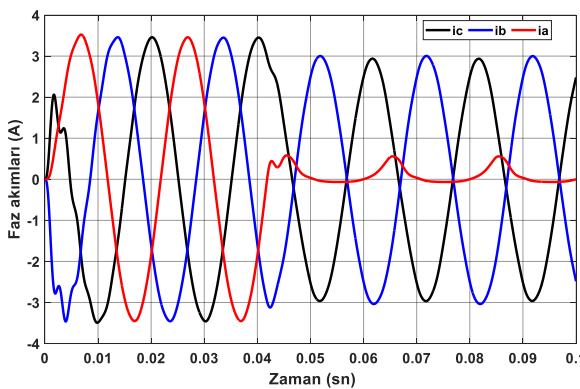
Eviricilerde normal koşullar altında dengeli üç-faz sinüzoidal çıkış akımları elde edilmektedir (Şekil 2). Sistemdeki bir veya daha fazla IGBT anahtarlarında açık devre arızası meydana geldiğinde bu akım dalga formları sinüzoidal formdan uzaklaşır ve aralarındaki denge durumu ortadan kalkar. Üst kollarda oluşan bir açık anahtar devre arızasında, arızalı anahtardan akım akımayacaktır, bununla birlikte kolun alt anahtarında ise akım akmeye devam edecektir. Örneğin  $S_1$  anahtarı için  $t=0,04\text{sn}$ 'de açık devre arızası oluştuğunda;  $S_1$ 'den akım akmazken  $S_4$  anahtarı üzerinden akım akmeye devam etmektedir. Böylece a-fazındaki akım negatif olduğundan b ile c-fazlarındaki akımlara pozitif bileşenler eklenir ve Şekil 3'te gösterildiği gibi üç-fazlı akım dalga formu bozulur. Benzer şekilde, alt kollarda oluşan bir açık anahtar devre arızasında (örneğin  $S_4$ ),  $S_4$ 'den akım akmazken  $S_1$  anahtarı üzerinden akım akmeye devam eder. Böylelikle durum tersine dönüşmüş olur ve a-fazındaki akım pozitif olduğundan b ile c-fazlarındaki akımlara negatif bileşenler eklenecek ve Şekil 4'te gösterildiği gibi üç-fazlı akım dalga formları oluşacaktır.



Şekil 2. Normal koşullar altında (arızasız durum) faz akımları

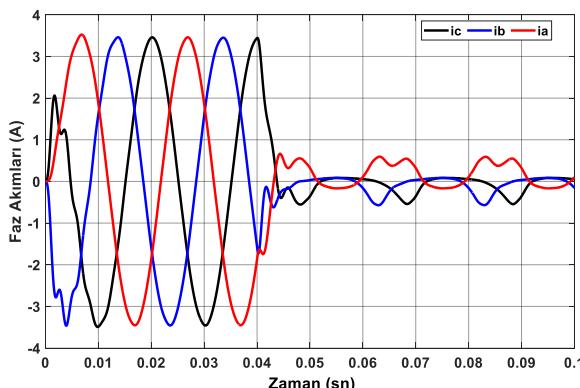


Şekil 3. S<sub>1</sub> anahtarının açık devre olduğu durumda faz akımları.

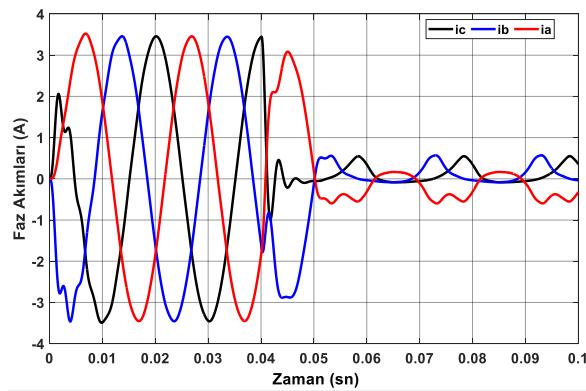


Şekil 4. S<sub>4</sub> anahtarının açık devre olduğu durumda faz akımları.

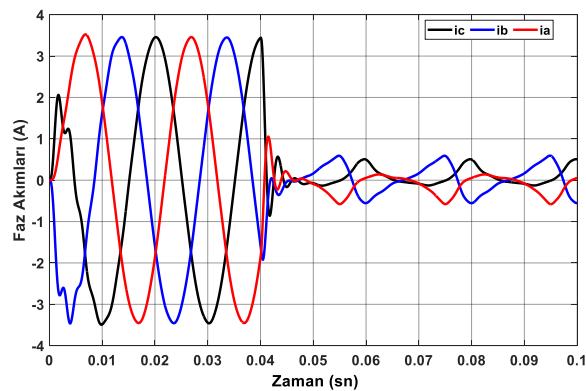
Üst kollardaki iki anahtarda açık devre arıza durumları oluştuğunda (örneğin S<sub>3</sub> ve S<sub>5</sub>) her iki anahtardan da akım akımayacaktır, b ile c-fazlarındaki akımların ortalama değerleri Şekil 5'te gösterildiği gibi negatif bileşenlere sahip olacaktır. Arızalı anahtarlar alt kollarda ise (örneğin S<sub>6</sub> ve S<sub>2</sub>) durum tersine döner, anahtarların bulunduğu b ile c-fazlarındaki akımların ortalama değeri Şekil 6'da gösterildiği gibi pozitif olmaktadır. Ayrıca, Şekil 7'de gösterildiği gibi arızalı anahtarların biri alt diğerini üst kolda ise (örneğin S<sub>1</sub> ve S<sub>2</sub>) bu anahtarlardan akım akımayacak ve a ile c-fazlarında pozitif ve negatif akımlar oluşacaktır.



Şekil 5. S<sub>3</sub>-S<sub>5</sub> anahtarlarının açık devre olduğu durumda faz akımları.

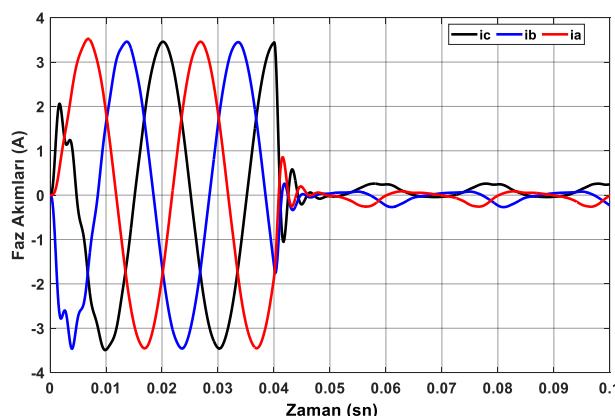


Şekil 6. S<sub>6</sub>-S<sub>2</sub> anahtarlarının açık devre olduğu durumda faz akımları.



Şekil 7. S<sub>1</sub>-S<sub>2</sub> anahtarlarının açık devre olduğu durumda faz akımları.

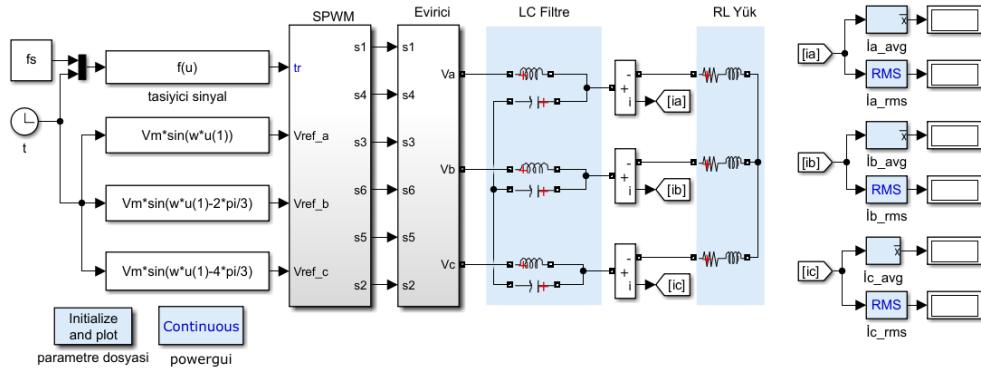
Evirici devresindeki üç adet anahtarda açık devre arızası oluştugunda üç-fazlı akım dalga formları arızanın bulunduğu kola göre pozitif veya negatif yarı döngülere sahip olmaktadır. Örneğin S<sub>1</sub>, S<sub>2</sub> ve S<sub>3</sub> anahtarlarında oluşan açık devre arızası durumunda, a ile b-faz akımı negatif, c-faz akımı ise pozitif değerlerde olacağı Şekil 8'de görülmektedir.



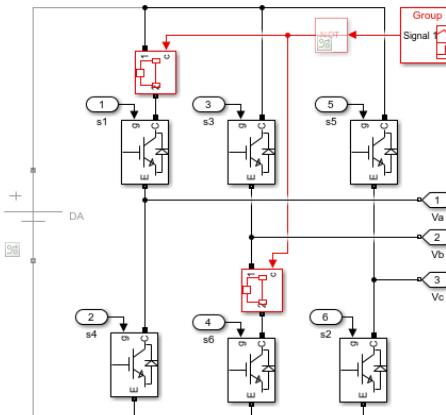
Şekil 8. S<sub>1</sub>-S<sub>2</sub>-S<sub>3</sub> anahtarlarının açık olduğu durumda faz akımları.

### 3. Benzetim Modeli ve Sınıflandırma Teknikleri

Bu çalışmada incelenen üç-fazlı iki-seviyeli eviricilerdeki IGBT anahtarları için açık devre arızalarının tanımlanması ve sınıflandırılması, faz akımlarının ortalama ve rms değerlerine göre gerçekleştirilmişdir. Arıza bilgilerini çıkarmak için gerekli rms ve ortalama akım değerleri sağlıklı ve arızalı durumlar için MATLAB/Simulink benzetim ortamında elde edilmiştir (Şekil 9). Bir periyot süresince her bir faz için ortalama ve rms akımlar Denklem 1 ve 2 kullanılarak hesaplanmıştır.



(a) SPWM tekniği ile denetlenen evirici sistemi



(b) Evirici devresindeki  $S_1$  ve  $S_6$  anahtarları için arıza durumu oluşturma

Şekil 9. MATLAB/Simulink benzetim ortamı.

$$i_{rms} = \sqrt{\frac{1}{T} \int_0^T i^2(t) dt} \quad (1)$$

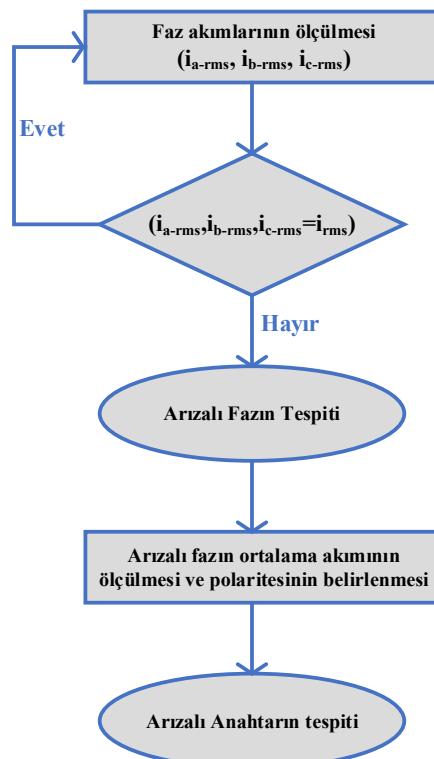
$$i_{ort} = \frac{1}{T} \int_0^T i(t) dt \quad (2)$$

Faz akımlarının her bir arızalı durum için elde edilen rms değerleri ile arızasız durumda rms değerleri karşılaştırılarak arızanın bulunduğu kol tespit edilebilmektedir. Ancak belirlenen kol üzerindeki hangi anahtarda arızanın olduğu rms değerleri kullanılarak belirlenmemektedir. Bu soruna çözüm olarak arızalı faz akımının ortalama değeri kullanılarak kol üzerindeki arızalı anahtarın tespiti sağlanabilmektedir. Ortalama ve rms değerlerinin ayrı ayrı etkinliği bulunmasına rağmen tek başına yeterli değillerdir [4,39]. Araştırmacılar yük bağımlılığı problemini çözmek için ortalama akımın normalleştirildiği vektör yaklaşımını önermektedirler [24,27,40]. Bu normalleştirme tekniğinin sadece tekli ve ikili anahtar arızalarını tanımlayabilmesi ve düşük akım değerlerinde etkili olmaması gibi dezavantajları vardır. Bu çalışmada, literatür [12]'de detaylandırılan ortalama akım değerinin rms akıma oranını kullanan normalleştirme yöntemi ile yük bağımlılığı, üçlü arızalı anahtar

tanımlaması ve düşük akım değerlerindeki sınırlamalar giderilmiştir. Anahtarlar arıza olmadığında veya bir başka deyişle sağlıklı durumda ortalama akım değeri sıfırdır. Tablo 2'de sağlıklı durum ve farklı açık anahtar devre arızalarında, iki farklı yük durumu için faz akımlarının ortalama ve rms değerleri değişirken, ortalama/rms oranının sabit kaldığı gösterilmiştir. Mevcut çalışmalardan farklı olarak bu çalışmada rms ve ortalama akım değerleri yanın da ortalama/rms oranının da arıza tanımlamaları için birer ayrı değişken olarak kullanılmıştır. Şekil 10'da ise arızalı fazın ve anahtarının tespit edilmesinde izlenen adımlar gösterilmiştir.

**Tablo 2.** Farklı yük durumları için faz akımlarının ortalama, rms değerleri ile ortalama/rms oranları.

		Yük-1			Yük-2		
Arıza Türü		ort. akım	rms akım	ort./rms oranı	ort. akım	rms akım	ort./rms oranı
Arızasız durum	a fazı	-0,000681	2,438	-0,000279	-0,000258	0,703	-0,000367
	b fazı	0,002431	2,438	0,000997	0,007290	0,703	0,001037
	c fazı	-0,001750	2,437	-0,000718	-0,000471	0,7025	-0,000671
S <sub>1</sub>	a fazı	-0,107	0,228	-0,471	-0,079	0,168	-0,472
	b fazı	0,056	2,153	0,026	0,040	0,610	0,066
	c fazı	0,052	2,075	0,025	0,039	0,619	0,063
S <sub>1</sub> -S <sub>2</sub>	a fazı	-0,106	0,243	-0,434	-0,077	0,166	-0,461
	b fazı	0,021	0,340	0,062	0,007	0,231	0,031
	c fazı	0,084	0,211	0,401	0,069	0,160	0,433
S <sub>1</sub> -S <sub>2</sub> -S <sub>3</sub>	a fazı	-0,043	0,119	-0,365	-0,036	0,098	-0,370
	b fazı	-0,044	0,119	-0,366	-0,036	0,098	-0,367
	c fazı	0,087	0,142	0,612	0,072	0,119	0,611



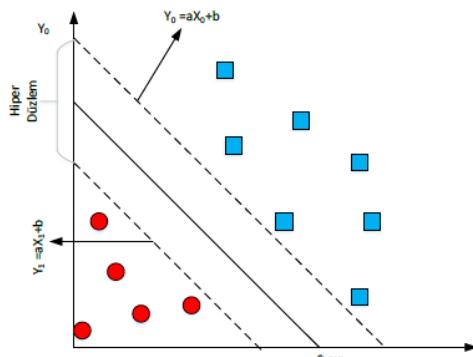
**Şekil 10.** Arıza tespiti için akış şeması.

Arızalı anahtarların tespit edilmesi ve konumlandırılması amaçlanan bu çalışmada dört farklı sınıflandırma algoritması kullanılmıştır. Sınıflandırıcıların başarıları değerlendirilirken doğruluk ve verimlilik göz önünde

bulundurulmaktadır. Sınıflandırıcının doğruluğunu veri kümesinin parametreleri ve verilerin dengeli dağılımı belirlemektedir. Aşırı uyumdan korunmak ve başarılı bir sınıflandırma için veri setine çapraz doğrulanma uygulanmıştır. Çapraz doğrulama tekniği ile veri seti eğitim ve test verilerine bölünerek, model eğitilmediği veriler üzerinde test edilmiştir. Böylelikle modelin performansının daha sağlamlaştırılmıştır.

### 3.1. Destek vektör makineleri (SVM)

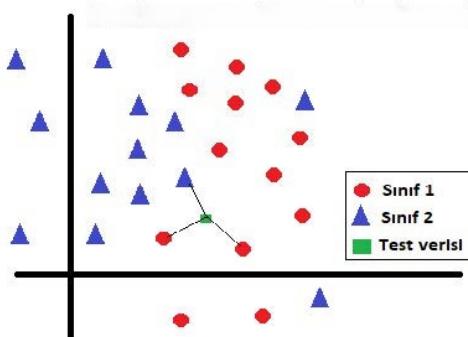
Destek vektör makineleri, Vapnik ve ekibi tarafından geliştirilen sınıflandırma ve regresyon problemlerinde kullanılan denetimli bir makine öğrenmesi algoritmasıdır [41]. Bu algoritmanın temel amacı, veri noktalarını çok boyutlu uzaya yansıtarak optimal bir hiperdüzlem bularak sınıflandırmaktır. Şekil 11'de gösterildiği üzere SVM, veri sınıfları arasında maksimum mesafe sahip hiperdüzlemi belirlemeye dayanmaktadır. Karar düzlemi olarak da adlandırılan hiperdüzlem, bir sınıfın verileri diğer sınıflardaki verilerden ayıran düzlemdir. Hem doğrusal hem de doğrusal olmayan veri kümelerini sınıflandıabilen matematiksel öğrenme şemasıdır [42]. Küçük ve orta boyutlu veri kümeleri için basit ve başarılı bir sınıflandırma tekniğidir.



Şekil 11. SVM modeli [43].

### 3.2. K-en yakın komşular (KNN)

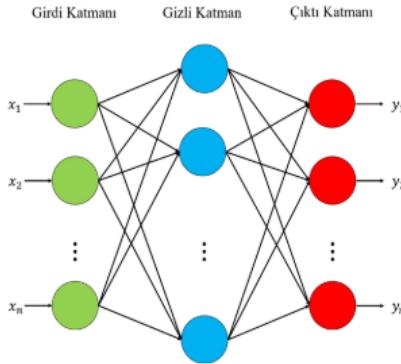
K-en yakın komşular, eğitim veri sınıflarının yakınlıklarını analiz ederek minimum mesafelere göre k değeri (benzerliği) ile gruplandıran parametrik olmayan bir sınıflandırma modelidir [44]. Sınıflandırma algoritması tasarlanırken yalnızca bir mesafe fonksiyonu ve sınıflandırma kuralı oluşturulması gereklidir [45]. Model eğitimi ve test verisi tahmini olmak üzere iki aşamadan oluşmaktadır. Eğitim aşamasında, genellikle çapraz uygulama kullanılarak en uygun k değerini bulmaya çalışılır. Tahmin aşamasında, k komşu arasında en sık bulunan test verisi sınıfına dayanarak tahminde bulunulur [46]. Şekil 12'de KNN modeli gösterilmiştir. KNN sınıflandırıcının, bir test örneğinin sınıfını tahmin ederken k komşu parametresini bulmak için tüm eğitim veri kümесini hafızada tutması gerekmektedir [47].



Şekil 12. KNN modeli [48].

### 3.3. Yapay sinir ağı (ANN)

Yapay sinir ağları kendi kendine öğrenme, bilgiler arasında ilişki kurma, analiz etme ve karar verme gibi işlevleri gerçekleştiren nöronlardan oluşan derin öğrenme algoritmalarıdır [49]. Herhangi bir ön bilgi olmadan girişler ile çıkışlar arasındaki doğrusal olmayan karmaşık ilişkileri tanımlayabilen, eksik bilgilerle de tahminde bulunabilinen modellerdir [50]. Temel olarak bir dizi giriş katmanı, gizli katman ve çıkış katmanından oluşan yapay sinir ağı modeli Şekil 13'te gösterilmiştir.

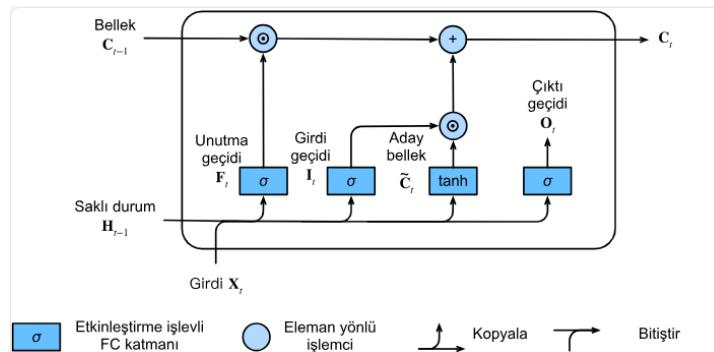


**Şekil 13.** ANN modeli [51].

Her katman bir önceki katmana bağlıdır ve önceki katmandan aldığı bilgileri alarak analiz etmektedir [52]. Gizli katman sayısı ve katmandaki nöron sayısı probleme göre belirlenmektedir. Tek bir gizli katmana sahip olanlar sığ ANN, birden fazla gizli katmana sahip olanlar ise derin öğrenme ANN'leri olarak adlandırılır. Daha fazla nöron ve katman eklenerek, ANN'lerin öğrenme yetenekleri genişletilebilmektedir [53]. Topolojisi iyi ayarlanan bir sinir ağı karmaşık ve yüksek boyutlu veri kümeleri için başarılı bir sınıflandırma sağlayabilmektedir.

### 3.4. Uzun kısa süreli bellek (LSTM)

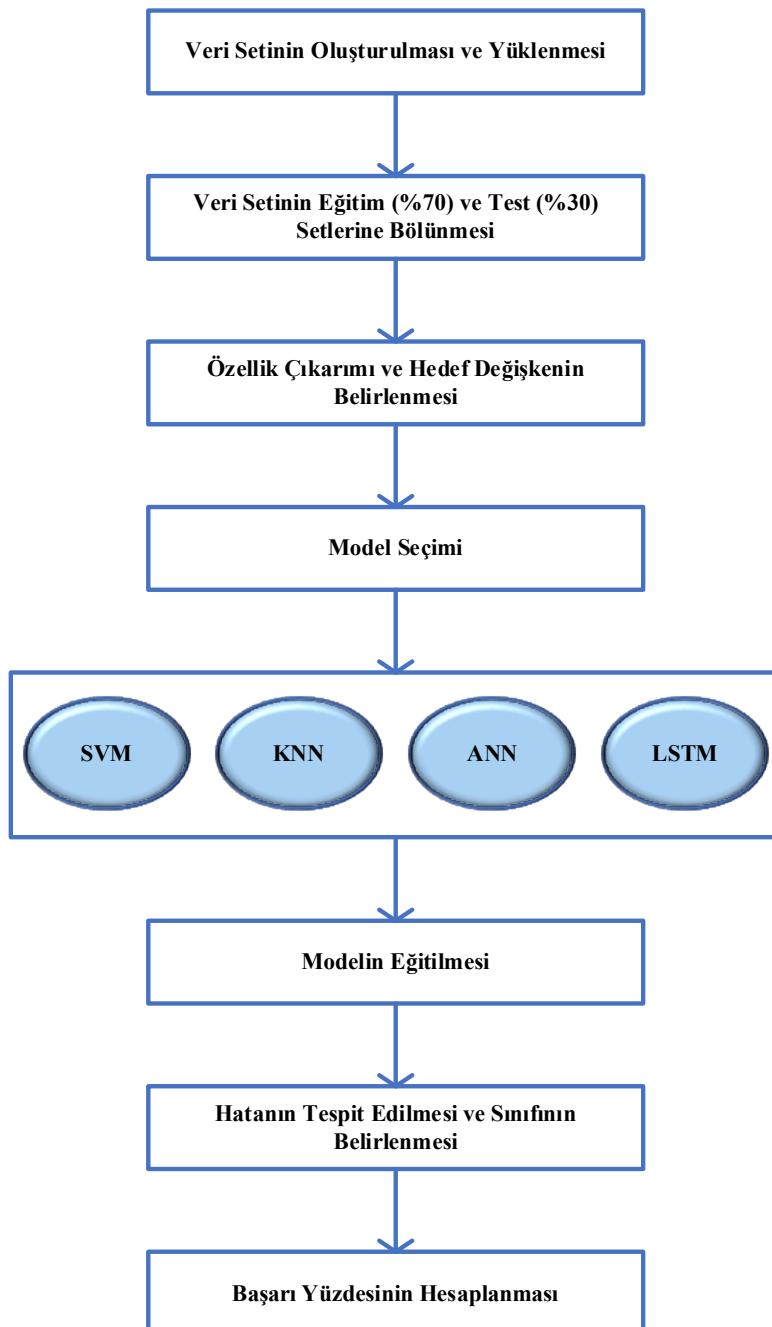
LSTM sınıflandırıcısı uzun süre bilgileri tutma ve kısa zamanlı girdileri atlama sorunlarını çözmeye çalışan geliştirilmiş yinelemeli sinir ağı (RNN-Recurrent Neural Network) mimarisidir [54-55]. LSTM ağları, diğer ağ birimlerinin yerine veya bunlarla birlikte ana yapı taşıları olarak LSTM birimlerini kullanmaktadır. LSTM ağlarının en önemli özelliği, herhangi bir aktivasyon işlemi içermeyen tekrarlayan bileşenleri kullanmasıdır [56]. Şekil 14'te gösterildiği üzere LSTM modeli; öneksiz bilgileri tutmayan, önemli olanları bir sonraki katmana aktarmayı sağlayan giriş, unutma ve çıkış olmak üzere üç kapıdan, gizli durumu ve bellek hücresini içeren gizli katmandan oluşmaktadır.



**Şekil 14.** LSTM modeli [57]

Çalışmada kullanılan tüm sınıflandırma algoritmaları için aynı arıza etiketleri kullanılmıştır (Tablo 3). Her bir arıza türü için faz akımlarının rms, ortalama ve ortalama/rms oranları kaydedilmiştir. Böylelikle her bir faz için

üç ayrı özellik kullanılmıştır. Her bir etiket için 100 periyotluk değerler alınarak sınıflandırıcı modelleri için veri kümesi oluşturulmuştur. Çapraz doğrulama uygulanmış, [44,58] referanslar doğrultusunda veri kümesinin %70'i eğitim, %30'u ise test için ayrılmıştır. Toplam 2500 periyot için elde edilen veri setinin 1750'si modelleri eğitmek ve 750'si test etmek için kullanılmıştır. Denetimli eğitim veri seti kullanılarak SVM ve KNN makine öğrenmesi modelleri ile ANN ve LSTM derin öğrenme sınıflandırıcıları eğitilerek analizler yapılmıştır. Şekil 15'te seçilen modellerin eğitim adımları gösterilmiştir.



**Şekil 15.** Sınıflandırıcı modellerinin akış şeması.

Sınıflandırıcıların performanslarını karşılaştırmak için doğruluk metriği ve karışıklık matrisi kullanılmıştır. Doğruluk, doğru sınıflandırılmış verilerin tüm verilere oranını ifade etmektedir. Karışıklık matrisi Şekil 16'da gösterildiği gibi tahmin edilen ve gerçek değerlerden oluşturulan 4 farklı kombinasyondan oluşan bir tablodur.

**Tablo 3.** Arıza türlerinin etiketleri.

Arıza türü	Arıza etiketi	Arıza türü	Arıza etiketi
Arızasız durum	0	S <sub>3</sub> -S <sub>2</sub>	13
S <sub>1</sub>	1	S <sub>5</sub> -S <sub>4</sub>	14
S <sub>3</sub>	2	S <sub>5</sub> -S <sub>6</sub>	15
S <sub>5</sub>	3	S <sub>4</sub> -S <sub>6</sub>	16
S <sub>4</sub>	4	S <sub>4</sub> -S <sub>2</sub>	17
S <sub>6</sub>	5	S <sub>2</sub> -S <sub>6</sub>	18
S <sub>2</sub>	6	S <sub>1</sub> -S <sub>2</sub> -S <sub>3</sub>	19
S <sub>1</sub> -S <sub>3</sub>	7	S <sub>1</sub> -S <sub>6</sub> -S <sub>5</sub>	20
S <sub>1</sub> -S <sub>5</sub>	8	S <sub>1</sub> -S <sub>6</sub> -S <sub>2</sub>	21
S <sub>1</sub> -S <sub>6</sub>	9	S <sub>3</sub> -S <sub>4</sub> -S <sub>2</sub>	22
S <sub>1</sub> -S <sub>2</sub>	10	S <sub>5</sub> -S <sub>4</sub> -S <sub>6</sub>	23
S <sub>3</sub> -S <sub>5</sub>	11	S <sub>4</sub> -S <sub>3</sub> -S <sub>5</sub>	24
S <sub>3</sub> -S <sub>4</sub>	12		

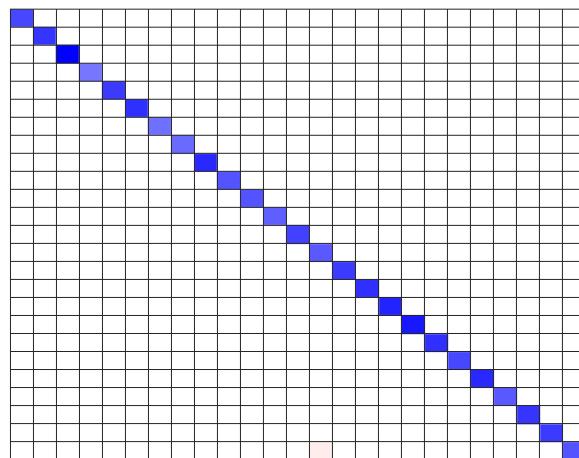
		Gerçek Sınıf	
		Pozitif	Negatif
Tahmin Sınıfı	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

**Şekil 16.** Karışıklık matrisi.

Doğu Pozitif (TP-True Positive) gerçekte doğru olan veriyi doğru tahmin etmeyi, Doğru Negatif (TN-True Negative) gerçekte doğru olmayan veriyi doğru tahmin etmemeyi, Yanlış Pozitif (FP-False Positive) gerçekte doğru olmayan veriyi doğru tahmin etmeyi, Yanlış Negatif (FN-False Negative) ise gerçekte doğru olan veriyi doğru tahmin etmemeyi ifade etmektedir [59]. Sınıflandırıcıların başarıları Doğru Pozitif Oranı (TPR-True Positive Rate) ve Yanlış Negatif Oranı (FNR-False Negative Rate) kullanılarak değerlendirilmiştir. Karışıklık matrislerinde en yüksek FNR kırmızı renkle gösterilirken en yüksek TPR mavi renk ile gösterilmiştir. FNR'lerin varlığı TPR'nin en yüksek seviyeye ulaşmadığını ve yoğunluğunun azaldığını göstermektedir.

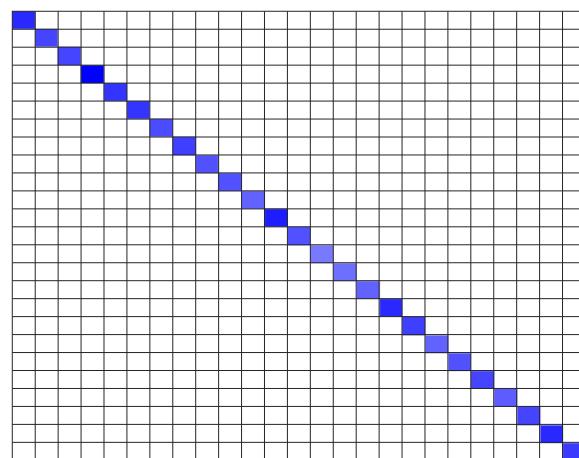
#### 4. Sonuç

Bu çalışmada üç-fazlı iki-seviyeli eviricilerde açık anahtar devre arızalarının tespit ve tanısı incelenmiştir. Bunun için eviricideki tekli ve çoklu anahtar arızalarının sınıflandırılmasında dört farklı model kullanılıp sonuçları değerlendirilmiştir. Her bir model evirici faz akımlarının ortalama, rms değerleri ile birlikte ortalama/rms oranları kullanılarak eğitilmiştir. Modellerin başarım oranlarının karşılaştırıldığı matris grafiklerinde bulunan sayılar hata türlerinden rastgele kaç tane örnek kullanıldığını ifade etmektedir. Grafiklerde bulunan renkler ise hata örneklerinin doğru tahmin edilip edilmediğini belirtmektedir. Örneğin Şekil 17'de çok sınıflı SVM kullanılan modelin karışıklık matrisi gösterilmiştir. 0'a 0 sütununda bulunan 29 sayısı, "0" etiketi için seçilen rastgele 29 örneğin 29'unu doğru sınıflandırıldığını belirtmektedir. 24'e 13 sütununda bulunan açık kırmızı renkle gösterilen 1 sayısı ise, gerçek sınıfı "24" olan bir örneği "13" olarak sınıflandırıldığını ve yanlış olduğunu ifade etmektedir. Yanlış örneklerin sayısı arttıkça açık kırmızı olan renk koyulmaktadır ve başarım oranını düşürmektedir. Matriste görüldüğü üzere SVM modeli test setinden sadece 1 verinin sınıfını yanlış tahmin ederek (gerçek sınıf etiketi 24 iken sınıfını 13 olarak tahmin etmiştir) %99,87 başarı göstermiştir.



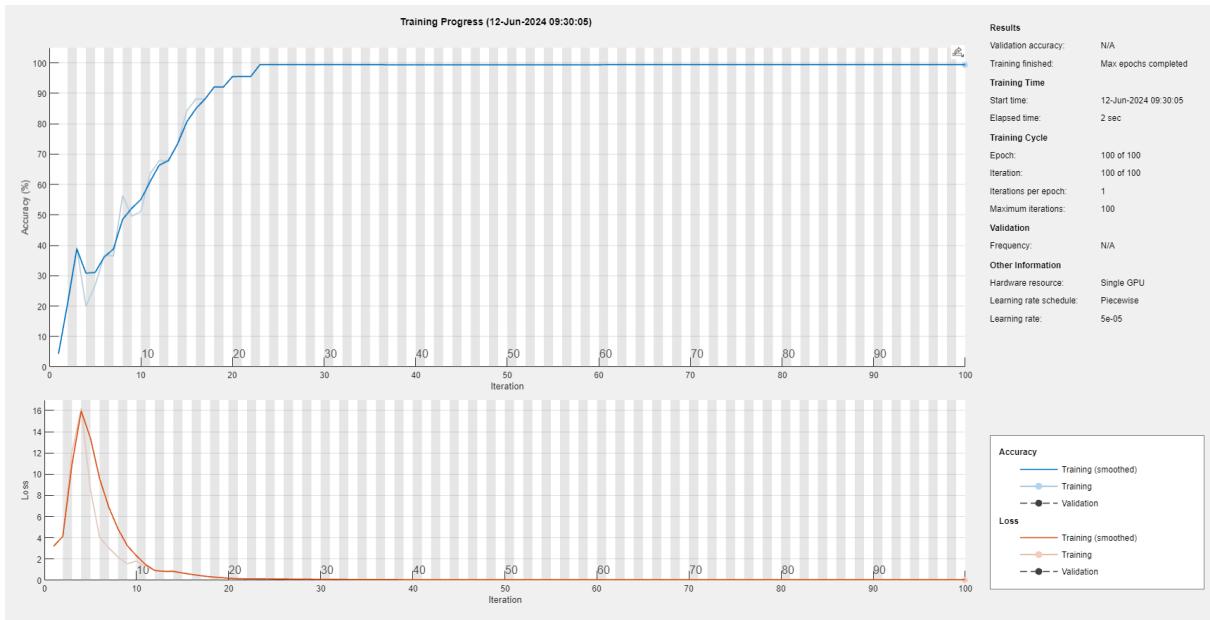
**Şekil 17.** SVM karışıklık matrisi.

Çok sınıfı KNN modeli kullanılan sınıflandırıcının karmaşıklık matrisi Şekil 18'de gösterilmiştir. Göründüğü üzere eğitilen model tüm test verilerinde %100 başarı elde ederek tüm arızaları doğru sınıflandırmıştır.

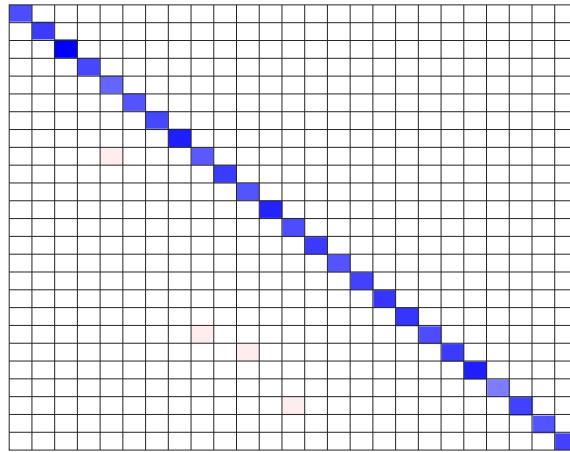


**Şekil 18.** KNN karışıklık matrisi.

Eğitim setinin ANN modeli ile eğitimi ve doğruluğu Şekil 19'da verilmiştir. Yaklaşık 750 test verisinin sadece 4 tanesinin etiketini yanlış tahmin ederek %99,47 başarı gösteren ANN modelinin karışıklık matrisi Şekil 20'de gösterilmiştir.



Şekil 19. ANN modelinin eğitimi.

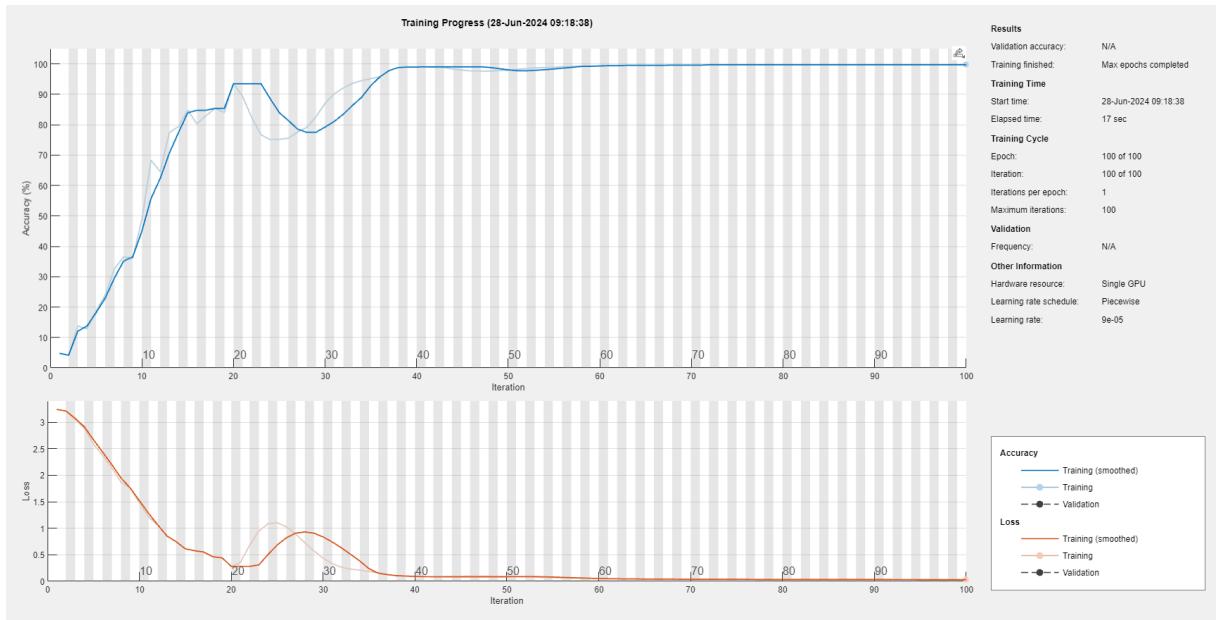


Şekil 20. ANN karışıklık matrisi.

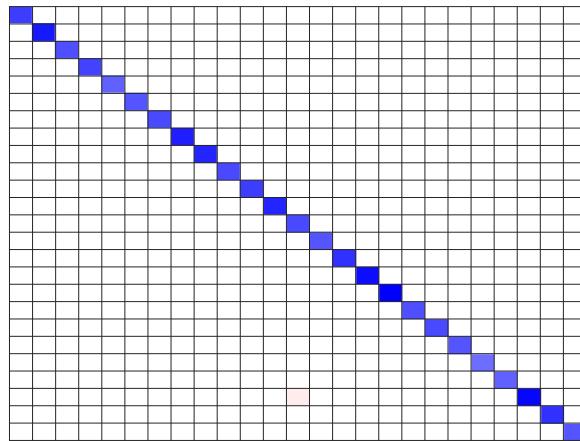
LSTM modeli kullanılan sınıflandırılmanın eğitim süreci ve doğruluğu Şekil 21'de verilmiştir. %99,87 başarı gösteren sınıflandırıcının karışıklık matrisi Şekil 22'de gösterilmiştir.

Kullanılan makine öğrenmesi ve derin öğrenme modelleri ile üç-fazlı iki-seviyeli gerilim eviricilerde oluşturulan açık anahtar arızaları başarılı bir şekilde tespit edilip, etiketlerine göre sınıflandırılmıştır. Mevcut çalışmalarla kıyasla, tekli açık anahtar arıza tespitlerinin yanı sıra çoklu açık anahtar arızaları da tespit edilebilmiştir. Tablo 4'te kullanılan dört sınıflandırma modelinin eğitim süreleri ile başarım oranları karşılaştırılmıştır. Derin öğrenme ile eğitilen modellerde LSTM sınıflandırıcının başarı oranı ANN sınıflandırıcıya göre daha yüksek ancak eğitim süresi daha uzundur. ANN sınıflandırıcının eğitimi 2 saniye sürerken, LSTM sınıflandırıcının 17 saniye sürmektedir. Makine öğrenmesi tekniklerinde ise rastgele eğitim ve test setine bölünen veri seti kullanılarak modeller eğitilmiş, KNN sınıflandırıcı ile SVM sınıflandırıcısına göre hem daha yüksek başarı hem de daha kısa eğitim süresi elde edilmiştir. Her bir model ile arızalı anahtarın tespiti ve lokalizasyonu başarılı bir şekilde sağlanmıştır. İki-seviyeli eviriciler için yapılmış bu çalışmanın çok seviyeli eviriciler için de geliştirilmesi, çok seviyeli eviricilerde anahtar sayısının çokluğundan kaynaklanan arıza tespitinin zorluğunun iyileştirilmesi amaçlanmaktadır.

## Gerilim Kaynaklı Eviricinin Faz Akımlarının İzlenmesiyle Açık Devre Arızalarının Teşhisisi



**Şekil 21.** LSTM modelinin eğitimi.



**Şekil 22.** LSTM karışıklık matrisi.

**Tablo 4.** Sınıflandırma modellerinin performansları.

Sınıflandırma teknigi	Eğitim süresi (sn)	Başarı oranı (%)
SVM Sınıflandırıcı	1,42sn	%99,87
KNN Sınıflandırıcı	0,67sn	%100
ANN Sınıflandırıcı	2sn	%99,47
LSTM Sınıflandırıcı	17sn	%99,87

## Kaynaklar

- [1] Kharjule S. Voltage source inverter. In: 2015 International Conference on Energy Systems and Applications; 2015; Pune, India. pp. 537-542.
- [2] Xia Y, Xu Y. A transferrable data-driven method for IGBT open-circuit fault diagnosis in three-phase inverters. *IEEE Trans Power Electron* 2021; 36(12): 13478-13488.
- [3] Hang C, Ying L, Shu N. Transistor open-circuit fault diagnosis in two-level three-phase inverter based on similarity measurement. *Microelectron Reliab* 2018; 91: 291-297.
- [4] Ibem CN, Farrag ME, Aboushady AA, Dabour SM. Multiple open switch fault diagnosis of three phase voltage source inverter using ensemble bagged tree machine learning technique. *IEEE Access* 2023; 11: 85865-85877.
- [5] Deng X, Wan C, Jiang L, Gao G, Huang Y. Open-switch fault diagnosis of three-phase PWM converter systems for magnet power supply on EAST. *IEEE Trans Power Electron* 2023; 38(1): 1064-1078.
- [6] Prejbeanu RG. A sensor-based system for fault detection and prediction for EV multi-level converters. *Sensors* 2023; 23(9): 4205.
- [7] Achintya P, Kumar Sahu L. Open circuit switch fault detection in multilevel inverter topology using machine learning techniques. In: 2020 IEEE 9th Power India International Conference (PIICON); 2020; Sonepat, India. pp. 1-6.
- [8] Dabour SM, Masoud MI. Open-circuit fault detection of five-phase voltage source inverters. In: 2015 IEEE 8th GCC Conference & Exhibition; 2015; Muscat, Oman. pp. 1-6.
- [9] Kumar MD, Kodad SF, Sarvesh B. Simplified fault detection algorithm for voltage source fed induction motor. *Mater Today Proc* 2018; 5(1): 1401-1410.
- [10] Ibem CN, Farrag ME, Aboushady AA. Open circuit fault diagnosis technique for inverter switches and gate drive malfunction. In: 2023 58th International Universities Power Engineering Conference (UPEC); 2023; Dublin, Ireland. pp. 1-6.
- [11] Zdiri MA, Bouzidi B, Abdallah HH. Improved diagnosis method for VSI fed IM drives under open IGBT faults. In: 2018 15th International Multi-Conference on Systems, Signals & Devices (SSD); 2018; Yasmine Hammamet, Tunisia. pp. 905-910.
- [12] Gao Z, Cecati C, Ding SX. A survey of fault diagnosis and fault-tolerant techniques-Part I: Fault diagnosis with model-based and signal-based approaches. *IEEE Trans Ind Electron* 2015; 62(6): 3757-3767.
- [13] Malik A, Haque A, Kurukuru VSB, Khan MA, Blaabjerg F. Overview of fault detection approaches for grid connected photovoltaic inverters. *e-Prime-Advances in Electrical Engineering, Electronics and Energy* 2022; 2:100035.
- [14] Zhuo S, Gaillard A, Xu L, Liu C, Paire D, Gao F. An observer-based switch open-circuit fault diagnosis of DC-DC converter for fuel cell application. *IEEE Trans Ind Appl* 2020; 56(3): 3159-3167.
- [15] Wassinger N, Penovi E, Retegui RG, Maestri S. Open-circuit fault identification method for interleaved converters based on time-domain analysis of the state observer residual. *IEEE Trans Power Electron* 2019; 34(4): 3740-3749.
- [16] Berriri H, Naouar MW, Slama-Belkhodja I. Easy and fast sensor fault detection and isolation algorithm for electrical drives. *IEEE Trans Power Electron* 2012; 27(2): 490-499.
- [17] Zhou D, Yang S, Tang Y. A voltage-based open-circuit fault detection and isolation approach for modular multilevel converters with model-predictive control. *IEEE Trans Power Electron* 2018; 33(11): 9866-9874.
- [18] Xie D, Ge X. A state estimator-based approach for open-circuit fault diagnosis in single-phase cascaded H-bridge rectifiers. *IEEE Trans Ind Appl* 2019; 55(2): pp. 1608-1618.
- [19] Poon J, Jain P, Konstantakopoulos IC, Spanos C, Panda SK, Sanders SR. Model-based fault detection and identification for switching power converters. *IEEE Trans Power Electron* 2017; 32(2): 1419-1430.
- [20] Poon J, Jain P, Spanos C, Panda SK, Sanders SR. Fault prognosis for power electronics systems using adaptive parameter identification. *IEEE Trans Ind Appl* 2017; 53(3): 2862-2870.
- [21] Yan H, Peng Y, Shang W, Kong D. Open-circuit fault diagnosis in voltage source inverter for motor drive by using deep neural network. *Eng Appl Artif Intell* 2023; 120; 105866.
- [22] Shahbazi M, Poure P, Saadate S, Zolghadri MR. FPGA-based fast detection with reduced sensor count for a fault-tolerant three-phase converter. *IEEE Trans Industr Inform* 2013; 9(3): 1343-1350.
- [23] Freire NMA, Estima JO, Cardoso AJM. A voltage-based approach without extra hardware for open-circuit fault diagnosis in closed-loop PWM AC regenerative drives. *IEEE Trans Ind Electron* 2014; 61(9): 4960-4970.
- [24] Mendes AMS, Cardoso AJM. Voltage source inverter fault diagnosis in variable speed AC drives, by the average current Park's vector approach. *IEEE International Electric Machines and Drives Conference*; 1999; Seattle, WA, USA. pp.704-706.
- [25] Im WS, Kim JS, Kim JM, Lee DC, Lee KB. Diagnosis methods for IGBT open switch fault applied to 3-phase AC/DC PWM converter. *Journal of Power Electronics* 2012; 12(1):120-127.
- [26] Im WS, Kim JM, Lee DC, Lee KB. Diagnosis and fault-tolerant control of three-phase AC-DC PWM converter systems. *IEEE Trans Ind Appl* 2013; 49(4): 1539-1547.
- [27] Freire NMA, Estima JO, Cardoso AJM. Open-circuit fault diagnosis in PMSG drives for wind turbine applications. *IEEE Trans Ind Electron* 2013; 60(9): 3957-3967.
- [28] Peugot R, Courtine S, Rognon JP. Fault detection and isolation on a PWM inverter by knowledge-based model. *IEEE Trans Ind Appl* 1998; 34(6): 1318-1326.
- [29] Trabelsi M, Boussak M, Gossa M. Multiple IGBTs open circuit faults diagnosis in voltage source inverter fed induction motor using modified slope method. *The XIX International Conference on Electrical Machines - ICEM* 2010; 2010; Rome, Italy. pp. 1-6.

- [30] Shi T, He Y, Wang T, Tong J, Li B, Deng F. An improved open-switch fault diagnosis technique of a PWM voltage source rectifier based on current distortion. *IEEE Trans Power Electron* 2019; 3(12): 12212-12225.
- [31] Cai B, Zhao Y, Liu H, Xie M. A data-driven fault diagnosis methodology in three-phase inverters for PMSM drive systems. *IEEE Trans Power Electron* 2017; 32(7): 5590-5600.
- [32] Li Z, Gao Y, Zhang X, Wang B, Ma H. A model-data-hybrid-driven diagnosis method for open-switch faults in power converters. *IEEE Trans Power Electron* 2020; 36(5): 4965-4970.
- [33] Xia Y, Xu Y, Gou B. A data-driven method for IGBT open-circuit fault diagnosis based on hybrid ensemble learning and sliding-window classification. *IEEE Trans Industr Inform* 2020; 16(8): 5223-5233.
- [34] Moosavi SS, Djerdir A, Ait-Amirat Y, Khaburi DA, N'Diaye A. Artificial neural network-based fault diagnosis in the AC-DC converter of the power supply of series hybrid electric vehicle. *IET Electrical Systems in Transportation* 2016; 6(2): 96-106.
- [35] Gou B, Xu Y, Xia Y, Deng Q, Ge X. An online data-driven method for simultaneous diagnosis of IGBT and current sensor fault of three-phase PWM inverter in induction motor drives. *IEEE Trans on Power Electron* 2020; 35(12): 13281-13294.
- [36] Wang B, Cai J, Du X, Zhou L. Review of power semiconductor device reliability for power converters. *CPSS Transactions on Power Electronics and Applications* 2017; 2(2): 101-117.
- [37] Liang W, Wang J, Luk PCK, Fang W, Fei W. Analytical modeling of current harmonic components in PMSM drive with voltage-source inverter by SVPWM technique. *IEEE Transactions on Energy Conversion* 201; 29(3): 673-680.
- [38] Rocabert J, Luna A, Blaabjerg F, Rodríguez P. Control of power converters in AC microgrids. *IEEE Trans Power Electron* 2012; 27(11): 4734-4749.
- [39] Khelif AM, Bendiabellah A, Cherif BDE. A combined RMS-mean value approach for an inverter open-circuit fault detection. *Periodica Polytechnica Electrical Engineering and Computer Science* 2019; 63(3): 169-177.
- [40] Caseiro JAA, Mendes AMS, Marques Cardoso AJ. Fault diagnosis on a PWM rectifier AC drive system with fault tolerance using the average current Park's vector approach. In: 2009 IEEE International Electric Machines and Drives Conference; 2009; Maimi, FL, USA. pp. 695-701.
- [41] Harman G. Destek vektör makineleri ve naive bayes sınıflandırma algoritmalarını kullanarak diabetes mellitus tahmini. *Avrupa Bilim ve Teknoloji Dergisi* 2021; 32: 7-13.
- [42] Chandra MA, Bedi SS. Survey on SVM and their application in image classification. *Int J Inf Technol* 2021; 13(59): 1-11.
- [43] Metlek S, Kayaalp K. Derin öğrenme ve destek vektör makineleri ile görüntüden cinsiyet tahmini. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi* 2020; 8(3): 2208-2228.
- [44] Gong W, Chen H, Zhang Z, Zhang M, Gao H. A data-driven-based fault diagnosis approach for electrical power DC-DC inverter by using modified convolutional neural network with global average pooling and 2-D feature image. *IEEE Access* 2020; 8: 73677-73697.
- [45] Zhang S, Li J. KNN classification with one-step computation. *IEEE Trans Knowl Data Eng* 2021; 35(3): 2711-2723.
- [46] Zhang S. Challenges in KNN classification. *IEEE Trans Knowl Data Eng* 2022; 34(10): 4663-4675.
- [47] Zhang S. Cost-sensitive KNN classification. *Neurocomputing* 2020; 391: 234-242.
- [48] Coşar M, Deniz E. Makine öğrenimi algoritmaları kullanarak kalp hastalıklarının tespit edilmesi. *Avrupa Bilim ve Teknoloji Dergisi* 2021; 28: 1112-1116.
- [49] Pham BT, Nguyen MD, Nguyen-Thoi T, Ho LS, Koopalipoor M, Quoc NK, Armaghani DJ, Van Le H. A novel approach for classification of soils based on laboratory tests using adaboost, tree and ANN modeling. *Transportation Geotechnics* 2021; 27: 100508.
- [50] Bhagya Raj GVS, Dash KK. Comprehensive study on applications of artificial neural network in food process modeling. *Crit Rev Food Sci Nutr* 2022; 62(10): 2756-2783.
- [51] Konakoğlu B. Çok katmanlı algılayıcı yapay sinir ağı ile jeodezik elipsoidal koordinatların ( $\varphi$ ,  $\lambda$ ,  $h$ ) 3 boyutlu global kartezyen koordinatlara ( $x$ ,  $y$ ,  $z$ ) dönüşümü. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi* 2020; 10(3): 702-710.
- [52] Kuşkapan E, Çodur MK, Çodur MY. Türkiye'deki demiryolu enerji tüketiminin yapay sinir ağları ile tahmin edilmesi. *Konya Mühendislik Bilimleri Dergisi* 2022; 10(1): 72-84.
- [53] Guillod T, Papamanolis P, Kolar JW. Artificial neural network (ANN) based fast and accurate inductor modeling and design. *IEEE Open J Power Electron* 2020; 1: 284-299.
- [54] Rajendran GB, Kumarasamy UM, Zarro C, Divakarachari PB, Ullo SL. Land-use and land-cover classification using a human group-based particle swarm optimization algorithm with an LSTM classifier on hybrid pre-processing remote-sensing images. *Remote Sens* 2020; 12(24): 4135.
- [55] Kłosowski G, Rymarczyk T, Niderla K, Rzemieniak M, Dmowski A, Maj M. Comparison of machine learning methods for image reconstruction using the LSTM classifier in industrial electrical tomography. *Energies* 2021; 14(21): 7269.
- [56] Gür YE. Stock price forecasting using machine learning and deep learning algorithms: A case study for the aviation industry. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 2024; 36(1): 25-34.
- [57] Aslan E. LSTM-ESA hibrit modeli ile MR görüntülerinden beyin tümörünün sınıflandırılması. *Adiyaman Üniversitesi Mühendislik Bilimleri Dergisi* 2024; 11(22): 63-81.
- [58] Bouchiba N, Kaddouri A. Application of machine learning algorithms for power systems fault detection. In: 2021 9th International Conference on Systems and Control (ICSC); 2021; Caen, France. pp. 127-132.
- [59] Sağıroğlu S, Arslan Tuncer S, Karahan B, Özercan İH. Evrişimsel sinir ağları kullanarak ÇKA sınıflandırıcısı ile mide displazisinin tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 2024; 36(1): 291-300.

## SARS CoV-2 (COVID-19) ve Biyolojik Etkileri

Nuray TEMİZKAN<sup>1</sup>, Özlem GÖK<sup>2</sup>, Abdullah ASLAN<sup>3\*</sup>

<sup>1,2,3</sup> Biyoloji-Moleküler Biyoloji ve Genetik Bölümü, Fen Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

<sup>1</sup> temizkanuray@gmail.com, <sup>2</sup> ogok@firat.edu.tr, <sup>3\*</sup> aaslan@firat.edu.tr

(Geliş/Received: 07/09/2024;

Kabul/Accepted: 27/09/2024)

**Öz:** Koronavirüs hastalığı 2019 (COVID-19)'un etkeni olan Ağır Akut Solunum Sendromu Koronavirüs-2 (SARS CoV-2), dünyanın mücadele ettiği bir salgına neden olmuş ve küresel çapta bir pandemiyi başlatmıştır. Salgın başlangıcı olan 2019'dan beri Türkiye de dahil birçok ülke COVID-19'dan korunmak için çeşitli aşılar ve tedavi yöntemleri geliştirmiştir. Pandemi boyunca yapılan tüm çalışmalar SARS CoV-2 enfeksiyonuna karşı vücuttan bağışıklık sistemini aktifleştirmeyi ve salgını kontrol altına almayı amaçlamıştır. Aşıların hedefi SARS CoV-2'nin yapısal proteinlerine spesifik antikor hafızası oluşturmaktır. Ayrıca tedavi teknikleri de vücutta bu virüse karşı gelişen aşırı bağışıklık sonucu salınan sitokin fırtınası gibi doku hasarı meydana getiren ürünlerin birikimine engel olmayı sağlamaktadır.

**Anahtar kelimeler:** Aşı, COVID-19, pandemi, SARS CoV-2, spike proteinı.

## SARS CoV-2 (COVID-19) and Its Biological Effects

**Abstract:** Severe Acute Respiratory Syndrome Coronavirus-2 (SARS CoV-2), the causative agent of coronavirus disease 2019 (COVID-19), has caused an epidemic that the world is struggling with and has initiated a global pandemic. Since the beginning of the epidemic in 2019, many countries, including Turkey, have developed various vaccines and treatment methods to protect against COVID-19 disease. All studies during the pandemic aimed to activate the body's immune system against SARS CoV-2 infection and to control the epidemic. The goal of vaccines is to create antibody memory specific to the structural proteins of SARS CoV-2. In addition, treatment techniques prevent the accumulation of products that cause tissue damage, such as cytokine storm, which is released as a result of excessive immunity against this virus in the body.

**Key words:** COVID-19, pandemic, SARS CoV-2, spike protein, vaccine.

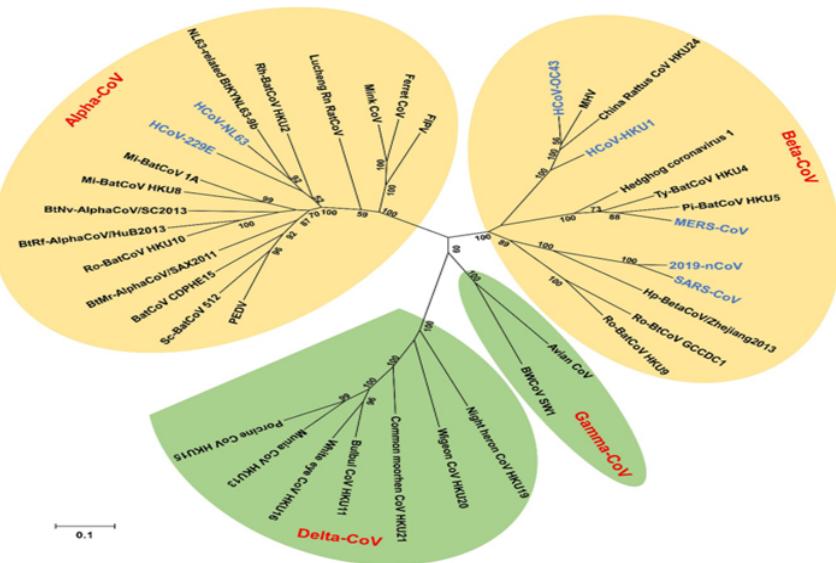
### 1. Giriş

Tarihte ilk insan Korona Virüsü (hCoV) 1966 yılında keşfedildiğinde genel olarak soğuk algınlığına sebep olduğu sanılıyorken son 22 yılda ölümcül olan üç yeni koronavirüs saptanmıştır. Bu virüsler ortaya çıkış sırasıyla; Ağır Akut Solunum Sendromu (SARS CoV), Ortadoğu Solunum Sendromu (MERS CoV) ve SARS CoV-2 (COVID-19)'dır [1]. Yapısal olarak koronavirüslerin 1968 yılında elektron mikroskopu altında incelenmesi sonucu taç benzeri yüzeysel proteinlere sahip olduğu ve bu nedenle taç anlamına gelen korona terimi kullanıldığı bildirilmiştir. Yakın tarihte tüm dünyaya korku salan COVID-19 (Koronavirüs 2019) hastalığı, 2019'da Çin'de ortaya çıkmış ve hızla yayılım göstermiştir. Bu salgına sebebiyet veren virüs, Ağır Akut Solunum Sendromu Koronavirüs-2 (SARS CoV-2)'dir. Türkiye de dahil olmak üzere Dünya'nın ileri gelen birçok ülkesi bu virüsle mücadele etmek amacıyla aşı geliştirme ve klinik tedavi yollarına başvurarak bilimsel çalışmalar başlatmıştır. Özellikle bu virüsün genetik yapısı araştırılmış, kendisine spesifik tekniklerle aşılar geliştirerek insan vücudunun güçlü bir bağışıklık yanıyla kendini koruması ve salgının kontrol altına alınması amaçlanmıştır [2].

### 2. Koronavirüslere Genel Bakış

Koronavirüsler, Coronaviridae familyasının Orthocoronavirinae alt ailesine ait virüslerdir [3]. Orthocoronavirinae alt ailesi; *Alphacoronavirus* ( $\alpha$ CoV), *Betacoronavirus* ( $\beta$ CoV), *Gammacoronavirus* ( $\gamma$ CoV) ve *Deltacoronavirus* ( $\delta$ CoV) olmak üzere dört cins virüs içermektedir (Şekil 1) [2].

\* Sorumlu yazar: aaslan@firat.edu.tr. Yazarların ORCID Numarası: <sup>1</sup> 0000-9691-7232, <sup>2</sup> 0000-0001-8521-6369, <sup>3</sup> 0000-0002-6243-4221



**Şekil 1.** Koronavirüslerin filogenetik sınıflandırılması [4].

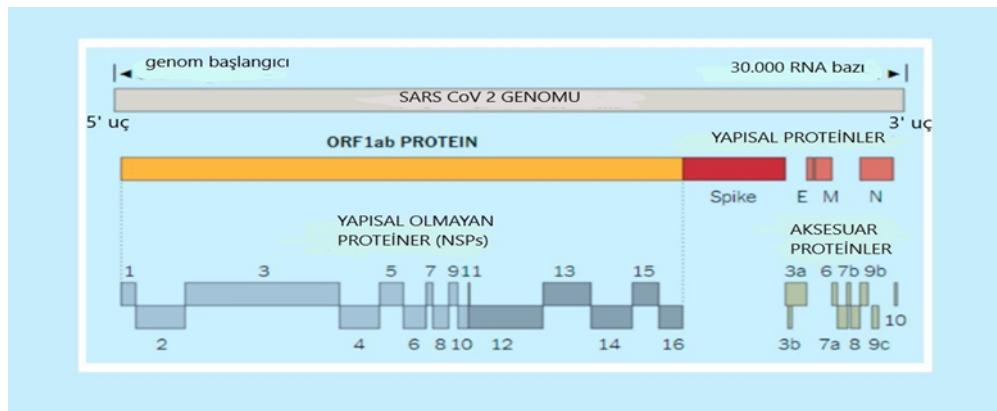
Karşı karşıya kaldığımız üç yeni korona virüsün ilki olan SARS virüsü 2002 yılında Uzak Doğu Asya'da ortaya çıkmış olup, yarasalarlardan orijin aldığı düşünülmektedir. Genel olarak diğer nezle virüsleri gibi SARS CoV'da dayanıklı ve oldukça bulaşıcı bir RNA virüsüdür [5]. Bir diğer salgın sebebi olan koronavirüs MERS ise 20 Eylül 2012 yılında Suudi Arabistan'da saptanıp 26 ülkeye yayılmıştır. İlk olarak develerde ortaya çıktıgı bilinmektedir [2]. Tüm dünyayı etkisi altına alan son koronavirüs ise SARS CoV-2'dir. Çin Halk Cumhuriyeti'nin Wuhan Eyaletinde 2019'da ortaya çıkmıştır. Virüsün ilk başlarda Dünya Sağlık Örgütü (DSÖ) tarafından "2019 yeni Koronavirüs" (2019-nCoV) ismi verilmiştir [2]. Fakat bu virüsün SARS CoV-1 ve MERS CoV ile genetik olarak benzerlik gösterdiği anlaşıldıktan sonra Uluslararası VIRüs Taksonomisi Komitesi bu virüse SARS-CoV-2 (Ağır Akut Solunum Sendromu Koronavirüs-2) adını vermiştir. Virüsün sebep olduğu hastalığa ise "Koronavirüs Hastalığı -2019" (COVID-19) ismi verilmiştir. Hızla yayılan virüs nedeniyle 11 Mart 2020'de DSÖ tarafından "pandemi" ilan edilerek tüm dünyada bu virüsle mücadele amacıyla tanı, teşhis ve aşı çalışmaları hızlandırılmıştır [2, 6].

### **3. SARS CoV-2'nin Yapısal Özellikleri**

SARS-COV-2'nin transmisyon elektron mikroskopu ile incelendiğinde, 60 ila 140 nm aralığında bir çapa sahip olduğu ve morfolojisinin Coronaviridae ailesinin diğer üyelerinkile uyumlu olduğu görülmüştür [6]. SARS-COV-2, helikal simetriselli kapsid yapıda ve tek sarmallı pozitif polariteye sahip RNA genomu içeren zarflı bir virüstür [2].

### **3.1. SARS CoV-2'nin genomu**

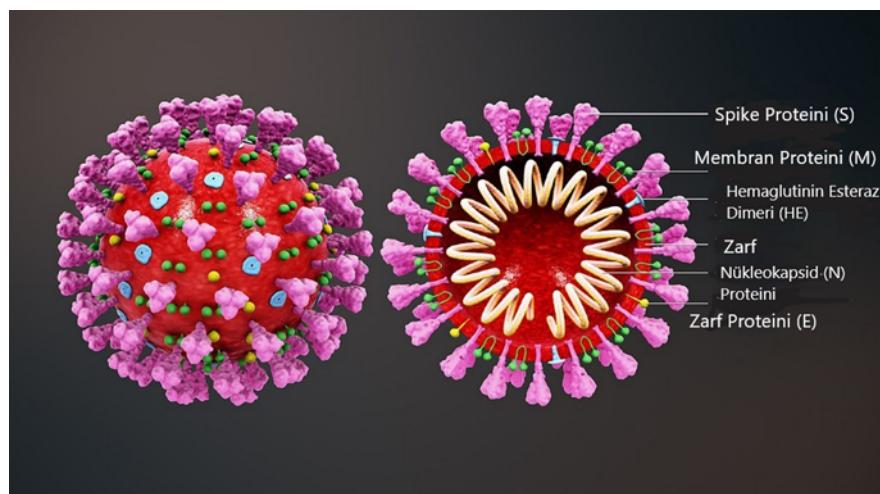
SARS-CoV-2,  $\beta$ -koronavirüslerin genel genom organizasyonuna sahiptir [7]. Bu virüs, 26 ila 35 kb civarında tek sarmallı pozitif bir RNA genomuna sahiptir ve yaklaşık 27 proteini kodladığı bilinmektedir [6]. Genomu, her iki uçta iki kodlanmayan bölge, yapısal proteinleri, yapısal olmayan proteinleri (NSP = Non structurel proteins) ve yardımcı proteinleri kodlayan çoklu bölgeler olmak üzere toplam 14 fonksiyonel açık okuma çerçevesinden (ORF) olusmaktadır (Şekil 2) [6].



Şekil 2. SARS CoV-2 genom yapısı ve proteinlere özgü bölgelerinin gösterimi [8].

### 3.2. SARS CoV-2'nin protein yapısı

Virüs fiziksel olarak incelendiğinde, nükleokapsid proteini ile genomik RNA'nın birleşmesine ek olarak bu yapının viral zarf蛋白 ile çevrilmesi sonucunda helikal simetrik nükleokapsid yapısı oluşmaktadır [9]. Yardımcı proteinler dokuz tanedir ve enfekte olan konakçada seçici bir avantaj sağlamamaktadır [7]. SARS CoV-2 proteinleri; Yapısal proteinler ve Yapısal olmayan protein (NSP)'ler şeklinde sınıflandırılır. Yapısal proteinler; Zarf proteinleri (Spike, Zarf, Membran, Hemagglutinin Esteraz), Kapsid Proteinini ve Aksesuar protein (ORF)'leri içerir (Şekil 3) [9].

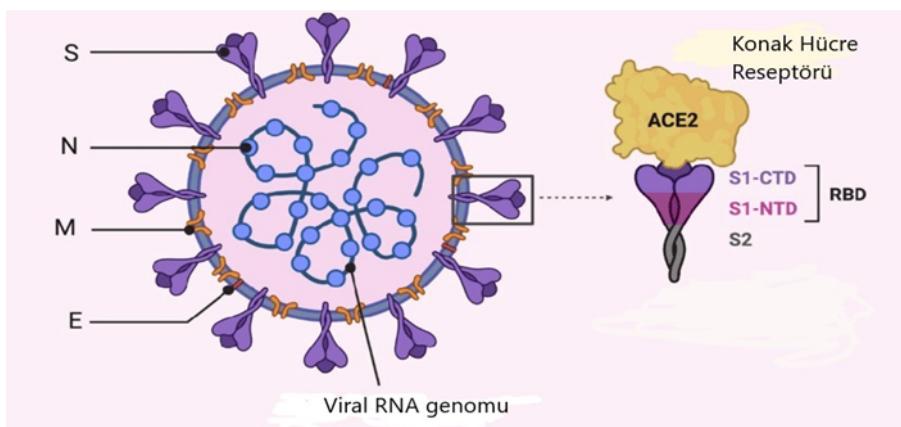


Şekil 3. SARS CoV'nin genel yapısı [5].

#### 3.2.1. Yapısal proteinler

##### 3.2.1.1. S proteinı (Spike)

S proteinı (Spike), virüsün konakçı hücrenin yüzeyinde bulunan reseptörlere bağlanmasıını sağlar ve hücrenin zarı ile virüs arasında gerçekleşecek füzyonu teşvik eder [7]. S proteinı iki fonksiyonel alt birimden oluşmaktadır; bir tarafı N-terminal (S1), bir tarafı ise C-terminal (S2) [10]. S1 alt birimi konak hücre reseptörüne bağlanır ve viral membranın konak hücre membranına füzyonunu başlatır [11]. Hücre yüzeyinde spike denilen çıkışlı yapıları S proteinlerinin homotrimlerini oluşturur ve koronavirüse adını veren de bu taç görünümü protein yapılarıdır (Şekil 4) [2].



**Şekil 4.** SARS CoV-2'nin S proteini yapısı [12].

### 3.2.1.2. E proteini (Zarf Proteini)

Virüsün konak hücreyle birleşmesi, salınması ve viral patogenezinde rol almaktadır. E proteini yağlı balonculklara benzeyen iyon kanallarının oluşumunda da görevlidir [2]. E proteini bir transmembran protein olarak N-terminal ektodomain ve C-terminal endodomaine sahiptir [9].

### 3.2.1.3. M proteini

Üç tane transmembran bölgesi vardır. Bu proteinin virionları şekillendirme, membran kavisini artırma ve nükleokapsite bağlanarak virüs oluşum ve salınımında etken rol oynamak gibi işlevleri mevcuttur [13].

### 3.2.1.4. Hemaglutinin esteraz protein (HE)

Virüsün sialik asit içeren reseptörlerle tutunmasını sağlayan ve virüs zarfı üzerinde yer alan bir proteindir [2].

### 3.2.1.5. N proteini

SARS-CoV-2'nin RNA genomuna bağlı halde konumlanan, onu koruyan ve genomun yapısını şekillendirerek viral RNA'yı stabil tutan bir nükleokapsid proteinidir [2]. Yani RNA'ya bağlanmasıyla virüsün replikasyonunda ve konak hücrenin viral enfeksiyonlara karşı oluşturduğu hücresel tepkilerde etkilidir [14]. Koronavirüslerin N proteinin üç adet ileri düzeyde korunan bölge içermektedir. Bunlar; N-terminal RNA bağlanması domaini (NTD), C-terminal dimerizasyon domaini (CTD) ve merkezi Ser-Arg'dan zengin linkler bölgeleridir [2].

### 3.2.1.6. Aksesuar proteinler (ORF)

Geneli protein işleme, viral RNA replikasyonu ve mRNA sentezi gibi önemli olaylarda görev almaktadır [6]. Ayrıca virüsün enfekte ettiği canlinin bağışıklık sisteminden kaçmasına katkıda bulunurlar [7].

## 3.2.2. Yapısal olmayan proteinler

Bu proteinler, Nsp 1'den Nsp 16'ya kadar olmak üzere toplam 16 tanedir. Nsp'ler genel olarak viral RNA sentezi için gereklidirler. Ayrıca konağın immün sistemini baskılama, vezikül oluşturup yeni virüslerin hücre dışına salınımı sağlamak gibi işlevleri vardır [2].

#### 4. SARS CoV-2'nin Mutasyonu

Bir virusün genomundaki (genetik kod) değişikliklere mutasyon denir [15]. RNA virusleri, replikasyon sırasında doğal olarak hataya meyilli bir RNA polimeraz kullanır ve genomları, replikasyon döngüsünün her aşamasında mutasyonlar biriktir. Koronavirüsler, RNA polimerazlar tarafından eklenen hatalı mutajenik nükleotitleri kesen enzimlere sahip oldukları için diğer RNA viruslerine göre daha az mutasyona uğrarlar. Sonuç olarak, yüksek bir replikasyon doğruluğu ve virus transkripsiyonunu koruma özelliğine sahiptirler [16]. Yapılan araştırmalarda SARS CoV-2'nin en çok ORF1ab geninde, ORF8 geninde ve N geninde olmak üzere toplam 116 mutasyon çeşidi tanımlanmıştır. Mutasyonlar sayesinde SARS-CoV-2'nin bulaşıcılığı ve hastalığın ölümcül olma ihtimali artmaktadır. Viral mutasyon araştırmaları; yeni aşiların, antiviral ilaçların ve teşhis sistemlerinin geliştirilmesinde gereklidir [15].

##### 4.1. COVID-19 varyantları

Bir veya daha fazla mutasyon bulunduran viral genom'a varyant denir. Dolayısıyla virus'ün yapısal değişimi sonucunda varyantlar ortaya çıkmıştır [17, 18]. DSÖ varyantları özelliklerine göre; Endişe Verici Varyantlar (VOC), Dikkate Alınması Gereken Varyantlar (VOI) ve İzleme Altındaki Varyantlar (VUMs) şeklinde isimlendirmiştir [17]. Tanimlanan beş tip endişe verici varyant; Alfa, Beta, Gamma, Delta ve Omicron varyantlarıdır [18].

###### 4.1.1. Alfa varyantı

İlk kez İngiltere'nin Kent bölgesinde görülmüş 50'den fazla ülkeye yayılarak mutasyona uğramış ve farklı türleri de tespit edilmiştir [19].

###### 4.1.2. Beta varyantı

Güney Afrika'da ortaya çıkış 20'den fazla ülkeye yayılmış göstermiştir. Fakat uygulanan seyahat kısıtlamalarıyla dünyada büyük bir yayılmanın önü kesilmiştir [19].

###### 4.1.3. Gama varyantı

Güney Afrika'da ortaya çıkararak 20'den fazla ülkeye yayılmış ve seyahat kısıtlamaları sonucunda dünyaya yayılmış engellenmiştir [19].

###### 4.1.4. Delta varyantı

İlk kez Ekim 2020'de Hindistan'da tespit edilmiş olup "P681R" ve "L452R" adında iki mutasyon içermektedir. Virusün insan hücrelerine tutunmasını ve enfekte etmesini sağlayan diken proteinine etki eden mutasyonlar, bulaşıcılığı artırmamasını ve vücuttan antikor direncinin azalmasını sağlamaktadır [20].

###### 4.1.5. Omicron varyantı

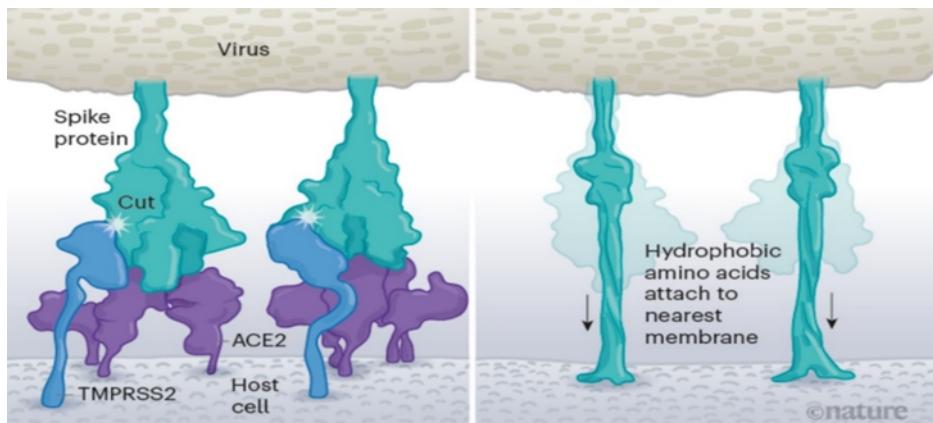
Omicron varyantı, virusün aşısı bağılılığından kaçmasına imkan veren mutasyonlara sahiptir. Rezeptör bağlanması dahil olmak üzere spike proteininde 30'dan fazla mutasyon saptanmıştır. Spike protein, viruslerin çoğu tarafından vücut hücrelerine girmek için kullanılır ve çoğu aşısı, spike proteinlerini hedef almak için üretilir. Bu nedenle Omicron varyantı, mutasyonları sayesinde aşiların koruyuculuğunu azaltabilmektedir [18]. Genel olarak, 60'tan fazla ikame/silme/ekleme mutasyona sahip olduğu saptanmıştır. Bu kadar fazla mutasyon içermesi Omicron'u şimdide kadarki tüm SARS-CoV-2 varyantlarından daha yüksek oranda mutasyon bölgelerine sahip bir varyant olarak tanıtmaktadır. Diğer dört VOC karşılaşıldığında, Omicron varyantında bulunan mutasyonlar tüm tanımlanan mutasyonların yaklaşık 3-4 kat fazlasıdır [16].

#### 5. SARS CoV-2'nin Hücreye Girişi ve Enfeksiyonu

İnsanda enfeksiyon esnasında SARS-CoV-2'nin konakçı içerisindeki yaşam döngüsü 5 aşamada gerçekleşir; bağlanma, penetrasyon, biyosentez, olgunlaşma ve hücre dışına salınma [21].

## 5.1. Bağlanma

Virüs konakçı hücreye S proteininin S1 alt biriminde bulunan reseptör bağlanması (RBP) ile bağlanmaktadır. S proteinin hedefi akciğerler, böbrekler, kalp ve gastrointestinal sistem (GIS)'de yer alan anjiyotensin dönüştürücü enzim-2 (ACE-2) reseptöridür [22]. Virüs konak hücreye temas ettiğinde S proteininin S1 alt birimi konak hücredeki ACE-2'ye bağlanır ve bu durum S proteininin parçalanmasına imkan vererek füzyon için S2 alanının aktifleşmesini sağlar (Şekil 5) [23].



**Şekil 5.** S proteininin S1/S2 alt birimlerinin konakçı hücre ile etkileşimi [24].

## 5.2. Penetrasyon

S proteininin S2 alanının aktifleşmesi de konakçı hücreye ait bir transmembran proteaz serin 2 (TMPRSS2) veya başka bir proteaz olan furin tarafından S1/S2 bölgesinde bulunan furin tanıma alanından ("RPPA" dizisi) kesilmesini tetiklemektedir. Aktive edilen S2, virüs ve konakçının çift katmanlı lipit tabakalarını birleştirerek tek sarmallı RNA genomunun konak hücrede birikmesine yol açar [23]. Böylece virüsün hücre membranına füzyonu ile hücreye girişi gerçekleşmektedir [21].

## 5.3. Biyosentez

Viral genom konakçı hücrelerin sitoplazmasına bırakıldığında, viral RNA replikasyonu için çekirdek içeresine girer ve pozitif RNA genomundan doğrudan replikaz transkriptaz kompleksi oluşturulur. Bu kompleks, viral RNA sentezi yapar ve buna bağlı olarak konakçının bağışıklık tepkisinden kaçmayı başarır. Virüs proteinlerinin biyosentezi için viral mRNA kullanılır, ardından M, S ve E proteinleri endoplazmik retikulum zarına entegre olur [25]. SARS-CoV-2'nin pozitif duyarlı genomu, endoplazmik retikulum (ER) zarında viral protein sentezini başlatır. Protein üretiminin ER'de bulunan ve replikaz proteinlerinin oluşturduğu replikasyon fabrikalarında gerçekleştirilmektedir. Bu replikasyon fabrikaları, çift sarmallı RNA (dsRNA) transkripsiyon ara maddelerini sitoplazmik model tanıma reseptörleri (PRR'ler) tarafından tanımaktan korur ve içlerinde transkripsiyonun gerçekleştiği çift zarlı veziküler bulundurmaktadır [23].

## 5.4. Olgunlaşma

Son olarak Nükleokapsidin Endoplazmik retikulum-golgi ara bölgesi (ERGIC)'ne ulaşmasıyla olgunlaşma evresi tamamlanır [25].

## 5.5. Hücre dışına salınma

Oluşan yeni virüsler ekzositoz yoluyla serbest kalır [25].

## 6. SARS CoV-2'ye Karşı Gelişen Yanıt

COVID-19'a karşı vücutun gösterdiği bağıışıklık sistemi doğuştan gelen bağıışıklık ve adaptif bağıışıklık sistemi olarak iki şekilde gerçekleşmektedir [26]. Doğuştan gelen bağıışıklık sistemini meydana getiren hücreler; monositler, makrofajlar, doğal öldürücü hücreler (Natural Killer -DÖ), dendritik hücreler, mast hücreleri ve granülositlerden oluşan miyeloid kökenli hücrelerdir. Adaptif bağıışıklık ise T ve B lenfositlerin aracılık ettiği antijene spesifik bir yanıt oluşturmaktadır. B ve T lenfositlerin, kendine özgü antijenlere maruz kalarak aktif hale gelmesiyle immünolojik hafıza oluşmaktadır [27].

### 6.1. Doğal immün yanıt

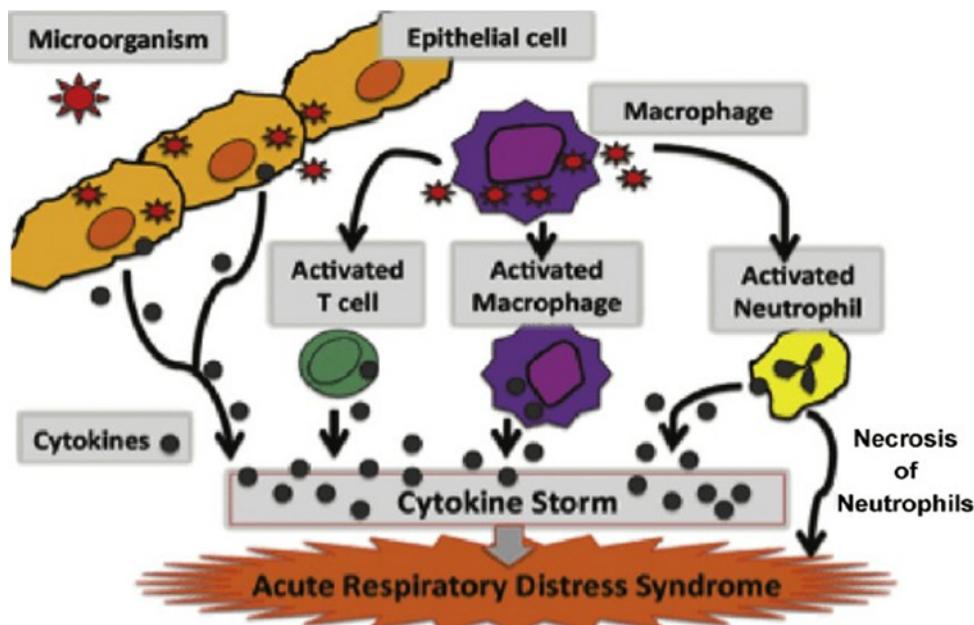
Doğuştan gelen bağıışıklık tepkisinin üç temel hedefi vardır: (1) Enfekte hücrelerde viral replikasyonun engellenmesi, (2) doğuştan gelen bağıışıklık sisteminin efektör hücrelerinin toplanmasıyla beraber konakçı doku ortamında bir antiviral durum meydana getirilmesi ve (3) adaptif bağıışıklık tepkisine hazırlanma [26]. Özetleyeceğ olursak; doğal immün hücreler, viral replikasyonu inhibe eden, adaptif immün tepkiyi uyaran ve enfeksiyon bölgesine diğer immün hücreleri çağırın proinflamatuv sitokinleri salgılamaktadır. Doğal bağıışıklık hücresi olan Granülositler (nötrofil, eozinofil, bazofil), hücre dışı patojenlere yanıt olarak degranülle (hücre dışına salınım) olup enzimleri ve toksik proteinleri serbest bırakmaktadır. Monositler dokulara geçiş yapar ve monosit türevli makrofajlara veya dendritik hücrelere dönüşür. Makrofajlar ve nötrofiller, enfekte hücrelerle benzer şekilde patojenleri de fagositozla yok ederler [27]. Tüm bu olaylar sonucunda antijen sunumu vücutun adaptif bağıışıklığını uyarmaktadır [28].

### 6.2. Adaptif immün yanıt

Doğal immün sistemin tetikleyerek başlattığı adaptif bağıışıklık sistemi üç ana hücre tipinden oluşur: B hücreleri, CD4+T hücreleri ve CD8+T hücreleri [26]. Hafızası vardır ve aynı patojen ile karşılaşlığında onu spesifik olarak tanımlamaktadır. Doğal bağıışıklığa göre daha hızlı ve etkili bir şekilde işlev görmektedir. Adaptif bağıışıklık, hücresel ve humoral bağıışıklık olarak iki farklı şekilde işlevlerini gerçekleştirmektedirler. Hücresel Bağıışıklıkta T lenfosit hücreleri görevlidir ve patojenleri tespit ederek, fagositoz yoluyla yok ederler. Humoral bağıışıklıkta ise B lenfositler görevlidir ve antikor sentezleyip bu antikorlar (immunoglobulin) aracılığı ile patojenleri öldürürler [27]. T lenfosit olan CD4+ T hücreleri, bir dizi yardımcı ve efektör işlevselliğe sahipken CD8+ T hücreleri ise enfekte olmuş hücreleri öldürme işlevi göstermektedir [26].

### 6.3. Sitokin firtınası

SARS-CoV-2'nin ACE2 reseptörüne bağlanmasıından sonra immun sistemin tepki oluşturma süreci başlamaktadır. Solunum yolunun submukozasında ve burun boşluğunda bulunan mast hücreleri, mikroorganizmalara karşı bir koruma bariyeri oluşturur ve bu bariyer virüslerin varlığında aktifleşmektedir. Mast hücrelerinin aktivasyonu, erken inflamatuv molekülleri olan histamin ve proteazları salgılarken, geç aktivasyon ile interlökin (IL)-1 IL-6 ve IL-33 dahil olmak üzere proinflamatuv IL-1 aile üyelerinin üretimini indüklemektedir. Tüm bunlar, T hücresi alt gruplarındaki sitokinlerin üretimiyle birlikte T hücresi aktivasyonu, farklılaşması ve bunu takiben çok büyük bir sitokin salımına yol açmaktadır (Şekil 6). Böylece proinflamatuv sitokinlerin kontrolsüzce ve çok miktarda salınmasına sitokin firtinası adı verilmektedir. Sitokin firtinası genellikle çoklu organ yetmezliği olarak vücuda yansır. Ağır COVID-19 hastalarının çoğu sitokin firtinası akciğer hasarını şiddetlendirebilmektedir. Bu nedenle COVID-19 komplikasyonlarını yönetebilmek için sitokin üretiminin kontrol etmek önerilmektedir [27].



**Şekil 6.** Bağışıklık yanıtları sonucu sitokin fırtınası [29].

#### 6.4. SARS CoV-2'nin immün yanıtının kaçış yolları

Koronavirüsler, konağın kendilerini tanımamasını engellemek için bazı kaçış mekanizmaları geliştirmiştir. Bu mekanizmalar arasında çift katmanlı endozomal yapıların içine saklanma, enfeksiyona karşı IFN yanıtının düzeyini ve zamanlamasını bozma gibi yetenekler yer almaktadır [30]. Diğer bir kaçınma mekanizması olarak Treg (T regülatör hücreler) hücrelerinin etkisi göz önüne alınmaktadır. Düzenleyici T hücrelerin (Treg), patojenlere, kanser hücrelerine ve nakledilen organlara karşı oluşan aşırı bağışıklık yanıtlarını baskılama; otoimmün ve allerjik hastalıkların gelişimini önlemek ve kontrol altında tutmak için vazgeçilmez bir role sahiptir [31]. COVID-19 hastalık durumunda ise dolaşımındaki Treg hücrelerinin azaldığı ( $CD3+CD4+CD25+CD127\text{düşük}^+$ ) ve bundan ötürü virüsün bağışıklıktan kaçma olağlığı bulduğu anlaşılmaktadır [29].

### 7. COVID-19 Tanı ve Teşhisı

SARS CoV-2 virüsünün vücutta saptanması ve hastalık teşhisi konulabilmesi için Moleküler testler ve Serolojik Testler (antijen testi, antikor testleri)' dir [32].

#### 7.1. Moleküler testler

Moleküler testler, SARS-CoV-2 viral RNA'sının tespiti için geliştirilmiştir. Bu testler yüksek duyarlılığı sahiptir ve düşük seviyede yalancı negatif sonuç vermektedirler [32]. Temelde PCR ve sekanslama tekniklerine dayanan bu testler: RT-PCR, LAMP (Döngü Aracılı izotermal amplifikasyon), CRISPR, Sekans Analizi testleridir [33].

#### 7.2. Serolojik testler

Serolojik test yöntemleri daha çok viral nükleik asidin saptanmadığı durumlarda ve enfeksiyonu geçiren kişilerde bağışıklık tepkisinin izlenmesi için kullanılmaktadır. Antijen/antikor testleri adıyla da bilinen bu testler; viral antijenin veya virüse karşı vücutta oluşan antikor cevabının belirlenmesi prensibine dayanmaktadır [32]. Antijen saptayan testler, enfeksiyon sırasında oluşan viral bileşenleri saptar. Çünkü antijenler sadece virus replikasyonu sırasında oluşur ve o an için virus varlığı göstermektedir. Antikor testleri ise daha geç dönemde virüse karşı gelişen bağışıklığı yani antikorları (IgG, IgM, IgA) saptar. Antikorlar, vücutta beliren antijenlerin üzerine yerleşerek onları inaktiv hale getirir ve enfeksiyon sonliğinde da vücutta bulunabilirler [33].

## 8. COVID-19 Tedavisi

COVID-19 hastalığı için uygulanan tedaviler; Antiviral Tedaviler ve Klinik Tedavide veya Sitokin Fırtınasını Yatıştırmak Amacıyla Kullanılan Ajanlar olarak iki gruba ayrılmaktadır [21, 34].

### 8.1. Antiviral tedaviler

Bu tedavi türünde Remdesivir, Klorokin/Hidroksiklorokin, Proteaz inhibitörleri (Lopinavir/Ritonavir-LPV/r), Azitromisin, Rekombinant solubl ACE2, Tip 1 İnterferonlar ve Favipiravir gibi ajanlar kullanılmaktadır [21, 34].

### 8.2. Klinik tedavide veya sitokin fırtınasını yatıştırmak amacıyla kullanılan ajanlar

Bu tedavi yönteminde ise İmmün (Konvelesan) Plasma, Kortikosteroidler, İntravenöz İmmünglobulin (IVIG), Janus Kinaz (JAK) İnhibitörleri, IL-1 Antagonistleri, İnterlökin-6 (IL-6) Antagonistleri, Sitokin uzaklaştırma ve Plazmaferez teknikleri kullanılmaktadır [21,34].

## 9. COVID-19 Aşları

COVID-19 aşlarının geliştirilmesinde kullanılan yöntemlere göre aşı türleri; komple viron aşları (canlı attenue, inaktif), nükleik asit bazlı DNA ve mRNA aşları, viral vektör aşları (replikatif ve nonreplikatif) ve rekombinant protein (protein subunit ve virus like particle (VLP)) aşlarıdır [35]. Aşı geliştirme çalışmaları sürecinde aşların bilimsel olarak onaylanması ve kabul edilmesi için tamamlanması gereken faz aşamaları vardır. Bu fazlar sırasıyla: Preklinik Faz, Faz 1, Faz 2, Faz 3, Regulatory Review/RR (Devletlerin düzenleyici kuruluşları ruhsat verme süreci) ve Faz 4 aşamalarıdır [36].

### 9.1. Komple virion aşları

#### 9.1.1. İnaktif aşırı

Hücre kültüründe SARS-CoV-2'nin üretilmesi ve virüsün kimyasal olarak aktivitesinin bozulmasıyla elde edilmektedir. İnaktif virüs, bağışıklık yanıtını güçlendirmek amacıyla alüminyum gibi bir adjuvan ile intramüsküler olarak birleştirilmektedir [35].

#### 9.1.2. Canlı zayıflatılmış (attenue) aşırı

Vahşi tip virüsün, genetik olarak modifiye edilerek ya da olumsuz şartlarda pasajlanarak virülansı ortadan kaldırılmaktadır fakat immünojenitesi korunmaya devam etmektedir. Zayıflatılan virüs, bağışıklık yanımı oluşturmak için konak hücrede çoğalar ama hastalığa sebep olamaz [35].

### 9.2. Nükleik asit bazlı aşırı

DNA ve mRNA aşırıları en yeni aşı teknolojileridir. Bu aşırılar insan hücrelerinde bağışıklık yanımı oluşturmak istenen virüse ait proteinlerin sentezlenmesine sebep olurlar [37].

#### 9.2.1. mRNA aşırı

Bu aşırılar, hücre içine girişi sağlamak amacıyla S proteini kodlayan mRNA lipid nanopartikül kılıf içine yerleştirilmektedir. Aşının kasa enjekte edilmesini takiben miyositler lipid nanopartiküller endositoz yoluyla içeriye alırlar. Hücre içine giren mRNA sitoplazmaya gider ve hücrede S protein üretilir. Hücre dışına salgılanan S proteinler antijenik tepki oluşturarak salgısal (B hücre yanıtı) ve hü cresel (sitotoksik T hücre yanıtı) bağışıklık cevabının olmasını sağlamaktadır [37].

#### 9.2.2. DNA aşırı

DNA aşırı, kas hücrelere enjekte edilebilmektedir. Enjeksiyon yapılan bölgedeki antijen sunan hücrelerin hedeflenen antijenik yapıya benzer proteinleri üretmek için plazmid DNA ile enfekte edilmesi sağlanmaktadır. Bunun sonucunda enfekte olan hücreler devamlı antijen üretirler. Böylece salgısal ve hü cresel bağışıklık sisteminin

tepki oluşturması sağlanmış olur. Fakat insan hücre genomuna yabancı bir DNA'nın entegre edilmesinin nelere sebep olacağının bilinmediği için güvenilir değildir [37].

### **9.3. Viral vektör aşları**

Vektör aşlarında, adenovirus gibi canlı ya da cansız vektörlerin içine yerleştirilen RNA vücuda aktarılmaktadır. Bu şekilde RNA'nın istenen proteinlerin sentezini sağlaması ve immün sistemi uyarması amaçlanmaktadır [35]. Viral vektör aşlarının en önemli avantajları, taşıyıcı virüs sayesinde gerçek bir viral enfeksiyon gibi doğal bağışıklık sisteminin tüm elemanlarının aktifleşmesine neden olmalarıdır [37].

#### **9.3.1. Replikatif viral vektör aşları**

Replikatif özelliğe sahip vektörler, zayıflatılmış virüs suşlarından üretilir. Bu tür aşilar viral giriş alanında mukozal bağışıklığı tetiklemek amacıyla intranasal olarak da kullanılabilir [35].

#### **9.3.2. Nonreplikatif viral vektör aşları**

Çoğalma yeteneği olmayan vektörler kullanılır ve viral proteini eksprese edecek şekilde tasarlanmış aşılardır. Viral vektör aşılarda en çok adenovirus kullanılmaktadır [35].

### **9.4. Rekombinant protein aşları**

Rekombinant protein aşları virüs proteinlerini ya da viral molekülleri enjekte ederek uygulanır. Virüsün bir kısmı enjekte edildiği için koruyuculukları sınırlıdır. Üstelik bazen dengesiz bağışıklık tepkisine neden olabilmektedir [37]. Bu aşilar, patojenin yüzeyindeki epitoplar denilen protein yapıdaki antijenik bölgelerin sentezi sonucunda elde edilen protein aşlarıdır [38].

#### **9.4.1. Protein alt ünite aşları**

Protein subunit (alt ünite) aşları genelde virüsün spike proteinini ya da reseptör bağlanma kısmını hedef almaktadır. Bu aşiların başarılı olması için bağışıklığı tetikleyecek adjuvanlar kullanmak önerilmektedir [35].

#### **9.4.2. Virüs benzeri parçacık aşları**

VLP aşılarda, boş virüs kabuk抗jenleri kullanılmaktadır. Genetik materyale sahip olmadıkları için bulaşıcı değildirler [35]. Bu aşilar viral kapsid proteinlerinden bazılarını içerirler. Genetik materyal içermedikleri için daha güvenli aşilar ve antijenik protein içerdikleri için güçlü bağışıklık tepkisi oluşturmaktadırlar [37].

## **10. Acil Kullanım Onayı Alan Başlıca Önemli Aşilar**

### **10.1. Pfizer biontech**

Almanya tarafından üretilen bir mRNA aşısıdır. Bir RNA virüsü olan SARS-CoV-2'nin S-proteinini kodlayan genetik kodunun lipid nanopartiküler aracılığıyla insan vücutuna verilmesi sonucu immün cevabı indükleyen bir aşıdır [36]. Hücreye enjekte edilen mRNA, burada okunduktan sonra spike proteinleri üretilir. Vücutta viral protein yerine, istenen proteini sentezletecek olan genetik materyal aktarılmaktadır. Kolay parçalanabilen RNA'yı korumak amacıyla bir lipid nanopartikül (LNP) içerisine konularak mRNA vücuta verilmektedir [35].

### **10.2. Moderna**

Moderna'nın mRNA-1273 aşısı Pfizer/Biontech aşısına benzer şekilde SARS-CoV-2'nin genomunun S-proteinini (Spike proteinini) kodlayan genetik kodu, lipid nanopartiküler içerisine yerleştirilerek üretilmektedir. Aralarındaki fark ise genetik kod diziliminde kullanılan farklı lipid nanopartiküllerdir [36].

### 10.3. Sinovac

Geleneksel aşı üretim teknigiyle, canlı olan SARS-CoV-2'nin laboratuvar ortamında üretildikten sonra inaktif hale getirilmesiyle oluşturulan bir aşıdır. Bu aşı bir alüminyum hidroksit adjuvanı içermektedir [35].

### 10.4. Turkovac

Bu aşı, Erciyes Üniversitesi ve Sağlık Bakanlığı iş birliği ile geliştirilerek TURCOVAC ticari adı ile piyasaya sunulmuştur. Türkiye'de ticari olarak üretilen ilk COVID-19 aşısıdır. Turkovac aşısının özelliği bir inaktif virüs aşısı olmasıdır. Tüm faz çalışmaları kurallara uygun olarak tamamlandığı için güvenlidir [39].

### 10.5. Bharat biotech

Bu aşı, inaktive edilmiş bir tam virüs aşısıdır. İçerisinde bir alüminyum hidroksit ve bir reseptör agonisti adjuvanı bulundurmaktadır [35].

## SONUÇ

Tüm dünyada yüksek ölüm sayılarına neden olan COVID-19 hastalığı etkeni SARS CoV-2, bireylerin çoğunda solunum yetmezliğine, akeçiger, karaciğer, böbrek gibi organlarda doku hasarına, nörolojik hastalıklara, eklem ve iskelet sisteminde işlevsel bozukluklara neden olmuştur. Ayrıca pandemi sürecinde yaşanan problemler insanlarda sosyal ve psikolojik sorunların artmasını ciddi şekilde tetiklemiştir. Salgın başlangıcı olan 2019'da aşı üretimi ve sağlık hizmeti konusunda hazırlıklı olunmadığı için dünya ekonomisi büyük bir düşüş yaşamıştır fakat 2021'den itibaren aşı ve sağlık malzemelerinin üretimi artırılarak ekonomik bir yükselişe geçilmiştir [40]. Küresel çapta pandemi süreci değerlendirildiğinde her ne kadar gerekli tanı ve tedavi yöntemleri geliştirilip normal hayatı dönmeyi başarmış olsa da bu süreç çok yüksek sayıda ölüm vakaları ve zor şartlar altında geçti. Ayrıca toplum, temizlik kuralları ve sağlıklı ilgili önlemler hakkında yeterince bilgili olmadığı için salgının yayılması daha hızlı olmuştur. Gelecekte karşılaşılacak yeni bir salgın hastalık olasılığına karşı tüm dünya ülkeleri hazırlıklı olmalıdır. Bunun için toplum daima bilinçlendirilmeli, devlet salgın hastalıklar için yüksek bütçeler ayırmalı, bilimsel çalışmalar daha fazla desteklenerek teknolojik açıdan sağlam altyapılar oluşturulmalıdır.

### Bilgi

Bu derleme Fırat Üniversitesi Fen Bilimleri Enstitüsü Bünyesinde Biyoloji Bölümü, Moleküler Biyoloji Anabilim Dalında yüksek lisans semineri olarak sunulmuştur.

### Kaynaklar

- [1] Kurtuluş M, Pirim İ. COVID-19 ve Sitokin fırtınası. *Forbes J Med* 2020; 1(3): 55-60.
- [2] Tanrıverdi ES, Yakupoğulları Y, Otlu B. COVID-19 etkeninin özellikleri. Çiçek C, Editör. *Mikrobiyoloji ve COVID-19*. Türkiye Klinikleri, 2020; 1: 7-14.
- [3] Tatar B, Adar P. SARS-CoV-2: mikrobiyoloji ve epidemiyoloji. *Tepecik Eğitim ve Araştırma Hastanesi Dergisi* 2020; 30: 27-35.
- [4] Mollarasouli F, Zare-Shehneh N, Ghaedi M. A review on corona virus disease 2019 (COVID-19): current progress, clinical features and bioanalytical diagnostic methods. *Microchim Acta* 2022; 189(3): 103.
- [5] Yücel B, Görmez AA. SARS-Corona virüsüne genel bakış. *Turk J App Sci Tech* 2019; 2(1): 32-39.
- [6] Safiabadi Tali SH, LeBlanc JJ, Sadiq Z, Oyewunmi OD, Camargo C, Nikpour B, Armanfard N, Sagan SM, Jahanshahi Anbuhi S. Tools and techniques for severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2)/COVID-19 detection. *Clin Microbiol Rev* 2021; 34(3): e00228-20.
- [7] Bai C, Zhong Q, Gao GF. Overview of SARS-CoV-2 genome-encoded proteins. *Sci China Life Sci* 2022; 65(2): 280-294.
- [8] Sağlam Y. Koronavirüs (COVID-19) Genomu [Internet]. 2020 [cited 2023 June 8]. Available from: [https://www.yamansaglam.com/tr/koronavirus-COVID-9-genomu\\_a.html](https://www.yamansaglam.com/tr/koronavirus-COVID-9-genomu_a.html).
- [9] Babaoğlu AR., Dağalp SB, Doğan F, Kırmızı GA. SARS-CoV-2'nin genom organizasyonu. *Eurasian J Vet Sci* 2020; 36.
- [10] Wrapp D, Wang N, Corbett KS, Goldsmith JA, Hsieh CL, Abiona O, Graham BS, McLellan CS. Cryo-EM structure of the 2019-nCoV spike in the prefusion conformation. *Science*. 2020; 367(6483): 1260-1263.
- [11] Walls CAC, Park YJ, Tortorici MA, Wall A, McGuire AT, Veesler D. Structure, function, and antigenicity of the SARS-CoV-2 spike glycoprotein. *Cell* 2020; 181(2): 281-292.
- [12] [Internet] 2020. [cited 2023 June 8]. Available from: [https://www.researchgate.net/figure/Coronavirus-structure-showing-the-organization-of-spike-S-membrane-M-and-envelope\\_fig1\\_343443540](https://www.researchgate.net/figure/Coronavirus-structure-showing-the-organization-of-spike-S-membrane-M-and-envelope_fig1_343443540)

- [13] Aylaz R, Yıldız ÜE. Yeni koronavirüs hastalığının toplum üzerine etkileri ve hemşirelik yaklaşımları. Malatya İnönü Üniversitesi Yayınevi. 2020; 38.
- [14] Akdoğan H, Karşlıgil T. SARS-CoV-2: Bildiklerimiz, Bilmediklerimiz. Türk Mikrobiyol Cemiy Derg 2021; 51(3): 203-213.
- [15] Durmaz B., Abdulkmajed O, Durmaz R. Mutations observed in the SARS-CoV-2 spike glycoprotein and their effects in the interaction of virus with ACE-2 receptor. Medeni Med J 2020; 35(3): 253.
- [16] Kaya G, Altındış M. SARS-CoV-2 Omicron (B. 1.1. 529) Varyantının Virolojik, Epidemiyolojik Özellikleri ve Korunma: Derleme. KOU Sag Bil Derg 2022; 8(3): 162-171.
- [17] Çelebi F, Saridoğan HÖ. Farklı Disiplinlerden COVID-19 Çalışmaları, Duvar Yayıncıları. 2021.
- [18] Çebi E, Çöl M. 3 Doz mRNA COVID-19 Aşısı ve SARS-CoV-2 Omicron Varyantı Enfeksiyonu Arasındaki İlişki. Arşiv Kaynak Tarama Dergisi 2022; 31(4): 249-253.
- [19] [Internet] 2021. [cited 2023 June 9]. Available from: <https://www.bbc.com/turkce/haberler-dunya-55508893>
- [20] [Internet] 2021. [cited 2023 June 9]. Available from: <https://tr.euronews.com/2021/06/30/alfa-beta-delta-gamma-koronavirus-varyantlar-neler-hangi-varyant-ne-kadar-etkili>
- [21] Soyöz M, Ayna TK, Pirim İ. İmmünolojik Açıdan COVID-19 Enfeksiyonuna Bakış. Tepecik Eğit ve Araşt Hast Dergisi. 2020.
- [22] Tekol SD. SARS-CoV-2: Virolojisi ve Tamda Kullanılan Mikrobiyolojik Testler. South Clin of Ist Euras 2020.
- [23] Lamers MM, Haagmans BL. SARS-CoV-2 pathogenesis. Nat Rev Microbiol. 2022; 20(5): 270-284.
- [24] [Internet] 2021. [cited 2023 June 8]. Available from: <https://evrimagaci.org/sarscov2-insan-hucrelerine-nasil-giriyor-kendini-nasil-kopyaliyor-delta-varyanti-bagisiklik-sisteminin-nasil-atlatabiliyor-10824>
- [25] ] İnal AS, Duman ZG, Kurtaran B. SARS-CoV-2 Mikrobiyoloji ve Patogenez. Arşiv Kaynak Tarama Dergisi. 2020; 29 (Özel Sayı): 11-23.
- [26] Sette A, Crotty S. Adaptive immunity to SARS-CoV-2 and COVID-19. Cell 2021; 184(4): 861-880.
- [27] Saltekin A, Alim NE. COVID-19 Pandemi Sürecinde İdeal Vücut Ağırlığının Önemi. YIU Saglik Bil Derg 2021; 2: 49-55.
- [28] Yazdanpanah F, Hamblin MR, Rezaei N. The immune system and COVID-19: Friend or foe?. Life sciences 2020; 256: 117900.
- [29] [Internet] [cited 2023 June 8]. Available from: <https://www.bilgiustam.com/sitokin-nedir-sitokin-firtinasi-nasil-olusur-neye-sebep-olur/>
- [30] Mavi D, İnkaya A. COVID-19: Immunopathogenesis. Flora Infeksiyon Hastalıkları ve Klinik Mikrobiyoloji Dergisi. 2020; 25(2).
- [31] Gürel Z. COVID-19 Hastalarında Nötrolizan Antikor Düzeyinin 6 Aylık Prospektif İzlemi, Uzmanlık Tezi, Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi, Konya, 2022.
- [32] Tanrıverdi ES, Yakupoğulları Y, Otlu B. COVID-19 tanısı: Serolojik ve Moleküler testler. Arşiv Kaynak Tarama Dergisi. 2020; 29 (Özel Sayı): 31-37.
- [33] Keleş GT, Bozkurt İ. COVID-19 hastalığı tanı ve tedavisinde kullanılan laboratuvar testleri. MCBU SBED 2021; 8(2): 380-387.
- [34] Atalay S, Ersan G. COVID-19 tedavisi. Tepecik Eğit ve Araşt Hast Dergisi. 2020; 30: 126-34.
- [35] Dayan S. COVID-19 ve Aşı. Dicle Med J. 2021; 48: 98-113.
- [36] Yavuz E. COVID-19 aşları. Türkiye Aile Hekimliği Dergisi. 2020; 24(4): 223-234.
- [37] Azap A. COVID-19 Aşları: Tunelin Ucundaki Işık. Arşiv Kaynak Tarama Dergisi. 2020; 29 (Özel Sayı): 94-100.
- [38] Şerefoğlu B, Koç RÇ, Tokyay BK, Yolalan G, Balaban BG, Tanyeri Y, İslambey S. SARS-CoV-2'ye Karşı Geliştirilen Aşılar ve Üretim Metotları. JHIT. 2021; 4(2): 14-32.
- [39] Demirden SF, Alptekin K, Geboloğlu IK, Öncel SŞ. Dünden Bugüne Türkiye'de Aşılama ve Aşı Üretiminin Tarihçesi. Turk Mikrobiyol Cemiy Derg. 2022; 247.
- [40] Ünűvar İ, Aktaş H. Dünya'da ve Türkiye'de COVID-19 pandemisinin ekonomik etkileri. Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi. 2022; 25(1): 124-140.





## Fırat Üniversitesi Fen Bilimleri Dergisi

### Telif Hakkı Devir Formu / Copyright Form

Biz aşağıda gerekli bilgileri bulunan,

[Yazarların Adı / Author names]

.....tarafımızdan yazılmış,

[Makale Adı / Article title]

başlıklı makale içeriği, sunduğu sonuç, bilgi, bulgu ve yorumları konusunda, Fırat Üniversitesi Fen Bilimleri Dergisi Editörlüğü'nün hiç bir sorumluluk taşımadığını kabul ederiz.

Sunduğumuz makalenin orijinal olduğunu; herhangi bir başka dergiye yayınlanmak üzere gönderilmedinini; daha önce yayınlanmadığını; tümüyle yada bir bölümü herhangi bir kongre/sempozyum da sunulup fakat tam metin olarak basılmadığını ve orijinal telif hakkı devri formu ile birlikte Fırat Üniversitesi Fen Bilimleri Dergisi Editörlüğü'ne gönderildiğini garanti ederiz.

Makalenin telif hakkından feragat etmeyi kabul ederek sorumluluğu üstlenir ve imza ederiz. Bu vesileyle makalenin telif hakkı Fırat Üniversitesi Fen Bilimleri Enstitüsü'ne devredilmiştir. Fırat Üniversitesi Fen Bilimleri Dergisi Editörlüğü makalenin yayınlanabilmesi konusunda yetkili kılınmıştır. Bununla birlikte yazarların aşağıdaki hakları saklıdır:

Aşağıdaki ve diğer bütün durumlarda makalenin Fırat Üniversitesi Fen Bilimleri Dergisi tarafından yayınlanmasına dair referans verilmelidir.

1. Telif Hakkı dışında kalan patent v.b. bütün tescil edilmiş haklar.
2. Makaleyi satmamak koşulu ile kendi amaçları için çoğaltma hakkı.
3. Yazarın gelecekteki kitaplar ve dersler gibi çalışmalarında; makalenin tümü ya da bir bölümünü ücret ödemeksiz kullanma hakkı.

**Bütün yazarlar tarafından imzalanması gerekiyor:** (Sorumlu yazar/Corresponding author\*)

Yazarın Adı ve Soyadı / Author Names

İmzası / Signature

Tarih / Date

1 .....

2 .....

3 .....

4 .....

5 .....

**NOT:** Eksik imza durumunda sorumluluk imzalayan yazarlara aittir. Lütfen formu doldurunuz, imzalayanız ve aşağıdaki adrese metinle birlikte gönderiniz.

Adres: Fırat Üniversitesi Fen Bilimleri Dergisi Editörlüğü, F.Ü. Fen Bilimleri Enstitüsü, 23119-Elazığ.