

# MÜHENDİSLİK ALANINDA YAPAY ZEKA



**EDİTÖRLER**

**Doç. Dr. Murat SARIKAYA**

**Dr. Öğr. Üyesi Mustafa Kemal BALKİ**

**Öğr. Gör. Volkan ÇAVUŞ**



# MÜHENDİSLİK ALANINDA YAPAY ZEKA

## EDİTÖRLER

Doç. Dr. Murat SARIKAYA  
Dr. Öğr. Üyesi Mustafa Kemal BALKİ  
Öğr. Gör. Volkan ÇAVUŞ

## BÖLÜM YAZARLARI

Doç. Dr. Çaęrı Vakkas YILDIRIM  
Dr. Öğr. Üyesi Ayşegül ÇAKIR ŞENCAN  
Dr. Öğr. Üyesi Cenk GEZEGİN  
Dr. Öğr. Üyesi Ezgi GÜNEY  
Dr. Öğr. Üyesi Hasan DİRİK  
Öğr. Gör. Alperen Mehmet SEVİNÇ  
Öğr. Gör. Salih DAĞLI  
Öğr. Gör. Yakup İRİM

Akademik unvan ve harf sırası gözetilerek sıralanmıştır.

Bu kitapta yer alan her bölümün tüm sorumluluęu (görseller, tablolar, çizelgeler, çizimler, grafikler, direkt alıntılar, etik/kurum izni vb.) yazarlara aittir.

Herhangi hukuki bir olumsuzlukta Çizgi Kitabevi Yayınları ve kitap editörü hiçbir konuda bir yükümlülük ve hukuki sorumluluęu kabul etmez, hukuki yükümlülük altına alınamaz. Her türlü hukuki yükümlülük ve sorumluluk ilgili bölüm yazar(lar)ına aittir.

Çok bölümlü/yazarlı olan bu kitap maddi bir deęer ile alınıp satılamaz. Kitapta yer alan bilgiler alıntı yapılmak ve ilgili alıntıya atıf yapılmak koşulu ile kaynak gösterilmek üzere bilimsel ya da ilgili araştırmacılar tarafından kullanılabilir.

**ÇİZGİ**  
K İ T A B E V İ

Çizgi Kitabevi Yayınları (e-kitap)  
Eğitim Bilim

Genel Yayın Yönetmeni  
Mahmut Arlı

©Çizgi Kitabevi  
Aralık 2022

ISBN: 978-605-196-913-8  
Yayıncı Sertifika No: 52493

**KÜTÜPHANE BİLGİ KARTI**  
**- Cataloging in Publication Data (CIP) -**  
EDİTÖRLER

SARIKAYA, Murat | BALKİ, Mustafa Kemal | ÇAVUŞ, Volkan  
MÜHENDİSLİK ALANINDA YAPAY ZEKA

Sayfa Düzeni ve Kapak Tasarımı  
Ozsum Academy  
Tel: +90 541 191 57 41

Baskıya Hazırlık: Çizgi Kitabevi Yayınları  
Tel: 0332 353 62 65- 66

### ÇİZGİ KİTABEVİ

Sahibiata Mah. Alemdar Mah.  
M. Muzaffer Cad. No:41/1 Çatalçeşme Sk. No:42/2  
Meram/**Konya** Çağaloğlu/**İstanbul**  
(0332) 353 62 65 - 66 - (0212) 514 82 93  
www.cizgikitavebi.com  
f t @ / cizgikitavebi

## İÇİNDEKİLER

<b>İÇİNDEKİLER</b>	iv
<b>ÖNSÖZ</b>	v-vi
<b>BÖLÜM 1: YAPAY ZEKAYA GİRİŞ VE İMALAT ALANINDAKİ UYGULAMALARI</b> <i>Ayşegül ÇAKIR ŞENCAN</i>	1-24
<b>BÖLÜM 2: ENDÜSTRİ 4.0 için YAPAY ZEKA UYGULAMALARI</b> <i>Salih DAĞLI &amp; Yakup İRİM</i>	25-44
<b>BÖLÜM 3: EKLEMELİ İMALAT SÜRECİNDE MAKİNE ÖĞRENME UYGULAMALARI</b> <i>Çağrı Vakkas YILDIRIM</i>	45-67
<b>BÖLÜM 4: GÜÇ TRANSFORMATÖRLERİNİN SAĞLIK İNDEKSİNİ BELİRLEMEDE YAPAY ZEKA YÖNTEMLERİNİN KULLANIMI</b> <i>Cenk GEZEGİN &amp; Hasan DİRİK</i>	68-91
<b>BÖLÜM 5: GÜÇ KALİTESİNDE YAPAY ZEKA SINIFLANDIRMA TEKNİKLERİ</b> <i>Ezgi GÜNEY</i>	92-122
<b>BÖLÜM 6: İNSANSIZ HAVA ARAÇLARINDA GÖRÜNTÜ İŞLEME UYGULAMALARI</b> <i>Alperen Mehmet SEVİNÇ &amp; Çağrı Vakkas YILDIRIM</i>	123-139

Bölüme ulaşmak için 

## ÖNSÖZ

Literatürde “AI” (Artificial Intelligence ) kısalması ile bilinen “Yapay Zekâ” Dördüncü Sanayi Devrimi'nde (Endüstri 4.0), akıllı sistemlerin ve teknolojilerin fiziksel ve sanal dünyalar arasında aktif bir bağlantı oluşturmak için kullanıldığı dijitalleşme çağında temel bir rol oynamaktadır. Temelde bir bilgisayar bilimi ile ilişkili olan AI, otomasyonu artırma ve üretkenliği hızlandırma potansiyeli nedeniyle son yıllarda mühendisliğin her branşında oldukça popüler hale gelmiştir. Şüphesiz bu duruma zemin hazırlayan en önemli etmenlerin başında, çok sayıda eğitim verisi, geliştirilmiş bilgi işlem gücü ve gelişmiş derin öğrenme algoritmalarının farklı mühendislik disiplinlerinde zamanla yerleşmesi gelmektedir. Günümüzde mühendisler, karmaşık sorunları çözmek için kendilerine destek sağlayabilecek çeşitli AI teknikleri kullanmaktadırlar. Dahası araştırmacılar ve mühendisler yapay zekanın yalnızca halihazırda gerçekleştirdikleri görevlerde onları desteklemekle kalmayıp, aynı zamanda daha önce yapamadıkları görevleri yapmalarını sağlayan yazılım ve donanım bileşenlerini de araştırmaya devam etmektedirler. Bu nedenle, mühendislik sektöründe yapay zekanın mevcut ve ileriye dönük uygulamalarda artan stratejik önemi onun gelecekteki rekabet gücü için belirleyici bir faktör olarak kabul edilmesinin en önemli nedenleri arasında gösterilmektedir.

Bu kapsamda hazırlanan mevcut kitap, farklı mühendislik alanlarında kullanılan yapay zeka uygulamalarından örnek çalışmalar sunarak okuyuculara farklı perspektiflerden yapay zekayı ve uygulama zenginliğini değerlendirme fırsatı sunmayı amaçlamaktadır.

## EDİTÖRLER

Doç. Dr. Murat SARIKAYA  
Dr. Öğr. Üyesi Mustafa Kemal BALKİ  
Öğr. Gör. Volkan ÇAVUŞ  
Aralık 2022


# BÖLÜM


# 1

## YAPAY ZEKAYA GİRİŞ VE İMALAT ALANINDAKİ UYGULAMALARI

**Ayşegül ÇAKIR ŞENCAN**

*Dr. Öğr. Üyesi, Zonguldak Bülent Ecevit Üniversitesi, aysegulcakir@beun.edu.tr*

 0000-0002-0506-6522




## BÖLÜM 1

### YAPAY ZEKAYA GİRİŞ VE İMALAT ALANINDAKİ UYGULAMALARI


**Ayşegül ÇAKIR ŞENCAN**

*Dr. Öğr. Üyesi, Zonguldak Bülent Ecevit Üniversitesi, aysegulcakir@beun.edu.tr*

 0000-0002-0506-6522

#### 1. YAPAY ZEKAYA GİRİŞ

İnsan zekasının algılama, algıladıklarını değerlendirme ve bu değerlendirme sonucunda bir karar vererek tepki ortaya koyma yetisini modelleyip bilgisayarlara veya bilgisayar kontrollü makinelere kazandırmaya çalışmak için geliştirilen yaklaşıma yapay zeka denir. Bu modellemenin yapılabilmesi için ise, insan sinir sistemi fizyolojisinin çok iyi bilinmesi gerekir. İnsan vücudunda bulunan beş duyu organından elde edilen bilgilerin tespit edilmesi, alınması, iletilmesi, değerlendirilmesi ve cevap oluşturulması merkezi sinir sistemi (Beyin, beyincik ve omurilik) ve çevresel sinir sisteminin (kas, organ ve salgı bezleri , vb. tüm dokulara bağlantılı sinir ağı ) koordineli olarak çalışması ile gerçekleştirilir (Squire vd., 2008). Bu sistemin temel birimi nörondur. Sinir sistemi milyarlarca nöronun birbiri ile seri ya da paralel bağlantısı ile oluşmuştur. Bir nöron; dendrit (alıcı uç), gövde ve akson (verici uç) olmak üzere üç bölümden oluşur. Bir nöron üzerinde bilgi yönü dendritten akson ucuna doğrudur ve iletim elektriksel potansiyel fark ile gerçekleşir (Kandel vd., 2013). Nöronlar arası bağlantı, bilgi aktaran nöronun akson ucunun bilgi alan nöronun dendrit ucuna bağlanması ile sağlanır. Bu bağlantıya sinaps, dendrit ve akson arasındaki bölgeye sinaptik bölge denir. Şekil 1.1'de bir nöron hücresine ait bölümler ve nöronlar arası sinyal iletimi verilmiştir.



**Şekil 1.1** Nöron hücresine ait bölümler ve nöronlar arası sinyal iletimi



Sinaptik bölgede iletim nörotransmitter olarak tanımlanan kimyasal maddeler ile sağlanır. Bir nöron ortalama  $10^5$  adet nöron ile bağlantılıdır (Bear vd., 2007).

Nöron fizyolojisi en kısa şekilde şöyle açıklanabilir. Nöronun her bir dendritinden alınan değer nicelik olarak birbirinden farklı olabilir. Bu farklılık sinaps büyüklüğü ve kalitesine de bağlıdır. Ayrıca dendrit uzunluğuna bağlı olarak değişen bir elektriksel direnç oluşur. Binlerce dendritten gelen bilgiler hücre gövdesinde birleşerek tek bir elektriksel potansiyel elde edilir. İşte bu noktada en temel karar verme mekanizması olan eşik değer karşılaştırması devreye girer. Bu mekanizma, nöronun gövdesinden akson ucuna doğru bir elektriksel sinyal gönderilip gönderilmeyeceğine karar verir. Eğer gövdede oluşan elektriksel potansiyel, hücrenin eşik değerinden yüksek ise bu sinyal oluşur ve akson ucuna ulaşır. Bu sinyal akson ucundan sinaptik bölgeye nörotransmitter salınımını sağlar ve kimyasal yolla hedef nöronun dendritine sinyal iletilmiş olur (Purves vd., 2012).

Nöron fizyolojisi ile ilgili matematiksel model ilk kez Alan Hodgkin ve Andrew Huxley tarafından 1952 yılında yapılmıştır. Bu model, en kısa tabirle nöron hücresinin içinde ve dışında bulunan iyonların elektriksel potansiyel değişimlerini inceler (Dayan & Abbott, 2005).

Dendritten akson ucuna kadar gerçekleşen fizyolojik sürecin ilk modeli ise 1957 yılında Frank Rosenblatt tarafından oluşturulmuştur. Perceptron (algılayıcı) olarak adlandırılan bu model yapay sinir ağının temel birimini teşkil eder. Perceptron, giriş değerleri, ağırlık değerleri, ağırlık ve giriş değerlerinin ayrı ayrı çarpılarak toplandığı toplam dizisi ve aktivasyon fonksiyonu olmak üzere dört bölümden oluşur.

Bir nöron hücresinin ve perceptron modelinin kısımları incelendiğinde;

- ✓ Nöronda dendritlere gelen her bir sinyal perceptronda giriş değerlerine,
- ✓ Nöronda sinaps ve dendrit direncine bağlı faktörler perceptronda ağırlık değerlerine,
- ✓ Nöronda tüm dendritlerden gelen sinyallerin gövdede toplanması perceptronda toplam dizisine,
- ✓ Nöronda eşik değer karşılaştırması ise perceptronda aktivasyon fonksiyonuna karşılık gelmektedir.

Perceptron matematiksel olarak en basit haliyle (tek giriş) şu şekilde ifade edilebilir :

$$z = w \times x - \mu, \quad y = \theta(z) \quad (1.1)$$

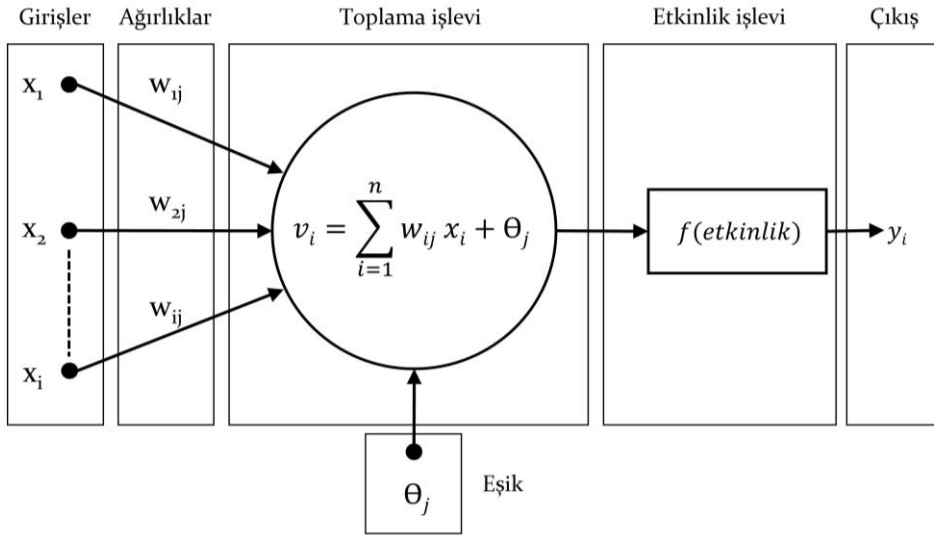
Burada, "x" giriş değerini, "w" ağırlık değerini, "μ" eşik değerini, "y" ise çıkış değerini ifade eder. θ aktivasyon fonksiyonuna göre; "z" değeri sıfırdan büyükse sonuç "+1", değilse "0" olarak

sınıflandırılır. Matematiksel ifadeden de anlaşılacağı üzere bu bir doğru denklemdir ve düzlemi doğrusal olarak ikiye ayırır. Yani doğrusal çizgi ile sadece iki küme oluşacak şekilde sınıflandırma işlemini gerçekleştirebilir. Yapay sinir ağlarının en ilkel sınıflandırma şeklidir.

Birden fazla giriş olması durumunda ise perceptron şöyle ifade edilebilir:

$$y_i = \theta \left( \sum_{i=1}^n w_i x_i - \mu \right), \quad (i, n \in Z^+) \quad \text{yada} \quad Y = \theta(W^T X - \mu) \quad (1.2)$$

Burada, “X” giriş değerlerinin bulunduğu vektörü, “W” ağırlık değerlerinin bulunduğu matrisi, “Y” çıkış değerlerinin bulunduğu vektörü, “μ” ise eşik değeri gösteren skaleri tanımlar. Şekil 1.2’de perceptron için akış diyagramı verilmiştir.



**Şekil 1.2** Perceptron akış diyagramı (Elmas, 2007)

Perceptron, sınıflandırma işleminin doğrusal bir çizgi ile yapılamadığı durumlarda kullanılamaz. Böyle durumlarda birden fazla perceptron gerektiği şekilde seri ve paralel bağlanarak katmanlı bir yapı oluşturulur. Buna Multi Layer Perceptron (MLP) denir. MLP’de bir adet giriş katmanı, bir veya birden fazla gizli katman ve bir adet çıkış katmanı olmak üzere üç kısımdan söz edilebilir. Her katmanda birden fazla perceptron yer almaktadır ve MLP’de perceptron, düğüm (node) olarak ifade edilir. Artık, “ağ” diyebileceğimiz sayıda düğüm bulunmaktadır. MLP’de giriş katmanındaki düğümlerin çıkış değerleri gizli katmandaki düğümlerin giriş değerleri olur. Benzer şekilde gizli katmandaki düğümlerin çıkış değerleri de çıkış katmanındaki düğümlerin giriş değerleri olmaktadır. Giriş katmanındaki düğüm sayısı değerlendirilmek istenen veri sayısına bağlıdır. Çıkış katmanındaki düğüm sayısı ise sınıflandırılmak istenen küme sayısına bağlıdır. Gizli katman sayısı ve her katmandaki düğüm sayısı ise, değerlendirilecek veri sayısı ve istenen sınıflandırma doğruluk oranına doğrudan,

hesaplama kapasitesi ve hesaplama süresine ise dolaylı olarak bağlıdır. MLP'de bulunan düğümlerin birbirleriyle olan bağlantıları farklı olabileceği gibi aktivasyon fonksiyonları da birbirlerinden farklı olabilir. Bu farklılıklar duruma özel hesaplama kabiliyeti ve öznelik kazandırır (Trappenberg, 2010).

Düğümler arası bağlantı farklılıkları bağlantı yönüne ve bağlantı sayısına göre gruplandırılabilir. Bağlantı sayısına göre;

**Tam Bağlantılı Katmanlar:** Ağda bulunan her bir düğüm kendisinden sonraki katmanda bulunan tüm düğümlerle bağlantı kurar. Bağlantılar genellikle ileri beslemelidir.

**Kısmi Bağlantılı Katmanlar:** Ağda bulunan düğümler kendisinden sonra gelen katmandaki gerekli olan düğümlerle bağlantı kurar. Bağlantılar ileri ya da geri beslemeli olabilir.

Bağlantı yönüne göre;

**İleri Beslemeli Bağlantı:** Ağda bulunan tüm bağlantılar sadece girişten çıkışa yönlendirilmiş şekilde bağlanmıştır.

**Geri Beslemeli Bağlantı:** Ağda bulunan bağlantılar ileri beslemeli şekilde bağlanmış olup, çıkış değerinin geri besleme yöntemiyle optimizasyonu amacıyla gerekli düğümlerde geri yönlü bağlantılar oluşturulmuştur.

**Yinelemeli Bağlantı:** Çok katmanlı bir ağda t anında gizli katmandan çıkış olarak alınan verilerin t+1 anında ağı giriş katmanına giriş değeri olarak verilmesi şeklinde tanımlanabilir. Burada t anındaki veriler aynı zamanda çıkış katmanına da aktarılır (Elmas, 2007).

Yukarıda belirtildiği gibi aktivasyon fonksiyonu farklılıkları da ağa hesaplama kabiliyeti kazandırır. Onlarca çeşit aktivasyon fonksiyonundan söz edilebilir. Fakat en çok kullanılan aktivasyon fonksiyonları basitten karmaşığa şöyle sıralanabilir.

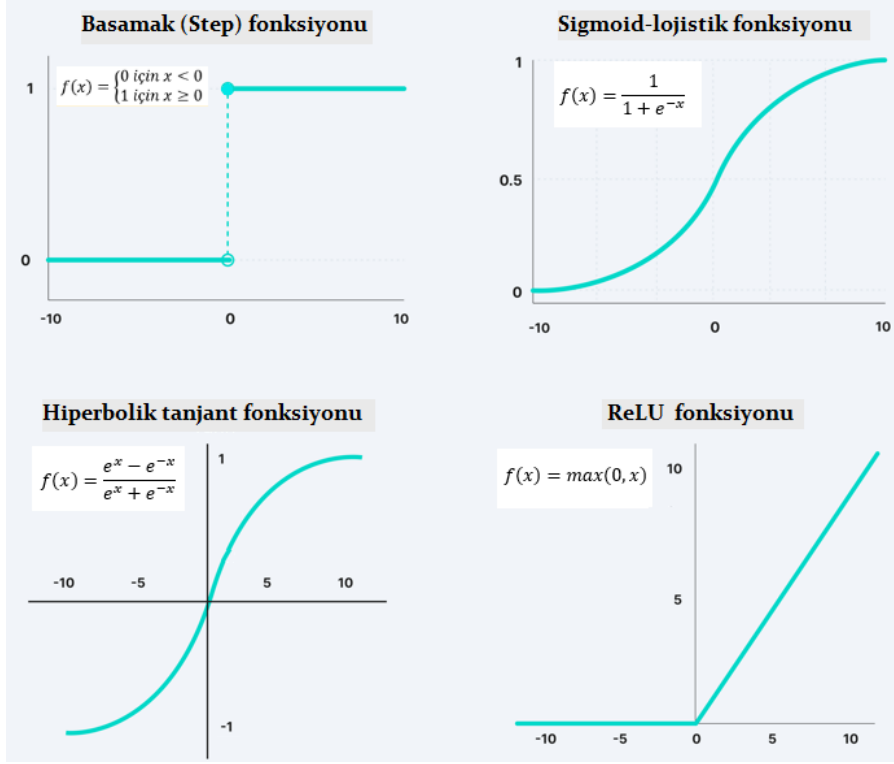
**Basamak (Step) fonksiyonu:** Fonsiyonun giriş değerini sifira göre kıyaslayarak ikili sınıflandırma çıktısı verir. Çıktı değeri ikili (0,1) ya da kutuplu (-1,+1) olabilir.

**Sigmoid-lojistik fonksiyonu:** Özellikle öğrenme algoritmalarında en sık kullanılan aktivasyon fonksiyonudur. [0,1] aralığında çıkış değeri üretir. 0 ve 1 değerine yaklaşıldıkça eğim azalacağından türev sifira yakınsar. Yani giriş değeri çıkış değerini neredeyse hiç değiştirmemektedir. Bu durum öğrenme oranının da sifira yaklaştığını gösterir. Öğrenme algoritmalarında istenmeyen bir durumdur.

**Hiperbolik tanjant fonksiyonu:** Görüntü itibariyle sigmoid fonksiyona çok benzerdir. Fakat, [-1,+1] aralığında çıktı ürettiğinden eğim daha dik, yani türev değeri daha yüksektir. Giriş değerinin çıkış değerini etkileme oranı daha fazladır. Öğrenme algoritmalarında sıklıkla tercih edilmektedir.

Sigmoid fonksiyonunda olduğu gibi -1 ve 1 değerine yaklaşıldıkça eğim azalacağından türev sıfıra yakınsar. Bu istenmeyen bir durumdur.

**ReLU (Rectified Linear Unit) fonksiyonu:** Giriş değerlerinin negatif olduğu durumda çıkış değerleri "0" olur, pozitif olduğu durumda ise doğrusal aktivasyon fonksiyonu şeklinde çıkış verir. Çıkış değerleri  $[0, +\infty)$  aralığındadır (Trappenberg, 2010).



**Şekil 1.3** Bazı aktivasyon fonksiyonları

Yapay sinir ağı modelinin tahmin kabiliyeti değerlendirmek için çeşitli performans ölçütleri uygulanmaktadır. Bunlar; Hata Kareleri Ortalaması (Mean Squared Error – MSE), Ortalama Hata Karelerinin Karakökü (Root Mean Squared Error –RMSE), Ortalama Mutlak Hata (Mean Absolute Error –MAE), Ortalama Yüzde Hata (Mean Percentage Error –MPE), Hata Kareleri Toplamı (Sum of Squared Errors –SSE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error – MAPE) ve Theil-U istatistiği olarak sıralanabilir (Ataseven,2013). Tablo 1.1’de bu performans ölçütlerine ait formüller verilmiştir.

**Tablo 1.1.** Yapay sinir ağı performans ölçütlerine ait formüller (Çavuş & Sarıkaya, 2021)

Performans Ölçütleri		Eşitlik
MSE	Ortalama Hata Kareleri Toplamı	$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$
RMSE	Ortalama Hata Karelerinin Toplamının Kökü	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$
SSE	Hata Karelerinin Toplamı	$SSE = \sum_{i=1}^N (x_i - \bar{x})^2$
MPE	Ortalama Yüzde Hata	$MPE = \frac{1}{N} \sum_{i=1}^N \frac{x_i - \bar{x}}{x_i}$
MSPE	Ortalama Yüzde Hata Karelerinin Toplamı	$MSPE = \frac{1}{N} \sum_{i=1}^N \left( \frac{x_i - \bar{x}}{x_i} \right)^2$
RMSPE	Ortalama Yüzde Hata Karelerinin Toplamının Kökü	$RMSPE = \sqrt{\frac{1}{N} \sum_{i=1}^N \left( \frac{x_i - \bar{x}}{x_i} \right)^2}$
MAPE	Ortalama Mutlak Yüzde Hata	$MAPE = \frac{1}{N} \sum_{i=1}^N \left  \frac{x_i - \bar{x}}{x_i} \right $
MAE	Ortalama Mutlak Hata	$MAE = \frac{1}{N} \sum_{i=1}^N  x_i - \bar{x} $
R <sup>2</sup>	Korelasyon Katsayısı	$R^2 = \frac{\sum_{i=1}^N (x_i - x_{ort})(\bar{x} - \bar{x}_{ort})}{\sqrt{\sum_{i=1}^N (x_i - x_{ort})^2 (\bar{x} - \bar{x}_{ort})^2}}$

## 2. YÖNTEM

Bu çalışmada talaşlı imalat alanında yapılan deneysel bir araştırmadan elde edilen sonuçlar yapay sinir ağları (YSA) ile analiz edilmiştir. Talaşlı imalat, istenilen şekilde, boyutta ve yüzey özelliklerinde ürün elde etmek için bir kesici takım kullanılarak iş parçasından talaş kaldırma işlemi olarak tanımlanabilir. (Günan, 2019). En yaygın uygulanan talaşlı imalat işlemlerinden biri olan tornalama işlemi, bu çalışmada deney operasyonu olarak seçilmiştir. Tornalama işlemi yapılırken işlem sırasında mekanik enerjinin neredeyse tamamı ısı enerjisine dönüşür. Kesme sıvısı kullanılarak, oluşan bu ısının kesme bölgesinden uzaklaştırılması sağlanır (Tosun vd., 2010). Fakat, üretim maliyetini artırmasının yanında çevreye ve insan sağlığına zarar vermesi sebebiyle, son yıllarda kullanılan kesme sıvısı miktarını azaltmayı hedefleyen uygulamalar araştırma konusu olmuştur.

Minimum miktarda yağlama (MMY) yöntemi bu amaçla geliştirilen uygulamalardandır. (Gürbüz vd., 2017). Geleneksel uygulamalara göre MMY yönteminde kullanılan kesme sıvısının 1000-10000 kat azaltıldığı bilinmektedir (Holmes 2008; Çakır, 2015). Kullanılan kesme sıvısı miktarını azaltırken işleme performansını da olumsuz etkilememek gerekir. Bu çalışmada uygulanacak kesme sıvısı miktarının optimum seviyesini belirleyebilmek için farklı debilerde çeşitli testler yapılmıştır.

Tornalama sırasında çeşitli nedenlerden dolayı iş parçası yüzeyinde, adına *yüzey pürüzlüğü* denilen, istenmeyen izler oluşur. Yüzey pürüzlüğü, ürünün nihai kalitesi hakkında bilgi veren en önemli çıkış parametrelerinden birisidir (Ağar, 2014). Bu nedenle bu çalışmada kalite karakteristiği olarak yüzey pürüzlüğü seçilmiştir.

### **2.1. Uygulanan YSA Metodu**

İmalatta işleme performansını incelerken şimdiye kadar YSA modellerinden faydalanılan çeşitli araştırmalar yapılmıştır. Örneğin frezeleme işleminde takım aşınmasının tahmini için takıma etkiyen kuvvetleri kullanarak tahminler yapan modeller geliştirilmiştir. Yapılan çalışmada takımın en keskin durumu, kesme yapabilecek durumu ve körelmiş durumu sırasıyla -1,0 ve +1 ile ifade edilip takımın işleme performansı konusunda tahminler yapan bir YSA modeli başarıyla kullanılmıştır (Sönmez vd., 2022). YSA'nın imalat süreçlerine uygulandığı bir diğer çalışmada MMY yöntemi kullanılarak yüzey iyileştirme operasyonunda işleme parametrelerinin optimizasyonu için bir YSA modeli üzerinde çalışılmıştır. Özellikle MMY yönteminin uygulanmasında kullanılan nozul çapı, mesafesi, açısı ile uygulanan kesme sıvısının debisi ve basıncının optimum seviyeleri araştırılmıştır. En iyi çözümü belirlemek için geliştirilen YSA modellerinin 4-10-2 ağ yapısı ile yüzey kalitesi verimli bir şekilde tanımlanmış ve yanıt değerleri kesin olarak tahmin edilebilmiştir (Nguyen vd., 2022). Bir başka çalışmada eğilme gerilmesi etkisindeki millerin çentik faktörünü belirlemek için YSA modeli kullanılmıştır. Bunun için kademeli, kanallı ve delikli olmak üzere 3 farklı tipte mil üzerinde çalışılmıştır. Mil çapı, pah yarıçapı ve zorlanma türünün çentik faktörüne etkisinin incelendiği çalışmada Pythia adında bir yazılım kullanılarak YSA modellerinin hazırlandığı bu çalışmada doğruya yakın tahminler yapılmıştır (Özkan vd., 2013).

Bu çalışmada MMY yöntemi uygulanarak yapılan tornalama işleminde kullanılan işleme parametrelerin yüzey kalitesine etkisini modelleyebilmek için bir YSA yönteminden faydalanılmıştır. Etkisi incelenen işleme parametreleri kesme sıvısı debisi, kesme hızı ve ilerlemedir. Bu girdilerin ortalama yüzey pürüzlüğü değeri olan  $R_a$ 'ya etkisi araştırılmıştır (Çakır vd., 2016). Kullanılan YSA modeli ileri beslemeli çok katmanlı YSA modelidir. YSA modeli oluşturulurken Pythia yazılımından faydalanılmıştır. Bu yazılım aracılığıyla doğruya en yakın sonucu verebilecek 3-6-5-1 ağ yapısı elde edilmiştir. Deneylerden elde edilen verilerin bir kısmı YSA modelini test etme ve doğrulama için

ayrıldıktan sonra, kalan kısmı öğrenme işleminde kullanılmıştır. YSA modelinde kullanılan aktivasyon fonksiyonu “Fermi” adında bir sigmoid-lojistik fonksiyonudur. Bu fonksiyonda veriler 0 ile 1 arasında değişir ve normalize edilmiş veriler kullanılır. Bu çalışma için oluşturulan YSA modelinin yaptığı tahminler ayrılan verilerle test edilmiştir. Daha sonra modelin tahmin performansını ölçmek için “Hata Kareleri Toplamı (Sum of Squared Errors –SSE)” ve “Mutlak Değişim Yüzdesi ( $R^2$ )” olmak üzere iki ayrı doğrulama yöntemi kullanılmıştır.

## 2.2. Uygulanan Deney Tasarımı

Tam faktöriyel tertibine göre yapılan deneylerde kontrol faktörü olarak 4 farklı değişken kullanılmıştır. Bu değişkenler; dört farklı kesme sıvısı debisi, dört farklı kesme hızı, iki farklı ilerlemedir. Bu şekilde  $4 \times 4 \times 2$  olmak üzere toplamda 32 farklı kesme şartında deneyler gerçekleştirilmiştir. Yapılan deneylerde 2,5 mm sabit kesme derinliği kullanılmıştır. Deneylerde kullanılan kontrol faktörleri (girdiler) ve performans kriteri (çıkıtı) Tablo 2.1’de verilmiştir

**Tablo 2.1.** Deneylerde kullanılan kontrol faktörleri ve performans kriteri

Girdiler			Çıkıtı
MMY için debi (A)	Kesme hızı (B)	İlerleme (C)	Ortalama
A1: 0,25 ml/dk	B1: 150 m/dk	C1: 0,1	yüzey
A2: 0,45 ml/dk	B2: 187,5	mm/dev	pürüzlüğü
A3: 0,90 ml/dk	m/dk	C2: 0,2	(Ra)
A4: 3,25 ml/dk	B3: 240 m/dk	mm/dev	$\mu\text{m}$
	B4: 300 m/dk		

## 2.3. Deneylerde Kullanılan Makine ve Teçhizatlar

Deneyler için Gazi Üniversitesi Teknoloji Fakültesi Bünyesindeki Johnford , TC 35 marka CNC Torna tezgahı kullanılmıştır. MMY sistemi SKF marka, LubriLean-Basic model soğutma sistemidir. MMY sisteminde soğutma yağı olarak LubriFluid F100 kesme yağı kullanılmıştır. LubriFluid F100 soğutma sıvısının özelliklerin Tablo 2.2’de verilmiştir.

**Tablo 2.2.** MMY siteminde kullanılan kesme/soğutma yağının özellikleri

Yağ Cinsi	Litre (lt)	İçerik	DIN 51757	DIN 51562	DIN ISO 2992
			Yoğunluk [20°C] (g/cm <sup>3</sup> )	Vizkozite[40°C] (mm <sup>2</sup> /sn)	Yanma Nokt. (°C)
<b>LubriFluid- F100</b>	2,5 ; 5 ; 10	Yağ Alkolleri	0,84	25	184

AA7075 alüminyum alaşımları dayanım/ağırlık oranı yüksek olduğu için havacılık ve uzay sanayiinde sıklıkla kullanılmaktadır. Ve çoğu alüminyum alaşımlarında olduğu gibi AA 7075 alaşımının talaşlı imalatında, kesme bölgesi yeterli yağlanmadığında iş parçasının kesici takıma sıvanıp kesme geometrisini bozması sıklıkla görülen işleme problemlerindedir (Mills & Redford, 1983). Savunma sanayinde yaygın kullanılan bu alaşımların işlenmesindeki problemlere çözüm aranması amacıyla deneylerde iş parçası malzemesi olarak AA 7075 kullanılmıştır. Kullanılan AA 7075 alaşımının kimyasal ve mekanik özellikleri Tablo 2.3'te verilmiştir.

**Tablo 2.3** AA 7075 alaşımının kimyasal ve mekanik özellikleri

	Si	Cu	Mn	Mg	Cr	Zn	Gerilim (kg/mm <sup>2</sup> )	Uzama (%)	Sertlik (Brinell)
<b>AA 7075</b>	0,40	1,60	0,30	2,50	0,30	5,6	58,4	11,0	150

Deneylerde kesici takım olarak değiştirilebilir karbür uçlar kullanılmıştır. Her deney için yeni bir kesici takım kullanılmıştır. Kullanılan kesici takımlar CCGT 12 04 04 HP formunda olup, alüminyum alaşımlarına özel Kennametal K313 kalitesindedir.

AA7075 alüminyum alaşımlarının farklı her kesme şartları için tornada işlenmesiyle elde edilen deney numunelerinin yüzey pürüzlükleri Mahr Perthometer yüzey pürüzlülük cihazı ile ölçülmüştür. Kullanılan yüzey pürüzlülük ölçme cihazının teknik özellikleri Tablo 2.4'de verilmiştir.



**Tablo 2.4.** Yüzey pürüzlülük ölçme cihazının teknik özellikleri

Model	Mahr Perthometer M1
Ölçme prensibi	Sylus metodu
Tarama hızı (mm/sn)	0,5
Ölçüm aralıkları	100-150
Filtre	Gaussian
Tarama uzunlukları (mm)	1,75 - 5,6 - 17,5

### 3. DENEYSEL BULGULAR VE YSA İLE ANALİZİ

#### 3.1. Deneylelerden elde edilen Ra sonuçları

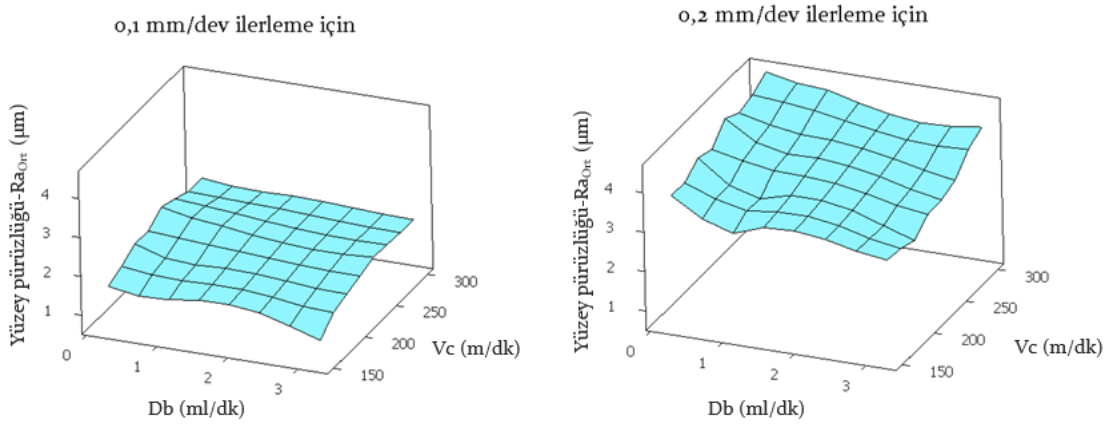
Tam faktöriyel tertibine göre yapılan deneylerde, uygulanan kesme sıvısı debisi (Db), kesme hızı (Vc) ve ilerleme (f) olmak üzere, 3 farklı işlem parametresinin çeşitli seviyelerinin kullanılması ile ortaya çıkan 32 farklı kesme şartı için elde edilen yüzey pürüzlüğü (Ra) sonuçları Tablo 3.1'de verilmiştir.

**Tablo 3.1.** Farklı kesme şartlarından elde edilen Ra sonuçları (Çakır vd., 2016)

Deney No	Db (ml/dk)	Vc (m/dk)	f (mm/dev)	Ra <sub>1</sub>	Ra <sub>2</sub>	Ra <sub>3</sub>	Ra <sub>Ort</sub>
1	0,25	150	0,1	1,739	1,686	1,636	1,687
2	0,45	150	0,1	1,421	1,339	1,564	1,441
3	0,90	150	0,1	1,532	1,621	1,438	1,530
4	3,25	150	0,1	1,078	1,135	1,282	1,165
5	0,25	187,5	0,1	2,270	2,161	2,092	2,174
6	0,45	187,5	0,1	1,729	1,973	1,825	1,842
7	0,90	187,5	0,1	1,735	1,855	1,636	1,742
8	3,25	187,5	0,1	1,529	1,826	1,649	1,668
9	0,25	240	0,1	2,653	2,488	1,989	2,377
10	0,45	240	0,1	2,371	2,254	2,289	2,305
11	0,90	240	0,1	2,054	2,322	2,068	2,148
12	3,25	240	0,1	2,068	1,880	1,838	1,929
13	0,25	300	0,1	2,406	1,787	1,977	2,057
14	0,45	300	0,1	1,943	1,829	2,157	1,976
15	0,90	300	0,1	1,868	1,944	1,972	1,928
16	3,25	300	0,1	1,992	1,726	1,846	1,855

17	0,25	150	0,2	3,764	3,940	3,929	3,878
18	0,45	150	0,2	3,315	3,960	3,619	3,631
19	0,90	150	0,2	2,915	2,902	3,063	2,960
20	3,25	150	0,2	2,736	3,471	3,098	3,102
21	0,25	187,5	0,2	4,263	4,289	4,286	4,279
22	0,45	187,5	0,2	3,541	3,755	3,800	3,699
23	0,90	187,5	0,2	3,176	2,909	3,226	3,104
24	3,25	187,5	0,2	2,932	2,725	2,996	2,884
25	0,25	240	0,2	4,052	4,838	4,696	4,529
26	0,45	240	0,2	4,438	3,958	3,909	4,102
27	0,90	240	0,2	3,820	3,688	3,620	3,709
28	3,25	240	0,2	3,402	2,907	3,417	3,242
29	0,25	300	0,2	4,738	4,612	4,419	4,590
30	0,45	300	0,2	4,717	4,318	4,418	4,484
31	0,90	300	0,2	4,465	4,656	4,162	4,428
32	3,25	300	0,2	4,018	4,116	4,034	4,056

Hata payını azaltmak adına, ölçümler her şart için 3 kez tekrarlanmış ve elde edilen bu 3 değer aritmetik ortalaması alınmıştır. Bu şekilde elde edilen ortalama yüzey pürüzlüğü ( $Ra_{ort}$ ) verilerinin kesme parametrelerine göre değişimini gösteren 3 boyutlu grafikler Şekil 3.1’de verilmiştir.



**Şekil 3.1.** Yüzey pürüzlüğünün kesme şartlarına göre değişimi

İlerleme parametresinin ortalama yüzey pürüzlüğü üzerindeki en etkili parametre olduğu grafiklerde açık bir şekilde görülmektedir. Düşük ilerleme şartlarında yüzey kalitesi, yüksek ilerleme şartlarından çok daha iyi çıkmıştır. Özellikle yüksek ilerleme şartlarında kesme hızı ve uygulanan debinin yüzey kalitesi üzerindeki etkisi biraz daha belirgin olduğu söylenebilir. Bu şartlar altında yüksek debi ve düşük kesme hızı kullanıldığında daha iyi yüzey kalitesi elde edildiği gözlenmektedir. Ortalama yüzey pürüzlüğü sonuçlarının değişen kesme şartları ile birlikte anlamlı bir değişim yaşadığı

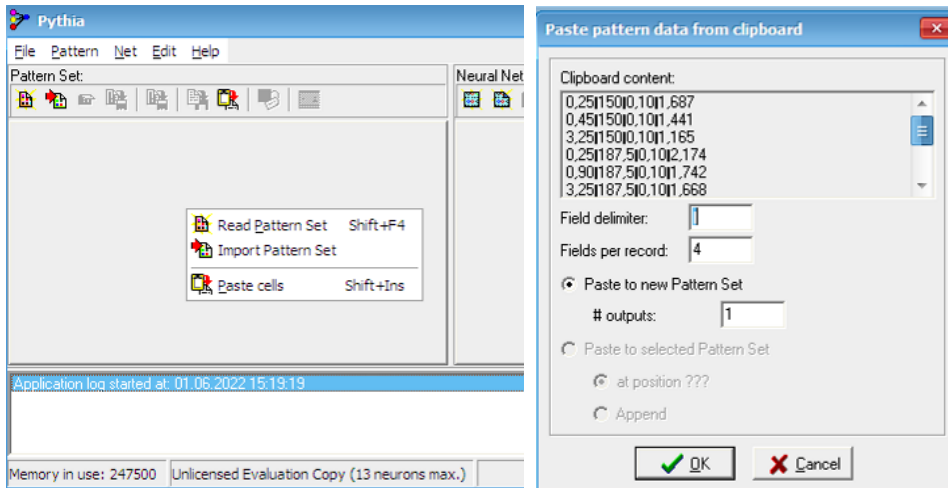
Şekil 3,1’de görülmektedir. Girdiler ve çıktılar arasındaki bu ilişkinin YSA’da öğretilmesinin, test edilmesinin ve doğrulanmasının mümkün olacağı düşünülmektedir.

### 3.2. Pythia ile Bir YSA Modeli Oluşturulması ve Analizi

YSA modeli oluşturulurken ihtiyaca uygun kod yazılarak çalıştırılabileceği gibi, hazır bir paket programdan da faydalanılabilir. Günümüzde Matlab Neural Network, EasyNN, Pythia, Neuro Dimension, Statistica v.b. çeşitli yazılımlar ile YSA modelleri oluşturulabilmektedir. Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için yeni bir ara yüz tasarlanarak, bu ara yüzün kullanıldığı araştırmalar da yapılmıştır (Arı & Berberler, 2017). YSA modelini oluştururken uygun ağ yapısının belirlenmesi, en doğru denklemlerin türetilmesi, öğrenme, test ve tahmin değerlerinin kontrol edilmesi, vb. işlemlerin yapılması gerekmektedir. Pythia paket programı ile bu işlemler pratik bir şekilde gerçekleştirilebilmektedir (Özkan vd., 2013). Bu sebeple yapılan çalışmada Pythia paket programı kullanılarak YSA modeli oluşturulmuştur.

#### 3.2.1. Verilerin Pythia programına girilmesi

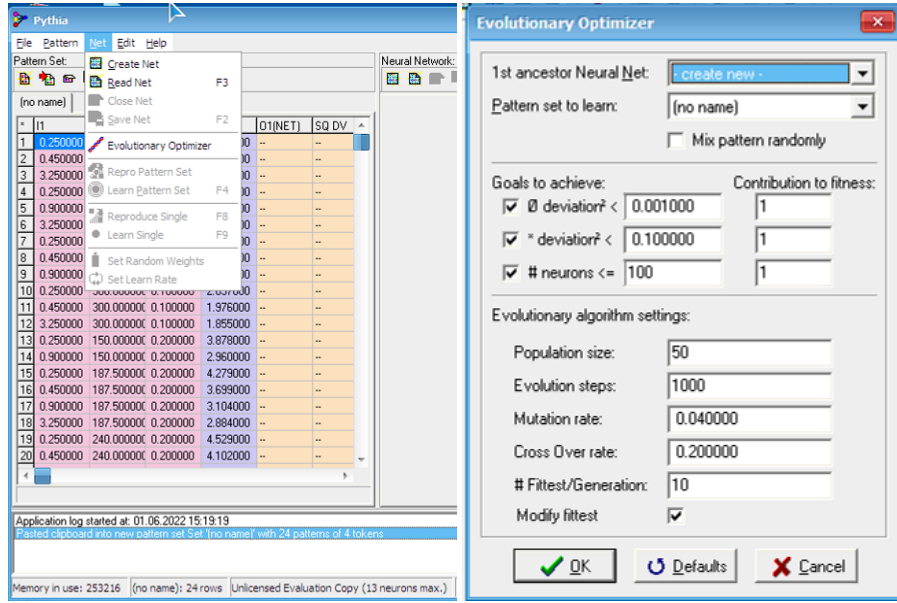
Pythia programında açılan boş bir sayfaya Tablo 3.1’deki veriler girilmiştir. Veri girişi tek tek yapılmasındansa, toplu yükleme komutları kullanılarak yapılması daha pratiktir. Verileri kopyaladıktan sonra program ara yüzüne “paste cell” komutuyla yapıştırmadan önce gelen ekranda aşağıdaki gibi 3 giriş ve 1 çıkış olmak üzere toplam 4 sütun kaydı için “Fields per record” alanına 4; bir çıktı alınacak olduğu için “outputs” alanına 1 değeri girilmiştir.



Şekil 3.2. Verilerin Pythia programına aktarılması

### 3.2.2. Uygun ağ yapısının araştırılması

Uygun ağ yapısını araştırmak amacıyla “Net” menüsünden “Evolutionary Optimizer” sekmesi seçilmiş ve en uygun ağ yapısına ulaşabilmek için ayarların yapılabildiği pencereye ulaşılmıştır. Çıkan pencerede “Population Size” (bir nesildeki birey sayısı ya da bir nesildeki deneme sayısı) sekmesine ve “Evolution Steps” (gelişim sayısı veya nesil sayısı) sekmesine gerekli değerler girilmiştir. Deneme sayısı (Population size) mümkün olduğu kadar artırılmalıdır. Böylelikle Pythia programı daha çok ağ yapısının uygunluğunu kontrol edip, optimum olası ağ yapıları hakkında öneriler sunabilir. Şekil 3.3. uygun ağ yapısına ulaşabilmek için kullanılan ayar penceresi görülmektedir.



Şekil 3.3. Uygun ağ yapısına ulaşabilmek için ayar penceresi

Yapılan ağ ayarlarına göre program tarafından belirlenen uygun ağ yapılarının gösterildiği “Evolutionary Optimization (Generation)” penceresi Şekil 3.4’te verilmiştir.

No	Topology	Neurons	Ø dev²	* dev²	Fitness
6	3,4,4,1	9	0.001003	0.004662	99.91438
7	3,5,4,1	10	0.000424	0.002965	100.00000
8	3,6,6,4,1	17	0.000961	0.005282	100.00000
9	3,5,6,5,1	17	0.000936	0.005446	100.00000
10	3,6,5,5,1	17	0.000698	0.004626	100.00000
11	3,6,5,1	12	0.000374	0.002700	100.00000
12	3,6,5,1	12	0.000550	0.002919	100.00000
13	3,6,6,5,1	18	0.000307	0.003337	100.00000
14	3,7,7,5,1	20	0.000296	0.002973	100.00000
15	3,6,5,1	12	0.000526	0.005234	100.00000
16	3,6,7,5,1	19	0.000132	0.001242	100.00000
17	3,6,7,5,1	19	0.000252	0.001343	100.00000
18	3,6,7,4,1	18	0.000595	0.004329	100.00000
19	3,5,7,4,1	17	0.000596	0.003684	100.00000
20	3,5,7,4,3,1	20	0.001328	0.012925	91.76146
21	3,5,7,4,3,1	20	0.000096	0.001262	100.00000
22	3,6,7,4,3,1	21	0.000395	0.001809	100.00000
23	3,6,7,4,3,1	21	0.001283	0.012588	92.64827
24	3,6,7,5,3,1	22	0.000502	0.002801	100.00000
25	3,6,7,5,3,1	22	0.000805	0.005312	100.00000

**Şekil 3.4.** Program tarafından belirlenen uygun ağ yapıları

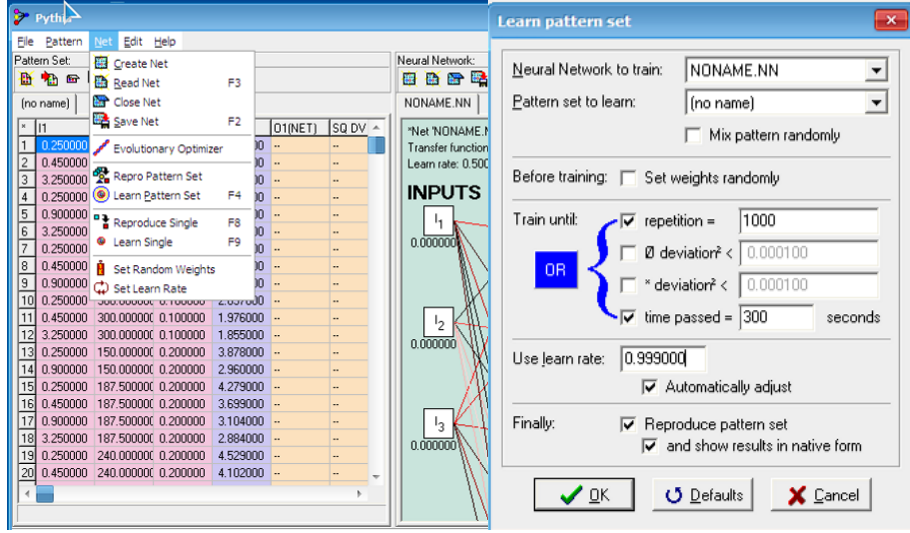
Uygun ağ yapıları Şekil 4'teki "Evolutionary Optimization (Generation)" penceresinde yeşil yuvarlak ile belirtilmiş ve "Fitness" değerleri 100 olarak gösterilmiştir. Program tarafından belirlen hesaplanabilmesi en uygun ağ yapıları;

- ✓ 3,5,4,1 max. dev² = 0,000427
- ✓ 3,6,5,1 max. dev² = 0,000374
- ✓ 3,6,5,1 max. dev² = 0,000550 olarak listelenebilir.

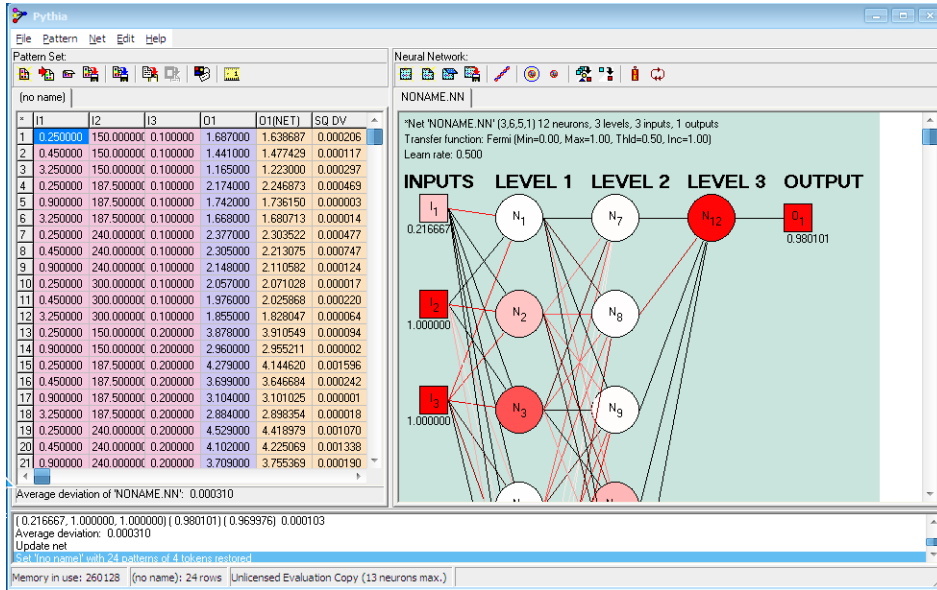
Bu ağ yapıları arasından da hesaplanabilme kolaylığı ve sapma miktarları dikkate alınarak, max. dev² değeri 0,000374 olan 3,6,5,1 ağ yapısı seçilmiştir.

### 3.2.3. Verilerin Pythia programına öğretilmesi

"Net" menüsünden "Creat net" ile belirlenen ağ yapısı oluşturulduktan sonra, ağın veri setindeki değerlere göre girişlerin çıkışa olan ağırlıklarını bulması için "Learn Pattern Set" komutu kullanılmıştır. Bu komutun içindeki ayarlardan "repetition" (tekrarlama sayısı) 100000 "time passed"(geçen süre) 300 "Use Learn Rate" (kullanılan öğrenme oranı) 0,9999 olarak alınmıştır. Verilerin programa öğretilmesi için ayar penceresi Şekil 5'te, yapılan ayarlar sonucunda program tarafından hesaplanan çıktılar, ağırlıklar ve ortalama sapma değerleri Şekil 6'da verilmiştir.



Şekil 3.5. Verilerin programa öğretilmesi için ayar penceresi



Şekil 3.6. Hesaplanan çıktılar, ağırlıklar ve ortalama sapma değerleri

Veri setinin eğitimi sonucunda program giriş değerlerine ve kullandığı ara nöronlara ait ağırlıkları bulunmuştur. Formüle dayalı çıkış değerleri ve ortalama sapma değeri program tarafından hesaplanmıştır. Bu değerleri öğrenen Pythia programının bu öğrenme işleminde ne kadar başarılı olduğunu ortalama sapma (average deviation) miktarları göstermektedir. Hesaplanan ortalama sapma değeri 0,000310'dur. Bu değer YSA'nın yapacağı tahminlerdeki hata payının çok az olacağını ortaya koymaktadır. Programın hesapladığı ortalama yüzey pürüzlüğü değerleri Şekil 6'daki "O1(NET)" veri sütununda verilmiştir. Yine şekil 6'da "SQ DV" sütununda, deneylerde ölçülen veriler ile sistemin öğrenme sonrası bulduğu veriler arasındaki fark görülmektedir.

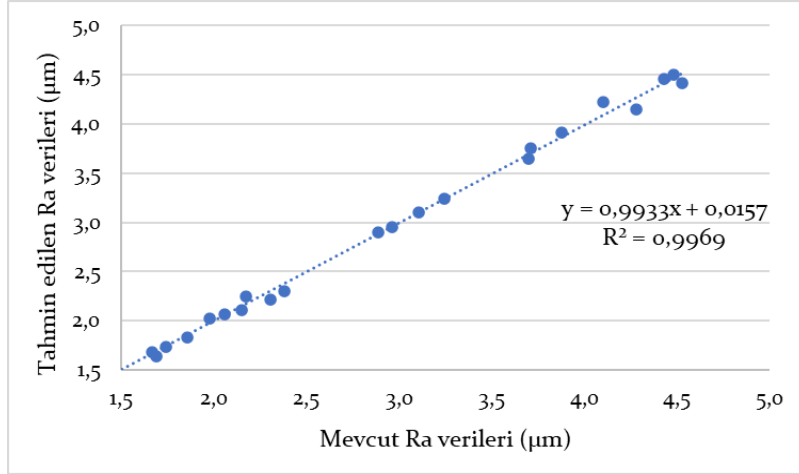
### 3.2.4. Mevcut çıktılarla Pythia ile tahmin edilen çıktıların karşılaştırılması

Pythia yazılımında deney verilerinin hepsi YSA oluşturmak için kullanılmamıştır. Deney verilerinin % 75'lik kısmı öğrenme için kullanılmıştır. Geri kalan % 12,5'lik bölümü test için ve % 12,5'lik bölümü de yapılan YSA tahminlerinin hata oranlarını görmek adına doğrulama işlemleri için kullanılmıştır. Dolayısıyla 32 adet deneyin içinden rastgele seçilen 24 adet deney öğrenmede kullanılmıştır. Tablo 3.2'de 24 adet deney ile ilgili ölçülen mevcut veriler (Q1) ile Pythia yazılımıyla tahmin edilen veriler ( $Q_{(NET)}$ ) görülmektedir. "SQ DV" sütunu ile bu iki veri seti arasındaki fark verilmiştir.

**Tablo 3.2.** Mevcut çıktılar ile Pythia ile tahmin edilen çıktıların karşılaştırılması

No	Q1	$Q_{(NET)}$	SQ DV	No	Q1	$Q_{(NET)}$	SQ DV
1	1,687	1,639	0,0002060	17	3,878	3,911	0,0000940
2	1,441	1,477	0,0001170	19	2,960	2,955	0,0000020
4	1,165	1,223	0,0002970	21	4,279	4,145	0,0015960
5	2,174	2,247	0,0004690	22	3,699	3,647	0,0002420
7	1,742	1,736	0,0000030	23	3,104	3,101	0,0000010
8	1,668	1,681	0,0000140	24	2,884	2,898	0,0000180
9	2,377	2,304	0,0004770	25	4,529	4,419	0,0010700
10	2,305	2,213	0,0007470	26	4,102	4,225	0,0013380
11	2,148	2,111	0,0001240	27	3,709	3,755	0,0001900
13	2,057	2,071	0,0000170	28	3,242	3,243	0,0000000
14	1,976	2,026	0,0002200	30	4,484	4,502	0,0000290
16	1,855	1,828	0,0000640	31	4,428	4,462	0,0001030

Şekil 3.7'ye bakıldığında mevcut veriler ile Pythia tarafından tahmin edilen verilerin %99 uyumlu olduğu ( $R^2= 0,9969$ ) açık bir şekilde görülmektedir.



Şekil 3.7. Mevcut çıktılar ile Pythia ile tahmin edilen çıktılarının uyumu

### 3.2.5. Çıktıların tahmininde kullanılan YSA modelinin test edilmesi

Pythia yazılımında oluşturulan 3,6,5,1 YSA modeli 3 giriş, 6 tane 1. seviye nöronu, 5 tane 2. seviye nöronu ve 1 tane 3. seviye çıkış nöronu olmak üzere toplam 12 tane nörona sahiptir. Buradaki her bir nöron için giriş, ağırlık ve çıkış değerleri yine program tarafından hesaplanmaktadır. Şekil 3.8 de Pythia programından alınan 1., 2. ve 3. seviyelerdeki nöronlara ait giriş, çıkış, ağırlık vb. değerleri görülmektedir.

Neuron 'N1_001'			Neuron 'N2_007'			Neuron 'N3_012'		
INPUTS	WEIGHTS	ACTIVITY	INPUTS	WEIGHTS	ACTIVITY	INPUTS	WEIGHTS	ACTIVITY
0.216667	0.473299	-1.740278	0.000128	1.057082	-0.608994	0.011705	-0.980791	1.474249
1.000000	-1.368408		0.226336	-0.264427		0.006353	0.617932	
1.000000	-0.474418		0.675610	-0.830898		0.010974	-1.333233	
		FERMI	0.000862	0.332048	FERMI	0.283385	-1.463485	FERMI
		OUTPUT	0.925345	0.041970	OUTPUT	0.909669	2.100944	OUTPUT
		0.000128	0.594661	-0.045473	0.011705			0.980101

Şekil 3.8. Mevcut çıktılar ile Pythia ile tahmin edilen çıktılarının uyumu

Şekil 3.8'de "N1\_001" 1. seviyedeki 1. nöron için, "N2\_007" 2. seviyedeki 7. nöron için ve "N3\_012" 3. seviyedeki 12. nöron için değerleri içermektedir. Bir nörona ait ağırlık sayısı aldığı giriş sayısı ile ilgilidir. Bunun için 1. seviye nöronlarının ağırlık sayısı modelin giriş sayısı olan 3'tür. 2. seviye nöronların ağırlık sayısı ise 1. seviye nöronların sayısı olan 6'dır. Benzer şekilde 3. seviye nöronların ağırlık sayısı da 2. seviye nöronların sayısı olan 5'tir. Program öncelikle belirlenen giriş değerlerini ve bu değerlere göre hesapladığı ağırlıkları kullanarak bir transfer fonksiyonu aracılığıyla çıkış değerleri oluşturmaktadır. Girişten alınan değerlerin ağırlıkları kullanılarak bir transfer fonksiyonundan geçmesiyle elde edilen çıkışlar 1. seviye nöronların giriş değerleri olmaktadır. Aynı şekilde 1. seviye nöronlara gelen giriş değerleri ile, o nöronlara ait ağırlıklar kullanılarak transfer fonksiyonundan geçmesiyle elde edilen çıkış değerleri de 2. seviye nöronlar için giriş değeri olarak kullanılır. Ve bu



şekilde tekrar eden aşamalarla son çıkış değeri elde edilir. Kullanılan transfer fonksiyonu ise “Fermi” adı verilen ve verdiği çıkış değerleri 0 ile 1 arasında değişen bir çeşit sigmoid fonksiyonudur.

$$N = \frac{1}{1 + e^{-4(\sum X_i \cdot W_i - 0,5)}} \quad (3.1)$$

Burada N çıkış değerini, X giriş değerini ve W ağırlık değerini ifade etmektedir. Pythia tarafından tahmin edilen çıkış değerlerini test etmek için toplan çıkış verilerin % 12,5’u test için ayrılır. Ve bu çıkış değerleri 0 ile 1 arasına gelecek şekilde normalize edilir. Normalizasyon fonksiyonu aşağıdaki gibidir.

$$X_N = \frac{x_i - x_{min}}{x_{mak} - x_{min}} \quad (3.2)$$

Maksimum ve minimum seviyeler için Pythia programının “pattern” menusünden “options” seçilir. Gelen ekrandaki veriler maksimum ve minimum değerlerdir. Test için ayrılan değerler, normalizasyon işleminden geçmiş halleri ve giriş değerlerinin maksimum ve minimum seviyeleri Tablo 3.3’te verilmiştir.

**Tablo 3.3.** Test için ayrılan veriler ve normalize edilmiş halleri

Tets için ayrılan veriler					Normalize edilmiş veriler			
No	I1	I2	I3	Q1	N_I1	N_I2	N_I3	N_Q1
3	0,9	150	0,1	1,530	0,216667	0	0	0,106569
12	3,25	240	0,1	1,929	1	0,600000	0	0,223066
18	0,45	150	0,2	3,631	0,066667	0	1	0,720000
29	0,25	300	0,20	4,590	0	1	1	1
<b>Max</b>	3,25	300	0,2	4,590	1	1	1	1
<b>Min</b>	0,25	150	0,1	1,165	0	0	0	0

Test işleminde yapılan hesaplamalar için Excel paket programı kullanılmıştır. Pythia programı aracılığıyla tespit edilen 1., 2. ve 3. seviyelerdeki nöronlara ait ağırlık değerleri, Excel’e girilir. Şekil 3,9’da Excel’e girilen tüm nöronlara ait ağırlıklar verilmiştir.

AĞIRLIKLAR (W)											
1. SEVİYE NÖRONLARI						2. SEVİYE NÖRONLAR					3. Sv. NR.
N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12
0,473299	1,003184	1,092065	-0,963908	2,283164	-0,981558	1,057082	-0,862022	1,091505	-0,234988	-1,030965	-0,980791
-1,368408	-0,509096	1,004079	-0,155262	-0,061867	-0,162289	-0,264427	-0,328161	-0,286306	0,680836	0,901531	0,617932
-0,474418	0,484461	-0,557276	-0,899765	0,696505	0,970777	-0,830898	-0,365303	-0,977194	-1,275049	-0,199301	-1,333233
						0,332048	-0,367216	0,843293	0,246246	0,779124	-1,463485
						0,041970	-0,05609	0,427601	1,457418	0,18917	2,100944
						-0,045473	-0,655332	-0,49919	-0,627909	1,399812	

Şekil 3.9. Pythia tarafından hesaplanan ağırlık değerlerinin Excel'e girilmesi

Bu ağırlıklar kullanılarak Fermi transfer fonksiyonu ile her nörona ait çıkış değerleri hesaplanmıştır. Şekil 10'daki fonksiyon satırında 3 numaralı kesme şartı için ilgili çıkışlar ve ağırlıklar kullanılarak transfer fonksiyonunun Excel'e uyarlanan formülü görülmektedir. Ayrıca test için ayrılan 4 şart için Excel'de hesaplan çıkış değerlerinin normalize hali N12 çıkış nöronun altında verilmiştir.

NÖRONLAR İÇİN HESAPLANAN ÇIKIŞ DEĞERLERİ												
	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12
3	0,169411	0,244055	0,258545	0,055442	0,494686	0,054646	0,094973	0,026136	0,164320	0,496998	0,236572	0,016213
12	0,032578	0,688026	0,991658	0,001969	0,999074	0,001804	0,003283	0,009047	0,008082	0,647289	0,581376	0,281495
18	0,022501	0,551160	0,019117	0,002854	0,801368	0,834982	0,071431	0,005477	0,052418	0,876500	0,994348	0,663528
29	0,000085	0,109239	0,447003	0,001985	0,631476	0,774510	0,025754	0,006884	0,012975	0,095832	0,945726	0,994693

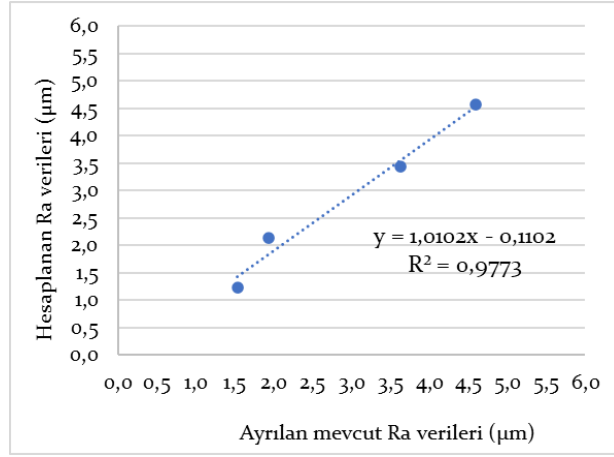
Şekil 3.10. Her nörona ait çıkış değerinin Excel ile hesaplanması

N12 nöronunda normalize olarak hesaplanmış çıkış değerleri normalizasyon formülünün tersi kullanılarak denormalize edilir. Tablo 3.4'te test için ayrılan çıkış değerleri (Q1) ve normalizasyon işleminden geçmiş halleri (N\_Q1) ile Fermi transfer fonksiyonu kullanılarak Excel'de hesaplanan normalize çıkış değerleri (N\_Q(HES)) ve denormalize halleri (Q(HES)) verilmiştir.

Tablo 3.4. Test için ayrılan çıktılar ile Fermi fonksiyonu ile hesaplan çıktılar

Ayrılan mevcut çıktılar		Fermi ile hesaplanan çıktılar		
No	Q1	N_Q1	Q(HES)	N_Q(HES)
3	1,530	0,106569	1,221	0,016213
12	1,929	0,223066	2,129	0,281495
18	3,631	0,720000	3,438	0,663528
29	4,590	1	4,572	0,994693

Şekil 3.11’de mevcut çıktılar ile Fermi transfer fonksiyonuyla hesaplanan çıktıların uyumu verilmiştir.



**Şekil 3.11.** Ayrılan mevcut çıktılar ile formülle hesaplanan çıktıların uyumu

Şekil 3.11’e bakıldığında mevcut çıktılar ile Fermi transfer fonksiyonuyla hesaplanan çıktıların yaklaşık %98 uyumlu olduğu ( $R^2 = 0,9773$ ) açık bir şekilde görülmektedir.

### 3.2.6. YSA modelinin tahmin performansının doğrulanması

Deneylede ölçülen mevcut çıktılar ile YSA modeli ile tahmin edilen çıktılar arasındaki sapma miktarı (hata) kullanılan YSA modelinin performansı hakkında bilgi verir (Özkan vd., 2013). Bu çalışmada söz konusu hata miktarlarının analizi için iki istatistiksel yaklaşım kullanılmıştır. YSA modelinin tahmin performansı ölçümünde kullanılan bu yaklaşımlar:

1. Hata Kareleri Toplamı (Sum of Squared Errors –SSE)

$$SSE = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (3.3)$$

2. Mutlak Değişim Yüzdesi ( $R^2$ )

$$R^2 = 1 - \left[ \frac{\sum_i (X_i - \bar{x})^2}{\sum_i (\bar{x})^2} \right] \quad (3.4)$$

Burada  $x_i$  mevcut veriyi,  $\bar{x}$  YSA modeli tarafından tahmin edilen veriyi ve  $n$  değerlendirilen veri sayısını ifade etmektedir. (Çavuş & Sarıkaya, 2021)

Mevcut çıktılarının %12,5’i doğrulama için kullanılmıştır Doğrulama için ayrılan veriler ve bu verilere göre YSA modelinin hesapladığı çıktılar ( $Q_{(NET)}$ ) Tablo 3.5’teki gibidir.

**Tablo 3.5.** Doğrulama için ayrılan veriler ile YSA'da hesaplanan çıktıları

No	I1	I2	I3	Q1	Q <sub>(NET)</sub>
6	0,45	187,5	0,10	1,842	1,962648
15	0,90	300	0,10	1,928	1,986855
20	3,25	150	0,20	3,102	3,091547
32	3,25	300	0,20	4,090	4,058900

Doğrulama yaklaşımlarının (SSE ve R<sup>2</sup>) 6 numaralı kesme şartı için örnek uygulaması aşağıdaki gibidir:

$$SSE = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{1} (1,842 - 1,963)^2 = \mathbf{0,01464}$$

$$R^2 = 1 - \left[ \frac{\sum_i (X_i - \bar{x})^2}{\sum_i (\bar{x})^2} \right] = 1 - \left[ \frac{(1,842 - 1,963)^2}{1,963^2} \right] = \mathbf{0,9962}$$

Her iki yaklaşımı kullanılarak doğrulama adına ayrılan 4 kesme şartı için yapılan hesaplamalar sonunda elde edilen veriler Tablo 3.6'da verilmiştir.

**Tablo 3.6.** YSA modelinin performans ölçümünde yapılan doğrulama işlemleri

Çıktılar			Doğrulama	
No	Q1	Q <sub>(NET)</sub>	SSE	R <sup>2</sup>
6	1,842000	1,962648	0,01464	0,99619
15	1,928000	1,986855	0,00346	0,99912
20	3,102000	3,091547	0,00011	0,99998
32	4,090000	4,058900	0,00097	0,99994
<b>Ortalama</b>			<b>0,004795</b>	<b>0,99881</b>

Kullanılan YSA modelinin yüksek bir performansa sahip olabilmesi için SSE'de hesaplanan değerlerin 0'a yakın olması istenirken, R<sup>2</sup>'de hesaplanan değerlerin 1'e yakın olması istenir. Tablo 3.6'da 4 farklı kesme şartı için hesaplanan R<sup>2</sup>'lerin ortalaması olan 0,99881 değerinin bire çok yakın olduğu görülmektedir. Benzer şekilde farklı 4 şart için hesaplanan SSE'lerin ortalaması olan 0,004795 de sıfıra yakın bir değerdir. Dolayısıyla kullanılan YSA modelinin performansı ölçülmüş ve bu modelle doğruya yakın tahminler yapılabildiği iki istatistiksel yöntem (SSE ve R<sup>2</sup>) ile teyit edilmiştir.

## TARTIŞMA VE SONUÇ

Yapay zeka, insan zekasının karar verme kabiliyetinin modellenip bilgisayarlara veya bilgisayar kontrollü makinelere kazandırılması için geliştirilen bir yaklaşım olarak tanımlanabilir. Yapay sinir ağı (YSA) ise, yapay zeka alanında en çok kullanılan yöntemlerden biridir. Bir insan zekasından faydalanılarak yapay zekanın modellenebilmesi için, insan sinir sisteminin nasıl çalıştığına çok iyi bilinmesi gerekir. Biyolojik bir sinir ağı için bir sinir hücresi (nöron) yapay sinir ağına perceptrona (algılayıcı) karşılık gelir. Bir nöron hücresinin ve perceptron modelinin kısımları incelendiğinde nöronda dendritlere gelen her bir sinyal perceptronda giriş değerlerine karşılık gelir. Nöronda sinaps ve dendrit direncine bağlı faktörler perceptronda ağırlık değerlerine karşılık gelir. Nöronda tüm dendritlerden gelen sinyallerin gövdede toplanması perceptronda toplam dizisine karşılık gelir. Nöronda eşik değer karşılaştırması ise perceptronda aktivasyon fonksiyonuna karşılık gelmektedir.

Son yıllarda çok geniş bir alanda kullanılan yapay zeka uygulamaları imalat alanında da kullanılmaya başlanmıştır. Bu çalışmada talaşlı imalat alanında yapılan deneysel bir araştırmadan elde edilen sonuçlar YSA ile analiz edilmiştir. Deneylerde AA2024 alüminyum alaşımlarının tornalanmasında minimum miktarda yağlama (MMY) yönteminin ve kesme parametrelerinin yüzey kalitesine etkisi incelenmiştir. Tam faktöriyel tertibine göre yapılan deneylerde, uygulanan kesme sıvısı debisi (Db), kesme hızı (Vc) ve ilerleme (f) olmak üzere, 3 farklı işlem parametresi için elde edilen yüzey pürüzlüğü (Ra) sonuçları incelenmiştir. Deneyler sonucunda ilerleme parametresinin ortalama yüzey pürüzlüğü üzerindeki en etkili parametre olduğu açık bir şekilde görülmüştür. Düşük ilerleme şartlarında yüzey kalitesi, yüksek ilerleme şartlarından çok daha iyi çıkmıştır. Özellikle yüksek ilerleme şartlarında kesme hızı ve uygulanan debinin yüzey kalitesi üzerindeki etkisi biraz daha belirgin olmuştur. Bu şartlar altında yüksek debi ve düşük kesme hızı kullanıldığında daha iyi yüzey kalitesi elde edildiği gözlenmiştir.

Ortalama yüzey pürüzlüğü sonuçlarının değişen kesme şartları ile birlikte anlamlı bir değişim yaşadığı ve bu ilişkinin YSA'da öğretilmesinin mümkün olabileceği düşünülmüştür. YSA modelini oluştururken uygun ağ yapısının belirlenmesi, en doğru denklemlerin türetilmesi, öğrenme, test ve tahmin değerlerinin kontrol edilmesi, vb. işlemlerin yapılması gerekmektedir. Pythia paket programı ile bu işlemler pratik bir şekilde gerçekleştirilebildiği için bu çalışmada YSA modeli oluşturulurken Pythia yazılımından faydalanılmıştır. Kullanılan YSA modeli ileri beslemeli çok katmanlı YSA modelidir. Pythia yazılım aracılığıyla maksimum sapma değeri 0,000374 olan 3,6,5,1 ağ yapısı kullanılmıştır. YSA modelinde kullanılan aktivasyon fonksiyonu "Fermi" adında bir sigmoid-lojistik fonksiyondur. Bu fonksiyonda veriler 0 ila 1 arasında değişir ve normalize edilmiş veriler kullanılır.

Deneylelerden elde edilen verilerin bir kısmı YSA modelini test etme ve doğrulama için ayrıldıktan sonra, kalan kısmı öğrenme işleminde kullanılmıştır. Öğrenme işleminden sonra programın tahmin ettiği veriler ile mevcut veriler arasında %99,7'lik bir uyum olduğu görülmüştür. YSA modelinin yaptığı bu tahminler ayrılan verilerle de test edilmiştir. Yapılan testte %97,7 oranında bir uyum görülmüştür. Daha sonra modelin tahmin performansını ölçmek için “Hata Kareleri Toplamı (Sum of Squared Errors -SSE)” ve “Mutlak Değişim Yüzdesi ( $R^2$ )” olmak üzere iki ayrı doğrulama yöntemi kullanılmıştır. Kullanılan YSA modelinin yüksek bir performansa sahip olabilmesi için  $R^2$ 'de hesaplanan değerlerin 1'e yakın olması istenir. Doğrulama için kullanılan kesme şartları ile ilgili hesaplanan  $R^2$ 'lerin ortalaması 0,99881 çıkmıştır. Bu değer 1'e çok yakın olduğu görülmektedir. Kullanılan YSA modelinin yüksek bir performansa sahip olabilmesi için SSE'ler için hesaplanan değerlerin ise 0 (sıfır)'a yakın olması istenir. Doğrulama için hesaplanan SSE'lerin ortalaması 0,004795 çıkmıştır. Bu değer de sıfıra yakın bir değerdir. Dolayısıyla kullanılan YSA modelinin performansı ölçülmüş ve bu modelle doğruya yakın tahminler yapılabildiği iki yöntem (SSE ve  $R^2$ ) ile teyit edilmiştir. Böylece, bu çalışmayla imalat alanında bir YSA uygulaması başarılı bir şekilde gerçekleştirilmiştir.

**KAYNAKÇA**

- Ağar, S. (2014). AA 7075-T6 Alüminyum Alaşımının Minimum Miktarda Yağlama Yöntemiyle Talahlı İşlenebilirliğinin Araştırılması. [Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Makine Eğitimi Anabilim Dalı].
- Altun, H., Eminoglu, U. & Tezekici, B. S. (2022). MLP Yapay Sinir Ağlarında Öğrenme Sürecinin Aktivasyon Fonksiyonu ve İstatiksel Değişim Gösteren Giriş Verilerine Bağımlılığı. [https://www.emo.org.tr/ekler/490c742cd8318b8\\_ek.pdf](https://www.emo.org.tr/ekler/490c742cd8318b8_ek.pdf), Alınma tarihi: 31/05/2022
- Arı, A., & Berberler, M. E. (2017). Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı. *Acta Infologica*, 1(2), s:55-73, İstanbul University Press.
- Ataseven, B. (2013). Yapay Sinir Ağları ile Öngörü Modellemesi, *Öneri Dergisi*, Cilt:10, Sayı:39, 101-115.
- Bear, M. F., Connors, B. W., & Paradiso, M. A. (2007). *Neuroscience: Exploring the Brain* (3rd ed.). Lippincott Williams & Wilkins.
- Çakır, A. (2015). AA 7075 ve AA 2024 Alüminyum Malzemelerine Delik Delinmesinde Soğutma Yöntemlerinin İşleme Performansına Etkilerinin İncelenmesi. [Doktora tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü].
- Çakır A., Yağmur, S., Kavak, N., Küçüktürk, G., Şeker, U. (2016). The effect of minimum quantity lubrication under different parameters in the turning of AA7075 and AA2024 aluminium alloys. *Int. J. Manufacturing Technology*, 84, 2515-2521.
- Çavuş, V., & Sarıkaya, M. (2021). Yapay Zeka Uygulamalarında Güncel Konular ve Araştırmalar: Yapay Sinir Ağları ve Güneş Enerji Sistemlerinde Uygulamaları. 7-22, Çizgi Kitabevi.
- Dayan, P., & Abbott, L. F. (2005). *Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems*. Massachusetts Institute of Technology (MIT) Press.
- Elmas, Ç. (2007). Yapay Zeka Uygulamaları. Seçkin Yayınevi.
- Günan, F. (2019). Hastelloy C276 Alaşımının Frezelenmesinde Minimum Miktarda Yağlamanın Yüzey Pürüzlülüğü ve Takım Aşınması Üzerindeki Etkilerinin Araştırılması, [Yüksek Lisans Tezi, Düzce Üniversitesi, Fen Bilimleri Enstitüsü, İmalat Mühendisliği Anabilim Dalı].
- Gürbüz, H., Baday, Ş. & Gönülaçar, Y. E. (2017). Minimum Miktarda Yağlamanın Frezeleme İşlemleri Üzerine Etkisinin Araştırılması. *Batman Üniversitesi Yaşam Bilimleri Dergisi*, Cilt 7 Sayı 2/2, 59-79.
- Holmes, K. (2008). Minimum Quantity Lubrication (MQL) is a Key Technology to Lower Manufacturing Costs for Automotive, Aerospace, Defense and Other Industries. *Manufacturing Business and Technology Forum*, Dearborn, MI.
- Kandel, E.R., Schwartz, J.H., Jessell, T.M., Siegelbaum, S.A., Hudspeth, & A.J. (2013). *Principles of Neural Science* (5th ed.). The McGraw-Hill Companies.
- Mills, B., & Redford, A.H. (1983). *Machinability of Engineering Metaterials*. Applied Science Publishers.
- Nguyen, T.T., Nguyen, T.A., Trinh, Q.H., Le, X.B., Pham, L.H., & Le, X.H. (2022). Artificial neural network-based optimization of operating parameters for minimum quantity lubrication-assisted burnishing process in terms of surface characteristics, *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-021-06834-6>
- Özkan, M. T., Eldem, C., Köksal, E. (2013). Eğilme Gerilmesi Etkisindeki Millerin Çentik Faktörünün Yapay Sinir Ağları ile Belirlenmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, Cilt 19, Sayı 1, 24-32.
- Purves, D., Augustine, G. J., Fitzpatrick, D., Hall, W. C., LaMantia, A-S., & White, L. E. (2012). *Neuroscience* (5th ed.). Sinauer Associates.
- Sönmez, M., Ertunç, H. M. & Karakuzu, C. (2022). Kesici Takım Aşınma Durumunun Yapay Sinir Ağı Kullanılarak Belirlenmesi [https://www.emo.org.tr/ekler/6a1fa88adb5c33b\\_ek.pdf](https://www.emo.org.tr/ekler/6a1fa88adb5c33b_ek.pdf) Alınma tarihi: 31/05/2022
- Squire, L., Berg, D., Bloom, F., Du Lac, S., Ghosh, A., & Spitzer, N. (2008). *Fundamental Neuroscience* (3rd ed.). Elsevier.
- Tosun, N., Kuru, C., Altıntaş, E. & Erdin, E. O. (2010). Hava ve Geleneksel Soğutma Yöntemi ile Frezelemede Yüzey Pürüzlülüğünün İncelenmesi. *Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, Cilt 25, No 1, 141-146.
- Trappenberg, T. P. (2010). *Fundamentals of Computational Neuroscience* (2nd ed.). Oxford University Press.


# BÖLÜM

## 2

### ENDÜSTRİ 4.0 için YAPAY ZEKA UYGULAMALARI


**Salih DAĞLI**


*Öğr. Gör., Sinop Üniversitesi, sdagli@sinop.edu.tr*

 0000-0003-3805-5130

**Yakup İRİM**

*Öğr. Gör., Sinop Üniversitesi, yirim@sinop.edu.tr*

 0000-0002-1267-7153






## BÖLÜM 2

### ENDÜSTİRİ 4.0 için YAPAY ZEKA UYGULAMALARI


**Salih DAĞLI**

*Öğr. Gör., Sinop Üniversitesi, sdagli@sinop.edu.tr*

 0000-0003-3805-5130

**Yakup İRİM**

*Öğr. Gör., Sinop Üniversitesi, yirim@sinop.edu.tr*

 0000-0002-1267-7153

### GİRİŞ

Yapay zeka (Artificial Intelligence, AI), başta insanlar olmak üzere canlıların gerçekleştirebildiği yüksek bilişsel fonksiyonlar ile otonom davranışların, geniş kapsamda yapay sistemler, dar kapsamda da makineler ve yazılımlar tarafından gerçekleştirilmesi üzerine çalışan teknoloji alanıdır. Yapay zeka teknolojilerinin uygulamaları, malzeme tedarikinden pazarlamaya, ürün tasarımı, ürün kalitesini, performansı ve personel planlamasından çalışan refahını en üst düzeye çıkarmaya kadar çeşitli iş kolları ve seviyelerinde çalıştığı için endüstriyel üretimde sahip olduğu yetenekler önem arz etmektedir. Yapay zeka alanındaki gelişmeler, günümüz teknolojisinin merkezinde yer alır ve robotların daha fazla hesaplama görevini yönetmesine ve Endüstri 4.0 için gerçek zamanlı olarak çevresel verilere dayalı bağımsız kararlar alınmasına olanak sağlamaktadır. Yapay zeka, üretim yöntemleri, zaman planlaması ve bütçe kontrolü gibi birçok farklı kriterleri yönetmektedir. Fikirler ve diğer temel görevler, makine öğrenmesi (Machine Learning, ML) kullanılarak yönetilebilir ve değerlendirilebilir, bu da nihai işlemlere ilişkin daha fazla bilgi sağlamaktadır. Yapay zeka uygulamaları, Endüstri 4.0'da üretim sorunlarını tahmin etmek için ve endüstriyel makinelerin tahmine dayalı yönetimini sağlamak amacıyla fabrikalarda kullanılmaktadır. Yapay zeka, endüstriyel üretimde firmalara, plansız kalma sürelerini önlemek için tesislerin zamanında bakımı ve onarımı gibi önemli işlemlerde faydalar sağlamaktadır (Bécue vd., 2021; X. Yao vd., 2017).

Yapay zeka algoritmaları, işletmelerin üretim tedarik zincirlerini en üst düzeye çıkarmak için pazarlardaki değişimlerin tahmin edilmesine yardımcı olmaktadır. Yapılan bu tahminler rakiplere karşı üstünlük kurmayı sağlamaktadır. Yapay zeka algoritmaları, güncel satış trendlerini, sosyo-ekonomik ve makroekonomik değişkenleri, çevresel modelleri, durum politikasını, müşteri davranışını ve daha fazlasını araştırarak pazar taleplerini tahmin edebilmektedir. Algoritmalarından elde edilen

veriler, üreticilerin üretim kesintilerini azaltmalarına ve üretim hatlarının genel çalışma etkinliğini optimize etmelerine olanak tanımaktadır. Ek olarak, yapay zeka ve bilgisayarlar, makine özelliklerinin tahmine dayalı bir analiz üreterek ve nihai olarak üretim hatlarını düzene sokarak kalite yönetimini ve standardizasyonu artırabilmektedir. Yapay zeka uygulamaları ile tüm sektörler artık hızlı, veriye dayalı kararlar alabilir, üretim süreçlerini basitleştirebilir, işletme maliyetlerini en aza indirebilir ve müşteri hizmetlerini iyileştirebilir (Dal Mas vd., 2019; Gupta vd., 2022; Haenlein vd., 2019).

Yapay zeka sistemlerine sahip akıllı fabrikalar ile üretim, eşsiz bir şekilde uyumlu çalışacak, işletme maliyetlerini azaltacak, kaliteyi yükseltecek ve müşteri hizmetlerini iyileştirecektir. Yapay zeka ile endüstriyel üretimde olası gecikmeler tahmin edilebilmesi için stoklar takip edilip envanterler güncellenmesi sağlanacak, teslimat süreçleri tahmin edilerek de en yüksek kalitede üretim gerçekleştirilmesi ile olası sorunlar önlenebilecektir. Üretim sürecinde ortaya çıkabilecek hataların tespitinde bilgisayar destekli görüntüleme sistemleri kullanılmaktadır. Bu noktada yapay zeka yardımı ile Endüstri 4.0 sistemleri kullanılan endüstriyel üretim tesislerinde kalite sorunlarına yol açabilecek üretim hatalarının önlenmesini sağlanmaktadır (Javaid & Haleem, 2019; Sanchez vd., 2020; Wan Ibrahim & Hassan, 2019).

Derin öğrenme (Deep Learning, DL) ve yapay sinir ağlarında yer alan gelişmiş AI algoritmaları, üretim işlemlerinde gerçekleştirilecek arızaları formüle etmek için onarım tahmin sistemi kullanılır. Kalite kontrolünde, ürün kalitesi için meydana gelen üretim kusurlarını üretim ekiplerine bildirmek için yapay zeka algoritmaları kullanılmaktadır. Bu algoritmalar, makine davranışlarında meydana gelen anormallikleri, hammaddelerdeki değişiklikleri vb. analiz edebilir. Yapay sinir ağı entegrasyonları ile çizikler, çatlaklar, sızıntılar ve çeşitli yüzey kusurları tespit edebilir. Yapay zeka algoritmaları, kalite yönetimi için üretim birimlerini olası üretim hataları konusunda uyarmak için kullanılır ve bu da ürün kalitesinde iyileşmeyi sağlar (Bousdekis vd., 2020; G. -J. Cheng vd., 2016; Koh vd., 2019).

Bu çalışmanın amacı, Endüstri 4.0 teknolojisi ile yapay zeka teknolojisi arasındaki bağlantıya ışık tutmak ve yapay zeka tabanlı uygulamaların Endüstri 4.0 teknolojisine kazandırmış oldukları avantajların ve dezavantajların araştırılmasıdır. Endüstri 4.0 ile yapay zeka teknolojilerinin entegrasyonunu sağlayan önemli teknolojik gelişmeler değerlendirilmiştir. Yapay zekanın sahip olduğu avantajlarının ve paydaşların, yeni üretim düzenine ihtiyaç duyduklarında otomasyon sistemlerinin tasarımında, kalite kontrolünde, olası hataların öngörülmesinde, ürün dağıtım hatlarının oluşturulmasında ve daha birçok benzer faaliyetlerde kullanılabileceklerini gösteren çalışmalar incelenmiştir. Endüstri 4.0 ile yapay zekanın aralarındaki ilişkiyi farklı şekillerde ele alan makalelerin bazılarında çalışmamızda yer verilmiştir. Literatürde yer alan konu ile alakalı makalelerin incelenmesi

sonucunda, yapay zeka tarafından sağlanan avantajlar Endüstri 4.0'ın çeşitli hedeflerini kademeli olarak gerçekleştirmesinde katkıda bulunduğu gözlenmiştir.

## YÖNTEM

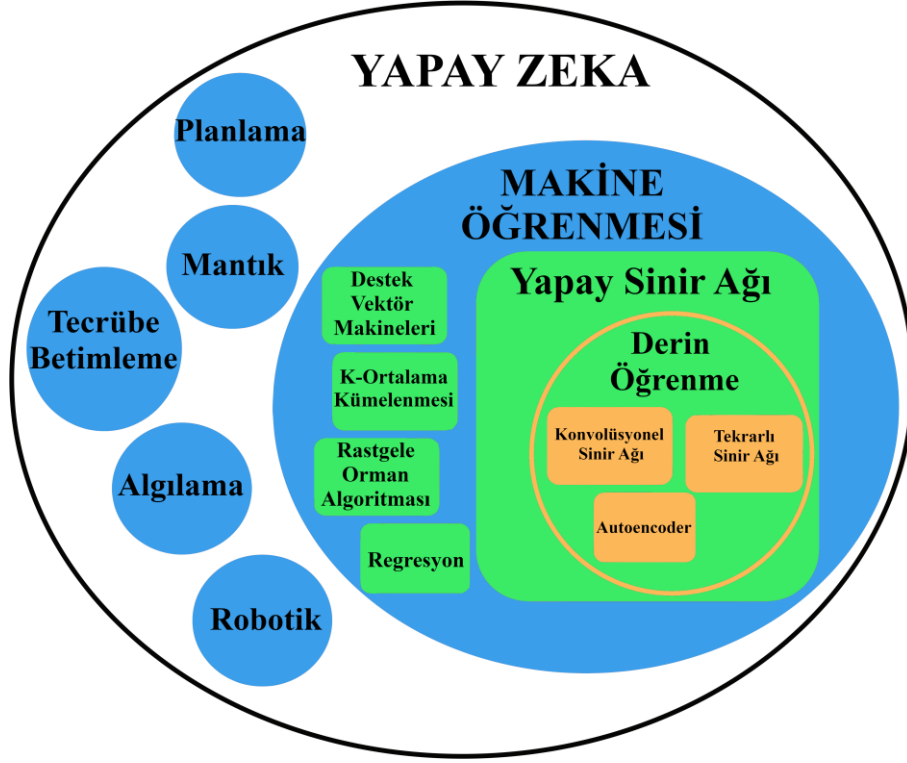
Endüstri 4.0'da kullanılan yapay zeka uygulamalarının daha net kavranması için öncelikle yapay zeka kavramının ve günümüzde sıkça karşımıza çıkan makine öğrenmesi ve derin öğrenme alt kümelerinin tanımlanması gerekmektedir. Yapay zeka uygulamalarında problemde çözüme çözüm yetenekleri birbirlerinden farklı modeller literatürde bulunmaktadır. Makine öğrenmesi, yapay sinir ağları ve derin öğrenme modellerinin ve bu modellere ait algoritmaların kısaca tanımlarına bu bölümde yer verilmiştir.

## YAPAY ZEKA

İlk olarak 1950'lerde ortaya çıkan "yapay zeka" kavramı, başlangıçta makinelerin insan zekasını referans alarak karar verme yapısına sahip olmaları olarak basit bir teori olarak ortaya çıkmıştır (Turing, 2009). Yazılımların, sistemlerin, makinelerin veya cihazların canlılara özgü olan algılama, gelişme, anlama ve kendi deneyimlerinden öğrenme gibi özelliklere sahip olmasını tanımlayan bir teknoloji alanı olarak yaşam sürecine devam etmektedir. Günümüzde gerçekleşen teknolojik gelişmeler ile yapay zeka olağanüstü bir şekilde salt teoriden somut uygulamalara geçiş yapmıştır (Abduljabbar vd., 2019; S. Zhao vd., 2021). İş hayatından gündelik hayata kadar birçok farklı alanda kendisine çok geniş kullanım yelpazesi oluşturmuştur. Otonom araçların kontrollerinde, büyük veri setlerinin değerlendirilmesinde, video izleme önerilerinde, üretim robotlarında, medikal alanda hastalık değerlendirilmesinde gibi farklı alanlarda kullanılmaktadır.

Yapay zeka, normalde insanlar tarafından gerçekleştirilen düşünsel görevleri otomatikleştirme çabasıdır. Bu nedenle, yapay zeka içerisinde makine öğrenimi ve derin öğrenmeyi kapsayan en genel (evrensel) kümedir. Makine öğrenmesi ve derin öğrenme yöntemleri uygun veri setleri ile insan gibi düşünerek karar verme yeteneğine sahip yöntemler olarak yapay zeka alanında kendilerine yer bulmaktadır (Janiesch vd., 2021). Bunun yanı sıra, herhangi bir öğrenmeyi içermeyen daha birçok yaklaşım da yapay zeka olarak tanımlanmaktadır. Örneğin ilk yapılan satranç programları, yalnızca programcılar tarafından kodlanmış sabit kuralları içerdikleri için programcı tarafından önceden karar verilmiş hamleleri gerçekleştirebilmişlerdir (Berliner, 1978). Makine öğrenmesi, yapay sinir ağları ve derin öğrenme gibi yapay zekanın alt kümeleri içerdikleri farklı algoritma modelleri ile sınıflandırma, kümeleme, regresyon ve boyut azaltma gibi işlemleri otomatik olarak gerçekleştirebilmektedirler. Makine öğrenmesi içerisinde denetimli ve denetimsiz olmak üzere iki farklı gruba ayrılırken, yapay sinir ağları temel olarak insan sinir ağının yapıtaşısı olan nöronları taklit ederek geliştirilmiş modellerdir. Derin öğrenme, yapay sinir ağlarının alt kümesinde yer alıp, yapı olarak nöronları

referans almasına karşın 2B ve 3B gibi büyük verilerin işlenmesinde çok yüksek başarıya sahiptir. Yapay zeka ve içerisinde yer alan alt kümeler ve kümelere ait bazı algoritmalar Şekil 1'de gösterilmiştir.



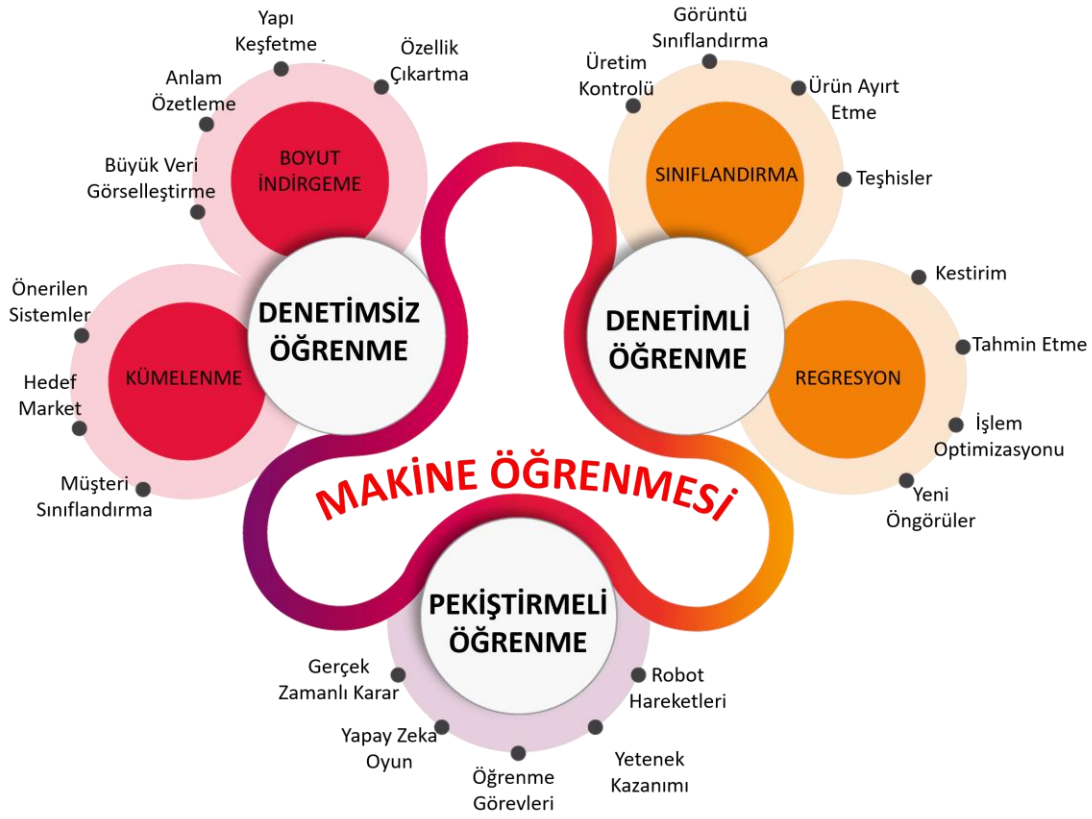
Şekil 1: Yapay zeka ve alt kümeleri

Yapay zeka insanlar gibi dış etkenlerden etkilenmemesi ve yorulmaması (7/24 çalışabilme yeteneği) gibi özellikleri göz önüne alındığı zaman endüstriyel üretim sistemlerinde ya da farklı çalışma dallarında insanlardan daha iyi performans verebilmektedir. Ayrıca, yapay zeka ile robotların kritik veya tehlikeli hammaddelerin taşınması veya mikroskobik öğelerin yerleştirilmesi gibi insanların gerçekleştirmekte zorluk çekebileceği ya da insan sağlığı için istenmeyen durumların ortaya çıkabileceği eylemlerin gerçekleştirilmesi kullanılmaktadır. Endüstriyel robotların kullanımının üretimde sağlamış olduğu faydalar bulunmakla birlikte bu robotların insanlar gibi akıllı olmadıkları göz önüne alınarak her eylemde görevlendirilmemeleri gerekmektedir.

## **Makine Öğrenmesi (Machine Learning, ML)**

Makine öğrenmesi, deneyimlerden bilgi edinmek için önceki verilerden otomatik olarak öğrenebilen ve yeni verilere dayalı tahminler yapmak için öğrenme davranışını kademeli olarak iyileştirebilen bir yazılım geliştirmeyi amaçlayan çok pratik bir yapay zeka alanıdır (Langley & Carbonell, 1984). En büyük zorluklar anlamlandırma, bağlamı anlama ve belirsizlik altında karar vermektir (Carbonell vd., 1983). Makine öğrenmesi, yapay zekanın gücü olarak görülebilir ve makine öğrenimi yöntemlerinin büyük veriler için benimsenmesi daha fazla kanıta dayalı karar vermeye yol açar (Jordan & Mitchell, 2015). Makine öğrenimindeki muazzam ilerleme, büyük veri setlerinin mevcudiyeti ve düşük maliyetli hesaplama ile yeni istatistiksel öğrenme algoritmalarının geliştirilmesiyle sağlanmıştır (Abadi vd., 2016). E-posta için bir spam filtresi, makine öğreniminin erken bir örneğidir. Makine öğrenmesi genellikle eski algoritmaların yerini almaktadır. Makine öğrenimi algoritmalarının çeşitliliğine rağmen, muhtemelen veriler seçilen algorithmadan daha önemlidir. Yetersiz veri, düşük veri kalitesi, yanlış veri, eksik veri, alakasız veri, yinelenen veri değerleri vb. gibi verilerle ilgili birçok sorun ortaya çıkabilir.

ML, talimatlardan ziyade deneyimlerden veya veri kümelerinden öğrenmektedir. ML tabanlı yöntemler, eğitim yoluyla sistem sonuçlarını otomatik olarak öğrenir ve geliştirir (Ang vd., 2017). Bu yöntemler, her tanınabilir model için nihai çıktıyı inceler ve bir çıktı sağlamak için tersine mühendislik yönlerini aramaktadır. Önceki deneyimlere dayalı olarak nasıl sonuç ve kararların alınacağına dair bir sistem geliştirmektedir (Bougdira vd., 2020). ML yöntemleri temel olarak denetimsiz, denetimli ve yarı denetimli yaklaşımlarında kategorize edilmektedir. Denetimli öğrenme, bir veri kümesindeki elemanların içeriğini tanımlayan bir etikete sahip olduğu anlamına gelmektedir. Denetimsiz öğrenme, tipik olarak kümeleme algoritmaları için geçerli olan etiketlenmemiş verileri içermektedir. Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenmenin bir birleşimidir: bazı veri noktaları etiketlenir ve bazıları etiketlenmez. Bir teknik, etiketlenmemiş verileri sınıflandırmak (yani etiketlemek) için etiketlenmiş verileri kullanmayı içerir, ardından bir sınıflandırma algoritması uygulanabilmektedir (Sarker, 2021). Makine öğrenmesinin öğrenme tipleri ve bu tiplerin kullanılabileceği uygulamalara örnekler Şekil 2'de gösterilmiştir.



**Şekil 2:** Denetimli ve denetimsiz makine öğrenme algoritmaları

Makine öğrenmesi, regresyon, sınıflandırma ve kümeleme olarak üç algoritma türüne ayrılmaktadır. **Regresyon**, sayısal nicelikleri tahmin etmek için denetimli bir öğrenme tekniğidir. Makine öğrenimindeki regresyon algoritmaları, lineer regresyon ve genelleştirilmiş lineer regresyonu içermektedir. **Sınıflandırma** algoritmaları da denetimli bir öğrenme tekniğidir, ancak sınıflandırma kategorik nicelikleri tahmin etmek için kullanılmaktadır. Günümüzde yaygın olarak kullanılan sınıflandırma algoritmalarına örnek olarak karar ağaçları (decision tree), rastgele orman (random forest), k-en yakın komşu (k-NN), lojistik regresyon (logistic regression) ve destek vektör makineleri (support vector machines) algoritmaları verilebilir (Sen vd., 2020). **Kümeleme**, benzer verileri bir arada gruplamak için denetimsiz bir öğrenme tekniğidir. Kümeleme algoritmaları, veri noktalarının yapısını bilmeden veri noktalarını farklı kümelere yerleştirmektedir. Kümeleme algoritmalarına örnek olarak k-Ortalama (k-Means), hiyerarşik sınıf analizi (hierarchical cluster analysis), beklenti maksimumu (expectation maximization) yöntemleri verilebilir (Rodriguez vd., 2019).

### Derin Öğrenme (Deep Learning, DL)

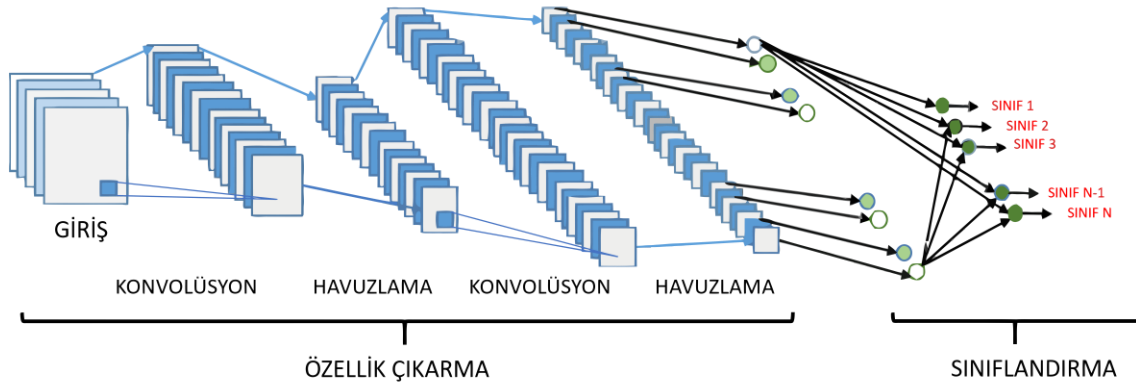
Sinir ağları, insan sinir hücreleriyle neredeyse aynı ilkeler üzerinde çalışır. Bir grup yöntem veya algoritma, farklı temel değişkenler arasındaki korelasyonu elde eder ve verileri bir insan beyninin yaptığı gibi hazırlar. Derin öğrenme, sinir ağı mimarilerini eğitmek için yeni ve karmaşık

yaklaşımlar sağlamıştır. Genel olarak, derin öğrenme algoritmaları da denetimsiz ve denetimli öğrenme metodolojileri ile eğitilebilir. Makine öğrenmesinde olduğu gibi denetimli öğrenmede, derin öğrenme modellerini eğitmek ve sınıflandırma veya regresyon için bir hedef değeri tahmin etmek için hatayı en aza indiren ağırlıkları öğrenmesi gerekmektedir. Bunun için etiketli veriler kullanılırken, denetimsiz öğrenmede eğitim etiketli verilere ihtiyaç duymadan gerçekleştirilir. Denetimsiz öğrenme genellikle kümeleme, özellik çıkarma veya boyut azaltma için kullanılır (LeCun vd., 2015).

Uzun yıllar boyunca, donanım sınırlamaları, özellikle gerçek zamanlı işleme gerektiren uygulamalar için hem eğitim hem de işleme için yüksek hesaplama gereksinimleri, derin öğrenme modellerini kullanışsız hale getirmiştir. Son yıllarda donanımdaki gelişmeler ve çok çekirdekli işleme yoluyla paralelleştirme yeteneği sayesinde bu sınırlamalar kısmen aşılmış olup derin öğrenme modelleri yapay zekada önemli bir atılım yapması sağlanmıştır. Derin öğrenme sistemleri veya modelleri yapı olarak sinir ağlarına benzer ve gelişmiş bir doğruluk oranı sunabildiğinden başarılı olarak kabul görmektedir.


Derin öğrenme, bir sistemi veya makineyi, bilgiyi katmanlar aracılığıyla işlemek, sınıflandırmak, yorumlamak ve sonucu tahmin etmek için yönlendirir. Temel olarak kullanılan bazı derin öğrenme yaklaşımları, konvolüsyonel sinir ağları (CNN), tekrarlayan sinir ağları (RNN), üretici sinir ağlarıdır (GNN), derin düşünce ağları (DBN) ve derin boltzman makinesi (DBM) şeklinde sıralanabilir (A. Shrestha & A. Mahmood, 2019). Derin öğrenme mimarisinin farklı alanlarda kullanımının artmasıyla problemlerin çözümü için her geçen gün farklı modelleri geliştirilmektedir. Mimariler arasında CNN ve RNN en yaygın olarak kullanılan modellerdir.

CNN, görüntü verilerini analiz etmek için en yaygın kullanılan derin öğrenme modelidir (O'Shea & Nash, 2015). Bu ağların adı, maske filtresi kullanarak karmaşık işlemleri gerçekleştirmenin kolay bir yolu olan konvolüsyon işleminden gelmektedir. Bir CNN'nin ana avantajı, geri yayılım sırasında ağı, filtrenin tek bir örneğine eşit sayıda parametreyi ayarlamasıdır. CNN kavramı büyük ölçüde görsel korteksin nörobiyolojik modelinden esinlenmiştir. CNN mimarisinin genel yapısı Şekil 3'te gösterilmiştir.



Şekil 3: CNN mimarisinin genel yapısı ve katmanları

RNN, veri akışlarını analiz edebilen gizli birimler içeren bir sinir ağı modelidir (Liang & Hu, 2015). RNN genellikle, önceki tüm zaman adımlarında ne olduğu hakkında bilgi sağlamak için güçlü bağlantılara sahiptir. Bu şekilde, RNN modeli yeni verilerin çıktısını sağlamak için şimdiki (t) ve yakın geçmiş (t-1) olmak üzere iki girdi kaynağından yararlanır. Bu nedenle, genellikle RNN'lerin hafızası olduğu söylenmektedir. RNN basit ve güçlü bir model olmasına rağmen, kaybolan gradyan probleminden kaynaklı veri setine uygun olarak seçilmesi gerekmektedir. RNN'ler, dil modelleme, biyoinformatik değerlendirme, konuşma tanıma ve görüntü tanımlama gibi birçok doğal dil işleme görevinde büyük başarılar göstermiştir. RNN mimarisinin genel yapısı Şekil 4'te gösterilmiştir.



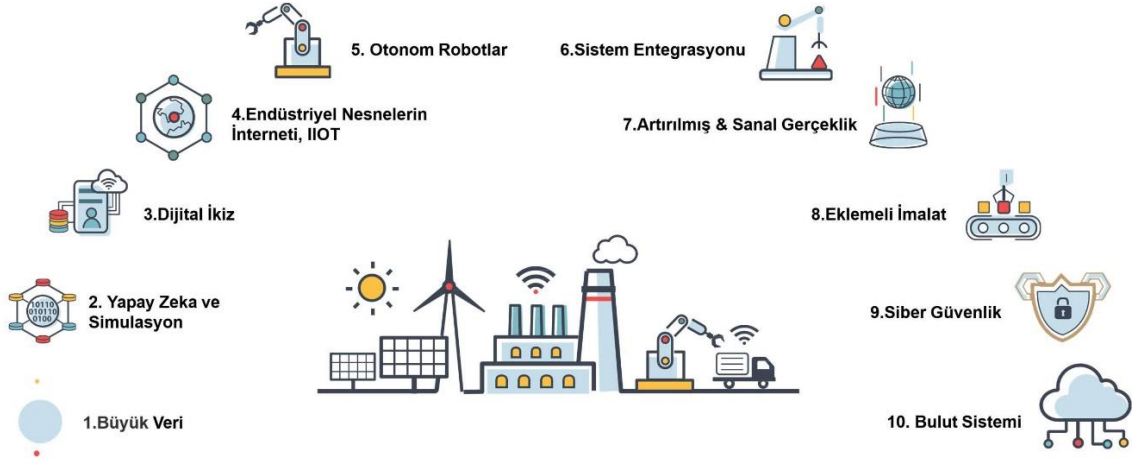
Şekil 4: RNN mimarisinin genel yapısı



## Endüstri 4.0

Endüstri 4.0 kavramı sanayi devriminin günümüze kadar süre gelen yansımasıdır. İlk olarak endüstri 4.0, güncel imalat endüstrisinde ortaya çıkan kolektif bir tanımdır. Günümüzde akıllı üretimin benimsenmesinden dağıtım kanallarının dijital ortamlara taşınmasına kadar temelinde üretim ve tüketim eylemlerinin dijitalleştirilmesini içermektedir. Üretim kısmında tüketicinin kullanımını ve erişimini kolaylaştıracak yeni çözümlerin üretilmesini, tüketicinin değişkenlik gösteren ihtiyacına uyum sağlayan ürün tasarımını sağlamaktadır. Endüstri 4.0, teknolojik gelişmelerin üretim alanına sağlamış olduğu yeniliklerin bir tanımıdır. Endüstri alanında ortaya çıkan gelişmeler sonucunda veriler ve veri işleme basamakları dijitalleşmiştir. Dijital ortamda bulunan verilerin işleme hızları da oldukça iyileştirilerek üretim banlarındaki basit kararlar verici (arızalı, bozuk, vb.) kararların yapay zeka uygulamaları, robotlar ve kendini güncelleyen algoritmalar, tarafından verilebilir hale getirmiştir. Endüstri 4.0 ile ortaya çıkan akıllı fabrikaların üretimi gerçekleştiren her aşamada kontrol noktalarından test noktalarına, sağlığa zararlı maddelerin kullanımından çok sıcak/soğuk ortamlarda çalışma gibi birçok şekilde karşımıza çıkmaktadır. Dijitalleşme aynı zamanda üretici ile tüketici arasındaki ilişkinin hızlanmasına olanak sağlamaktadır. Üreticinin sattığı ürünler hakkında geri dönüşleri tüketiciler tarafından daha hızlı alması ve üretici tüketicinin ihtiyacını daha hızlı tespit ederek ürünlerinde yenileme çalışması yapmasını sağlamaktadır. Fabrikalarda artan üretim miktarı ve hızına bağlı olarak büyük veriler açığa çıkmaktadır. Bu verilerin dijital olarak kaydedilerek depolanması evrensel olarak bir iletişim ağının meydana gelmesini sağlamaktadır. Her şeye rağmen, endüstri alanındaki yeniliklerin sonucunda arttırılan üretim oranı, özellikle pandemi sonrasında daha çok hissedilen kaynak (hammadde) eksikliğinin ve kullanılacak enerji miktarındaki eksikliğin ortaya çıkmasına da etkisi bulunmaktadır.

Bilgisayar teknolojisinde meydana gelen gelişmeler sayesinde hayatımızın birçok alanında kendisine yer bulan yapay zeka kavramı Endüstri 4.0 içerisinde temel yapıtaşlarından birini oluşturmaktadır. Endüstri de dijitalleşme sonucunda artan veri miktarının işlenmesinde ve verilerden bir karar mekanizması oluşturma aşamasında kullanılmaktadır. Endüstriyel kullanım amacı güdülen yapay zeka yöntemleri geliştirilmiştir. Bu teknolojik gelişmenin araştırılmasında önemli yatırımlar yapılmıştır. Endüstri alanına yönelik olarak geliştirilen yapay zeka yöntemleri sayesinde endüstriyel üretim, iş planlama, otomasyon sistemleri, risk analizi, kalite kontrol, bakım ve onarım, pazarlama gibi pek çok alanda gelişim meydana gelmiştir. Endüstri 4.0'in gelişmelerine katkıda bulunduğu alanlar Şekil 5'te gösterilmiştir.



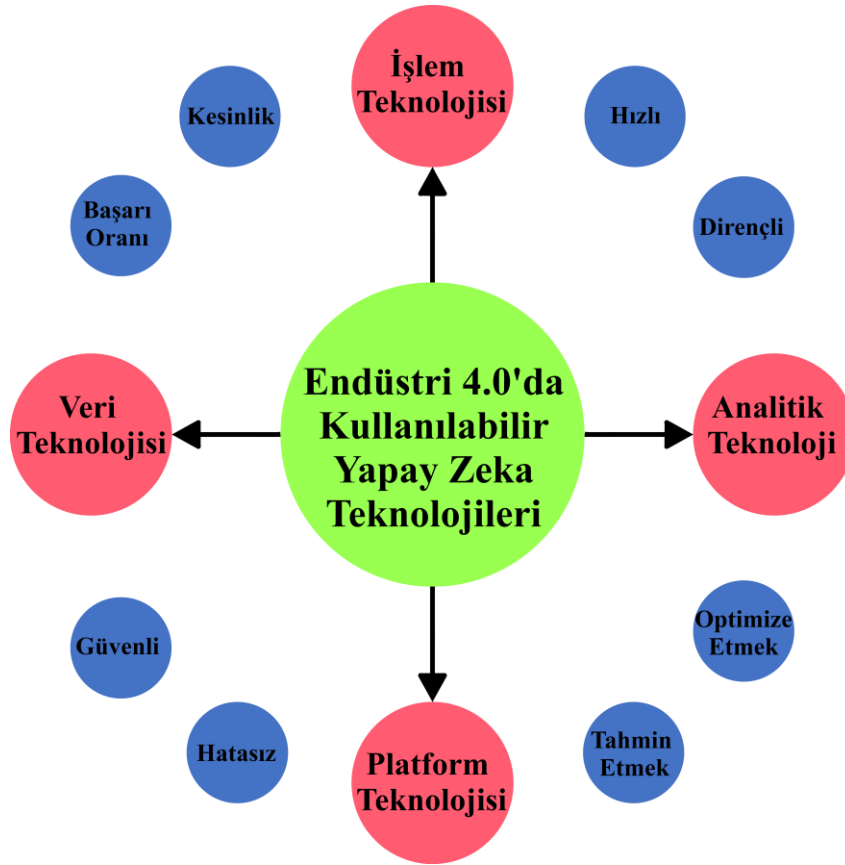
**Şekil 5:** Endüstri 4.0'ın teknolojik yenilik sağladığı alanlar

Endüstri 4.0 kelimesi, günümüzde endüstriyel üretim alanlarında ileri bilgi ve üretim teknolojilerinin uygulanması için geçerlidir. Bu, endüstrideki dijital devrim için sıklıkla kullanılan terimdir. Ayrıca, yapay zeka, Cyber, IoT, Cloud, ML, vb. gibi ileri teknolojileri ifade eden küresel bir kelimedir. Bunlar, üretim süreçlerinde akıllıca yorumlanabilir ve geliştirilebilir. Üretim sürecinde toplanan verileri hızlı bir şekilde değerlendirebilir. Bu değerlendirme ile yeni süreçler elde edilir ve çıktı değişiklikleri sürekli olarak ayarlanabilir. Dijitalleşme, bu sanayi devriminde yalnızca daha iyi bağlantılı olmakla kalmayıp, aynı zamanda modernleştirilir. Endüstri 4.0, yapay zeka ve makine öğrenimi uygulamalarıyla iletişim kurma şeklimizi değiştiren ve devrim yaratan endüstride dijitalleşmenin temelidir (Cioffi vd., 2020; Hofmann vd., 2019).

Endüstri 4.0 temel amaçlarından biri herhangi bir sorun anında veya müdahale gerektiren durumlarda bilgisayar sistemlerini özgün ve bağımsız bir şekilde çalıştırabilmektir. Fabrikalarda endüstriyel otomasyon teknolojisi, veri kontrolü ve paylaşımında yine bu kapsamdadır. Yapay zeka teknolojisi ile veriler etkin bir şekilde depolanarak gelecek üretimler kolaylıkla belirlenebilir. Makine veri setlerine ne kadar çok içerik girilerek beslenirse üretim ile alakalı o kadar çok metot geliştirilir, öğrenilir ve karar verilir. Endüstri 4.0 ve yapay zekanın oluşturduğu teknoloji, hataları doğru bir şekilde tahmin etmeye, iş yüklerini belirlemeye, sorunları takip etmeye ve bunları çözümlenmeye yardımcı olur (Dudukalov vd., 2021; Haleem, A., Vaishya, R., Javaid, M., & Khan, I. H., 2020).

Endüstri 4.0'ın tedarik zincirinden, tasarım ekibine, üretim hattından, kalite kontrolüne kadar son derece entegre olan dijital akıllı fabrikalar için yapay zeka yardımıyla pratik öngörüler sağlayan ve hızlı çözümler sunabilen akıllı bir sisteme hazırlanması gerekiyor. Endüstri 4.0'ın birçok fırsatından yararlanmak için üreticilerin, tüm tedarik zinciri döngüsü boyunca iş birliğine ihtiyaç duyduğu için tüm üretim sürecini dikkate alan bir sistem geliştirmesi gerekmektedir.

Endüstri 4.0 kültüründe bu felsefeyi uygularken gereksinimleri karşılayan yapay zekanın çeşitli teknolojik olanaklarını yansıtmaktadır. İşlem teknolojisi, veri teknolojisi, analitik teknolojisi ve platform teknolojisi olmak üzere dört farklı ana grup vardır (van Geest vd., 2021; Y. Chen & Y. Li, 2019). Bu özellikler, Endüstri 4.0'ı daha etkili ve gerçekçi, kesin, hızlı, optimize edilmiş ve güvenli hale getirmek için yapay zeka uygulamalarını destekler. Yapay zekanın üretim geliştirme ve önleyici faaliyetler üzerine bağlayıcı bir özelliği vardır. Bu özellik, imalat işlemlerinde makinelere ve ekipmanlara ani zarar gelmesini önlemek için öngörücü çözümler sağlar. Yapay zeka tabanlı sistemler üretim hattındaki bileşen kusurlarını tespit eder (Bogoviz, 2020; Chen & Xu, 2001; Romeo vd., 2020; Tang vd., 2001). Endüstri 4.0 alanında ihtiyaç duyulan fizyolojik gereksinimleri karşılayan yapay zekanın çeşitli teknolojik yetkinlikleri Şekil 6'da gösterilmiştir.



**Şekil 6:** Endüstri 4.0 için yapay zekanın çeşitli teknolojileri ve özellikleri

Endüstri 4.0'da yapay zekanın inanılmaz bir kullanımı var. Endüstriyel yapay zeka ve robotik iş birliği, üreticilerin üretim için gerekli hammaddeleri daha hızlı tedarik etmelerini sağlar. Yapay zeka, tasarımcıların endüstriyel sektörde ürün tasarlama şeklini değiştirmektedir. Yapay zeka üretim

çözümleri, uygun modellere rehberlik eder. Üretim sürecini izlemek, değerlendirmek ve kalite sorunlarının ortaya çıkıp çıkmayacağını veya ürün çıktısının beklenenden az olup olmadığını belirlemek için dijital ikiz kullanılır. Dijital ikizler, üreticilerin kullanılmış ürünlerin net bir resmine sahip olmalarını ve yeniden üretim sürecinin otomatik hale getirilmesini sağlar.

## **BULGULAR**

(Diez-Olivan vd., 2019), gerçekleştirdikleri çalışmada endüstriyel alandaki veri birleştirme ve makine öğrenmesindeki son gelişmelerin kapsamlı olarak bir araştırmasını sunmaktadır. Bu amaç doğrultusunda kullanılan özellik çıkartma teknikleri ve makine öğrenimi yöntemlerinin ilkeli bir sınıflandırıcısı tasarlanmıştır. Sınıflandırıcının dikkate aldıkları özellikleri; arıza sebebinin analizi, izlenen eylemin ne zaman hata vereceği, gerçekleşme olasılığı olan hatanın endüstrideki etkisini en aza indirecek planlamanın yapılması şeklinde sıralanmaktadır. Bu üçlü analiz sayesinde donanım ve yazılım etkileri üzerinde bir tartışma ile, gelecekteki çalışmalar için basamak olmayı amaçlamaktadırlar.

(L. Li vd., 2018), yaptıkları çalışmada yüksek başarı oranına sahip bir denetim sistemi kullanmak için, hatalı ürünleri bulabilen bir derin öğrenme modeli ile sınıflandırma önermektedirler. Akıllı fabrikalarda çok sayıda üretim hattı olacağı göz önüne alındığı zaman, buradaki büyük sorunlardan birisi büyük miktardaki verilerin gerçek zamanlı olarak işlenmesi olacağını söylemişlerdir. Ele aldıkları problemin çözümünde bulanık bilişim konseptini kullanmışlardır. Önerilen sistem, büyük miktardaki verilerin hesaplama yükünü merkezi sunucudan bulanık düğümlere gönderilmesi olarak planlanmıştır. Sistemde önemli iki avantaj kendisine yer bulmaktadır. Bunlardan birincisi, konvolüsyonel sinir ağı modelinin hesaplama verimliliğini önemli ölçüde artıran bulanık hesaplama ortamına uyarlanmasıdır. İkincisi ise, hata tipini ve derecesini aynı anda gösterebilen bir inceleme modeli sağlamış olmalarıdır. Çalışma kapsamında yapılan deneyler sonucunda önerilen sistemin sağlam ve verimli olduğu sonucuna varılmıştır.

(B. Luo vd., 2019), zamanla değişen koşullar altında bile üretim esnasında makinelerde meydana gelebilecek arızaların erken tespiti için yeni bir yöntem literatüre sunmuştur. Çalışmada, 288 günlük uzun süreli çalışma sonucunda elde edilen titreşim sinyallerinin dürtü yanıtlarını otomatik olarak seçecek bir derin öğrenme modeli tasarlanmıştır. Model tasarımının ardından, zamanla değişen koşullar altında dahi erken mekanik arızayı tespit etmek için seçilen darbe yanıtlarından dinamik özellikler tanımlanmıştır. Çalışmada önerilen yöntem, geleneksel yöntemlerle karşılaştırıldığında, deneysel sonuçlar ışığında, yöntemin zamanla değişen koşullardan etkilenmediğini ve imalatta erken hata tespiti için önemli bir potansiyel gösterdiğini ortaya koymuşlardır.

(J. Pan vd., 2018), çalışmalarında öncesinde bilgi sahibi olunmadan ham mekanik verileri kullanarak sınıflandırıcı oluşturmak için yeni bir derin öğrenme ağı (LiftingNet) önermişlerdir. Konvolüsyonel sinir ağı ve ikinci dereceden dalgacık dönüşümlerini temelinde içeren bu yeni derin öğrenme modeli, model girişlerinde önemli ölçüde gürültü ve rastgelelik içermesine rağmen mekanik verilerin sınıflandırılması için tasarlanmıştır. Öğrenme yeteneğinin geliştirilmesi için konvolüsyon katmanlarında farklı çekirdek boyutlarında işlem yapılmaktadır. Çok katmanlı yapıya sahip olan sinir ağı, ham verilerin karmaşık yapılarındaki sık alanlardan derin özellikler çıkartabilmektedir. LiftingNet'in fizibilite çalışması ve etkinliği iki motor yatağı verileri üzerinde değerlendirilerek doğrulanmıştır. Fizibilite çalışmasının sonuçları, önerilen yöntemin katman bazında özellik çıkartmayı başarabildiğini ve farklı dönme hızlarında ve rastgele gürültünün etkisi altında bile mekanik verileri başarılı bir şekilde sınıflandırabildiğini göstermişlerdir.

(Y. Cheng vd., 2019), literatüre sunmuş oldukları çalışmada uyarlanabilir çekirdek spektral kümeleme (AKSC) ve derin uzun kısa süreli bellek tekrarlayan sinir ağları (LSTM-RNN) kullanılarak yeni bir veri güdümlü makine sağlığı izleme yöntemi önerilmiştir. Önerilen sistem yapısında üç adım içermektedir; ilk olarak zaman alanındaki, frekans alanındaki ve zaman-frekans alanındaki özellikler büyük ölçülmüş sinyallerden çıkarılmaktadır. Bozulma özelliklerini seçmek için Öklid mesafesi tabanlı bir algoritma tasarlanmıştır. İkinci olarak da çoklu bozulma özelliklerinden makine meydana gelen anormal davranışların uyarlamalı olarak tanımlanması için AKCS algoritması kullanılmıştır. Son aşamada ise makinenin arıza süresini güncellemek ve tahmin etmek için yeni bir derin öğrenme modeli (LSTM-RNN) oluşturulmuştur. Önerilen sistemin fizibilite çalışması bir dizi doğru-hatalı deneysel veriler kullanılarak doğrulanmıştır. Fizibilite çalışmalarının sonuçları, önerilen yöntemin performansının mevcut diğer yöntemlerle rekabet ettiğini göstermektedir.

(Y. Tao vd., 2019), bu çalışmada düz dişli makede arıza teşhisi için çok katmanlı kapılı tekrarlayan birim (MGRU) yöntemi, yani üç katmanlı kapılı tekrarlayan birim (GRU) önerilmiştir. İlk olarak test tezgahındaki titreşim sinyalleri izlenir ve daha sonra hem zaman alanında hem de zaman-frekans alanında özellik çıkartılır. Daha sonra özellikler ve MGRU temsili sınıflandırıcı eğitiminde kullanılmaktadır. MGRU, artan katman sayısı ile bilginin temsilini iyileştirebilir ve hata türlerinin özelliklerini daha kesin bir şekilde tanımlayabilmektedir. Önerilen yöntemin fizibilite çalışması 10 durum modlu iki düz dişli makine ile test edilmiştir. Yöntemin sınıflandırma doğruluğunu değerlendirmek için, dört yöntem ile karşılaştırma yapılmıştır, sırasıyla GRU, uzun kısa süreli bellek (LSTM), çok katmanlı LSTM (MLSTM) ve destek vektör makinesi (SVM). Ayrıca, önerilen MGRU performansı için ayırılabilirlik ve sağlamlık analizi de araştırılmıştır. Tüm sonuçlar, önerilen MGRU yaklaşımının düz dişli arıza teşhisi için etkili olduğunu göstermiştir.

(Park vd., 2020), akıllı fabrikaların karmaşıklık seviyelerinin yüksek olduğunu, belirsizliğinden kaynaklı olarak beklenmeyen sorunların ortaya çıkmasını, olası arızaların tetiklenmesini gibi durumların önüne geçilmesi üzerine çalışma yapmışlardır. Gerçekleştirilen çalışmada ele aldıkları sorunların çözümü olarak makine öğrenmesi ile içeriğe duyarlı olarak ihlal (anormal durum) tespit sistemi oluşturmuşlardır. Akıllı fabrikadaki gerçekleştirilen eylemler için bu modellemenin yapılabileceğini söylemiştir. İlgili eyleme ait makine öğrenme modelinin tasarlanması için eylemin doğru ve yanlış verilerin toplanmasının yeterli olacağına değinmişlerdir. Önerilen sistem, önceden kullanılan sistemlere göre anormallik işaretlerini tespit etme görevinde süreç başarı olasılığında etkili olduğunu göstermişlerdir.

(Carvajal Soto vd., 2019), yaptıkları çalışmada üretim esnasında yüzeye montelenen ekipmanların arızalarının tespiti için bir makine öğrenme modeli ve düzenleme çerçevesinin bir arada kullanılmasını önermektedir. Gerçek zamanlı olarak makine öğrenme modeline girdi verebilmek için ölçeklenebilir ve esnek bir sistemin kurulmasını amaçlamışlardır. Önerilen yaklaşım, elektronik cihazlar için bir üretim hattının yeni ve gerçekçi bir simülasyonu kullanılarak değerlendirme yapılmıştır. Sistemin değerlendirme sonucunda yazılım mimarisi, hesaplamalı ölçeklenebilirlik, model doğruluğu, üretim performansı gibi çeşitli yönleri analiz ederek bütünsel bir şekilde yapılabileceğini göstermişlerdir.

(Kucukoglu vd., 2018), çalışmalarında bir otomotiv firmasında konektör montajının doğru ve hatalı işlemlerinin ayırt etme problemini ele almışlardır. Montaj işlemini dijitalleştirmek için giyilebilir teknoloji prototipi olarak dijital bir eldiven tasarlamışlardır. Eldiven sayesinde konektör montajının doğru ya da hatalı olarak yapıldığını sınıflandırmak için parmaklardaki titreşim ve kuvvet değerlerini kullanmışlardır. Dijital montaj eldiveninin sinyal sınıflandırması için yapay sinir ağı (YSA) yöntemini tercih etmişlerdir. YSA'nın eğitimi, doğrulaması ve test işlemleri için doğru ve hatalı konektör bağlantılarına ait sinyaller kullanılmıştır. Sinir ağının performansı, YSA'nın kusurlu işlemleri tespit etmek için düşünülen giyilebilir teknoloji için uygulanabilir bir yöntem olduğunu göstermiştir.

(S. Ferreira vd., 2020), çalışmalarında doğal dil işleme sinir ağı yöntemini kullanan modellerin bir uygulamasını ve doğal dilin İngilizce'den SQL'e dönüştürülmesinde dikkat mekanizmaları, sensörlerden gelen verileri depolamak için Endüstri 4.0 kavramı üzerine bir sistemin SQL veri tabanında uygulanmasını önermektedirler. Doğal dil ifadelerinin etiketlenmiş veri seti örnekleri, eğitim ve doğrulama için kullanılarak SQL'in fizibilite çalışması gerçekleştirilmiştir. Eğitilen sinir ağı modeli doğrulama verileri üzerinde %99 oranında başarı göstermiştir.

(Zhou vd., 2021), çalışmalarında farklı ülkelerdeki Endüstri 4.0 politikalarını ele almışlardır. İyi bir model tasarımı gerçekleştirmek ve modeldeki konu sayısına karar vermek için, Latent Dirichlet

Allocation'a dayalı iki makine öğrenmesi sınıflandırma yöntemi kullanarak tutarlılık değerinin karşılaştırmalı bir testi yapılmıştır. Ardından 2009-2018 döneminde bilim atıf indeksi genişletilmiş (SCI-EXPANDED) ve sosyal bilimler atıf indeksi (SSCI) ile indekslenen Endüstri 4.0'ne atıfta bulunan bir anket makalesi ile birleştirilmiştir. Her makalenin araştırma yönü, araştırma türü, araştırma yaklaşımları çıkarılmış olup tüm makalelerin konuları, bu alandaki araştırmacılar için uygun yollar ve değerli araştırma yönergeleri belirlenerek makine öğrenmesi ile sınıflandırılmıştır. Araştırma konularını sınıflandırmak için makine öğreniminde doğal dil işleme ve makale ayrıntılarını araştırmak için geleneksel literatür taramasının birleşimi, çalışmanın nesnelliğini ve bilimselliğini büyük ölçüde geliştirmiş ve daha sonraki araştırmalar için sağlam bir temel oluşturmuştur.

(Villalba-Diez vd., 2019), Endüstri 4.0'da bir endüstriyel kameralı ürün denetleme sürecinin doğruluğunu artırmak ve maliyetini düşürmek için bir derin öğrenme modeli ile yüksek çözünürlüklü optik bir kalite kontrol kamerası nasıl entegre edilebileceğinin bir uygulamasını yapmışlardır. Gravür silindirlerinin üretim sürecinde baskı silindirinde delik olması gibi üretim sorunlarını ele almışlardır. Kusur tespit performansını iyileştirmek ve kalite kontrol maliyetlerini azaltmak için taranan yüzeyi elde edilen gravür verileri ile karşılaştıran ve özellikleri öğrenerek otomatik bir kalite kontrol işlemi gerçekleştiren bir derin sinir ağı (DNN) önermektedirler. Tasarlanan derin öğrenme modeli üç konuda elle tutulabilir bilgiler vermektedir. Bir silindirin sahip olduğu hata miktarını tahmin etmek, operatöre hata olasılığını göstererek insan çalışmasını daha da desteklemek ve insan müdahalesi olmaksızın ürün kalitesi hakkında otonom olarak karar vermek.

(Lee, 2017), araştırmalarında çok sahalı ve farklı ürünlerin üretimini desteklemek amacıyla yeni ve etkili bir siber-fiziksel mimari önermektedir. Hedef olarak, araçların Yüksek Yoğunluklu Deşarj (HID) ile far ve kablo modüllerinin üretim süreçleri ele alınmaktadır. Hedef süreçlerin seçilmelerinin sebebi, üretimleri sırasında farklı bileşenlere sahip çok sayıda kablo modülü üretilmesidir. Bu sorunlar, genel işlemlerin niteliklerini iyileştirmeyi ve genel üretim tesisleri göz önünde bulunduranları kontrol etmeyi zorlaştırmaktadır. Bu sınırlamaların üstesinden gelmek için Nesnelere İnterneti (IoT) gömülü bulut kontrol mimarisi önerilmektedir. Geliştirilen IoT cihazı, birkaç sistem durumunu algılar ve sinyalleri ileterek, derin öğrenme tabanlı model kullanılarak hata algılama sınıflandırması (FDC) mekanizması sinyallerin analizini gerçekleştirir. Önerilen sistem çeşitli endüstriyel süreçlerin takibinde ve uygulamalarında kullanılabilirliği gösterilmiştir.

(Penumuru vd., 2020), endüstri 4.0'da kullanılan robotlar gibi malzeme taşıma cihazlarının yanı sıra makine araçlarının bilişsel yeteneklerine katkı sağlamak istenmektedir. Bu doğrultuda makine öğrenimi teknolojilerini kullanarak otomatik malzeme tanımlama için genelleştirilmiş bir metodoloji sunulmuştur. RGB renk paletinin kırmızı, yeşil ve mavi renk bileşenlerini çıkarmak için

tanımlanması ve sınıflandırılması gereken dört malzemenin (alüminyum, bakır, orta yoğunluklu fiber levha ve yumuşak çelik) yüzeylerinin bir veri seti hazırlanarak kullanılmıştır. Destek vektör makinesi sınıflandırıcı olarak kullanılmakta ve hazırlanan veri setine karar ağaçları, rastgele ormanlar, lojistik regresyon ve k-En yakın komşu gibi diğer sınıflandırma algoritmaları da uygulanmaktadır. Sunulan modelin, başarı oranını kontrol etmek için dört deney gerçekleştirilerek doğrulanmıştır. Önerilen sistemin büyük değişiklikler olmaksızın mevcut bir üretim kurulumunda uygulanabileceğini göstermektedir.

## **SONUÇ VE ÖNERİLER**

Endüstri 4.0, yapay zeka yardımıyla üretim süreçlerinde yer alan farklı aşamaların kontrolünü tamamen otomatik hale getirmektedir. Ürün özelliklerine bağlı olarak, üretim işlemlerinin herhangi bir aşaması gerçek zamanlı olarak iyileştirilebilmektedir. Tüm geliştirme zincirine entegre edebilir ve veri süreçlerinde yer alan iş yükü birçok bölüme genişletilebilir. Veri toplama sistemleri ve veri geri bildirim sistemleri, yapay zeka aracılığıyla üretim süreçlerine dahil edilebilir. Bu teknoloji, verimliliği artırmak için montaj hatlarını üretim süreçleriyle paylaşabilir. Gelişmiş yapay zeka algoritmaları, onarım tahmini için ve ürün arızası tahminlerini formüle etmek için kullanılır. Yapay zekanın Endüstri 4.0 ile entegrasyonu, çeşitli endüstriyel gelişmeler sağlar. Yapay zeka ilgili üretim hatlarındaki çıktı süreçlerini yönetebilir. Bu teknoloji, üretimde yaratıcılığa katkıda bulunan anlamlı bakış açıları yaratabilir. Üretim ortamının fiziksel temsili, sensörler ve kameralar gibi veri toplama araçlarıyla tamamen görselleştirilir. Akıllı bileşenler tarafından oluşturulan veriler bir bulut bağlantısı kullanılarak toplanır, kaydedilir ve işlenir. Yakın gelecekte yapay zeka, bulut bilgilerini toplanmasını ve Endüstri 4.0'ın sorunsuz çalışmasını sağlayacağı düşünülmektedir.



## KAYNAKÇA

- A. Shrestha & A. Mahmood. (2019). Review of Deep Learning Algorithms and Architectures. *IEEE Access*, 7, 53040-53065. <https://doi.org/10.1109/ACCESS.2019.2912200>
- Abadi, M., Chu, A., Goodfellow, I., Brendan McMahan, H., Mironov, I., Talwar, K., & Zhang, L. (2016). Deep Learning with Differential Privacy. 308-318. <https://doi.org/10.1145/2976749.2978318>
- Abduljabbar, R., Dia, H., Liyanage, S., & Bagloee, S. A. (2019). Applications of Artificial Intelligence in Transport: An Overview. *Sustainability*, 11(1). <https://doi.org/10.3390/su11010189>
- Ang, J. H., Goh, C., Saldivar, A. A., & Li, Y. (2017). Energy-Efficient Through-Life Smart Design, Manufacturing and Operation of Ships in an Industry 4.0 Environment. *Energies*, 10(5). <https://doi.org/10.3390/en10050610>
- B. Luo, H. Wang, H. Liu, B. Li, & F. Peng. (2019). Early Fault Detection of Machine Tools Based on Deep Learning and Dynamic Identification. *IEEE Transactions on Industrial Electronics*, 66(1), 509-518. <https://doi.org/10.1109/TIE.2018.2807414>
- Bécue, A., Praça, I., & Gama, J. (2021). Artificial intelligence, cyber-threats and Industry 4.0: Challenges and opportunities. *Artificial Intelligence Review*, 54(5), 3849-3886. <https://doi.org/10.1007/s10462-020-09942-2>
- Berliner, H. J. (1978). A chronology of computer chess and its literature. *Artificial Intelligence*, 10(2), 201-214. [https://doi.org/10.1016/S0004-3702\(78\)80012-5](https://doi.org/10.1016/S0004-3702(78)80012-5)
- Bogoviz, A. V. (2020). Perspective directions of state regulation of competition between human and artificial intellectual capital in Industry 4.0. *Journal of Intellectual Capital*, 21(4), 583-600. <https://doi.org/10.1108/JIC-11-2019-0270>
- Bougdira, A., Akharraz, I., & Ahaitouf, A. (2020). A traceability proposal for industry 4.0. *Journal of Ambient Intelligence and Humanized Computing*, 11(8), 3355-3369. <https://doi.org/10.1007/s12652-019-01532-7>
- Bousdekis, A., Apostolou, D., & Mentzas, G. (2020). A human cyber physical system framework for operator 4.0 – artificial intelligence symbiosis. *Manufacturing Letters*, 25, 10-15. <https://doi.org/10.1016/j.mfglet.2020.06.001>
- Carbonell, J. G., Michalski, R. S., & Mitchell, T. M. (1983). 1—AN OVERVIEW OF MACHINE LEARNING. İçinde R. S. Michalski, J. G. Carbonell, & T. M. Mitchell (Ed.), *Machine Learning* (ss. 3-23). Morgan Kaufmann. <https://doi.org/10.1016/B978-0-08-051054-5.50005-4>
- Carvajal Soto, J. A., Tavakolizadeh, F., & Gyulai, D. (2019). An online machine learning framework for early detection of product failures in an Industry 4.0 context. *International Journal of Computer Integrated Manufacturing*, 32(4-5), 452-465. <https://doi.org/10.1080/0951192X.2019.1571238>
- Chen, Z. B., & Xu, L. D. (2001). An object-oriented intelligent CAD system for ceramic kiln. *Knowledge-Based Systems*, 14(5), 263-270. [https://doi.org/10.1016/S0950-7051\(01\)00105-8](https://doi.org/10.1016/S0950-7051(01)00105-8)
- Cioffi, R., Travaglioni, M., Piscitelli, G., Petrillo, A., & De Felice, F. (2020). Artificial Intelligence and Machine Learning Applications in Smart Production: Progress, Trends, and Directions. *Sustainability*, 12(2). <https://doi.org/10.3390/su12020492>
- Dal Mas, F., Piccolo, D., Cobiانchi, L., Edvinsson, L., Presch, G., Massaro, M., Skrap, M., Ferrario di Tor Vajana, A., D'Auria, S., & Bagnoli, C. (2019). The effects of artificial intelligence, robotics, and industry 4.0 technologies. *Insights from the Healthcare sector*. 88-95.
- Diez-Olivan, A., Del Ser, J., Galar, D., & Sierra, B. (2019). Data fusion and machine learning for industrial prognosis: Trends and perspectives towards Industry 4.0. *Information Fusion*, 50, 92-111. <https://doi.org/10.1016/j.inffus.2018.10.005>
- Dudukalov, E. V., Munister, V. D., Zolkin, A. L., Losev, A. N., & Knishov, A. V. (2021). The use of artificial intelligence and information technology for measurements in mechanical engineering and in process automation systems in Industry 4.0. *Journal of Physics: Conference Series*, 1889(5), 052011. <https://doi.org/10.1088/1742-6596/1889/5/052011>
- G. -J. Cheng, L. -T. Liu, X. -J. Qiang, & Y. Liu. (2016). Industry 4.0 Development and Application of Intelligent Manufacturing. 2016 International Conference on Information System and Artificial Intelligence (ISAI), 407-410. <https://doi.org/10.1109/ISAI.2016.0092>
- Gupta, B. B., Tewari, A., Cvitić, I., Peraković, D., & Chang, X. (2022). Artificial intelligence empowered emails classifier for Internet of Things based systems in industry 4.0. *Wireless Networks*, 28(1), 493-503. <https://doi.org/10.1007/s11276-021-02619-w>
- Haenlein, M., Kaplan, A., Tan, C.-W., & Zhang, P. (2019). Artificial intelligence (AI) and management analytics. *Journal of Management Analytics*, 6(4), 341-343. <https://doi.org/10.1080/23270012.2019.1699876>

- Haleem, A., Vaishya, R., Javaid, M., & Khan, I. H. (2020). Artificial Intelligence (AI) applications in orthopaedics: An innovative technology to embrace. *Journal of clinical orthopaedics and trauma*, 11, 80-81. <https://doi.org/10.1016/j.jcot.2019.06.012>
- Hofmann, E., Sternberg, H., Chen, H., Pflaum, A., & Prockl, G. (2019). Supply chain management and Industry 4.0: Conducting research in the digital age. *International Journal of Physical Distribution & Logistics Management*, 49(10), 945-955. <https://doi.org/10.1108/IJPDLM-11-2019-399>
- J. Pan, Y. Zi, J. Chen, Z. Zhou, & B. Wang. (2018). LiftingNet: A Novel Deep Learning Network With Layerwise Feature Learning From Noisy Mechanical Data for Fault Classification. *IEEE Transactions on Industrial Electronics*, 65(6), 4973-4982. <https://doi.org/10.1109/TIE.2017.2767540>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695. <https://doi.org/10.1007/s12525-021-00475-2>
- Javaid, M., & Haleem, A. (2019). Industry 4.0 applications in medical field: A brief review. *Current Medicine Research and Practice*, 9(3), 102-109. <https://doi.org/10.1016/j.cmrp.2019.04.001>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Koh, L., Orzes, G., & Jia, F. (Jeff). (2019). The fourth industrial revolution (Industry 4.0): Technologies disruption on operations and supply chain management. *International Journal of Operations & Production Management*, 39(6/7/8), 817-828. <https://doi.org/10.1108/IJOPM-08-2019-788>
- Kucukoglu, I., Atici-Ulusu, H., Gunduz, T., & Tokcalar, O. (2018). Application of the artificial neural network method to detect defective assembling processes by using a wearable technology. *Journal of Manufacturing Systems*, 49, 163-171. <https://doi.org/10.1016/j.jmsy.2018.10.001>
- L. Li, K. Ota, & M. Dong. (2018). Deep Learning for Smart Industry: Efficient Manufacture Inspection System With Fog Computing. *IEEE Transactions on Industrial Informatics*, 14(10), 4665-4673. <https://doi.org/10.1109/TII.2018.2842821>
- Langley, P., & Carbonell, J. G. (1984). Approaches to machine learning. *Journal of the American Society for Information Science*, 35(5), 306-316. <https://doi.org/10.1002/asi.4630350509>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Lee, H. (2017). Framework and development of fault detection classification using IoT device and cloud environment. *High Performance Computing and Data Analytics for Cyber Manufacturing*, 43, 257-270. <https://doi.org/10.1016/j.jmsy.2017.02.007>
- Liang, M., & Hu, X. (2015, Haziran). Recurrent Convolutional Neural Network for Object Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- O'Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. *CoRR*, abs/1511.08458. <http://arxiv.org/abs/1511.08458>
- Park, S.-T., Li, G., & Hong, J.-C. (2020). A study on smart factory-based ambient intelligence context-aware intrusion detection system using machine learning. *Journal of Ambient Intelligence and Humanized Computing*, 11(4), 1405-1412. <https://doi.org/10.1007/s12652-018-0998-6>
- Penumuru, D. P., Muthuswamy, S., & Karumbu, P. (2020). Identification and classification of materials using machine vision and machine learning in the context of industry 4.0. *Journal of Intelligent Manufacturing*, 31(5), 1229-1241. <https://doi.org/10.1007/s10845-019-01508-6>
- Rodriguez, M. Z., Comin, C. H., Casanova, D., Bruno, O. M., Amancio, D. R., Costa, L. da F., & Rodrigues, F. A. (2019). Clustering algorithms: A comparative approach. *PLOS ONE*, 14(1), e0210236. <https://doi.org/10.1371/journal.pone.0210236>
- Romeo, L., Loncarski, J., Paolanti, M., Bocchini, G., Mancini, A., & Frontoni, E. (2020). Machine learning-based design support system for the prediction of heterogeneous machine parameters in industry 4.0. *Expert Systems with Applications*, 140, 112869. <https://doi.org/10.1016/j.eswa.2019.112869>
- S. Ferreira, G. Leitão, I. Silva, A. Martins, & P. Ferrari. (2020). Evaluating Human-Machine Translation with Attention Mechanisms for Industry 4.0 Environment SQL-Based Systems. *2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT*, 229-234. <https://doi.org/10.1109/MetroInd4.0IoT48571.2020.9138181>
- S. Zhao, F. Blaabjerg, & H. Wang. (2021). An Overview of Artificial Intelligence Applications for Power Electronics. *IEEE Transactions on Power Electronics*, 36(4), 4633-4658. <https://doi.org/10.1109/TPEL.2020.3024914>
- Sanchez, M., Exposito, E., & Aguilar, J. (2020). Autonomic computing in manufacturing process coordination in industry 4.0 context. *Journal of Industrial Information Integration*, 19, 100159. <https://doi.org/10.1016/j.jii.2020.100159>

- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>
- Sen, P. C., Hajra, M., & Ghosh, M. (2020). Supervised Classification Algorithms in Machine Learning: A Survey and Review. İçinde J. K. Mandal & D. Bhattacharya (Ed.), *Emerging Technology in Modelling and Graphics* (ss. 99-111). Springer Singapore.
- Tang, C., Xu, L. D., & Feng, S. (2001). An agent-based geographical information system. *Knowledge-Based Systems*, 14(5), 233-242. [https://doi.org/10.1016/S0950-7051\(01\)00101-0](https://doi.org/10.1016/S0950-7051(01)00101-0)
- Turing, A. M. (2009). Computing Machinery and Intelligence. İçinde R. Epstein, G. Roberts, & G. Beber (Ed.), *Parsing the Turing Test: Philosophical and Methodological Issues in the Quest for the Thinking Computer* (ss. 23-65). Springer Netherlands. [https://doi.org/10.1007/978-1-4020-6710-5\\_3](https://doi.org/10.1007/978-1-4020-6710-5_3)
- Van Geest, M., Tekinerdogan, B., & Catal, C. (2021). Design of a reference architecture for developing smart warehouses in industry 4.0. *Computers in Industry*, 124, 103343. <https://doi.org/10.1016/j.compind.2020.103343>
- Villalba-Diez, J., Schmidt, D., Gevers, R., Ordieres-Meré, J., Buchwitz, M., & Wellbrock, W. (2019). Deep Learning for Industrial Computer Vision Quality Control in the Printing Industry 4.0. *Sensors*, 19(18). <https://doi.org/10.3390/s19183987>
- Wan Ibrahim, W. M. R., & Hassan, R. (2019). Recruitment Trends In The Era Of Industry 4.0 Using Artificial Intelligence: Pro And Cons. *Asian Journal of Research in Business and Management*; Vol 1 No 1 (2019): Sep 2019. <https://myjms.mohe.gov.my/index.php/ajrbm/article/view/6604>
- X. Yao, J. Zhou, J. Zhang, & C. R. Boër. (2017). From Intelligent Manufacturing to Smart Manufacturing for Industry 4.0 Driven by Next Generation Artificial Intelligence and Further On. 2017 5th International Conference on Enterprise Systems (ES), 311-318. <https://doi.org/10.1109/ES.2017.58>
- Y. Chen & Y. Li. (2019). Intelligent Autonomous Pollination for Future Farming—A Micro Air Vehicle Conceptual Framework With Artificial Intelligence and Human-in-the-Loop. *IEEE Access*, 7, 119706-119717. <https://doi.org/10.1109/ACCESS.2019.2937171>
- Y. Cheng, H. Zhu, J. Wu, & X. Shao. (2019). Machine Health Monitoring Using Adaptive Kernel Spectral Clustering and Deep Long Short-Term Memory Recurrent Neural Networks. *IEEE Transactions on Industrial Informatics*, 15(2), 987-997. <https://doi.org/10.1109/TII.2018.2866549>
- Y. Tao, X. Wang, R. -V. Sánchez, S. Yang, & Y. Bai. (2019). Spur Gear Fault Diagnosis Using a Multilayer Gated Recurrent Unit Approach With Vibration Signal. *IEEE Access*, 7, 56880-56889. <https://doi.org/10.1109/ACCESS.2019.2914181>
- Zhou, R., Awasthi, A., & Stal-Le Cardinal, J. (2021). The main trends for multi-tier supply chain in Industry 4.0 based on Natural Language Processing. *Computers in Industry*, 125, 103369. <https://doi.org/10.1016/j.compind.2020.103369>


# BÖLÜM


## 3

### EKLEMELİ İMALAT SÜRECİNDE MAKİNE ÖĞRENME UYGULAMALARI

**Çağrı Vakkas YILDIRIM**

*Doç. Dr., Erciyes Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Uçak Gövde ve Motor Bakımı  
Bölümü, cvyildirim@erciyes.edu.tr*

 0000-0002-0763-807X




## BÖLÜM 3

### EKLEMELİ İMALAT SÜRECİNDE MAKİNE ÖĞRENME UYGULAMALARI

**Çağrı Vakkas YILDIRIM**

*Doç. Dr., Erciyes Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Uçak Gövde ve Motor Bakımı Bölümü,*  
*cvyildirim@erciyes.edu.tr*

 0000-0002-0763-807X

#### 1. GİRİŞ

Eklemeli üretim teknikleri, kritik endüstri alanlarına prototip ve nihai ürün oluşturmak için kullanılan ve gün geçtikçe kullanımı artan bir imalat yöntemidir (Paolini ve ark., 2019). ASTM'ye göre eklemeli üretim, "eksiltmeli üretim yöntemlerinin aksine, katman katman üç boyutlu (3D) model verilerinden nesnelere yapmak için malzemeleri birleştirme süreci" olarak tanımlanmaktadır (Guo ve ark., 2013). Bir başka deyişle, eklemeli üretim, geleneksel imalat yöntemlerindeki talaş kaldırılarak yapılan şekillendirmenin aksine artımlı, katman katman malzeme ekleme prensibindeki üretime dayanır. Bu nedenle, eklemeli imalat teknolojilerinin büyük bir bölümünde bir ısı kaynağı tarafından eritilen ve ürün oluşturmak için sonraki soğutma esnasında birleştirilen bir hammaddeyi kullanır. Bu hammadde genellikle toz veya tel şeklindedir. Çelikler, alüminyum alaşımları, titanyum alaşımları, süper alaşımlar, metal matrisli kompozitler ve seramik matrisli kompozitler günümüzde eklemeli imalat tarafından üretilmektedir. Üretilen malzeme portföyünün yakın gelecekte çok daha fazla olması beklenmektedir. Örneğin; yüksek performanslı malzemelerden olan metaller arası bileşikler ve yüksek entropi alaşımları üzerindeki çalışmaların devam ettiği bilinmektedir (Li ve ark., 2019). Bununla beraber, eklemeli imalat sürecinde geliştirilmesi gereken ve üzerinde çalışmaların devam ettiği eksiklikler bulunmaktadır. Bu eksikliklerin giderilmesi ve sürecin daha verimli bir hale getirilmesi için faydalanılan yöntemlerden birisi de yapay zeka uygulamalarıdır. Akıllı Üretim ve Endüstri 4.0 olarak bilinen yeni çağda, eklemeli imalat yönteminin de paydaşlar arasında yer alacağı açık bir gerçektir. Bu yeni gelişmeler ile mevcut üretim operasyonları ve gelecekteki stratejik yönleri mutlaka dikkate alınmalı ve gözden geçirme, inceleme, değerlendirme gibi aşamalar gelişen teknoloji ile yeniden planlanmalıdır (Monostori ve ark., 2016). Yapay zeka teknikleri sayesinde büyük sorun teşkil eden problemlerin belirlenmesi ve çözülmesinde büyük aşamalar kaydedilmiştir. Böylece, üretkenlik, kalite, esneklik, güvenlik ve maliyet konusunda iyileştirmeler ortaya çıkmıştır. Günümüze kadar, yapay zeka uygulamalarının imalat endüstrisinde kullanımı üzerine yapılan çalışmalar neticesinde makine öğrenimi tekniğinin öne çıktığı söylenebilir (Arinez ve ark., 2020).

Makine öğrenimi, insan öğrenme etkinliklerini simüle etmek için bilgisayarların nasıl kullanılacağını araştıran ve son dönemde oldukça popüler olan bir alandır. Yeni bilgi ve beceriler elde etmek, mevcut bilgileri tanımlamak, performans ve başarıyı sürekli iyileştirmek için bilgisayarların kendini geliştirmesine yönelik yöntemleri incelemek de yine makine öğrenmenin ilgi alanları arasında yer almaktadır. İnsan öğrenmesi ile makine öğrenmesini karşılaştığımızda makine öğrenmesi çok daha hızlı olabilir. Ayrıca, bilgi birikimi daha kolay olmakta ve öğrenmenin sonuçları daha kolay alınmaktadır. Bu nedenle, makine öğrenimi alanındaki herhangi bir ilerleme bilgisayarların kullanımı için bir sonraki seviyeye geçmek anlamına gelmektedir. Bunun sonucu olarak da insan toplumu üzerindeki etkisi önemli derecede artmaktadır (Wang ve ark., 2009). En temel makine öğrenme tanımlarından biri H. Simon tarafından yapılmıştır. Yapay zeka konusunda oldukça iyi çıkarımlara sahip olan H. Simon'a göre makine öğrenme kavramı, sistemin tekrarlanan çalışması sonucunda yeteneğinin artırılması sürecidir. Bir başka deyişle, sistem aynı veya benzer görevleri her yerine getirdiğinde daha çok öğrenmiş olacak ve daha verimli sonuçlar verecektir. Makine öğrenimi, yapay zekanın önemli bir göstergesidir ve bilgisayarların bilgi edinmesinin önemli bir yoludur. Bu yöntemde, insanların öğrenme etkinlikleri simüle edilir ve bunun bilgisayarlar üzerinde nasıl yapılacağı analiz edilir. Dahası, mevcut bilgileri belirler, kullanır ve böylece makinelere yeni bilgi ve beceri kazandırmanın yollarını araştırır. Bu bilgilere ve H. Simon'un öğretilerine dayanarak makine öğrenmenin temel modeli Şekil 1'deki gibi yapılabilir. Burada verilen dış ortam, dışarıdan gelen bilginin kaynağını temsil eden dış bilgi topluluğudur. Bir başka deyişle, makine öğrenme sürecinde dış ortamın sisteme sağladığı bilgilerin kalitesi birincil faktördür ve dış bilgi kaynaklarını temsil etmektedir. Öğrenme, dışarıdan gelen bilgiyi işleme sürecini temsil etmektedir. Dışarıdan gelen bilgilerin işlenmesinden sonra depolanması bu aşamada olmaktadır. Depo aşaması genel uygulama bilgilerinin saklandığı veri tabanıdır. Burada saklanan bilgi ister düzenli ister düzensiz olsun, çok önemlidir. Çünkü öğrenmenin gerçekleşmesini doğrudan etkiler. Deponun içerisinde birinci dereceden mantık ifadeleri, üretim kuralları, anlamsal ağlar, çerçeveler vb. gibi çok çeşitli bilgiler saklanabilir. Uygulama, belirli bir görevi yürütmek için depodaki bilgiyi kullanma sürecidir. Daha sonraki uygulamalara rehberlik etmek için uygulama sürecinde elde edilen bazı bilgileri geri besler.



Şekil 1. Makine öğreniminin temel modeli

Makine öğrenimi, modern bilgisayar çağında oldukça geniş uygulama alanına sahip olan bir yöntemdir. Otomotiv, fen bilimleri, tıp, mühendislik, pazarlama, eğlence gibi çok çeşitli sektörlerde kullanılmakta ve duygu analizi, görüntü tanıma, trafik bildirimleri, siber güvenlik, ürün tavsiyesi, borsa sinyalleri, sosyal medya, otonom sürüş, gerçek zamanlı dinamik fiyatlandırma vb. gibi konularda insanlığa önemli katkılar sunmaktadır. Dahası, makine öğreniminin uygulama alanları gün geçtikçe artmaktadır. Bu alanlardan birisi de eklemeli imalat sürecindeki kullanımıdır. Bu çalışmada, dünyada ve Türkiye’de eklemeli imalat sürecinde makine öğrenme uygulamalarına dair araştırmalar incelenmiş olup inceleme sonunda araştırma sonuçlarının bazılarına ait bulgulara yer verilmiştir. Temel kavramlar, araştırma bulguları ve sonuçlar aşağıda bölümler halinde sunulmuştur.

## 2. EKLEMELİ İMALAT

Eklemeli imalat, geleneksel imalat yöntemlerinin aksine, toz veya tel halindeki hammaddeleri kullanarak katman katman biriktirme yöntemiyle üç boyutlu parçalar oluşturulmasını sağlayan imalat yöntemidir. Bu yöntemde temel felsefe lazer kaynağı ile hammaddenin eritilmesine dayanır ve hangi yöntemin seçileceği hammaddenin durumuna göre değişiklik göstermektedir. Bu imalat yöntemi, ilk olarak 1986 yılında Charles Hull tarafından stereolitografi (SLA) olarak bilinen bir yöntemin geliştirilmesi ile ortaya çıkmıştır. Bu yöntemi daha sonra toz yatak füzyonu (PBF), eriyik yığma modelleme (FDM) ve mürekkep püskürtmeli baskı gibi yöntemler izlemiştir. Geçen zaman içerisinde eklemeli imalat, malzeme, yöntem, ekipman vb. gibi konularda oldukça büyük gelişim göstermiş ve günümüzde birçok kritik sektörde uygulamaları görülmektedir. Eklemeli imalat ayrıca, katmanlı imalat, eklemeli işlemler, doğrudan dijital imalat, hızlı prototipleme, hızlı imalat gibi farklı isimlerle de bilinmektedir. Bu terim, doğrudan endüstriyel uygulamalar için gerekli özelliklere sahip fonksiyonel parçaların üretilmesinin yanı sıra prototiplerin üretilmesi ve kontrolü, alet, model ve konsept parçaların üretimi gibi geniş bir fabrikasyon sürecini de temsil etmektedir (Ngo ve ark., 2018). Eklemeli imalatın uygulanabilmesi için öncelikle temel tasarımın yapılması gerekmektedir. Temel tasarım sürecinde modeller üç boyutlu olacak şekilde oluşturulmakta ve bilgisayar programları aracılığıyla üretilebilirlik analizine tabi tutulmaktadır. Analizden elde edilen sonuçlara göre tasarımı iyileştirecek geri bildirimler elde edilmekte ve bu geri bildirimler rehberliğinde tasarım iyileştirme çalışmaları yapılmaktadır. Daha sonra, elde edilen iyileştirilmiş tasarımın prototipleme işlemine geçilmektedir. Prototipleme işleminin sonrasında ürünler teste tabi tutulmaktadır ve testin sonucunun olumlu olması halinde seri üretim aşamasına geçilmektedir. Bu durum prototipleme sürecinin ve eklemeli imalatın önemini ortaya çıkarmaktadır. Bir başka açıdan bakıldığında ise eklemeli imalat sürecinin ilk aşaması bilgisayar destekli programlar (CAD) aracılığıyla üç boyutlu parçaların model dosyalarının elde edilmesidir. Daha sonra uygun yazılım kullanılarak üç boyutlu verilerin düzeni tanımlanır ve modele ait yüzey geometrileri küçük üçgenlere bölünerek yapılandırılan bir STL

(STereoLithography) dosyası oluşturulur. Bu süreç esnasında “slicer” adı verilen bir üç boyutlu dilimlere bölme yazılımı kullanılmaktadır. Bu yazılım, lazer gücü, tarama yönü, tarama mesafesi, katman kalınlığı vb. gibi üretim parametrelerine göre dilimlere ayırarak parçaya ait takım yollarını çıkarmaktadır (Aydın, 2022). Eklemeli imalatın en önemli avantajlarından birisi nihai şekli verirken hammaddeleri doğru kullanması ve minimum atık malzeme olmasıdır. Doğası gereği israfı ortadan kaldıran eklemeli imalat bu yönüyle çevre dostu üretim yöntemi olarak da bilinmektedir. Ayrıca, talaş kaldırarak elde edilmesi zor olan karmaşık geometriye sahip parçaların üretilmesi de eklemeli imalatın önemli avantajlarından biridir. Böylece, karmaşık geometri sebebiyle, önceleri küçük parçalar halinde üretilen ve daha sonra birleştirilen parçaların tek bir nesne olarak üretilmesine imkan tanır. Son olarak, gerçekleştirebildiği topolojik olarak optimize edilmiş tasarımlar, bir ürünün işlevselliğini artırabilir. Böylece, çalışması için gereken enerji, yakıt veya doğal kaynak miktarını azaltabilir. Özellikle, toplum refahının önemli ölçüde iyileştirmesi beklenen bireysel tüketim maddelerinin kişisel ihtiyaçlara göre üretilmesi, kişiye özel sağlık ürünlerinin üretilmesine imkan tanınması, hammadde ve enerji tüketimini önemli ölçüde azaltarak çevresel sürdürülebilirliğe önemli katkı sunması ve talep çerçevesinde üretim yaparak tedarik zincirini yeniden yapılandırma fırsatı sunması gibi beklentiler nedeniyle eklemeli imalat çok önemsenmektedir. Eklemeli imalat sürecinin uygulanması farklı alt yöntemlerle yapılabilir. Bazı alt yöntemlerde optik aracılığıyla tozları eritmek veya sinterlemek için yönlendirilen lazer veya elektron ışınlarından gelen termal enerji kullanılırken diğer bazı alt yöntemlerde toz seramik veya polimer bağlayıcı üzerine solventi doğru şekilde püskürtmek için mürekkep püskürtmeli baskı kafaları kullanılır (Huang ve ark., 2013).

## **2.1. Eklemeli İmalat Yöntemleri**

Electro Optical Systems (EOS), Z Corporation, Arcam, Stratasys, MCP Tooling Technologies, 3D Systems ve Optomec gibi büyük üreticilerin yanında birçok üretici tarafından çeşitli eklemeli imalat yöntemleri piyasaya sürülmüş ve halihazırda kullanılmaktadır. Eklemeli imalat yöntemleri, genel prensipler, terminoloji standardı ISO/ASTM 52900'a göre yedi kategoride sınıflandırılmaktadır (Mercado ve Rojas, 2020).

### **2.1.1. Vat Polimerizasyonu**

Polimerizasyon ile 3D baskı olarak da bilinen bu yöntemde, ultraviyole (UV) spektrumundaki bir ışık demeti, monomer moleküllerinden veya oligomerlerden yüksek moleküler ağırlıklı (polimerler) malzemeleri retiküle etmek için kullanılır. Böylece, belirli bir dalga boyutundaki ışık demetleri kullanılarak sıvı polimer katı nesnelere dönüştürülür. Bu yöntemin en bilinen uygulamalarından biri Stereolitografi (SLA) yöntemidir ki SLA ticari olarak temin edilebilen ilk eklemeli imalat teknolojisi olarak da bilinir. Bu yöntemde bir reçine teknesi ultraviyole (UV) ışığa



seçici olarak maruz bırakılır. Işığa duyarlı reçine katı duruma dönüşerek karakterize edilir. Bir başka deyişle, bir CAD modeli katmanlara bölünür ve her bir katman için reçineyi seçici olarak sertleştirmek gerekir. Bu aşamada ise UV ışığı kullanılır. Bir katman oluşturulduktan sonra, platform bir katman kalınlığı kadar alçalmaktadır. Ardından reçine dolgulu bir bıçak, parçanın enine kesitini süpürür ve parçayı bir katman kalınlığında taze reçineyle yeniden kaplar. Sonraki katman, önceki katmana bağlı kalarak taranır (Guo ve ark., 2013). Bu durum üç boyutlu parça üretilene kadar tekrarlanır. Vat polimerizasyonuna dayalı bir başka eklemeli imalat yöntemi de 2013 yılında ortaya çıkan Sürekli Sıvı Arayüz Üretimi (CLIP) yöntemidir. Bu yöntemde hammadde olarak bir kabın içerisindeki fotopolimerik reçine kullanılır. Reçinenin bulunduğu kabın alt kısmı genellikle UV ışığına karşı yarı saydamdır. Bu yöntemde üretim reçinenin katılaşmasını aktive ederek, kabın yarı saydam tabanından belirli bir geometriye sahip UV ışınlarının sürekli olarak yansıtılmasıyla başlar. Projeksiyon işlemi sırasında, yapı platformu düşük hızda sabit hareketle yer değiştirir, reçinenin parçanın altında sürekli akışına izin verir ve her ikisi arasında sürekli etkileşime neden olur. Bu iki eşzamanlı süreç, nesnelere sürekli olarak üretilmesini sağlar (Janusiewicz ve ark., 2016). CLIP, SLA yöntemine göre çok daha hızlı bir yöntem olarak bilinir.

### **2.1.2. Malzeme Püskürtme**

Malzeme püskürtme yöntemi 1984 yılında geliştirilmiş ve fotopolimeri bir yapı platformuna malzeme gönderen, hareketli mürekkep püskürtmeli baskı kafalarının kullanılmasıyla üç boyutlu nesnelere oluşturan bir eklemeli imalat yöntemidir. Püskürtülen malzeme, bir veya daha fazla baskı kafası aracılığıyla yapı alanı boyunca ana yapıya aktarılır. Bu yöntem genellikle yüksek doğruluk, düşük atık, küçük püskürtme boyutu ve daha geniş malzeme kullanılabilirliği ile öne çıkmaktadır. Oluşturulan malzeme UV ışık kullanılarak kürlenir. Bu yöntemde de modeller katman katman üretilir. Bu yöntemde kullanılan malzemeler çoğunlukla fotopolimer veya mum benzeri malzemelerdir. Bunların kullanılmasının en büyük nedeni damlaları oluşturan viskoz bir yapıya sahip olmalarıdır. Viskoziteyi artırmak bu yöntem için önemli bir gerekliliktir ve bunun için malzemeler ısıtılır. Böylece püskürtme kolaylaşır. Bu nedenle, sıvıda solventler veya diğer düşük viskoziteli bileşenlerin kullanılması yaygındır. Bu yöntemde farklı renk ve sertliğe sahip malzemeler aynı modele yerleştirilebilir. Böylece, farklı özelliklere sahip bileşenlerden oluşan modeller oluşturulabilir. Birçok eklemeli imalat yönteminde olduğu gibi bu yöntemde de çıkımlar için destek yapıları gereklidir. Destek yapıları genellikle farklı bir malzemedir. Seçilen model malzemelerle birlikte bir jel benzeri destek malzemesi karmaşık geometrilerin başarılı bir şekilde oluşturulmasını kolaylaştırmaktadır. İşlem sonunda destek malzemeleri sodyum hidroksit çözeltisi kullanılarak çıkarılabilir. Bu yöntemin en çok tercih edildiği uygulamalardan biri spor malzemelerinin üretilmesidir. Örneğin dışı sert ve içi dolgulu istenen kasklar, renkli lensler, bir tarafı kauçuk diğer

tarafı sert olması istenen kayak gözlükleri vb. gibi sert ve esnek, farklı renklere sahip malzemelerin kombinasyonu olan ürünler malzeme püskürtme teknolojisi ile kolaylıkla üretilebilir. Ayrıca, havacılıkta prototiplerin üretilmesi, uçak teknolojinde kullanılan polimerlerin karmaşık geometride üretilmesi, ortodontik cihazlar vb. gibi uygulamalar bu yöntem ile hızlı ve güvenilir bir şekilde üretilebilir. Bu nedenle malzeme püskürtme yöntemi çok geniş bir uygulama alanına sahip olan eklemeli imalat teknolojilerindedir (Calignano ve ark., 2017).

### **2.1.3. Bağlayıcı Püskürtme**

Bağlayıcı püskürtme yöntemi, 1990'lı yılların başında geliştirilen çok adımlı eklemeli imalat yöntemlerinden biridir. 1990'lı yıllarda geliştirilmesine karşın bu yöntemin ticarileşmesi 2010'lu yılları bulmuştur. Bu yöntemle alüminyum, bakır, demir, nikel ve kobalt gibi metaller ve alaşımlarından oluşan parçalar üretilebilir. Dahası, cam, kum, grafit gibi seramikler de bu yöntemin uygulama alanı içerisindeki malzemelerdendir. Bağlayıcı püskürtme yöntemi, metal/seramik esaslı tozlar ve katmanlar arasında bu tozları bağlamak üzere kullanılan bağlayıcıları kullanarak çalışır. Burada bağlayıcı genellikle bir sıvıdır. Modellerin oluşturulması işlemi diğer eklemeli imalat yöntemlerine benzemektedir. Bu yöntemde, metal ve seramik zorları zemine yayılır ve gerektiğinde, Bilgisayar Destekli Tasarım (CAD) modeli tarafından belirlenen toz metal/seramik tabakasının üzerine bir bağlayıcı tabakası bırakılır. Bu süreç, tüm parçayı oluşturmak için yinelenir. Bununla birlikte, bağlayıcı püskürtme yöntemi, kütleme, toz giderme, sinterleme, infiltrasyon ve tavlama gibi parçaların baskısını takip eden birkaç ikincil işlem içerir. Bu ikincil işlemler bazen gerçek baskıdan daha uzun sürer ve önemli maliyetlere neden olabilir. Bağlayıcı püskürtme yönteminin önemli avantajlarından biri, parçaların destek yapıları olmadan üretilebilmesidir. Yapı parçaları, birbirine bağlı olmayan gevşek toz yatağında bulunur. Bu nedenle, tüm yapı hacmi, aralarında sadece birkaç kat mesafe kalacak şekilde birkaç parça ile istiflenebilir. Bağlayıcı püskürtme yönteminde bağlayıcılar haricinde yapıştırıcı kullanılmaz. Bu nedenle sinterleme esnasında gözenekler oluşabilir ve havacılık/otomotiv gibi sektörlerde yapısal parçaların üretimi için uygun değildir. Bu yöntemde baskı işlemi SLM/EBM gibi yöntemlerden daha hızlıdır. Ayrıca, baskı kafasındaki deliklerin sayısı artırılarak daha da hızlandırılabilir. Buna ek olarak, farklı toz-bağlayıcı kombinasyonlarının oranları değiştirilerek farklı mekanik özelliklere sahip iki malzemeli parçalar da üretilebilir. Eklemeli imalat yöntemlerinde toz büyüklüğü azaldıkça maliyetler artabilir. Bu yöntem ile parça üretmek için işlem sırasında ısıtmak gerekmez. Bu nedenle üretilen modellerde artık gerilme gibi istenmeyen durumlar ortaya çıkmaz. Ayrıca, bağlayıcı püskürtme yöntemi en uygun maliyetli eklemeli imalat yöntemlerinden biri olarak bilinir. Bununla beraber, bağlayıcı püskürtme yönteminde erime olmadığı ve konsolidasyon ağırlıklı olarak sinterleme ile gerçekleştiği için hemen her zaman porozite görülür ve gözeneklerin hacmi,

boyutu, şekli üretilen her parçada farklılık gösterebilir. Bu nedenle üretilen parçaların mekanik özellikleri istenildiği kadar güçlü olmayabilir (Konda ve ark., 2017).

#### **2.1.4. Malzeme Ekstrüzyonu**

Malzeme ekstrüzyonu yöntemi, 1980'li yılların sonuna doğru ortaya çıkan eklemeli imalat yöntemlerinden biridir. Füzyon Biriktirme Modellemesi (FDM) ve Erimiş Filament İmalatı (FFF) gibi uygulamaları olan bu yöntemde termoplastik bir filamentin eritilmesi ve ısıtılmış bir nozula gönderilmesi mantığına göre çalışır. Erimiş filamentin nozula gönderilmesi esnasında ters dönen iki tekerleğin tahrik etmesinden faydalanılır. Basit olması ve kullanım kolaylığı nedeniyle en çok kullanılan eklemeli imalat tekniklerinden biridir. Tipik olarak herhangi bir termoplastik polimerin ekstrüzyonu ile hazırlanan makaralı filamanlar, hareketli bir biriktirme ünitesinden ısıtılmış bir yapı platformuna taşınır. Bu da yapısal elemanın CAD tanımlı katman konturlarına göre katman katman imalatıyla sonuçlanır. Nozuldan ekstrüde edilmek üzere, filaman sıvılaştırıcıda ve nozulda kolaylıkla akabileceği bir sıcaklığa kadar ısıtılır. Bu seviye çoğunlukla yarı kristalli termoplastik filamentlerin erime sıcaklığının üzerindedir. Nozuldan ayrıldıktan sonra, ekstrüde edilen malzeme yatay düzlemde bir yapı platformuna veya önceki bir katmana bırakılır. Biriken eriyik soğur ve yeniden katlaşır. Bir katmanın seçici biriktirme işlemi tamamlandıktan sonra, sonraki katmanları yazdırmak için yapı platformu bir katman yüksekliği kadar düşürülür (Spoerk ve ark., 2020). Bu esnada sıcaklığın istenilen seviyede tutulması önemlidir. Aşırı ısınma durumunda malzemenin bozulması ve/veya geometrik şekil kayıplarının ortaya çıkması gibi durumlar oluşabilir. Bu nedenle malzeme ekstrüzyonu yönteminde kullanılacak malzemeler sınırlıdır. Bu yöntemde kullanılan malzemeler genellikle ABS, PLA, polifenilsülfon (PPSF), PC-ABS karışımları ve polikarbonattır. Malzeme ekstrüzyonunda plastik malzemenin kullanımı uzun süredir uygulanmaktadır ancak kompozit malzemeler üzerindeki araştırmalar da devam etmektedir. Kompozit malzemeler üzerindeki araştırmalar henüz çok yenidir ve geliştirilmesine ihtiyaç vardır. Özellikle elyaf takviyeli kompozitlerin kullanılması ile ilgili çalışmalar giderek artmaktadır. Geline seviyede üretilen kısa elyaf takviyeli kompozitler plastiklere göre çok daha iyi mekanik özellikler gösterse de uzun elyaf takviyeli kompozitlerle kıyaslandığında hala çok yetersizdir (Jiang ve Fu, 2020).

#### **2.1.5. Toz Yatak Füzyonu**

Toz Yatak Füzyonu yöntemi, en çok uygulanan eklemeli imalat yöntemlerinden biridir. Kullanabildiği malzemelerin diğer yöntemlere göre daha düşük maliyetler vadedmesi nedeniyle son yıllarda büyük gelişme göstermiştir. Dahası, araştırmacılar arasında popülerliği günden güne artmaktadır. Toz yatağı füzyon işleminde, toz bir destek yapısı gibi davrandığından destek gerekmez veya minimum destek gerekir. Toz yatağı füzyon işlemi ayrıca plastik, cam, metaller ve alaşımları dahil

olmak üzere farklı malzemelerin kullanılmasına izin verir. İşleminde kullanılan toz, daha fazla parça üretmek için geri dönüştürülebilir. Geri dönüştürülebilir olması, yöntemin en iyi özelliklerinden biridir. Toz yatak füzyonu yönteminde üç boyutlu ürünler üretmek için malzeme tozlarının eritilmesi ve dolayısıyla bunun için bir ısı kaynağına ihtiyaç duyulmaktadır. Bu ısı kaynakları genellikle termal, elektron veya lazerdir. Bu nedenle termal füzyon, lazer füzyonu ve elektron ışını füzyonunu içeren bazı alt teknikleri bulunmaktadır. Bunların içerisinde en çok kullanılan alt teknik lazer füzyonu tekniğidir. Seçici Lazer Sinterleme (SLS), Elektron Işını Erimesi (EBM) ve Seçici Lazer Eritme (SLM) uygulamalarıyla bilinir. Bu yöntemde ısı doğrudan kaynaktan tozun depolandığı zemine gönderilir. Bir katman tamamlandıktan sonra üzerine yeni bir katman toz serilir ve işlem tekrarlanır. Tozu platform boyunca yaymak için bir silindir veya bıçak kullanılır. Bu yöntemin uygulandığı cihazda tozların bulunduğu ve ürünün oluşturulduğu iki bölüm bulunmaktadır. EBM tekniğinin kullanıldığı bazı cihazlarda, erimiş metalde paslanmayı önlemek için üretim işlemi soy gazlarla dolu bir vakum kutusu içinde yapılır. Toz ve yapı odaları, yatay düzleme dik olan ürüne uygun bir yükseklik sağlamak için doğrusal bir z ekseninde hareket edebilir (Singh ve ark., 2020).

#### **2.1.6. Levha Laminasyonu**

Levha laminasyonu veya lamine nesne üretimi olarak bilinen bu yöntemde metalik levhalar kullanılır. Üç boyutlu bir nesne oluşturmak için bir dizi hassas kesim levha birleştirilir ve bunun için genellikle ultrasonik veya lazer olan bir enerji kaynağı kullanılır. En yaygın teknikleri ultrasonik eklemeli imalat (UAM) veya ultrasonik konsolidasyondur (UC). Oda sıcaklığında sac yığınlarına mekanik basınç ve ultrasonik dalga uygulanarak, yığın halinde duran levhaların ara yüzleri difüzyonla bağlanır. Yığılmış levhalar herhangi bir ısı kaynağı kullanmadan katman katman yapıştırılır ve böylece üç boyutlu ürünler üretilir. Ultrasonik konsolidasyon bağlamadan önce, metalik levhalar genellikle tasarlanan geometriye göre kesilir. Bu yöntemin uygulanması esnasında metalik malzemelerden imal edilmiş levhalar bir plaka üzerine üstü üste gelecek şekilde yığılır. Dijital bir sonotrot, basınç ve ultrasonik titreşim sağlamak için yuvarlanma yönü ekseninde hareket eder. Bu işlem esnasında sonotrotun yüksek frekanslı titreşimi nedeniyle önceden yapılmış parçalarla yeni bir metal levha yapıştırılır. Bu esnada birbirine sürtünen yüzeylerde sürtünme nedeniyle ısı artar ve böylece konsolide bölgenin sıcaklığı yükselir. Bu işlem yapılırken artık gerilme olmaması için her bir katmanın üretimi arasında kısa bir soğuma periyodu bulunur. Tüm katmanlar oluşturulduktan sonra, ürün daha iyi yüzey bitirme için taban plakasından kesilir ve ardından cilalanır (Zhang ve ark., 2018).

#### **2.1.7. Doğrudan Enerji Biriktirme**

Doğrudan Enerji Biriktirme yönteminde, üç boyutlu nesnelere üretmek için hammadde termal enerji aracılığıyla eritilir ve daha sonra biriktirilir. Bu yöntemde odaklanmış enerji kaynağı ve

malzeme aynı anda istenilen bölgelere gönderilir. Besleme malzemesi eriyik havuzunu oluşturan ve önceden biriktirilmiş katmanların veya alt tabakanın bir kısmı ile neredeyse aynı anda erir. Bu işlemin sonunda erimiş malzeme katlaşır ve önceden biriktirilmiş malzeme veya alt tabaka ile bağlanır. Bu işlem çok kısa bir sürede meydana gelir ve yeni katmanların oluşması bu şekilde sağlanır. Bu yöntemde hammadde olarak toz, tel veya her ikisi birden kullanılır. Doğrudan enerji biriktirme yönteminde ısı kaynağı olarak lazer veya elektron ışını kullanılır (Guan ve Zhao, 2020). Lazer metal biriktirme veya lazerle tasarlanmış ağ şekillendirme olarak da bilinen lazer tabanlı doğrudan enerji biriktirme, vakum isteyen elektron ışını tabanlı doğrudan enerji biriktirme yöntemine göre daha yüksek üretim hızı ve daha esnek çalışma ortamı sunar. Bu nedenlerden ötürü daha fazla kullanılır. Doğrudan enerji biriktirme yöntemi daha yüksek lazer gücü kullanımı, daha büyük lazer çapı, daha yüksek birikme hızı gibi muadillerine göre önemli avantajlara sahiptir. Bu yöntem, gerçek zamanlı toz bileşimlerini ayarlayabilir. Böylece, direkt uygulamaya yönelik ürünler üretebilir. Bu da işlevsel olarak derecelendirmiş malzemeler ve alaşım malzemeleri üretmek için iyi bir seçenek olduğunu gösterir (Liu ve ark., 2021). Diğer eklemeli imalat yöntemleriyle kıyaslandığında doğrudan enerji biriktirme yöntemi monolitik metal ve fonksiyonel olarak derecelendirilmiş parçalar üretme ve onarımları gibi konularda benzersiz bir yöntemdir. Ayrıca, monolitik paslanmaz çelik, alüminyum, titanyum, nikel ve bakır alaşımları da bu yöntemin kullandığı malzemelerdendir (Saboori ve ark., 2019). Eklemeli imalat yöntemleri, uygulamaları ve kullanılan malzemeler özet şeklinde Tablo 1'de gösterilmektedir.

**Tablo 1.** ISO/ASTM standardına göre eklemeli imalat yöntemleri ve özet tanımlamaları

Eklemeli İmalat Yöntemi	Kullanılan Teknoloji	Uygulanan Malzeme
<b>Vat Polimerizasyonu</b>	Stereolitografi (SLA) Dijital Işık İşleme (DLP) Sürekli Sıvı Arayüz Üretimi (CLIP)	UV ile kürlenebilen fotopolimer reçineler (çeşitli dolgu maddeleri ile)
<b>Malzeme Püskürtme</b>	Eriyik Filament Üretimi (FFF) Eriyik Yığma Modelleme (FDM) Robocasting	Termoplastik polimerlerin, kompozitlerin ve metal veya seramiklerle yüksek oranda doldurulmuş polimerlerin peletleri veya filamanları. Seramik veya metalik toz içeren yüksek oranda doldurulmuş mürekkepler.
<b>Bağlayıcı Püskürtme</b>	3D Baskı ExOne VoxelJet	Toz plastikler, metaller, seramikler, cam ve kum.
<b>Malzeme Ekstrüzyonu</b>	Polyjet Pürüzsüz Eğrilikler Yazdırma (SCP) Çoklu Jet Modelleme (MJM)	Fotopolimerler, termoplastik polimerler, mumlar, kompozitler.
<b>Toz Yatak Füzyonu</b>	Seçici Lazer Sinterleme (SLS) Seçici Lazer Ergitme (SLM) Elektron Işını Ergitme (EBM) Seçici Isı Sinterleme (SHS) Çok Jetli Füzyon (MJF) Yüksek Hızlı Sinterleme	Plastikler, metaller, seramik tozları ve kum.
<b>Levha Laminasyonu</b>	Lamine Nesne Üretimi (LOM) Seçici Biriktirme Laminasyonu (SDL) Ultrasonik Katkı Üretimi (UAM)	Kağıt, plastik levhalar, metal folyolar/bantlar
<b>Doğrudan Enerji Biriktirme</b>	Lazer Metal Biriktirme Lazerle Tasarlanmış Ağ Şekillendirme Doğrudan Metal Biriktirme (DMD)	Metal tel ve tozlar ve toz seramikler

### 3. MAKİNE ÖĞRENME

Makine öğrenimi, büyük veri teknolojileri ve yüksek performanslı bilgi işlem aracılığıyla tarımsal operasyonel ortamlarda veri yoğun süreçleri çözmek, ölçmek ve anlamak için ortaya çıkmış bir yöntemdir. Makine öğreniminin birçok tanımı olmasına karşın en geçerli tanım makinelerle katı bir şekilde programlanmadan öğrenme yeteneği kazandıran bilimsel alan olarak söylenebilir. Makine öğrenmede, bir bilgisayar programı bazı görevleri yerine getirmek için kullanılır ve makine bu görevleri yerine getirdikçe daha fazla deneyim kazanır. Bu sayede performansı her seferinde daha fazla yükselir. Bu performans yükselmesi tamamen kendi deneyimlerinde yola çıkarak olur. Bu sürecin sonunda makine kararlar alabilir ve/veya verilere dayalı tahminlerde bulunur. Makine öğrenimi halihazırda havacılık, uçak ve uzay sanayi, temel mühendislik, biyoinformatik, biyokimya, tıp, meteoroloji, ekonomi, robotik, su ürünleri yetiştiriciliği, gıda güvenliği ve klimatoloji gibi alanlar dahil olmak üzere birçok bilimsel alanda uygulanmakta ve uygulama alanları gün geçtikçe artmaktadır (Liakos ve ark., 2018). Daha spesifik bakıldığında ise sanal kişisel asistanlar, bilgisayar oyunları, örüntü tanıma, doğal dil işleme, veri madenciliği, trafik tahmini, çevrimiçi ulaşım ağı, ürün tavsiyesi, hisse piyasası tahmini, tıbbi teşhis, çevrimiçi dolandırıcılık tahmini, tarım danışmanlığı, arama motoru sonuç arıtma, çevrimiçi müşteri desteği için sohbet robotları, e-posta spam filtreleme, video aracılığıyla suç tahmini, sosyal medya hizmetleri gibi birçok alanda makine öğrenme kullanılmaktadır. Basit bir şekilde anlatmak gerekirse, makine öğretme işi her denemede daha iyi sonuçların verildiği yapısal bir süreçtir. Makine öğrenimi genel olarak üç aşamalı bir süreçtir. İlk aşamada metin dosyaları, tablolar ve SQL veri tabanının kullanıldığı veri girdi aşaması vardır. İkinci aşama, seçilen algoritmaları kullanarak verilerin yapısal formda gösterildiği ve ilk öğretimin gerçekleştiği verilerin çıkarılması aşamasıdır. Üçüncü ve son aşama ise pratik uygulamanın olduğu uygulama aşamasıdır. Eğitim veri türlerinin ve kategorilerinin mevcudiyetine bağlı olarak, uygun makine öğrenimi algoritmasını uygulamak için “denetimli öğrenme”, “yarı denetimli öğrenme”, “denetimsiz öğrenme” ve “pekiştirmeli öğrenme” tekniklerinden birini seçmek gerekebilir (Ray, 2019).

#### 3.1. Genel Makine Öğrenme Algoritmaları

Makine öğrenimi algoritmaları genellikle bireyler, iş süreçleri, işlemler, olaylar vb. ile ilgili kalıpları öğrenmek için verileri işler. Günümüzde yapay zeka ve makine öğrenme uygulamaları oldukça popüler olup her geçen gün farklı bir disiplinde kullanımına rastlanmaktadır. Çok geniş bir konu olması ve çok fazla bilim dalına hizmet vermesi sebebiyle algoritmaların sınıflandırılmasında henüz net bir fikir birliği bulunmamaktadır. Bu nedenle her kaynakta farklı bir sınıflandırma şekli ile karşılaşılabilir. Aşağıda verilen alt bölümlerde, en yaygın olarak kullanılan makine öğrenimi algoritmaları genel olarak incelenmiştir.

### 3.1.1. Doğrusal Regresyon Algoritması

Doğrusal regresyon algoritması, denetimli bir öğrenme yaklaşımıdır. Bu yöntemde değişkenler sürekli modellenir ve böylece tahminler yapılır. Gayrimenkul fiyat tahmini, satış tahmini, öğrencilerin sınav puanlarının tahmini, borsadaki hisse fiyatlarındaki hareketlerin tahmini gibi uygulamalar regresyon analizinin uygulamasına örnek verilebilir. Doğrusal regresyon yönteminde etiketli veri kümeleri bulunmaktadır ve çıkış değişken değeri giriş değişken değerleri tarafından belirlenmektedir. Bu sebeple de denetimli öğrenme sınıfına dahildir. En basit regresyon şekli doğrusal regresyondur. Doğrusal regresyon, veri kümesinin değişkenleri arasındaki ilişkinin doğrusal olduğu durumlarda mümkündür. Doğrusal regresyonun en önemli avantajı anlaşılmasının kolay olmasıdır. Ayrıca, doğrusal modelleri yeni verilerle güncellemek için kullanılabilir. Ortak değişkenlerle yanıt değişkeni arasındaki ilişkinin doğrusal olduğu durumlarda iyi bir uyum ortaya çıkabilir. Bu yöntem, veri analiz sürecini yönetmek için iyidir. Buna karşın, gerçek dünya problemlerinin çözümünde önerilen bir yöntem değildir. Çünkü problemleri aşırı basitleştirir (Ray, 2019).

### 3.1.2. Çoklu Regresyon Algoritması

Temel bir doğrusal regresyon modelinde tek bir bağımsız değişken tarafından yönlendirilen bir bağımlı değişken vardır. Buna karşın, gerçek dünyadaki problemler çok daha karmaşık olabilir. Örneğin, bir evin fiyatı tek değişkenli olarak hesaplanabilir ancak bu çok gerçekçi bir hesaplama olmaz. Çünkü bulunduğu semt, bölge, sahip olduğu oda sayısı, sosyal imkanlar, toplu taşımaya yakınlık, alışveriş bölgelerine yakınlık, eğitim kurumlarına yakınlık vb. gibi birçok faktöre bağlıdır. Bir başka deyişle, basit doğrusal regresyonda girdi değişkeni ile çıktı değişkeni arasında bire bir ilişki vardır. Ancak çoklu doğrusal regresyonda, bir dizi bağımsız değişken ile bir bağımlı değişken arasında karmaşık bir ilişki vardır. Bununla beraber, daha fazla girdi değişkeni eklemek, regresyonun daha iyi olacağı veya daha iyi tahminler sunacağı anlamına gelmez. Sonuç olarak, doğrusal ve çoklu regresyon farklı kullanım alanlarına sahiptir ve hangisinin daha iyi olduğu ancak kullanım yerine göre değişebilir. Örneğin; bazı durumlarda çok fazla girdi değişkeninin olması aşırı uydurma ile sonuçlanacağı için işleri daha da karmaşık hale getirebilir (Ray, 2019).

### 3.1.3. Örnek Tabanlı Algoritmalar

Örnek Tabanlı Algoritmalar, eğitim verilerinden yola çıkılarak hedef fonksiyonun net bir şekilde tanımlandığı diğer makine öğrenme metodlarından farklıdır. Bu öğrenme yönteminde, başlangıç aşamasında herhangi bir hedef fonksiyonu tanımlanmaz. Bunun yerine bu algorithmada eğitim örneği saklanır ve genelleme yeni bir örnek sınıflandırılana kadar ertelenir. Bu yapısı sebebiyle tembel öğrenen algoritma olarak da bilinir. Bu tür uygulamalarda eğitim örneklerine ait bir veri tabanı oluşturulur. Yeni verilerin girdi olarak eklenmesi durumunda en yakın eşleşmeyi bulmak ve tahminde

bulunmak için bir benzerlik ölçüsü kullanır. Daha sonra bu verileri veri tabanındaki diğer örneklerle karşılaştırır. Tembel olarak adlandırılan öğrenici, sınıflandırılacak her yeni örnek için hedef fonksiyonu tüm örnek uzayı için global olarak tahmin etmek yerine farklı ve yerel olarak tahmin eder. Bu yapısından ötürü eğitilmesi daha hızlı olur ancak tahmin etmesi zaman alır. KMeans, k-medyan, hiyerarşik kümeleme ve beklenti maksimizasyonu, bazı popüler örnek tabanlı algoritmalarıdır (Alzubi ve ark., 2018).

#### **3.1.4. Karar Ağaçları**

Karar ağacı, en yaygın kullanılan sınıflandırma ve regresyon modellerinden biridir. Bu yöntemin yaygın olarak kullanılmasının en büyük nedenleri kolay yorumlanabilir olması, diğer sistemlerle entegrasyonunun daha kolay olması, anlaşılabilir kurallar ortaya koyacak bir yapıya sahip olması ve güvenilir olmasıdır. Herhangi bir parametrik yöntemde olması gereken homojen varyans, normal dağılım, bağımsız gözlemler, aralıklı ölçek olması varsayımlarının her zaman sağlanması mümkün olmayabilir. Böyle bir durumda parametrik olmayan veri analiz yöntemleri tercih edilmektedir. Karar ağaçları genelden özele giden ve aşağıya doğru eğitilmiş verilerden üretilmektedir. Bu ağaçların yapısı incelendiğinde kök, dallar ve yaprakların olduğu görülür. Bu yapısı nedeniyle standart bir ağaç görünümünü andırmaktadır. Ağaç, örneklem içerisindeki tüm verileri içeren bir kök düğümle başlamaktadır. Kök düğümle başlayan ağaçlar aşağı doğru iner ve inerken çok sayıda veri kümesini küçük gruplar halinde ayırır ve dallara böler. Kökten başlayıp dallara doğru gidildikçe yapıdaki her boğuma düğüm denir. Bu yapıdaki heterojen düğümlere çocuk düğüm denirken homojen düğümlere ise terminal düğüm denir. Her bir düğüm en az iki dala ayrılırken yeni soruların olmadığı durumlarda dallanmanın bittiği anlamı çıkar. Dallanmanın bittiği yerde ise sınıfı temsil eden yapraklara ulaşılır. Karar ağaçlarında öğrenme ve sınıflama olmak üzere iki aşamadan oluşan bir veri sınıflandırması yapılır. Öğrenme aşamasına geçilmeden önce eğitim verisi sınıflandırma yöntemi aracılığıyla incelenir. Buradaki nihai amaç modeli ortaya çıkarmaktır. Bu modelin öğrenilmesi ile sınıflama kuralları oluşturulur. İkinci aşama olan sınıflamada ise test verisi kullanılarak karar ağacının doğru olup olmadığı sorgulanır (Demirel ve Yakut, 2019).

#### **3.1.5. Naive Bayes Algoritması**

Naive Bayes algoritması, Bayes teoreminin güçlü ve bağımsız varsayımla uygulanmasına dayanan basit olasılıksal bir sınıflandırma yöntemidir. Kendi kendini belirleyen özellik modeli olarak da adlandırılan Naive Bayes algoritması, temel olarak bir sınıfın belirli bir özelliğinin varlığının, başka herhangi bir özelliğinin varlığıyla ilişkisiz olduğu prensibine göre çalışmaktadır. Naive Bayes sınıflandırıcısı, temel varsayım doğru olmasa bile oldukça iyi performans gösterir. Naive Bayes yönteminin özelliği, sınıflandırma yapmak adına gerekli olan değişkenlerin ortalamalarını ve



varyanslarını tahmin etmektir. En büyük avantajı ise bunun için çok az eğitim verisi gerektirmesidir. Bağımsız değişkenler tanımlanmadığından, kovaryans matrisinin tamamı değil, yalnızca her bir etiket için değişkenlere ait varyansların belirlenmesi gerekir (Vijayarani ve Dhayanand, 2015).

### **3.1.6. Yapay Sinir Ağları**

Yapay Sinir Ağları, biyolojiden ilham alarak oluşturulmuş bir yapay zeka modelidir. Bu model, sinirbilim alanında önemli ilerlemelerin olduğu ve sinir ağı modellerinin önemini anlamaya yönelik gelişmelerin ortaya çıktığı 1980'lerden beri büyük ilgi görmektedir. Beynin nöron fonksiyonları, oldukça anormal doğrusal olmayan değişkenler arasında ilişkiler kurabilen ve böylece öğrenme/eğitim süreçlerini yöneterek karmaşık problemleri basit, doğru ve güvenilir şekilde sonuçlandıran geniş algoritma setleri tarafından kopyalanır. Bu setler, yapay sinir ağlarını temsil etmektedir (Çavuş ve Sarıkaya, 2021). Genellikle iki tür sinir ağı bulunmaktadır. Bunlardan birincisi en temel ve basit YSA paradigması olan İleri Beslemeli Sinir Ağıdır. Bu paradigmada çıktı katmanının geri besleme bağlantıları veya tekrarlayan ağlar için bir döngü oluşmaz. Bir başka deyişle, ileriye doğru tek yönlü bir akış gerçekleşir. İkinci tür sinir ağı ise yaygın olarak denetimli öğrenme kullanılan ve Geri Yayımlı YSA olarak adlandırılan Geri Beslemeli Sinir Ağıdır. Daha doğru bir çıktı elde etmek için hata iyileşmeyi bitirene kadar ağırlık değerlerinin yinelemeli olarak değiştirilmesi için hatalı bilgilerin geri gönderildiği bir döngü oluşturulmasına izin verir (Otchere ve ark., 2021).

### **3.1.7. Derin Öğrenme**

Derin öğrenme, her düzeyde farklı soyutlama düzeyine karşılık gelen ve birden çok katman kullanan bir makine öğrenme algoritmasıdır. Derin öğrenme, giriş katmanı, çıkış katmanı ve birkaç gizli katmandan oluşmaktadır. Ses analizi, görüntü işleme, el yazısı tanıma, nesne algılama, tahmin analitiği ve karar verme derin öğrenmenin uygulamalarından bazılarıdır. Derin öğrenme, denetimli veya denetimsiz öğrenme tekniklerinden oluşan ve derin mimarilerde hiyerarşik temsilleri öğrenebilen birçok yapay sinir ağı katmanına dayanır. Bir başka deyişle, yapay sinir ağlarının genişletilmiş versiyonudur. Bu yöntemde, her katmanın girdi katmanından gelen verilere dayalı olan ve doğrusal olmayan yanıtlar üretilebilir. Bunun için derin öğrenme mimarileri birden çok işlem katmanından oluşmaktadır. Derin öğrenmede işlevsellik sinyallerin iyileşmesi adına insan beyni ve nöronların mekanizmalarının taklit edilmesinden gelir. Son yıllarda diğer geleneksel makine öğrenimi yaklaşımlarına kıyasla daha fazla ilgi gören derin öğrenme sığ yapılandırılmış öğrenme mimarileri arasında görülür (Chahal ve Gua, 2019).

#### 4. EKLEMELİ İMALATTA MAKİNE ÖĞRENME UYGULAMALARI

Makine öğrenme, yapay zeka uygulamalarından biridir ve eklemeli imalat sürecinde giderek daha popüler hale gelmektedir. Üç boyutlu ürünlerin baskısı veya hızlı prototipleme olarak da bilinen eklemeli üretim, bilgisayar destekli tasarım programları tarafından oluşturulan kodlar aracılığıyla katmanlı üretim yapan imalat süreci olarak tanımlanır. Makine öğrenimi, elde bulunan örnek verileri ya da geçmiş tecrübeleri kullanarak uygulanan performans kriterini optimize etmek için bilgisayar programlama olarak bilinmektedir. Son dönemde makine öğrenme algoritmaları ürün kalitesinin iyileştirilmesi, üretim sürecinin optimize edilmesi ve maliyetleri düşürmek için eklemeli imalat sürecinde kullanılmaktadır. Şu anda eklemeli imalattaki en büyük problemlerden biri baskı hızı ve katman kalınlığı gibi parametreler dahil olmak üzere çok sayıdaki işleme parametresinin ürün kalitesi üzerindeki tutarsız etkisidir. Bu problemi çözümlerin en iyi yolu güvenilir veriler elde etmek ve işleme parametrelerini optimize etmeyi sağlayacak deneyler veya yüksek doğrulukta simülasyon çalışmaları yapmaktır. Ancak, bu yöntemlerin her ikisi de hem yüksek maliyetli hem de zaman alıcıdır. Bu durum için başka yöntemler de denenebilir ancak hangi yöntem denirse denensin, veri analizi ve veri madenciliği için etkin bir araç her zaman önemli bir ihtiyaçtır (Meng ve ark., 2020). Burada makine öğrenme yöntemi ve algoritmaları bu açığı kapatabilecek potansiyele sahiptir. Bu amaçla ilgili araştırmacılar tarafından birçok çalışma yapılmış ve eklemeli imalat süreçlerinde makine öğrenmenin etkin kullanımı araştırılmıştır. Çalışmanın bu bölümünde, dünya ve Türkiye’de bu amaca yönelik yapılmış çalışmalar incelenmiş ve bunlardan bazıları paylaşılmıştır. Örneğin; Gue ve ark. hiyerarşik malzemelerin üretimi için makine öğrenimi tabanlı bir yaklaşım üzerinde çalışmışlardır. Sonlu elemanlar analizinde yüz binlerce geometriden oluşan bir veri tabanı kullanılarak eğitilen makine öğrenimi modeli ile oluşturulan yeni tasarımlar deneylerle doğrulanmıştır. Araştırmacılar, kendi kendine öğrenme algoritmasıyla sinir ağı modelini genişleterek daha iyi tasarımlar oluşturmak için örneklenmiş en iyi performans gösteren geometrileri elde etmeyi ve kalitesiz tasarımları ortadan kaldırmayı amaçlamışlardır. Araştırmacılar sonuç olarak, daha iyi performans gösteren daha iyi tasarımlar elde ettiklerini ve literatürde ilk kez, makine öğreniminin, tam mikroyapısal veriler kullanılmadan malzemeleri analiz etme ve tasarlama için alternatif bir yöntem olarak kullanılabileceğini iddia etmişlerdir (Gue ve ark., 2018). Yao ve ark. R/C araba komponentlerini eklemeli imalatla üretirken tasarım gelişimi için hibrit bir makine öğrenme algoritması olarak hiyerarşik kümelemeyi (denetimsiz makine öğrenme) kullanmışlardır. Bu makine öğrenme algoritmasında, kodlanmış eklemeli imalat tasarım özellikleri ve hedef bileşenler üzerinde hiyerarşik bir kümeleme gerçekleştirmişler ve bir dendrogram elde etmişlerdir. Mevcut endüstriyel uygulama örnekleri, istenilen eklemeli imalat tasarım özelliklerini içeren dendrogram içindeki son alt kümeyi belirleyen denetimli bir sınıflandırıcıyı eğitmek için kullanılmıştır. Araştırmacılar sonuç olarak, kullanılan hibrit makine öğrenme yönteminin optimum eklemeli imalat tasarım özelliklerini

önerebildiğini ve bunun da deneyimsiz tasarımcılar için uygulanabilir kavramsal tasarım çözümleri sağlamada yararlı olduğu iddia etmişlerdir (Yao ve ark., 2017). Zhang ve ark. lazer tozu yatak füzyon yöntemi ile ürettikleri paslanmaz çelik 316L'nin yorulma ömrünü tahmin etmek için nöro-bulanık tabanlı bir makine öğrenimi yöntemini kullanmışlardır. Araştırma esnasında girdi parametresi olarak lazer gücü, tarama kalınlığı ve katman kalınlığı kullanılırken üretim sonrası işlem olarak tavlama ve sıcak izostatik presleme kullanmışlardır. Bunlara ek olarak, döngüsel gerilimlere maruz kalan numuneler için yorulma ömrü verilerinden oluşan bir veri seti, karmaşık bir doğrusal olmayan girdiyi simüle etmek için kullanılmıştır. Eğitim verilerinden sırasıyla işleme/son işlem parametreleri ve statik çekme özellikleri girdi olarak kullanılarak iki model geliştirilmiştir. Sonuçları analiz eden araştırmacılar, çeşitli yorulma ve kırılma özelliklerine rağmen, test verilerine göre iyi bir tahmin doğruluğu gösterdiğini iddia etmişlerdir (Zhang ve ark., 2019). Tapia ve ark. Seçici Lazer Ergitme (SLM) yöntemiyle 17-4 PH paslanmaz çelik malzeme üretmişler ve üretilen numunelerdeki gözenekliliğin tahmin edilmesi için Gauss proses tabanlı bir tahmin modeli geliştirmişlerdir. Çalışma esnasında literatürde parça gözenekliliği üzerinde en etkili işleme parametrelerinden ikisi olarak tanımlanan lazer gücünün ve tarama hızının olduğu ve parça gözenekliliğinin bunların bir fonksiyonu olduğunu ifade eden araştırmacılar, Gauss proses tabanlı bir tahmin modeli formüle etmişlerdir. Araştırmacılar uzamsal Gauss proses regresyon modelinin ilk kez SLM proses parametrelerinin bir fonksiyonu olarak ürün gözenekliliğini modellemek için kullanıldığını vurgulamıştır. Daha sonra, istatistiksel model parametrelerini tahmin etmek için bir Bayes çıkarım çerçevesi kullanılmış ve herhangi bir ayarda parçanın gözenekliliği Kriging yöntemi kullanılarak tahmin edilmiştir. Çalışma sonunda araştırmacılar, optimum işleme parametresi ve minimum deney sayısını elde ettiklerini ve böylece zamandan ve maliyetten tasarruf sağlayan sistematik bir yaklaşım sunduklarını iddia etmişlerdir (Tapia ve ark., 2016). Douard ve ark. destek yapısı parametrelerinin geometrik kalite üzerindeki etkisini araştırmak için bir dizi numune üretmişlerdir. Araştırma esnasında eklemeli imalat yöntemi olarak EBM yöntemini kullanan araştırmacılar, bazı makine öğrenme algoritmalarını (Karar Ağacı, Tümevarım Kuralı ve Naive Bayes) kullanarak test yapmışlardır. Makine öğrenme modellerine ait sonuçların kıyaslamasını yapan araştırmacılar örnek sayısının çok düşük olduğunu ve bu nedenle yeterli seviyede kararlı performansa sahip yapay zeka modellerinin karşılaştırmasının zor olduğunu söylemişlerdir. Ayrıca, numune sayısının azlığı nedeniyle standart sapma oranının çok yüksek çıkabildiğini ve bunun da karar vermeyi zorlaştırdığını söylemişlerdir. Yine de sonuçları analiz eden araştırmacılar, Karar Ağaçları ve Tümevarım Kuralları modellerinin çok yakın sonuçlar verdiğini iddia etmişlerdir. Bu çalışma özelinde numune azlığının önemini vurgulayan araştırmacılar yine de sonuçların eklemeli imalat sürecinde makine öğrenme tekniklerinin kullanılmasının faydalı olduğunu gösterdiğini iddia etmişlerdir (Douard ve ark., 2018). Bayraktar ve ark. FDM yöntemini kullanarak üç boyutlu plastik parçaların mekanik özelliklerini araştırmışlardır. Deney numuneleri polilaktik asit

(PLA) malzemeden üretilirken üretim parametresi olarak üç erime sıcaklığı, dört katman kalınlığı ve üç raster desen yönelimi seçilmiştir. Numunelerin üretiminden sonra çekme dayanımı testleri yapılmış ve ayrıca kırılma yüzeyleri analiz edilmiştir. Çalışmada ayrıca, yapay sinir ağları kullanılarak, üç boyutlu üretimde kullanılan raster desene karşılık gelen çekme testi sonuçları için matematiksel bir model üretilmiştir. Deney sonuçlarını analiz eden araştırmacılar, eriyik sıcaklığının, tabaka kalınlığının ve raster desen oryantasyonunun numunelerin gerilme mukavemetleri üzerinde önemli bir etkiye sahip olduğunu iddia etmişlerdir. Ayrıca,  $R^2$ 'ye göre, sırasıyla 0,999199 ve 0,999997 test ve eğitim değerleri ile en iyi performans gösteren yapay sinir ağı modelinin çapraz tarama deseni olduğu iddia edilmiştir (Bayraktar ve ark., 2017). Meng ve Zhang lazer tozu yatak füzyon işleminde lazer gücü ve tarama hızının bir fonksiyonu olarak izlerin yeniden eritilmiş derinliğini tahmin etmek için Gauss Process (GP) tabanlı bir makine öğrenme modeli geliştirilmişlerdir. GP modelinin eğitilmesinde literatür verileri kullanılmıştır ve hem simülasyon hem de deneysel olarak eğitilmiştir. Araştırmacılar çalışma sonunda 30  $\mu$ m katman kalınlığına sahip bir toz yatağı için GP modeli tarafından bulunan ortalama mutlak tahmin hatasının 0,6  $\mu$ m olduğunu söylemişler ve bu sonucun GP modelinin yeterliliğini kanıtladığını iddia etmişlerdir. Francis ve Bian, (Francis ve Bian, 2019) Lazer Tabanlı Eklemeli İmalat yöntemindeki zorluklardan birinin üretilen parçalardaki geometrik yanlışlar olduğunu tespit etmişler ve bunu düzeltmek için bozulmanın yüksek doğrulukla tahmin edilmesi gerektiğini söylemişlerdir. Bu sorunu düzeltmeye yönelik yerel ısı transferini göz önünde bulunduran araştırmacılar, noktasal bozulma tahmini için yüksek boyutlu, termal geçmiş (ör. termal görüntüler) ve ilgili süreç/tasarım parametreleri için özelleştirilmiş bir Derin Öğrenme modeli geliştirmeyi amaçlamışlardır. Büyük Veri kullanarak Katmanlı İmalat Tahmini için Evrimsel ve Yapay Sinir Ağı adını verdikleri bu model termal görüntüleri analiz etmek için bir Evrimsel Sinir Ağı (CNN) ve ilgili süreç/tasarım parametrelerini dahil etmek için bir Yapay Sinir Ağı (YSA) içermektedir. Bu modelde Evrimsel Sinir Ağı çıktısı ile Yapay Sinir Ağı çıktısı Büyük Veri kullanarak Katmanlı İmalat Tahmini için Evrimsel ve Yapay Sinir Ağı içinde birleştirilmiş ve nihai bir noktasal bozulma tahmini vermek için daha fazla eğitilmiştir. Sonuç olarak araştırmacılar, oluşturulan modelin bozulmayı doğru bir şekilde tahmin edebildiğini iddia etmişlerdir (Meng ve Zhang, 2020). Caiazzo ve Caggiano yaptıkları çalışmada, 5 mm kalınlığındaki 2024 alüminyum alaşımı üzerine lazer doğrudan metal biriktirme yöntemi ile metal kaplama yapmışlar ve proses parametreleri ile çıktı parametreleri arasındaki korelasyonu bulmak istemişlerdir. Araştırmacılar bunun için yapay sinir ağlarına dayalı bir makine öğrenmesi yaklaşımı geliştirilmiştir. Sonuçları inceleyen araştırmacılar, yapay sinir ağı tabanlı makine öğrenimi paradigmasının, biriken metal izi için belirli bir geometri elde etmek adına gereken optimum işlem parametrelerini doğru bir şekilde tahmin edebildiğini iddia etmişlerdir (Caiazzo ve Caggiano, 2018). Koeppe ve ark. küçük kafes hücrelerinden yapılan yapıların mekanik davranışlarını verimli bir şekilde analiz etmek ve sonlu bir elemanın doğrusal elasto-plastisitesi alanındaki maksimum

gerilmeleri tahmin etmek için sinir ağlarını ve derin öğrenmeyi kullanan bir strateji modeli geliştirmişlerdir. Model, tek bir kafes hücre numunesi üzerinde gösterilmiştir. Sonuçları analiz eden araştırmacılar deney verileri, sonlu elemanlar ve yapay sinir ağı sonuçları arasında benzerlik olduğunu iddia etmişlerdir. Dahası, üretilen model ile hesaplama zamanının önemli bir seviyede düştüğünü söylemişlerdir (Koeppe ve ark., 2018). Shevchik ve ark. eklemeli imalatla üretilen ürünlerin kalitesini takip etmek için akustik emisyon kullanımının fizibilitesini araştırmış ve hassas bir akustik emisyon sensörünü makine öğrenme ile birleştirmiştir. Bunun için SLM yönetimiyle farklı gözenek oranlarına sahip numuneler üretmişler ve bunların kalitesini düşük, orta ve yüksek olarak tanımlamışlardır. Malzeme üretimi esnasında toplanan akustik sinyaller iki ayrı veri kümesine dönüştürülmüştür. Bu kümelerden birisi eğitim diğeri de test için kullanılmıştır. Spektral evrişimli sinir ağına dayanan sınıflandırıcı, farklı kalitedeki akustik özellikleri ayırt etmek için eğitilmiştir. Dar gözeneklilik aralığını göz önüne alan araştırmacılar sonuçların umut verici olduğunu ve alt katman uzamsal çözünürlüğü ile akustik emisyon kullanarak kalite izlemenin olumlu sonuçlar doğurabileceğini söylemişlerdir (Shevchik ve ark., 2018). Wang ve ark. Sıvı Metal Jet Baskı ile ürünler üretirken püskürtme aşamasında proses stabilitesi ile ürün kalitesini olumsuz etkileyen ve kontrol edilemeyen birçok parametre olduğunu iddia etmişlerdir. Bu sorunun çözümü adına damlacık davranışlarını denetlemek buna göre üretim sürecini stabilize etmek için kapalı döngü bir kontrol süreci oluşturmayı amaçlamışlardır. Bunun için görüntü tabanlı teknik ve yapay sinir ağı yöntemlerini kullanmışlardır. Buna göre, görsel denetim sonucuna dayalı olarak kontrol edilemeyen parametreleri telafi etmek için uygulanan sürücü voltajı otomatik ayarlanmaktadır. Sonuçları açıklayan araştırmacılar, gerçek zamanlı olarak önemli ölçüde kararlı püskürtme davranışının elde edilebileceğini söylemişlerdir (Wang ve ark., 2018). Gobert ve ark. Toz Yatak Füzyonu yöntemi ile üç boyutlu parça üretilmesi esnasında kusur algılama için bir model geliştirmişlerdir. Bu işlem için çözünürlük değeri yüksek ve dijital bir lensli refleks kamera kullanılarak her bir yapı katmanında birden fazla görüntü toplamışlardır. Elde edilen katmansal görüntü yığınlarının çok boyutlu görsel özellikleri çıkarılmış ve ikili sınıflandırma teknikleri doğrusal destek vektör makinesi kullanılarak değerlendirilmiştir. Ayrıca, eksik füzyon, gözeneklilik, çatlaklar veya kalıntılar otomatik analiz araçları veya elle tespit edilerek tanımlanmıştır. Araştırmacılar, sınıflandırıcı uygun şekilde eğitilen modelin çapraz doğrulama deneyleri esnasında %80'den daha büyük hata tespiti yapıldığını söylemişlerdir (Gobert ve ark., 2018). Zhang ve ark. parça kalitesini, yapım süresini ve maliyeti doğrudan etkilediği için eklemeli imalattaki en önemli süreç planlama işlerinden biri olan yapı oryantasyonunu optimize etmek için yapay zeka tekniklerini kullanmıştır. Bu optimizasyon sorununun çözümü için iki aşamalı bir çalışma uygulamışlardır. Birinci aşamada, her bir parçanın yapı kalitesini belirlemek için belirli bir ürün grubu içerisinde özellik tabanlı bir yöntem kullanmışlardır. Buradaki temel amaç bir dizi sonlu optimal alternatif oryantasyon oluşturmaktır. İkinci aşamada ise optimum yapım süresi ve maliyeti düşürmek adına bir genetik algoritma

uygulanmıştır. Burada yapı yönelimlerinin optimum kombinasyonu aranmıştır. Çalışma sonunda araştırmacılar sonuçların umut vadecici olduğunu söylemişlerdir (Zhang ve ark., 2017). Mahapatra ve Sood, FDM teknolojisinde proses parametreleri ve çıktılar arasında iyi bir ilişki kurmanın zorluklarından bahsetmiş ve bu sorunu çözmek için Yapay Sinir Ağlarını kullanmışlardır. Modelin oluşturulmasında katman kalınlığı, oryantasyon, raster açısı, raster genişliği ve boşluk oranının olduğu beş giriş parametresi kullanmışlar ve çıktı parametresi olarak da yüzey pürüzlülüğünü dikkate almışlardır. Boyuttan bağımsız olarak ağ parametrelerinin sayısını sabitleyebildiği için optimum ağ mimarisi seçiminde Bayes düzenleştirmesi kullanılmıştır. YSA modeli, Levenberg-Marquardt algoritması kullanılarak eğitilmiştir. Eğitimden sonra optimum mimari olarak 5-7-3 seçilmiştir. Çıktılar ve hedefler arasındaki yüksek korelasyon katsayısı ( $R^2$  değeri) ile ağın performans analizini yapan araştırmacılar sonuçların olumlu olduğunu iddia etmişlerdir (Mahapatra ve Sood, 2012). Chen ve Zhao Bağlayıcı Püskürtme yöntemini kullandıkları eklemeli imalat sürecinde uygun proses parametrelerinin seçiminin her zaman zor olduğunu vurgulamışlardır. Bunun en temel nedeninin ise üretilen ürünlerin kalite özelliklerinin proses parametrelerinden önemli ölçüde etkilenmesi olduğunu söylemişlerdir. Bu soruna ait çözüm önerisi üretmek için yaptıkları çalışmalarında, dört girdi parametresi ve iki çıktı parametresini kullanmışlardır. Taguchi Metodu kullanarak yaptıkları deney tasarımına göre 16 adet numune ürettikleri deneysel çalışmaya dayanarak Geriye Yayılım Sinir Ağı algoritması ile bir süreç modeli geliştirmişlerdir. Dolayısıyla, ürün kalite özelliklerini ve baskı süresini azaltmaya yardımcı olmak için bir model geliştirmişlerdir. Sonuç olarak araştırmacılar, elde edilen modelin üretim parametrelerini seçmek için iyi bir kılavuz olabileceğini iddia etmişlerdir (Chen ve Zhao, 2015). Xiong ve ark. katmanlı imalat kullanarak yapılan kaplama işleminde katman kalınlığı, yüzey kalitesi ve boyutsal doğruluk üzerinde önemli bir etkiye sahip olan tek kaynak dikışı geometrisini tahmin etmek için bir sinir ağı uygulaması ve ikinci dereceden regresyon analizini kullanmışlardır. Çalışma esnasında merkezi bir kompozit dönebilir tasarım uygulanarak bir dizi deney yapılmıştır. Sonuçları inceleyen araştırmacılar, sinir ağı modelinin herhangi bir doğrusal olmayan sürece yaklaşma kapasitesi nedeniyle ikinci dereceden regresyon modelinden daha iyi bir performans gösterdiğini söylemişlerdir. Bu nedenle, yapay sinir ağlarının yüksek hassasiyetle tahmin için kullanılabilmesini iddia etmişlerdir (Xiong ve ark., 2014). Li ve ark. eklemeli imalat ile üretilen numunelerin yüzey pürüzlülük değerlerini tahmin etmek için topluluk öğrenme algoritmasını kullanmışlardır. Çalışma sırasında zaman ve frekans alanlarındaki özellikler sensör tabanlı izleme verilerinden elde edilmiştir. Hesaplama verimliliği tahmin doğruluğunu artırmak için bu özelliklerin bir alt kümesi seçilmiştir. Deneysel sonuçlar, önerilen tahmine dayalı modelleme yaklaşımının, 3B yazdırılan bileşenlerin yüzey pürüzlülüğünü yüksek doğrulukla tahmin edebildiğini göstermiştir (Li ve ark., 2019). Zhu ve ark. eklemeli imalatta şekil sapmalarının modellenmesini ele almak için makine öğrenimi teknikleriyle birleştirilmiş bir kuralcı sapma modelleme yöntemi geliştirmişlerdir. Çalışma

esnasında düzlem içi sistematik sapmaları ve rastgele yerel varyasyonları modellemek için bir dönüşüm perspektifini ve bir Gauss proses çoklu görev öğrenmesini birleştiren bir yöntem kullanılarak geometrik sapma tahmin edilmiştir. Sonuçlar, üretilen model ile tasarımcıların üretimden önce eklemeli imalat ürünlerinin işlevselliğini değerlendirmelerini sağlayacak daha güvenilir bir modele katkıda bulunacağını göstermiştir (Zhu ve ark., 2018). Xia ve ark. tel ark eklemeli imalat yöntemi tarafından oluşturulan katmanların yüzey pürüzlülüğünü tahmin etmek ve iyileştirmek amacıyla çeşitli makine öğrenme tekniklerinden faydalanmışlardır. Bu amaca yönelik olarak Adaptive Neuro-Fuzzy Inference System (ANFIS), Extreme Learning Machine (ELM) ve Support Vector Regression (SVR) dahil olmak üzere çeşitli makine öğrenme modelleri geliştirilmiştir. Ayrıca ANFIS modeli, genetik algoritma ve parçacık sürüsü optimizasyonu algoritmaları ile optimize edilmiştir. Eğitim verilerini elde etmek için tam faktöriyel deneyler yapılmıştır. Çalışma sonunda araştırmacılar, genetik algoritma-ANFIS modelinin daha iyi sonuçlar verdiği iddia etmişlerdir (Xia ve ark., 2022).

## 5. SONUÇ VE ÖNERİLER

Bu çalışmada, ilk etapta eklemeli imalat ve makine öğrenimi ile ilgili genel literatür bilgileri sunulmuştur. Daha sonra eklemeli imalatla yapılan üretim sürecinde makine öğrenmenin uygulandığı bazı çalışmaların özet bilgileri verilmiştir. Hem literatür çalışması hem de uygulama örnekleri incelendiğinde makine öğrenmesinin eklemeli imalat üzerinde olumlu etkilere sahip olduğu görülmüştür. Özellikle, üretimi hızlandırmak, proses parametrelerinin seçimine yardımcı olmak, yeni malzemeleri keşfetmek, özellik-yapı ilişkisinin tanımlanmasını sağlamak, tasarım sürecindeki sorunların iyileştirilmesine yardımcı olmak, yüzey pürüzlülük değerlerini ve dolayısıyla yüzey kalitesini tahmin etmek, boşluk seviyesini tahmin etmek, yüzey hatalarını en aza indirmek ve işlevsel kafes tasarımı oluşturmak gibi spesifik konularda makine öğrenmenin faydalı sonuçlar verdiği görülmüştür. Bununla beraber, çok önemli bir üretim yöntemi olan ve gelecekte öneminin daha da artması beklenen eklemeli imalat sürecinin iyileştirilmesi için çok daha fazla çalışmaya ihtiyaç olduğu görülmüştür. Özellikle deneysel verilerle makine öğrenme modellerinin birleştiği çalışmalar sürecin iyileştirilmesine çok daha fazla yardımcı olacaktır.

**KAYNAKÇA**

- Alzubi, J., Nayyar, A., & Kumar, A. (2018, November). Machine learning from theory to algorithms: an overview. In *Journal of physics: conference series* (Vol. 1142, No. 1, p. 012012). IOP Publishing.
- Arinez, J. F., Chang, Q., Gao, R. X., Xu, C., & Zhang, J. (2020). Artificial intelligence in advanced manufacturing: Current status and future outlook. *Journal of Manufacturing Science and Engineering*, 142(11).
- Aydın, D. S. (2022). Tİ6AL4V alaşımının seçici lazer ergitme yöntemi ile üretilmesinde belirli üretim parametrelerinin malzeme özelliklerine etkisi. (Y. Lisans Tezi), Erciyes Üniversitesi. Sivil Havacılık A.B.D., Kayseri.
- Bayraktar, Ö., Uzun, G., Çakiroğlu, R., & Guldaz, A. (2017). Experimental study on the 3D-printed plastic parts and predicting the mechanical properties using artificial neural networks. *Polymers for Advanced Technologies*, 28(8), 1044-1051.
- Caiazzo, F., & Caggiano, A. (2018). Laser direct metal deposition of 2024 Al alloy: trace geometry prediction via machine learning. *Materials*, 11(3), 444.
- Calignano, F., Manfredi, D., Ambrosio, E. P., Biamino, S., Lombardi, M., Atzeni, E., ... & Fino, P. (2017). Overview on additive manufacturing technologies. *Proceedings of the IEEE*, 105(4), 593-612.
- Chahal, A., & Gulia, P. (2019). Machine learning and deep learning. *International Journal of Innovative Technology and Exploring Engineering*, 8(12), 4910-4914.
- Chen, H., & Zhao, Y. F. (2015, August). Learning algorithm based modeling and process parameters recommendation system for binder jetting additive manufacturing process. In *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference* (Vol. 57045, p. V01AT02A029). American Society of Mechanical Engineers.
- Çavuş, V., Sarıkaya, M. (2021). Yapay Sinir Ağları ve Güneş Enerji Sistemlerinde Uygulamaları. Volkan ÇAVUŞ (Ed.), *Yapay Zeka Uygulamalarında Güncel Konular ve Araştırmalar içinde* (ss. 7-22). Konya, Çizgi Kitabevi Yayınları.
- Demirel, Ş., & Yakut, S. G. (2019). Karar ağacı algoritmaları ve çocuk işçiliği üzerine bir uygulama. *Sosyal Bilimler Araştırma Dergisi*, 8(4), 52-65.
- Douard, A., Grandvallet, C., Pourroy, F., & Vignat, F. (2018, December). An example of machine learning applied in additive manufacturing. In *2018 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)* (pp. 1746-1750). IEEE.
- Francis, J., & Bian, L. (2019). Deep learning for distortion prediction in laser-based additive manufacturing using big data. *Manufacturing Letters*, 20, 10-14.
- Gobert, C., Reutzler, E. W., Petrich, J., Nassar, A. R., & Phoha, S. (2018). Application of supervised machine learning for defect detection during metallic powder bed fusion additive manufacturing using high resolution imaging. *Additive Manufacturing*, 21, 517-528.
- Gu, G. X., Chen, C. T., Richmond, D. J., & Buehler, M. J. (2018). Bioinspired hierarchical composite design using machine learning: simulation, additive manufacturing, and experiment. *Materials Horizons*, 5(5), 939-945.
- Guan, X., & Zhao, Y. F. (2020). Modeling of the laser powder-based directed energy deposition process for additive manufacturing: a review. *The International Journal of Advanced Manufacturing Technology*, 107(5), 1959-1982.
- Guo, N., & Leu, M. C. (2013). Additive manufacturing: technology, applications and research needs. *Frontiers of mechanical engineering*, 8(3), 215-243.
- Huang, S. H., Liu, P., Mokasdar, A., & Hou, L. (2013). Additive manufacturing and its societal impact: a literature review. *The International Journal of Advanced Manufacturing Technology*, 67(5), 1191-1203.
- Januszewicz, R., Tumbleston, J. R., Quintanilla, A. L., Mecham, S. J., & DeSimone, J. M. (2016). Layerless fabrication with continuous liquid interface production. *Proceedings of the National Academy of Sciences*, 113(42), 11703-11708.
- Jiang, J., & Fu, Y. F. (2020). A short survey of sustainable material extrusion additive manufacturing. *Australian Journal of Mechanical Engineering*, 1-10.
- Koepe, A., Padilla, C. A. H., Voshage, M., Schleifenbaum, J. H., & Markert, B. (2018). Efficient numerical modeling of 3D-printed lattice-cell structures using neural networks. *Manufacturing Letters*, 15, 147-150.
- Konda Gokuldoss, P., Kolla, S., & Eckert, J. (2017). Additive manufacturing processes: Selective laser melting, electron beam melting and binder jetting—Selection guidelines. *Materials*, 10(6), 672.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.
- Li, N., Huang, S., Zhang, G., Qin, R., Liu, W., Xiong, H., ... & Blackburn, J. (2019). Progress in additive manufacturing on new materials: A review. *Journal of Materials Science & Technology*, 35(2), 242-269.



- Li, Z., Zhang, Z., Shi, J., & Wu, D. (2019). Prediction of surface roughness in extrusion-based additive manufacturing with machine learning. *Robotics and Computer-Integrated Manufacturing*, 57, 488-495.
- Liu, Z., He, B., Lyu, T., & Zou, Y. (2021). A review on additive manufacturing of titanium alloys for aerospace applications: directed energy deposition and beyond Ti-6Al-4V. *Jom*, 73(6), 1804-1818.
- Mahapatra, S. S., & Sood, A. K. (2012). Bayesian regularization-based Levenberg–Marquardt neural model combined with BFOA for improving surface finish of FDM processed part. *The International Journal of Advanced Manufacturing Technology*, 60(9), 1223-1235.
- Meng, L., McWilliams, B., Jarosinski, W., Park, H. Y., Jung, Y. G., Lee, J., & Zhang, J. (2020). Machine learning in additive manufacturing: a review. *Jom*, 72(6), 2363-2377.
- Meng, L., & Zhang, J. (2020). Process design of laser powder bed fusion of stainless steel using a Gaussian process-based machine learning model. *Jom*, 72(1), 420-428.
- Mercado Rivera, F. J., & Rojas Arciniegas, A. J. (2020). Additive manufacturing methods: techniques, materials, and closed-loop control applications. *The International Journal of Advanced Manufacturing Technology*, 109(1), 17-31.
- Monostori, L., Kádár, B., Bauernhansl, T., Kondoh, S., Kumara, S., Reinhart, G., ... & Ueda, K. (2016). Cyber-physical systems in manufacturing. *Cirp Annals*, 65(2), 621-641.
- Ngo, T. D., Kashani, A., Imbalzano, G., Nguyen, K. T., & Hui, D. (2018). Additive manufacturing (3D printing): A review of materials, methods, applications and challenges. *Composites Part B: Engineering*, 143, 172-196.
- Otchere, D. A., Ganat, T. O. A., Gholami, R., & Ridha, S. (2021). Application of supervised machine learning paradigms in the prediction of petroleum reservoir properties: Comparative analysis of ANN and SVM models. *Journal of Petroleum Science and Engineering*, 200, 108182.
- Paolini, A., Kollmannsberger, S., & Rank, E. (2019). Additive manufacturing in construction: A review on processes, applications, and digital planning methods. *Additive manufacturing*, 30, 100894.
- Ray, S. (2019, February). A quick review of machine learning algorithms. In 2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon) (pp. 35-39). IEEE.
- Saboori, A., Aversa, A., Marchese, G., Biamino, S., Lombardi, M., & Fino, P. (2019). Application of directed energy deposition-based additive manufacturing in repair. *Applied Sciences*, 9(16), 3316.
- Shevchik, S. A., Kenel, C., Leinenbach, C., & Wasmer, K. (2018). Acoustic emission for in situ quality monitoring in additive manufacturing using spectral convolutional neural networks. *Additive Manufacturing*, 21, 598-604.
- Singh, R., Gupta, A., Tripathi, O., Srivastava, S., Singh, B., Awasthi, A., ... & Saxena, K. K. (2020). Powder bed fusion process in additive manufacturing: An overview. *Materials Today: Proceedings*, 26, 3058-3070.
- Spoerk, M., Holzer, C., & Gonzalez-Gutierrez, J. (2020). Material extrusion-based additive manufacturing of polypropylene: A review on how to improve dimensional inaccuracy and warpage. *Journal of Applied Polymer Science*, 137(12), 48545.
- Tapia, G., Elwany, A. H., & Sang, H. (2016). Prediction of porosity in metal-based additive manufacturing using spatial Gaussian process models. *Additive Manufacturing*, 12, 282-290.
- Vijayarani, S., & Dhayanand, S. (2015). Liver disease prediction using SVM and Naïve Bayes algorithms. *International Journal of Science, Engineering and Technology Research (IJSETR)*, 4(4), 816-820.
- Wang, H., Ma, C., & Zhou, L. (2009, December). A brief review of machine learning and its application. In 2009 international conference on information engineering and computer science (pp. 1-4). IEEE.
- Wang, T., Kwok, T. H., Zhou, C., & Vader, S. (2018). In-situ droplet inspection and closed-loop control system using machine learning for liquid metal jet printing. *Journal of manufacturing systems*, 47, 83-92.
- Xia, C., Pan, Z., Polden, J., Li, H., Xu, Y., & Chen, S. (2022). Modelling and prediction of surface roughness in wire arc additive manufacturing using machine learning. *Journal of Intelligent Manufacturing*, 33(5), 1467-1482.
- Xiong, J., Zhang, G., Hu, J., & Wu, L. (2014). Bead geometry prediction for robotic GMAW-based rapid manufacturing through a neural network and a second-order regression analysis. *Journal of Intelligent Manufacturing*, 25(1), 157-163.
- Yao, X., Moon, S. K., & Bi, G. (2017). A hybrid machine learning approach for additive manufacturing design feature recommendation. *Rapid Prototyping Journal*.
- Zhang, M., Sun, C. N., Zhang, X., Goh, P. C., Wei, J., Hardacre, D., & Li, H. (2019). High cycle fatigue life prediction of laser additive manufactured stainless steel: A machine learning approach. *International Journal of Fatigue*, 128, 105194.

- Zhang, Y., Bernard, A., Harik, R., & Karunakaran, K. P. (2017). Build orientation optimization for multi-part production in additive manufacturing. *Journal of Intelligent Manufacturing*, 28(6), 1393-1407.
- Zhang, Y., Wu, L., Guo, X., Kane, S., Deng, Y., Jung, Y. G., ... & Zhang, J. (2018). Additive manufacturing of metallic materials: a review. *Journal of Materials Engineering and Performance*, 27(1), 1-13.
- Zhu, Z., Anwer, N., Huang, Q., & Mathieu, L. (2018). Machine learning in tolerancing for additive manufacturing. *CIRP Annals*, 67(1), 157-160.


# BÖLÜM

## 4

### GÜÇ TRANSFORMATÖRLERİNİN SAĞLIK İNDEKSİNİ BELİRLEMEDE YAPAY ZEKA YÖNTEMLERİNİN KULLANIMI


**Cenk GEZEGİN**


*Dr. Öğr. Üyesi, Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği  
Bölümü, cenk.gezegin@omu.edu.tr*

 0000-0002-4442-904X

**Hasan DİRİK**

*Dr. Öğr. Üyesi, Sinop Üniversitesi, Meslek Yüksekokulu, Elektrik ve Enerji Bölümü  
hasan\_dirik@hotmail.com*

 0000-0003-0625-7213




## BÖLÜM 4

### GÜÇ TRANSFORMATÖRLERİNİN SAĞLIK İNDEKSİNİ BELİRLEMEDE YAPAY ZEKA YÖNTEMLERİNİN KULLANIMI


**Cenk GEZEGİN**

*Dr. Öğr. Üyesi, Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, cenk.gezegin@omu.edu.tr*

 0000-0002-4442-904X

**Hasan DİRİK**

*Dr. Öğr. Üyesi, Sinop Üniversitesi, Meslek Yüksekokulu, Elektrik ve Enerji Bölümü hasan\_dirik@hotmail.com*

 0000-0003-0625-7213

#### 1. GİRİŞ

Transformatörler elektrik şebekelerinde gerilim seviyesinin yükseltilmesi veya alçaltılmasında kullanılırlar (Köroğlu, 2022). Bu donanımlar elektrik enerji sistemlerinin önemli araçlarından birisi olup özellikle yüksek gerilim sistemlerinde kullanılan güç transformatörleri büyük boyutları ve MVA seviyelerindeki güçleriyle oldukça pahalıdır (Gezegin, 2018). İletim şebekelerinin şalt sahalarında toplam yatırımın en yüksek kısmını %60 ile güç transformatörleri oluşturur (Scatiggio ve Pompili, 2013). Günümüzün elektrik şebekelerinde elektrik enerjisi büyük güçteki elektrik santrallerinde üretilerek iletim ve dağıtım şebekeleri aracılığıyla nihai tüketicilere ulaştırılır (Martin, 2009). Elektrik üretim ve tüketim tesisleri arasındaki uzak mesafeler büyük miktardaki elektrik gücünün bir noktadan başka bir noktaya olabildiğince düşük kayıplar ile taşınmasını gerektirir. İletim esnasında bu gücün bir kısmı hatlardaki kayıplara harcanır. Bu kayıpların büyük bir kısmı alternatif akımın iletkenlerde meydana getirdiği deri etkisi ve iletkenlerin omik dirençlerinden kaynaklanır. Genellikle bu kayıplar toplam iletilen gücün yaklaşık %5'ini oluşturur (Khan, 2022). İletim kayıplarını azaltabilmek için gerilim seviyesi transformatörler ile yükseltilerek akım azaltılır ve böylece  $I^2R$  kayıplarının azaltılması sağlanır. Tüketim noktalarında taşınan elektrik enerjisinin gerilimi transformatörler kullanılarak tekrar istenilen seviyelere düşürülür.

Dünyada 2018-2050 yılları arasında enerji ihtiyacının %50 artacağı öngörülmektedir. Bu süre zarfında elektrik enerjisindeki tüketim artışından dolayı elektrik üretiminin de %79 oranında artacağı tahmin edilmektedir (U.S. Energy Information Administration, 2019). Özellikle elektrik enerjisindeki talep artışı ilerleyen yıllarda transformatörlerin nominal yük değerlerine daha yakın çalışmasına ve bazen de aşırı yüklü çalışmak zorunda kalmasına neden olacaktır. Son yapılan çalışmalarda güç


transformatörlerinin hizmet yıllarının önerilen tasarım ömrüne ulaştığını veya çoktan aştığını göstermektedir. Bu durum transformatör kaynaklı arıza olasılıklarının artmasına neden olmaktadır (Abu-Siada, 2018). Ayrıca enerji sektöründe yaşanan rekabet ve varlık yönetimi konusundaki yeniden yapılanma anlayışı mevcut donanımların bakım ve yenileme maliyetlerinin düşürülmesi için transformatörlerin daha uzun süreli kullanımını gerektirmektedir. Bu nedenle, transformatörlerin izlenmesi ve arızaların önceden teşhisi ile ilgili çalışmalar son yıllarda araştırmacıların ve mühendislerin ilgisini çekmektedir.

İzleme sistemleri çevrimdışı veya çevrimiçi olabilir. Fakat gelişen haberleşme teknolojisi sayesinde eğilim daha çok çevrimiçi tekniklere yöneliktir (Kulkarni ve Khaparde, 2017). Çevrim içi durum izlemenin, transformatör sağlık koşulları hakkında zamanında bilgi vermesi, varlık yöneticilerinin doğru ve zamanında karar almalarına yardımcı olması en önemli özellikleridir. Bunun yanında kayıpların azaltılması, yeni başlayan arızanın tespiti ve katastrofik arızalar nedeniyle planlanmayan arıza olasılığının azaltılması gibi çeşitli avantajları vardır. İzleme sistemi sayesinde transformatör arızasından dolayı yaşanabilecek enerji kesintileri ve üretim kayıpları ortadan kaldırılabılır. Ayrıca personelin yüksek gerilim transformatör merkezine daha az sıklıkla erişim ihtiyacı iş kazası riskini de azaltır. Bu nedenle, güç transformatörleri için durum izleme yöntemlerinin geliştirilmesi ve kullanımı giderek daha önemli hale gelmektedir (Jin ve ark., 2022). Transformatörün üzerinde sürekli bir biçimde veri toplayan çeşitli izleme cihazları bulunmakla birlikte bazı periyodik bakımlarda elde edilen ölçüm verileri sürekli olarak birikmektedir. Bu verilerden transformatörün durumu hakkında bilgi edinmek uzmanlık gerektirmektedir (Birlik ve ark., 2018). Bazı durumlarda artan bu çok sayıdaki teknik verinin anlamlandırılması için gelişen teknolojiyle birlikte yapay zeka teknolojilerinden yararlanılmaktadır (Žarković ve Stojković, 2017). Transformatörlerin durumu hakkında bilgi veren en önemli parametre sağlık indeksi (SI) olarak tanımlanan bir değerdir. Bu değer transformatörün yapısı ve sağlığı ile ilişkili birçok değişkenin birleştirildiği bir indeks olup oluşturulması ve yorumlanması uzman bilgisi gerektirir. Yapay zeka yöntemleri işte bu indeksin oluşturulması ve yorumlanmasında kullanılan önemli bir araç olarak öne çıkmaktadır.

## **2. TRANSFORMATÖR TESTLERİ**

Bir güç transformatörünü oluşturan yapısal parçalar Şekil 2.1'de görülmektedir. Bu yapısal parçalardan yalıtım yağı, yalıtım kağıdı, yük altında kademe değiştirici ve buşingler vb. çeşitli nedenlerden dolayı yaşlanırlar. Bu da transformatörün arızalanmasına neden olur. Bu durum transformatörün durumunu tespit etmek için bazı yapısal parçalara çeşitli testlerin yapılmasını gerektirir. Bu testler üretim sonrası fabrikada, montaj sonrası sahada ve devreye alındıktan sonra

belirli periyotlar ile veya sürekli olarak gerçekleştirilir. Sürekli izleme için yapılan ölçüm değerlerinin izlenmesi gerekmektedir.



**Şekil 2.1.** Transformatör yapısal parçaları (D&F Liquidators, 2022)

Transformatörler, müşterinin istediği özellikleri ve tasarım beklentilerini karşıladığının kanıtlanması amacıyla transformatör üretim tesislerinde farklı test prosedürlerinden geçirilir. Transformatörlerin temel tasarım beklentisini doğrulamak için bazı transformatör testleri yapılır. Bu testler, rutin testler, tip testler ve özel testler olmak üzere üçe ayrılırlar (Odabaşı, 2012). Transformatörlerin rutin testleri, üretilen her transformatöre yapılan testlerdir. Üretilen tüm partideki transformatörlerin beklenen özelliklerini doğrulamak için yapılır. Transformatörlerin tip testi, bir üretim partisinin ana ve temel tasarım kriterlerini doğrulamak için partinin ilk üretilen transformatörüne uygulanan testlerdir. Transformatörlerin özel testleri ise müşterinin istek ve ihtiyaçlarına göre yapılan testlerdir. Ayrıca transformatörlere sahada devreye alınmadan önce yapılan testlere transformatör devreye alma öncesi testi denir. Bu testler, kurulumdan sonra transformatörün durumunu değerlendirmek ve tüm test sonuçlarını fabrika test raporları ile karşılaştırmak için yapılır.

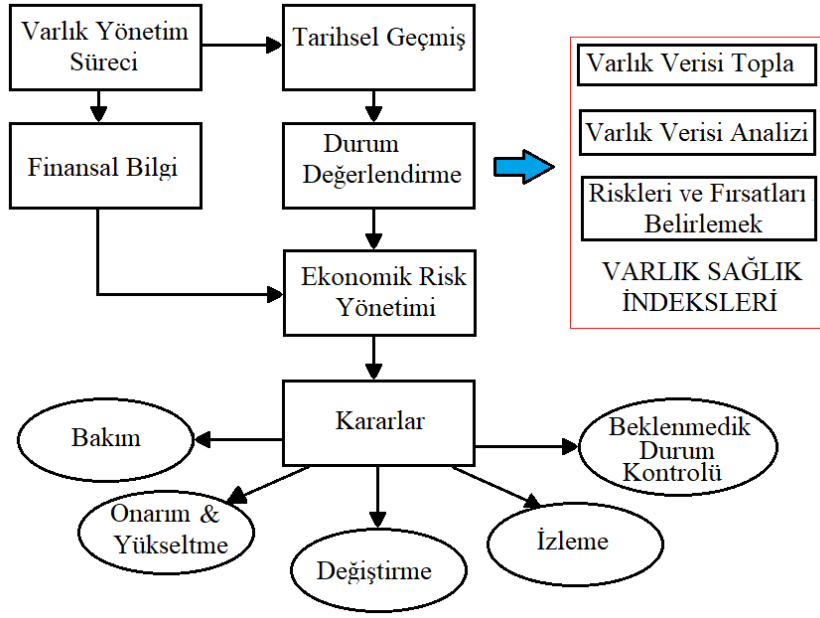
Transformatörün devreye alınması sonrasında yapısal parçaların neredeyse tamamına belirli periyotlarla yapılabilecek testler bulunmaktadır. Bu testler sonucunda transformatörün sağlık durumu hakkında çeşitli bilgiler elde edilebilir (Islam ve ark., 2018). Bu testlerin bazıları transformatör enerji hattına bağlıyken yapılamaz ve bu yüzden transformatörün devre dışı bırakılmasını gerektirir. Bu

yüzden bu testler transformatörün enerjisi kesilip gerekli güvenlik önlemleri alındıktan sonra çeşitli ekipmanlar ile ölçümler alınarak yapılır. Sahada yapılan ölçümler haricinde bazı laboratuvar analiz sonuçları da elde edilir. Bu ölçüm sonuçları transformatör etiket değerleri veya imalat sonrasında yapılan test sonuçları ile bazen de bir önceki test sonuçları ile karşılaştırılır. Ölçüm verileri arasındaki benzerlikler ve farklılıklar uzman personel tarafından bilimsel gerçekliklere göre yorumlanarak transformatörün durum tespiti yapılır (Murugan ve Ramasamy, 2019). Son yıllarda güç transformatörlerinin öngörülemez arızalarını önlemek için, zamana dayalı bakımı ve testleri artırmak yerine sürekli durum izleme tercih edilmektedir (Islam ve ark., 2018).

### **3. TRANSFORMATÖR VARLIK YÖNETİMİ**

Güvenilir ve uygun maliyetli durum izleme ve varlık yönetimi teknikleri, elektrik şirketleri için önemlidir. Bu, şirketlerin transformatör varlıklarının gelecekteki bakım, onarım ve değiştirme maliyetlerini tahmin etmek için uygun bir finansal plan hazırlamasını sağlar. Bu bağlamda, kamu hizmeti veren şirketlerin varlık yönetimi ile işletme ve bakım maliyetlerini optimize etmelerine yardımcı olmak için birçok araştırma yapılmıştır (Rediansyah ve ark., 2021). Transformatörlerin varlık yönetiminin amacı, transformatörlerin olası hizmet ömrünü uzatmak ve işletme maliyetlerini en aza indirmektir. Varlık yönetiminde bir transformatörün tüm yaşam döngüsü maliyetini belirlemek için işletimi, bakımı ve yenilenmesi birlikte düşünülür (Zhang ve Gockenbach, 2008).

Daha kapsamlı bir şekilde bakacak olursak transformatör varlık yönetiminin yürütülmesi şu faktörleri içerir: tarihsel inceleme, durum değerlendirmesi, finansal bilgiler, ekonomik risk yönetimi, bakım, onarım, yükseltme, değiştirme, izleme ve transformatörlere acil durum kontrolü yapıp yapılmayacağına ilişkin nihai karar (Boss ve ark., 2002; Suwnansri, 2014). Bu yaklaşım, gelecekteki sistem kaynak ihtiyaçlarını sağlamada risk altında olan transformatörleri veya transformatör gruplarını belirlemek için önemlidir (Ma ve ark., 2015). Şekil 3.1, temel varlık yönetiminin sürecini şematik olarak göstermektedir (Azmi ve ark., 2017).



**Şekil 3.1.** Transformatör varlık yönetiminin süreci


Bu şemaya göre transformatörlerin varlık yönetim süreci, tarihsel inceleme ve finansal bilgiler olmak üzere iki ana bölüme ayrılır. Tarihsel incelemede, geçmiş bilgiler, yükleme geçmişi, teşhis verileri ve arıza geçmişi gibi verilerin yanında şebekenin belirli bir yerinde gelecekte beklenen streslere ait bilgiler transformatörün koşullarını değerlendirmek için toplanır. Aynı şekilde gösterildiği üzere süreçteki ikinci adım olan durum değerlendirmesi, dikkatli bir incelemeyi ve transformatörün test ile ölçüm sonuçlarını, gözlemleri, çalışma geçmişini, arıza mekanizmalarını ve benzer veya karşılaştırılabilir ekipman ile diğer ilgili bilgilerle süreç bilgisini ve önceki deneyimleri içeren kapsamlı testi içerir. Durum değerlendirmesinin normal çıktısı, basit bir normal veya anormal değerlendirmeden, gelecekteki bakım veya değiştirme kararlarına izin vermek için tek veya çoklu ölçekte bir sıralama veya puanlama sistemine atıfta bulunan karmaşık bir 'varlık sağlığı endeksine' kadar değişebilir (CIGRE, 2011). Finansal bilgi yaklaşımı, yaşam döngüsü maliyet modeli, yatırım, işletme, bakım, arıza ve elden çıkarma maliyetlerini içeren şebeke varlık yönetiminin verimliliğini artırmak için bir başka önemli süreçtir (Wies ve ark., 2005). Son araştırmalarda, yaşam döngüsü maliyet modeli artık çevresel ve önleyici testlerin maliyeti ile entegre edilmiştir (Guo-Hua ve ark., 2014). Hem finansal bilgi hem de durum değerlendirmesi, ekonomik risk yönetimini gerçekleştirmek için birleştirilir. Ekonomik risk yönetimi, transformatörün bakımını, onarımını ve güç artırımını, değiştirmeyi, izlemeyi veya transformatörde beklenmedik durum kontrolünü yürütmeyi yapmak için kullanılacaktır. Transformator durum değerlendirmelerinin, gelecekteki planlamada ve transformator varlık yönetiminin bütçelenmesinde ana karar faktörü olması beklenmektedir (Azmi ve ark., 2017).




#### 4. TRANSFORMATÖR SAĞLIK İNDEKSİ

Transformatörlerin arıza oranı ve beklenen ömrü, elektriksel, termal ve mekanik bir dizi iç ve dış mekanizmadan etkilenir. İç nedenler yalıtımın kötüleşmesi, sargı birleşim yerlerinde zayıflama, aşırı ısınma, yalıtım yağı içindeki oksijen, nem ve katı parçacıklar, kısmi deşarj, tasarım ve üretim hataları ile sargı rezonansı olarak sıralanabilir. Dış nedenler ise yıldırımlar, sistemdeki anahtarlama işlemleri, aşırı yüklenme ve kısa devreler olarak sıralanabilir. Güç transformatörlerinin, tüm etkilere rağmen yıllık %1-2 olan küresel arıza oranı ile normal çalışmada güvenilir oldukları kanıtlanmıştır (Wang ve ark., 2002).

Transformatör arızalarının yaygın nedenleri ile ilgili bir istatistik Şekil 4.1'de verilmiştir (Zhang ve Gockenbach, 2008; Islam ve ark., 2018). CIGRE çalışma grubu WGA2.37 tarafından 364 tane transformatör arızası üzerine yapılan bir incelemeye göre tipik arıza yerinin oranları ise Şekil 4.2'de gösterilmiştir (Florian Predl, 2015).



Şekil 4.1. Transformatör arıza nedenleri (Zhang ve Gockenbach, 2008; Islam ve ark., 2018)




Şekil 4.2. Transformatörlerin arıza konumları

Bugün bildiğimiz varlıklar için genel Sağlık Endeksi kavramı ilk kez Hughes (Hughes, 2003) tarafından tanıtıldı. Bu indeksin anlamı Tablo 4.1'deki aralıklara bakılarak anlaşılabilir. Buna göre, sağlık indeksi 0 ile 100 arasında değişen bir puanlama olup 100 transformatörün çok iyi ve 0 transformatörün çok kötü olduğunu gösterir. Bu puanlamanın aynı zamanda transformatörün arızalanma ihtimali ile ilişkili olacağı da açıktır. Bu ilişki Şekil 4.3'te verilmiştir.

**Tablo 4.1.** Sağlık indeksi skalası

Sağlık indeksi	Durum	Tanım	Yaklaşık beklenen ömür
85-100	Çok iyi	Sınırlı sayıda bileşende bazı eskime veya küçük bozulmalar	15 yıldan fazla
70-85	İyi	Bazı bileşenlerde önemli ölçüde bozulmalar	10 yıldan fazla
50-70	Orta	Belirli bileşenlerin yaygın olarak önemli ölçüde bozulması veya ciddi şekilde bozulması	10 yıla kadar
30-50	Kötü	Yaygın ciddi bozulmalar	3 yıldan az
0-30	Çok kötü	Kapsamlı ciddi bozulmalar	Ömrünün sonunda

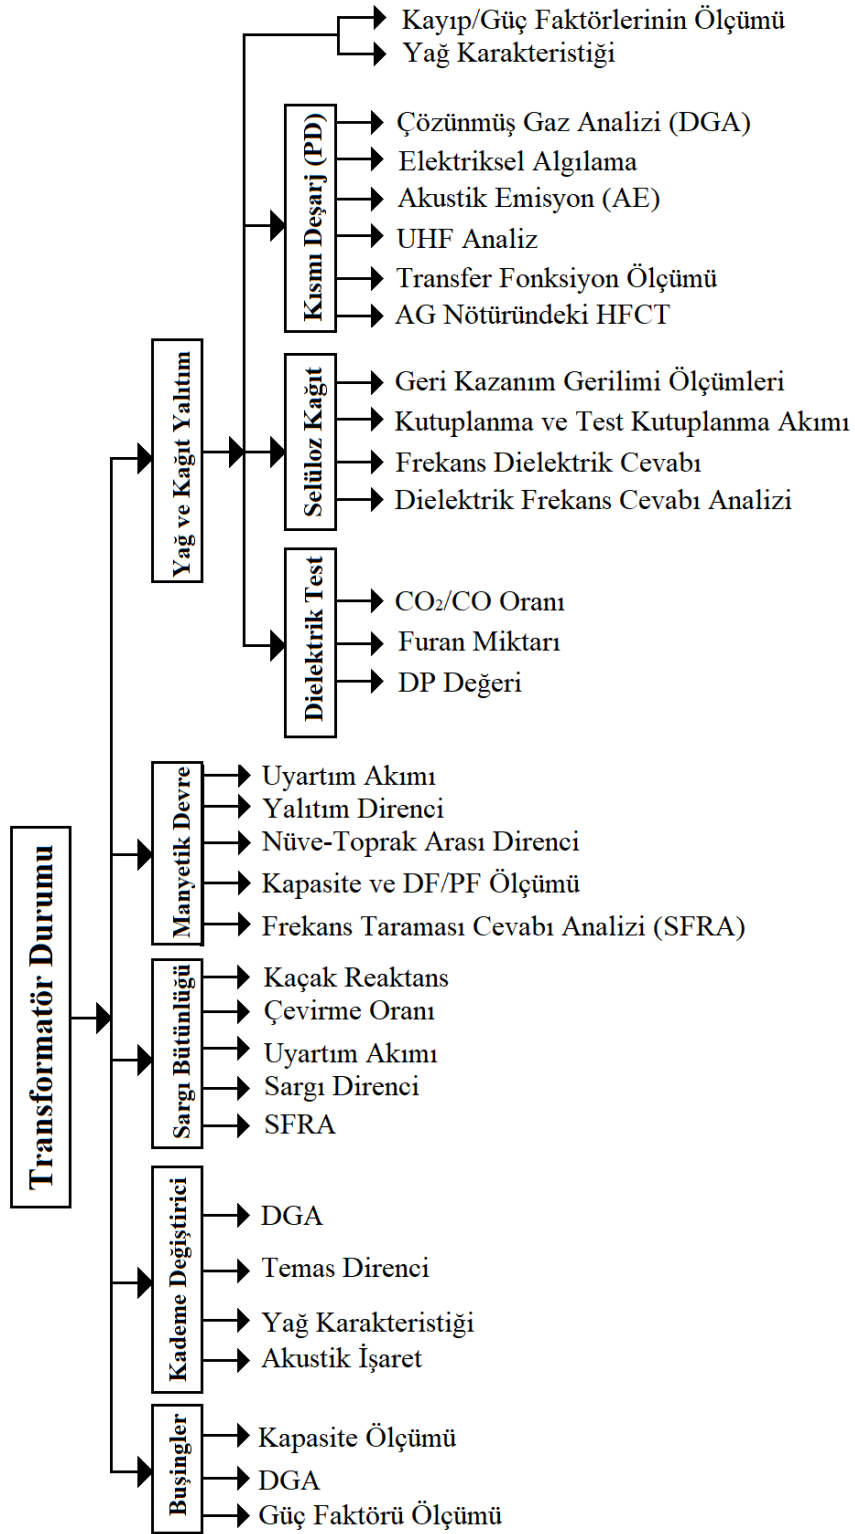
**Şekil 4.3.** Arıza olasılığının sağlık indeksi puanına bağlı değişimi

Transformatör varlık yönetiminde kullanılan önemli yaklaşımlardan biri durum değerlendirmesidir. Bu yaklaşımda, veriler toplanıp analiz edildikten sonra transformatörün sağlık durumunu gösteren bir sağlık indeksi oluşturulur (Abu-Elanien ve ark., 2010; Azmi ve ark., 2017). SI, varlığı yönetmek, sermaye ve bakım planlarına yapılan yatırımlara öncelik vermek için işletme gözlemlerinin, saha incelemelerinin ve saha ile laboratuvar testlerinin sonuçlarını birleştiren pratik bir aracı temsil eder (Jahromi ve ark., 2009). Bu bağlamda güvenilir bir transformatör varlık yönetim kararı sağlamak için transformatör SI değeri oluşturmak önemlidir.

Avrupa çapında yapılan bir çalışma, buşing arızalarının %80'inin orta hizmet döneminde (12-20 yaş) meydana geldiğini ve transformatör arızalarının %30'unu başlattığını göstermektedir. Bu istatistikler göz önüne alındığında, bir transformatörün sağlığının birden çok faktöre bağlı olduğu

açıktır. Ayrıca, her bir bileşenin transformatör sağlığı üzerindeki etkisinin derecelendirilmesine dayalı olarak tanı testlerine öncelik vermek gerektiği de anlaşılır.

Transformatörlerin durum değerlendirmesi için kullanılan önemli teşhis yöntemlerinin bir sınıflandırması Şekil 4.4'te verilmiştir (Islam ve ark., 2018). Bu sınıflandırmada yer alan her bir yöntem ile elde edilen değerlerin transformatörün genel sağlık durumuna olan etkisi farklı oranlarda olacaktır. Bu oranların tespiti için tecrübeli ve uzman kişilerce verilerin belli bir sistematik içinde değerlendirilmesi ve bir sayıya dönüştürülmesi gerekir. Bu sayı literatürde transformatör sağlık indeksi olarak adlandırılır.

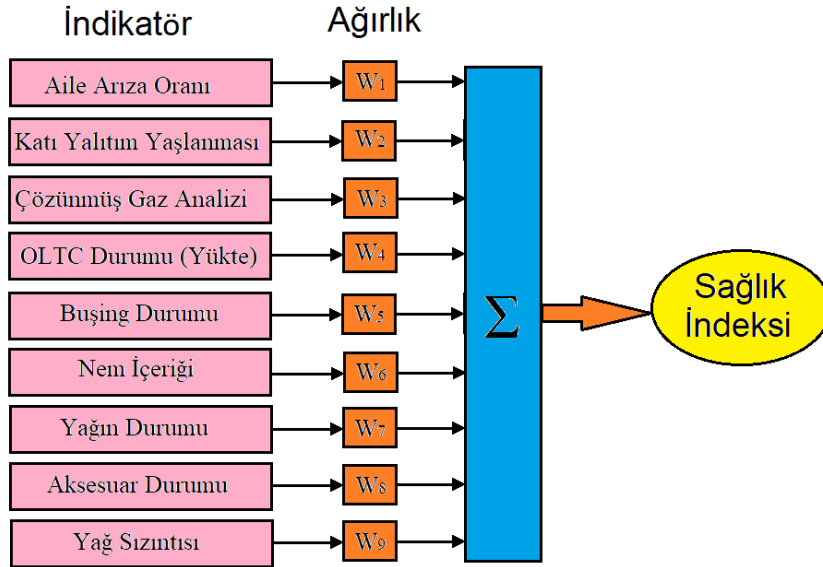


Şekil 4.4. Durum izleme ve arıza teşhis teknikleri

SI modellerinde kullanılan verilerin çoğu yağ yalıtım sistemi testlerine dayanmaktadır. Yağ yalıtım testleri, çözülmüş gaz analizini (ÇGA), yağ kalitesi analizini (OQA) ve furan analizini (FFA) içerir. Çalışan transformatörlerdeki yüksek elektriksel ve termal stres nedeniyle yağ ve kağıt yalıtımı,

yağda çözünen ve dielektrik gücünü azaltan bazı gazları ayrıştırır ve serbest bırakır. Bu gazlar arasında hidrojen ( $H_2$ ), metan ( $CH_4$ ), etilen ( $C_2H_4$ ), asetilen ( $C_2H_2$ ), etan ( $C_2H_6$ ), karbon monoksit ( $CO$ ) ve karbon dioksit ( $CO_2$ ) bulunur. ÇGA testi, transformatörün iç elektriksel ve termal arızaların tanımlanabileceği bu gazları ölçmek için yapılır (Bakar ve ark., 2014). IEEE C57.106-2015 standardındaki kılavuz dikkate alınacak olursa OQA, yağ arıza gerilimi (BDV), asitlik, su içeriği, arayüzey gerilimi (IFT), dielektrik dağılma faktörü (DDF) ve renk analiz edilerek belirlenir. FFA, selüloz bozulması nedeniyle oluşan ve transformatör yağında çözünen furan bileşiklerini ölçmek için yapılır. 5 furan bileşiği arasında, furfuraldehit (furfural/ $_2$ FAL olarak da bilinir) ölçümlerde en önemli yeri tutar ve kağıt yalıtımının polimerizasyon derecesi ile ilişkilidir (Kachler ve Hohlein, 2005; Rediansyah ve ark., 2021).

Güç transformatörlerinin SI değerlerini hesaplamak için bir ağırlıklı-puanlama (ağırlıklı toplam olarak da adlandırılır) kullanımı oldukça yaygındır (Rediansyah ve ark., 2021). Şekil 4.5'te ağırlık katsayılarının tanımlandığı bir transformatör sağlık endeksi hesaplamasının genel modeli gösterilmektedir (Padmanaban ve ark., 2022).



**Şekil 4.5.** Transformatör sağlık endeksini hesaplamada kullanılan genel model

Bu yaklaşımda, her bir parametre bir puanlama tablosuyla karşılaştırılarak ve ardından her bir parametre önemine göre ağırlıklandırılarak kullanılır. Ağırlık faktörü, bir transformatörün durumunu etkileyen herhangi bir özel değişkenin önem derecesini veya katkısını temsil eder (Azmi ve ark., 2017). Ağırlıklar genellikle uzman personel tarafından belirlenir. Bireysel puanlar, transformatörün genel sağlık durumunu ortaya çıkaran tek bir endekste birleştirilir. SI farklı puanların ve ağırlıklı ölçüm verilerinin doğrusal bir birleşimidir. Bu yüzden SI değerini belirlemek için kullanılan verilerin

belirsizliği ile başa çıkmak zor bir iştir (Rediansyah ve ark., 2021). Bu durum böylesi karmaşık ve zor problemlerin çözümü için yapay zeka yöntemlerinin kullanımını gerektirir.

## 5. TRANSFORMATÖR SAĞLIK İNDEKSİNİN BELİRLENMESİ

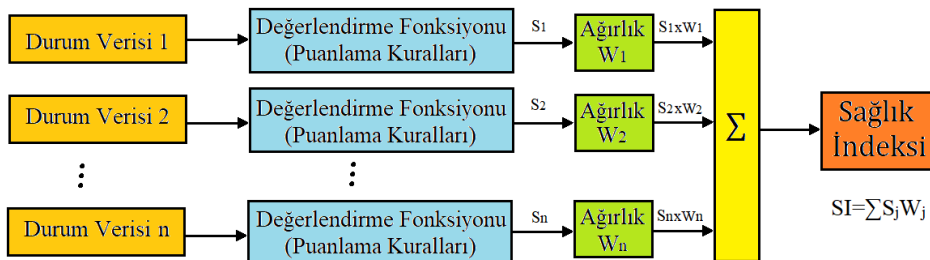
Genel olarak  $SI$  hesaplama yöntemleri ağırlıklandırılmış skor toplamı yaklaşımları ve yapay zeka yaklaşımları olmak üzere iki ana gruba ayrılabilir.

Ağırlıklandırılmış skor toplamı yaklaşımlarında sağlık endeksi, farklı türdeki durum izleme verilerinin ağırlıklı puan toplamı olarak elde edilir. Örneğin yağda çözülmüş gazların çeşitleri, yağ test parametreleri (dielektrik dayanım, IFT, asit sayısı, su içeriği, renk, yayılma faktörü), furan içeriği, kademe değiştirici verileri, yük geçmişi ve bakım kayıtları, transformatör sağlık endeksini hesaplamak için kullanılabilir. Bu tür bir sağlık endeksi aşağıdaki eşitlik kullanılarak formüle edilebilir.

$$SI = \sum_{i=1}^n w_i \cdot SI_i$$

$$SI_i = \sum_{j=1}^m S_j w_j / \sum_{j=1}^m w_j$$

Burada  $SI_i$  transformatörün kısmi sağlık endeksi,  $w_i$   $SI_i$ 'nin  $\sum w_i = 1$  olmak üzere ağırlık faktörü,  $S_j$  belli bir durum verisinin durum skoru ve  $w_j$  ise ağırlık değeridir.  $S_j$ 'nin durum puanı Şekil 5.1'de gösterilen değerlendirme fonksiyonlarına göre belirlenir. Bu fonksiyonlar genellikle ilgili standartlarca, konu hakkında deneyimli bir uzmanca veya her ikisinin bir kombinasyonu tarafından belirlenir. Ağırlıklı puan toplamına dayalı sağlık endekslerinde yerel sağlık endeksi  $SI_i$  farklı biçimde elde edilebilmektedir. Öyle ki bazıları benzer özelliklere sahip bir grup test verisinin alt endeksini temsil ederken bazıları bir transformatör bileşeninin alt endeksini temsil edebilir. Örneğin, (Ortiz ve ark., 2016)'da  $SI_i$ , yağda çözünen bir grup gaz içeriğine ilişkin alt endeksi temsil ederken, (Brandtzæg, 2015)'te transformatör sargısının alt endeksini temsil eder.




Şekil 5.1. Ağırlıklı puan toplamı yaklaşımlarına dayalı transformatör sağlık endeksinin genel şeması.

Transformatör sağlık endeksini ağırlıklı puan toplamı olarak elde eden yaklaşımların haricinde sınıflandırma, regresyon, bulanık sentez ve olasılık çıkarımı için kullanılan bazı yapay zeka algoritmaları da bu görevi yerine getirmede üstünlüklerini ispatlamışlardır. Bu tür yaklaşımların algoritmaları birer kara kutu olarak düşünülürse, durum verileri ve sağlık indeksi sırasıyla girdi ve çıktıdır. Bu durum, Şekil 5.2'de gösterilmiş olup aşağıdaki eşitlik gibi formüle edilebilir.

$$SI = f(v_1, v_2, \dots, v_n)$$

Burada  $v_i$  transformatöre ait  $i$ . tip durum verisini,  $n$  durum izleme verisinin toplam sayısını ve  $f$  durum verisinden ( $v_i$ ) sağlık indeksine ( $SI$ ) haritalama yapan bir doğrusal olmayan fonksiyonu göstermektedir. Bu fonksiyon bir regresyon fonksiyonu olabileceği gibi bir bulanık mantık kuralları seti de olabilir.



**Şekil 5.2.** Yapay zeka algoritmaları tabanlı transformatör sağlık indeksi hesaplama yöntemlerinin genel yapısı

## 6. YAPAY ZEKA TABANLI SAĞLIK İNDEKSİ BELİRLEME YÖNTEMLERİ

Bilgisayar biliminin ve veri işlemenin hızlı gelişimi, büyük veri analizi için yapay zeka algoritmalarına dayalı yeni yöntemlerin ortaya çıkmasını sağlamıştır. Bu gelişmeler transformatör izleme sistemlerinde yeni SI hesaplama yaklaşımlarının kullanımını desteklemiştir.

Tüm yapay zeka tabanlı yöntemlerin ortak noktası, istenen korelasyonları öğrenmek için bir veri tabanına ihtiyaç duymalarıdır. Yapay zeka tabanlı SI yöntemleri veri tabanlı modeller olduğundan, uygulanabilirliği verinin alındığı transformatör filosu, çevre ve yük koşulları ile sınırlıdır. Modelin diğer transformatörlere uygulanabilmesi için ek verilere ihtiyaç vardır. Yapay zeka tabanlı yöntemlerde, farklı sağlık durumu seviyelerine sahip çeşitli transformatörler üzerinde gerçekleştirilen çeşitli ölçümleri içeren eğitim veri tabanı dikkatli bir şekilde hazırlanmalıdır. Eğitim veri seti, transformatör sağlık durumunu tahmin eden yapay zeka modelini oluşturmak için kullanılır. Bu modeli oluşturmak için yapay sinir ağları, ANFIS, destek vektör makineleri, genel regresyon sinir ağları ve karar ağaçları dahil olmak üzere çeşitli yapay zeka algoritmaları kullanılır. Güç transformatörlerinin

durum değerlendirmelerinde yapay zekanın kullanımı, özellikle büyük veri kümelerini analiz etmek için yararlıdır (Rediansyah, ve ark., 2021).

Literatürde transformatör sağlık durumunu elde etmek için bulanık mantık (Abu-Elanien ve ark., 2012), bulanık SVM (Ashkezari ve ark., 2013), sentetik azınlık aşırı örnekleme tekniği (Cui ve ark., 2014), ikili kedi sürüsü optimizasyonu tabanlı SVM (Mohamadeen ve ark., 2014) ve çok aracıli sistem (Morais ve ark., 2014) gibi yapay zeka algoritmaları kullanılmıştır. Ayrıca, transformatörlerin arıza durumunu tespit etmek için sinir ağı (Huang, 2003; Bhalla ve ark., 2012) ve sinirsel-bulanık mantık (Hooshmand ve ark., 2012; Khan ve ark., 2015; Malik ve ark., 2013; Zeinoddini-Meymand ve ark., 2021) yöntemleri de kullanılmaktadır. (Benhmed ve ark., 2017)'de, transformatörün SI endeksini belirlemek için sınıflandırma tekniklerini kullanan bir özellik çıkarım yöntemi sunulmuştur. (Murugan ve Ramasamy, 2019)'da transformatör bakımında kullanılmak üzere transformatör verilerinin önce istatistiksel analizini yapan ve ardından bir SI değeri elde eden bir yöntem verilmiştir. Transformatörün SI değerini veri belirsizliği ortamında hesaplayan bir olasılıksal yöntem (Li ve ark., 2020) ve (Prasojo ve Abu-Siada, 2021)'de verilmiştir. (Tamma ve Prasojo, 2021)'de SI azalma oranı transformatör durum değerlendirmesini iyileştirmek amacıyla kullanılmıştır. (Sharma, 2021)'de SI tahmini yapan bazı regresyon tabanlı modellerin simülasyonu yapılmıştır. (Mohd Selva ve ark., 2021)'de transformatörlerin SI değerini tahmin etmek amacıyla istatistiksel dağılım yöntemi kullanılmıştır. Yağlı tip transformatörlerin SI değerini ikili lojistik regresyon kullanarak hesaplayan bir yöntem (Zuo ve ark., 2016)'da sunulmuştur. (Vermeer ve ark., 2015)'de varlıkların ek bakım ve değiştirme ihtiyacını belirlemek ve etki analizini yapmak amacıyla kullanılabilecek bir karar-destek modeli sunulmuştur. (Ahmed ve ark., 2015)'te, transformatör test sonuçlarını kullanan bir ortogonal dalgacık ağı, transformatör SI değerini tahmin etmek için kullanılmıştır. Sonuç olarak transformatör SI değerini elde etmeyi sağlayan veya kullanan pek çok yapay zeka tabanlı yöntemi literatürde kullanılmıştır.

Transformatör SI değerini belirlemede kullanılan başlıca yapay zeka yöntemleri:

1. Bulanık mantık algoritmaları
2. Yapay sinir ağları
3. Destek vektör makineleri
4. Sürü optimizasyon teknikleri
5. Bayesian yaklaşımları
6. k-en yakın komşuluk yöntemi
7. Dalgacık dönüşümü yöntemi
8. Uyarlamalı sinirsel-bulanık (ANFIS) metotları



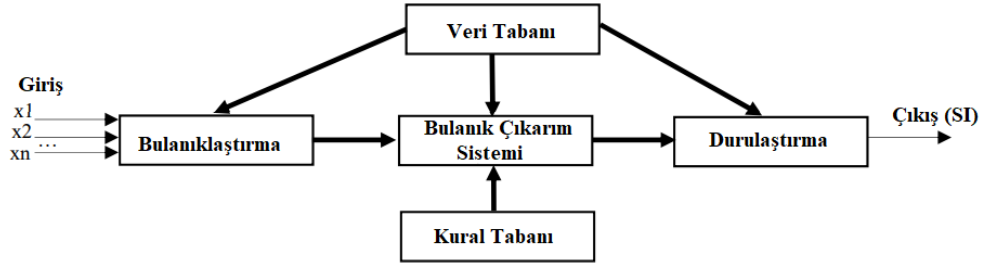
olarak özetlenebilir. Bu algoritmalar arasında yapay sinir ağları (YSA) ve destek vektör makineleri (SVM) en sık kullanılan yöntemlerdir. Burada bir transformatörün sağlık indeksi, ağı/algortmayı eğitmek için belirli bir miktarda durum verisi (bilinen sağlık indeksi ile) ile bir sınıflandırma veya regresyon problemi olarak alınır. Bu verilerin sağlık indeksi genellikle daha önce bahsedilen ağırlıklı puan toplamı yaklaşımlarıyla belirlenir. Güvenilir bir transformatör sağlık endeksi elde etmek için, ağırlıklı puan toplamı yaklaşımlarının veya yapay zeka algoritmalarının yanında uzman deneyimini de kullanmak ihmal edilemez derecede önemlidir (Li ve Dong, 2019). Bu yöntemler transformatörün durumu ile verileri arasındaki ilişkiyi modeller. Model, yeni veriler geldiğinde transformatörün durumunu bir sağlık indeksi olarak kullanıcıya sunar. Aşağıda bu yöntemlerin en önemli dört tanesi detaylandırılarak açıklanmıştır.

### 6.1. Bulanık Mantık Tabanlı Sağlık İndeksi Belirleme Yöntemleri

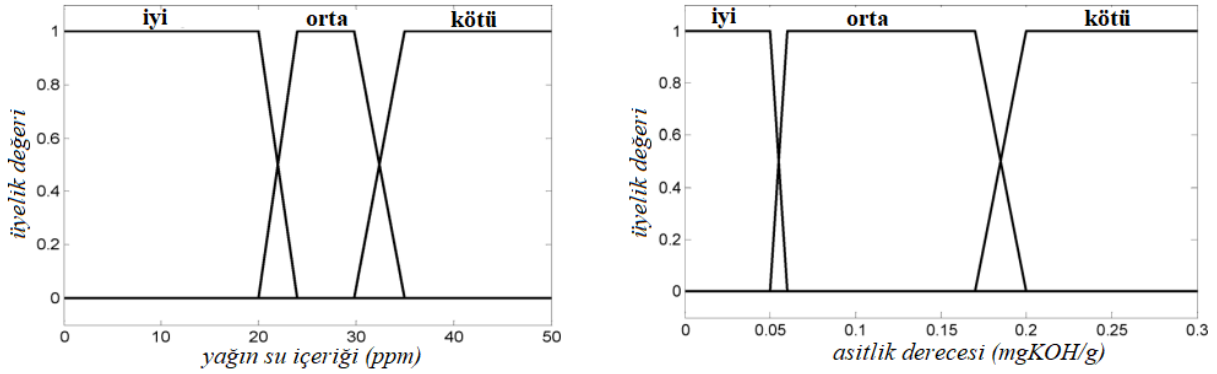
Bulanık mantık, genellikle kelimeleri değişken olarak kullanan yumuşak bir hesaplama tekniğidir. Sözcüklerin matematiksel formüllere kıyasla günlük hayattaki kullanımı kolay ve yaygın olduğundan bulanık mantık kuralları bir insan tarafından kolayca anlaşılabilir (Idrees ve ark., 2019). Bulanık mantıkta, kelimeler değişken olarak kullanılır. Bu yöntem ile yapılan transformatör incelemelerinde giriş ve çıkış değerleri arasındaki ilişkiyi modellemek için üyelik fonksiyonları kullanılır (Li ve Dong, 2019).

Bir yapay zeka yöntemi olarak bulanık mantık herhangi bir eğitim verisine ihtiyaç duymaz. Sağlık indeksini hesaplamak için kullanılan bulanık mantık yöntemleri konunun uzmanı olan kişilerin düşüncelerine, dilsel ifadelerine ve kurallarına dayanır. Buna karşın bu kurallar uzmandan uzmana ve şebekeden şebekeye farklılık gösterebilmektedir.

Şekil 6.1'de bulanık mantık tabanlı SI belirleme yöntemlerinin genel yapısı verilmiştir. Bu yapıya göre transformatör verileri  $(x_1, x_2, \dots, x_n)$  önce bir bulanıklaştırma işlemine tabi tutulur. Bulanıklaştırma süreci her bir değişken için tanımlanan üyelik fonksiyonları üzerinden yapılır. Örneğin Şekil 6.2'de verilmiş olan transformatör yağının su içeriği ve asitlik derecesine ait üyelik fonksiyonları yardımıyla bu işlem gerçekleştirilerek her bir giriş değişkeni için üyelik değerleri belirlenir. Bu değerler bulanık çıkarım sisteminden geçirildikten sonra durulaştırmaya tabi tutulur. Bulanık çıkarım sistemi verileri bir kural tabanına ve veri tabanına uygun olarak işler. En sonunda veriler bir transformatör SI değerine dönüştürülmüş olur.



**Şekil 6.1.** Bulanık mantık tabanlı SI belirleme yöntemlerinin genel yapısı



**Şekil 6.2.** Transformatör yağının su içeriği ve asitlik derecesine ait üyelik fonksiyonları

Transformatör SI değerinin bulanık mantık tabanlı yöntemler kullanılarak hesaplandığı bazı çalışmalar için (Ashkezari ve ark., 2013; Jaiswal ve ark., 2016; Chantola ve ark., 2018; Abu-Elanien ve ark., 2012) kaynakları incelenebilir.

## 6.2. Yapay Sinir Ağı Tabanlı SI Belirleme Yöntemleri

Önemli yapay zeka dallarından biri de yapay sinir ağlarıdır (YSA). YSA, insan beynindeki biyolojik sinir sistemlerinden ilham alan bir bilgi işleme paradigmasıdır. YSA, karmaşık veya kesin olmayan verilerden anlam çıkarma konusunda dikkate değer bir yeteneğe sahiptir. İnsanlar veya diğer bilgisayar teknikleri tarafından fark edilemeyecek kadar karmaşık olan kalıpları çıkarmak ve eğilimleri tespit etmek için kullanılabilirler. Eğitimli bir sinir ağı, analiz etmesi için kendisine verilen bilgi kategorisinde bir "uzman" olarak düşünülebilir.


Yapay sinir ağı, insan sinir ağlarına dayalı matematiksel bir model veya hesaplama modelidir. Tek bir katman veya birden çok katman oluşturmak için birbirine bağlanan düğümlerden oluşur. Nöron olarak da adlandırılan bu düğümler arasındaki bağlantılara ağırlık denir. Ağırlıklar, istenen hedefe ulaşmak için ayarlanması gereken sabitlerdir.

YSA'lar doğrusal olmayan haritalama özellikleri nedeniyle, karmaşık sistemlerin tanımlanması ve kontrolü için uzun yıllardır etkili bir araç olarak kullanılmaktadırlar. YSA'ları kullanmanın başlıca

avantajları şunlardır: 1) Kullanılan verinin artışı ile belirlenmiş çalışma noktalarının stokastik değişimlerinin üstesinden gelebilme özelliğine sahiptir. 2) Veriyi hem çevrimiçi işlemeyi hem de sınıflandırmayı önemli ölçüde hızlandırır. 3) Gizli doğrusal olmayan modelleme ve sistem veri süzgeçlemesi için yerleşik bir işlev içerir.

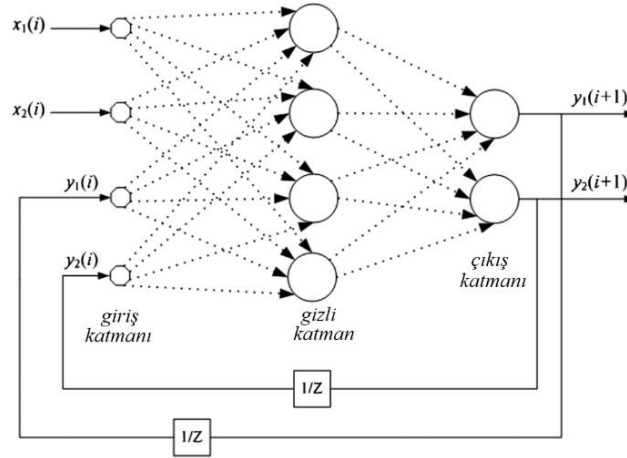
Bir YSA'nın girişinden verilen işaret ağın ara bağlantıları da dahil olmak üzere her zaman ileriye doğru yayılıyorsa böyle bir YSA ileri beslemeli bir yapay sinir ağı olarak (İB-YSA) adlandırılır. Yani ileri beslemeli bir YSA'da girişten verilen bilgi herhangi bir döngü olmadan gizli katmanlar aracılığıyla girişten çıkışa doğru ilerler. Yinelemeli bir sinir ağı (Y-YSA) ise birden fazla geri beslemeli döngüye sahip ağ olarak tanımlanabilir.

İleri beslemeli YSA'lar tek ve çok katmanlı YSA'lar olmak üzere iki kategoriye ayrılır. Tek katmanlı bir ağda, girişler ve çıkışlar, ilgili ağırlıkları aracılığıyla doğrudan bağlanır. Her bir nöron için girişlerin her biri ağırlıkları ile çarpılarak elde edilen değerlerin toplamı bir aktivasyon fonksiyonuna uygulanır. Aktivasyon fonksiyonu ise girişi sırasıyla eşik değerinden (tipik olarak 0) daha büyük veya daha düşük olduğunda +1/-1'e eşit bir çıktı üretir. Şekil 6.3'te gizli katmanlara sahip ileri beslemeli yapay sinir ağının genel yapısı verilmiştir.



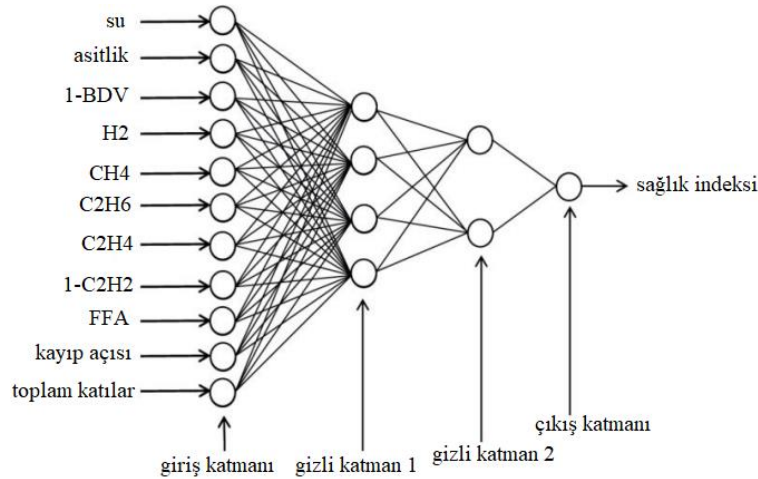
**Şekil 6.3.** Gizli katmanlara sahip ileri beslemeli yapay sinir ağının genel yapısı

Yinelemeli YSA'lar, çıkışlardan gelen girdiler aracılığıyla yönlendirilen geri besleme döngülerine sahip doğrusal/doğrusal olmayan dinamik sistemlerdir. İleri beslemeli bir sinir ağı, nöron çıkışları ilgili girişlere bağlanarak bir yinelemeli YSA'ya dönüştürülebilir. Şekil 6.4'te gizli katmana sahip bir yinelemeli YSA gösterilmektedir. Yinelemeli YSA'da, çıkışların ilgili girişlere yeniden yönlendirilmesinden dolayı ağın çıkışı zamanın bir fonksiyonudur.



**Şekil 6.4.** Gizli katmana sahip bir yinelemeli YSA'nın yapısı

Şekil 6.5'te bir YSA tabanlı SI belirleme yönteminin yapısı verilmiştir. Bu yapıda kullanılan ağ iki tane gizli katmana ve bir tane de giriş katmanına sahiptir. Bu ağın kullanılabilmesi için transformatörün giriş verileri ile SI değerleri arasındaki ilişkiyi kurabilmeyi sağlayacak miktarda veri setine ihtiyaç vardır. Bu veriler bir eğitim algoritması yardımıyla ağın katsayılarının ve ağırlıklarının elde edilmesini sağlar. Ağırlık değerleri ve diğer parametreleri güncellenen ağ çevrim içi veya çevrim dışı kullanılarak bir transformatörün SI değerlerinin elde edilmesini sağlayacaktır.



**Şekil 6.5.** Bir YSA tabanlı SI belirleme yönteminin yapısı (Abu-Elanien ve ark., 2011)

Transformatör SI değerinin hesaplanmasında yapay sinir ağı tabanlı yöntemlerin kullanıldığı diğer çalışmalar için (Rediansyah ve ark., 2021; Nurcahyanto ve ark., 2019; Abu-Elanien ve ark., 2011; Birlik ve ark., 2016) kaynakları incelenebilir.

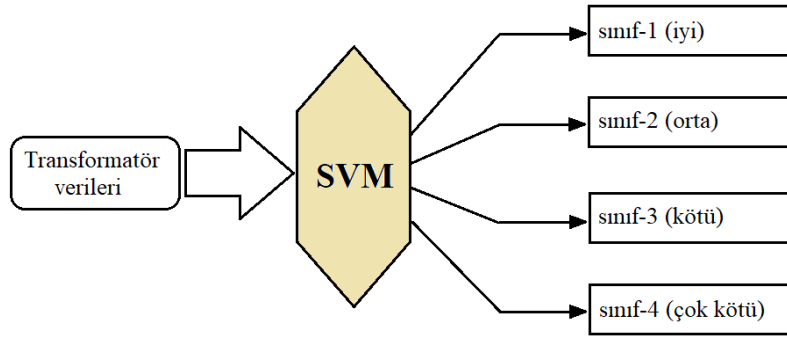
### 6.3. Destek Vektör Makineleri Tabanlı SI Belirleme Yöntemleri

Destek vektör makineleri (DVM), sınıflandırma, örüntü tanıma ve regresyon için kullanılan yapay zeka yöntemleridir. DVM, hem doğrusal hem de doğrusal olmayan verileri sınıflandırma ve iyi

bir şekilde regresyon gerçekleştirme yeteneği nedeniyle etkili bir makine öğrenme yöntemidir. Regresyon için DVM, yaygın olarak Destek Vektör Regresyonu olarak adlandırılır.

DVM, girdi vektörlerini yüksek boyutlu bir özellik uzayına eşleyerek ve ardından bu uzayda en iyi ayırıcı hiper düzlemi oluşturarak çalışır. Ayrıca DVM, ayırıcı hiper düzlem ile veriler arasındaki mesafeyi arttırarak genelleme hatasının üst sınırını en aza indirmeye çalışır. DVM, sınıf kategorilerini ayırmak için bir dizi hiper düzlem oluşturarak örnekleri sınıflandırır. DVM'ler, diğer sınıflandırma algoritmalarından daha az hesaplama yoğun olması, yüksek boyutlu uzaylarda iyi bir performans göstermesi ve doğrusal olmayan sınıflandırmayı verimli bir biçimde yapması avantajlarına sahiptir (Alqudsi ve El-Hag, 2019).

Bir yapay zeka tabanlı yaklaşım olarak DVM, transformatör SI indeksinin belirlenmesinde yaygın olarak kullanılır. DVM, sınıflandırma ve regresyon analizi uygulayarak çalışan bir yöntemdir. DVM'nin eğitimi için önce bir veri tabanının oluşturulması gerekir. Eğitim verileri sağlık durumu bilinen belirli sayıda transformatörden toplanan durum izleme verilerinden (ölçüm verileri, bakım kayıtları ve arıza istatistikleri) oluşur. DVM, her bir örnek veriyi uzayda bir nokta olarak düzenler. DVM modeli, örnek verileri açık bir boşlukla ayrılmış ayrı kategorilere eşler. Böylece transformatöre ait veri tabanı kullanılarak, transformatörün durumu ile durum izleme verileri arasındaki ilişki modellenir. Model daha sonra transformatörün sağlık indeksini belirlemek amacıyla kullanılır. Bunun için yeni örnek veriler aynı alana eşlenerek kategorisi tahmin edilir. Sınıflandırma yöntemi verileri iyi, orta, kötü ve çok kötü biçiminde tanımlanmış transformatör sağlık indeksi aralığına atar. Şekil 6.6'da böyle bir sınıflandırıcının yapısı verilmiştir. Bu yapıda yer alan ve daha önce eğitilmiş DVM yapısı girişine verilen yeni transformatör verilerini sınıflandırarak durum tayini yapar.



**Şekil 6.6.** DVM tabanlı sınıflandırıcı kullanılarak transformatör sağlık durumu izleme

Transformatör SI değerinin hesaplanmasında DVM tabanlı yöntemlerin kullanıldığı diğer çalışmalar için (Ashkezari ve ark., 2013; Mohamadeen ve ark., 2014; Sharma, 2021; Ibrahim ve ark., 2016) kaynakları incelenebilir.

#### **6.4. k-En Yakın Komşuluk Yöntemi**

K-en yakın komşuluk (kNN) algoritması basit ve kullanışlı veri madenciliği algoritmalarından biridir. Tipik bir kNN algoritmasının girdileri (örnek veri noktaları) bir dizi sınıflandırıcı olup çıktılar sınıf etiketleridir. kNN yöntemi, yeni veriler ile önceki durumlar arasında benzerlik olduğunu varsayarak yeni durumu mevcut kategorilerden en çok benzeyen kategoriye atar. Sonuç olarak, yeni örnek, k-en yakın komşularının büyük çoğunluğu ile sınıflandırılır. Yeni örneğin tahmin edilen değeri, k-en yakın komşularının ortalamasıdır, bu nedenle bu yöntem regresyon uygulamalarında da kullanılabilir.

kNN yöntemi, birçok makine öğrenmesi uygulamasında kullanılan danışmanlı bir öğrenme tekniğidir. Özellikleri bakımından en yakın eğitim örneklerine göre verileri sınıflandırır. kNN'nin arkasındaki fikir, belirli bir sorgu örneğine en yakın mesafede önceden tanımlanmış sayıda eğitim örneğini bulmak ve onlardan sorgu örneğinin etiketini tahmin etmektir. kNN, sınıflandırma açısından bir karar ağacı algoritmasına benzer, ancak bir ağaç bulmak yerine grafiğin etrafında bir yol bulur. Ayrıca karar ağaçlarından daha hızlıdır (Alqudsi ve El-Hag, 2019; Ghoneim ve Taha, 2020).

KNN'de k, sınıflandırılacak belirli bir nokta için dikkate alınacak komşu sayısını gösterir. Eğer iki sınıf varsa, k genellikle tek sayı olarak alınır. kNN için temel adımlar şunlardır: Her şeyden önce, verilen bir noktanın tüm noktalara olan mesafesi hesaplanır. Mesafeyi hesaplamak için Öklid formülü kullanılabilir. Eğitim veri setinin her noktası ile mesafe hesaplandıktan sonra, Öklid formülü kullanılarak bulunan mesafe değerine göre artan düzende sıralanır. Daha sonra uzaklık değerine göre ilgili noktanın en yakın komşularına karar verilir. Ardından, komşunun değerini seçen ve verilen verileri komşudaki en sık sınıfa bağlı olarak etiketleyen k değeri tanımlanır. Verilen veri boyutuna bağlı olarak herhangi bir tek k değerini alınır. KNN, verilen noktaya en yakın K noktalarını bulur (Javid ve ark., 2021).

kNN iki önemli avantaj sunar: ilk olarak, tasarımı çok basit bir makine öğrenme modelidir. İkincisi, ayarlamak için daha az parametre gerektirir. Bununla birlikte, örneklem boyutu büyük olduğunda ve k değerinin belirlenmesi zor olduğunda, hesaplama maliyeti önemli ölçüde artar. Ayrıca bazı araştırmacılar küçük eğitim setlerinde KNN çıktısının rastgele olduğunu belirtmektedir. Bu faktörler transformatör durum izlemelerinde kNN'nin popülaritesini azaltır. Ayrıca çoğu kNN tabanlı

algoritma, DVM ve YSA gibi diğer yapay zeka algoritmalarından daha kötü performans gösterir (Esmaili Nezhad ve Samimi, 2022).

Transformatör SI değerinin hesaplanmasında kNN tabanlı yöntemlerin kullanıldığı bazı çalışmalar için (Rediansyah ve ark., 2021; Benhmed ve ark., 2017; Shamsudin ve ark., 2021; Javid ve ark., 2021) kaynakları incelenebilir.

## 6. SONUÇ

Transformatörlerin durumunun izlenmesi varlık yönetimi, bakım ve değişim planlaması açısından önem arz eder. Böylece transformatörün arızalanmasından doğabilecek ekonomik kayıpların azaltılması sağlanabilir. Transformatör durum izleme sistemleri çevrim içi olabileceği gibi çevrim dışı da olabilmektedir. Her iki biçimde de transformatörün çeşitli parametrelerinin ölçümünün yapılması ve elde edilen sonuçların anlamlandırılması gerekir. Bu amaç için transformatör sağlık indeksi adı verilen bir değişken kullanılır. Sağlık indeksi transformatörün yağının, sargılarının, yalıtım kağıdının, manyetik nüvesinin, kademe değiştiricilerinin ve buşinglerinin durumu hakkında genel bir bilgi veren sayıdır. Bu sayı transformatörün genel durumunu 0 ile 100 arasında ölçeklendirilerek verir. Literatürde SI değerinin hesabı için kullanımı önerilen pek çok yapay zeka yöntemi mevcuttur. Bu yöntemlerde transformatöre ait veriler kullanılarak transformatörün sağlık durumunu temsil eden bir model ve parametreleri elde edilir. Bulanık mantık, yapay sinir ağları ve destek vektör makineleri gibi yapay zeka yöntemleri transformatörlerin SI değerini belirlemede başarılı bir biçimde kullanılmıştır.

**KAYNAKÇA**

- Abu-Elanien, A. E., & Salama, M. M. A. (2010). Asset management techniques for transformers. *Electric power systems research*, 80(4), 456-464.
- Abu-Elanien, A. E., Salama, M. M. A., & Ibrahim, M. (2011). Determination of transformer health condition using artificial neural networks. In *2011 International Symposium on Innovations in Intelligent Systems and Applications* (pp. 1-5). IEEE.
- Abu-Elanien, A. E., Salama, M. M. A., & Ibrahim, M. (2012). Calculation of a health index for oil-immersed transformers rated under 69 kV using fuzzy logic. *IEEE Transactions on Power Delivery*, 27(4), 2029-2036.
- Abu-Siada, A. (Ed.). (2018). *Power transformer condition monitoring and diagnosis* (Vol. 104). Energy Engineering.
- Ahmed, M., Elkhatab, M., Salama, M., & Shaban, K. B. (2015, October). Transformer health index estimation using orthogonal wavelet network. In *2015 IEEE Electrical Power and Energy Conference (EPEC)* (pp. 120-124). IEEE.
- Alqudsi, A., & El-Hag, A. (2019). Application of machine learning in transformer health index prediction. *Energies*, 12(14), 2694.
- Ashkezari, A. D., Ma, H., Saha, T. K., & Ekanayake, C. (2013). Application of fuzzy support vector machine for determining the health index of the insulation system of in-service power transformers. *IEEE Transactions on Dielectrics and Electrical Insulation*, 20(3), 965-973.
- Azmi, A., Jasni, J., Azis, N., & Kadir, M. A. (2017). Evolution of transformer health index in the form of mathematical equation. *Renewable and Sustainable Energy Reviews*, 76, 687-700.
- Bakar, N. A., Abu-Siada, A., & Islam, S. (2014). A review of dissolved gas analysis measurement and interpretation techniques. *IEEE Electrical Insulation Magazine*, 30(3), 39-49.
- Benhmed, K., Mooman, A., Younes, A., Shaban, K., & El-Hag, A. (2017). Feature selection for effective health index diagnoses of power transformers. *IEEE Transactions on Power Delivery*, 33(6), 3223-3226.
- Bhalla, D., Bansal, R. K., & Gupta, H. O. (2012). Function analysis based rule extraction from artificial neural networks for transformer incipient fault diagnosis. *International Journal of Electrical Power & Energy Systems*, 43(1), 1196-1203.
- Birlik, K. N., Ozgonenel, O., & Karagül, S. (2016, December). Transformer health index estimation using artificial neural network. In *2016 National Conference on Electrical, Electronics and Biomedical Engineering (ELECO)* (pp. 1-5). IEEE.
- Boss, P., Horst, T., Lorin, P., Pfammatter, K., Fazlagic, A., & Perkins, M. (2002, August). Life assessment of power transformers to prepare a rehabilitation based on a technical-economical analysis. In *Cigre Session* (pp. 12-106).
- Brandtzaeg, G. (2015). Health indexing of norwegian power transformers, master of energy and environmental engineering. Norwegian University of Science and Technology, Department of Electric Power Engineering, Trondheim.
- Chantola, A., Sharma, M., & Saini, A. (2018, April). Integrated fuzzy logic approach for calculation of health index of power transformer. In *2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT)* (pp. 1045-1050). IEEE.
- CIGRE Working Group, A2,34 (2011) *Guide for Transformer Maintenance*. Cigre Publ Tech Broch 445:1-122
- Cui, Y., Ma, H., & Saha, T. (2014). Improvement of power transformer insulation diagnosis using oil characteristics data preprocessed by SMOTEBoost technique. *IEEE Transactions on Dielectrics and Electrical Insulation*, 21(5), 2363-2373.
- D. T. Hughes, "The use of health indices to determine end of life and estimate remnant life for distribution assets," in *Proc. CIGRE 17th Int. Conf. Electr. Distrib.*, Barcelona, Spain, May 2003, pp. 1\_4.
- Gezegin, C. (2018), *Transformatör sargı sıcaklığı kestirimi için yeni bir yöntem*. Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü. Doktora Tezi.
- Ghoneim, S. S., & Taha, I. B. (2020). Comparative study of full and reduced feature scenarios for health index computation of power transformers. *IEEE Access*, 8, 181326-181339.
- Guo-Hua, Q., Zheng, R., Lei, S., Bo, Z., Jian-Gang, X., & Xiang-Ling, Z. (2014, October). A new life cycle cost model of power transformer and its comprehensive sensitivity analysis. In *2014 International Conference on Power System Technology* (pp. 1342-1348). IEEE.



- Hooshmand, R. A., Parastegari, M., & Forghani, Z. (2012). Adaptive neuro-fuzzy inference system approach for simultaneous diagnosis of the type and location of faults in power transformers. *IEEE Electrical Insulation Magazine*, 28(5), 32-42.
- Huang, Y. C. (2003). Evolving neural nets for fault diagnosis of power transformers. *IEEE Transactions on Power Delivery*, 18(3), 843-848.
- D&F Liquidators, "The Basics of Electrical Transformers", erişim: 05.11.2022, <https://www.dfliq.net/blog/the-basics-of-electrical-transformers/>
- Esmaeili Nezhad, A., & Samimi, M. H. (2022). A review of the applications of machine learning in the condition monitoring of transformers. *Energy Systems*, 1-31.
- Ibrahim, K., Sharkawy, R. M., Temraz, H. K., & Salama, M. M. A. (2016). Selection criteria for oil transformer measurements to calculate the health index. *IEEE Transactions on Dielectrics and Electrical Insulation*, 23(6), 3397-3404.
- Idrees, M., Riaz, M. T., Waleed, A., Paracha, Z. J., Raza, H. A., Khan, M. A., & Hashmi, W. S. (2019, August). Fuzzy logic based calculation and analysis of health index for power transformer installed in grid stations. In 2019 international symposium on recent advances in electrical engineering (RAEE) (Vol. 4, pp. 1-6). IEEE.
- Islam, M. M., Lee, G., & Hettiwatte, S. N. (2018). A review of condition monitoring techniques and diagnostic tests for lifetime estimation of power transformers. *Electrical Engineering*, 100(2), 581-605.
- Jahromi, A., Piercy, R., Cress, S., Service, J., & Fan, W. (2009). An approach to power transformer asset management using health index. *IEEE Electrical Insulation Magazine*, 25(2), 20-34.
- Jaiswal, G. C., Ballal, M. S., & Tutakne, D. R. (2016, December). Health index based condition monitoring of distribution transformer. In 2016 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES) (pp. 1-5). IEEE.
- Javid, J., Mughal, M. A., & Karim, M. (2021, November). Using kNN Algorithm for classification of Distribution transformers Health index. In 2021 International Conference on Innovative Computing (ICIC) (pp. 1-6). IEEE.
- Jin, L., Kim, D., Abu-Siada, A., & Kumar, S. (2022). Oil-Immersed Power Transformer Condition Monitoring Methodologies: A Review. *Energies*, 15(9), 3379.
- Kachler, A. J., & Hohlein, I. (2005). Aging of cellulose at transformer service temperatures. Part 1: Influence of type of oil and air on the degree of polymerization of pressboard, dissolved gases, and furanic compounds in oil. *IEEE Electrical Insulation Magazine*, 21(2), 15-21.
- Khan, D., Ali, M., Khan, A. M., & Ali, M. (2022). Significances, possibilities and challenges of developing power transmission line conductors from carbon nanotubes. *Materials Today: Proceedings*, 56, 1478-1483.
- Khan, S. A., Equbal, M. D., & Islam, T. (2015). A comprehensive comparative study of DGA based transformer fault diagnosis using fuzzy logic and ANFIS models. *IEEE Transactions on Dielectrics and Electrical Insulation*, 22(1), 590-596.
- Köroğlu, S., YILDIZ, M., DEMİRÇALI, A., & Çetin, E. (2022). Frekans tepkisi analizi ile güç transformatörü hatalarının değerlendirilmesinde istatistiksel yöntemlerin kullanılması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(4), 2105-2118.
- Kulkarni, S. V., & Khaparde, S. A. (2017). *Transformer engineering: design, technology, and diagnostics*. CRC press
- Li, S., & Dong, H. (2019, May). Transformer apparent age estimation based on probabilistic health index. In 2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia) (pp. 3936-3940). IEEE.
- Li, S., Wu, G., Dong, H., Yang, L., & Zhen, X. (2020). Probabilistic health index-based apparent age estimation for power transformers. *IEEE access*, 8, 9692-9701.
- Malik, H., Yadav, A. K., Mishra, S., & Mehto, T. (2013). Application of neuro-fuzzy scheme to investigate the winding insulation paper deterioration in oil-immersed power transformer. *International Journal of Electrical Power & Energy Systems*, 53, 256-271.
- Martin, J. (2009). Distributed vs. centralized electricity generation: are we witnessing a change of paradigm? An introduction to distributed generation. *Energy Track at HEC Paris*.
- Ma, H., Saha, T. K., Ekanayake, C., & Martin, D. (2015). Smart transformer for smart grid—intelligent framework and techniques for power transformer asset management. *IEEE Transactions on Smart Grid*, 6(2), 1026-1034.
- Mohamadeen, K. I., Sharkawy, R. M., & Salama, M. M. (2014, April). Binary cat swarm optimization versus binary particle swarm optimization for transformer health index determination. In 2014 International Conference on Engineering and Technology (ICET) (pp. 1-5). IEEE.

- Mohd Selva, A., Azis, N., Shariffudin, N. S., Ab Kadir, M. Z. A., Jasni, J., Yahaya, M. S., & Talib, M. A. (2021). Application of statistical distribution models to predict health index for condition-based management of transformers. *Applied Sciences*, 11(6), 2728.
- Morais, D. R., Bencz, E., & Rolim, J. G. (2014). Condition assessment of power transformers through the integration of historical and on-line data in a multi-agent system. *Journal of Control, Automation and Electrical Systems*, 25(1), 93-102.
- Murugan, R., & Ramasamy, R. (2019). Understanding the power transformer component failures for health index-based maintenance planning in electric utilities. *Engineering Failure Analysis*, 96, 274-288.
- Nurchayanto, H., Nainggolan, J. M., Ardita, I. M., & Hudaya, C. (2019, July). Analysis of power transformer's lifetime using health index transformer method based on artificial neural network modeling. In 2019 International Conference on Electrical Engineering and Informatics (ICEEI) (pp. 574-579). IEEE.
- Odabaşı, H. 2012. Transformator ve Şönt Reaktör Deneylemleri, EMO e-Kitap, EMO Yayın No: EK/2012/533 ISBN:978-605-01-0465-3
- Ortiz, F., Fernandez, I., Ortiz, A., Renedo, C. J., Delgado, F., & Fernandez, C. (2016). Health indexes for power transformers: a case study. *IEEE Electrical Insulation Magazine*, 32(5), 7-17.
- Prasojo, R. A., & Abu-Siada, A. (2021). Dealing with data uncertainty for transformer insulation system health index. *IEEE Access*, 9, 74703-74712.
- Padmanaban, S., Khalili, M., Nasab, M. A., Zand, M., Shamim, A. G., & Khan, B. (2022). Determination of Power Transformers Health Index Using Parameters Affecting the Transformer's Life. *IETE Journal of Research*, 1-22.
- Rediansyah, D., Prasojo, R. A., & Abu-Siada, A. (2021). Artificial intelligence-based power transformer health index for handling data uncertainty. *IEEE Access*, 9, 150637-150648.
- Scatiggio, F., & Pompili, M. (2013, June). Health index: The TERN's practical approach for transformers fleet management. In 2013 IEEE Electrical Insulation Conference (EIC) (pp. 178-182). IEEE.
- Shamsudin, M. S., Yakub, F., Shapiai, M. I., Mohamad, A., & Abd Hamid, N. A. (2021, December). Investigation on Online DGA Monitoring to Determine Transformer Health Index Using Machine Learning. In *Journal of Physics: Conference Series* (Vol. 2128, No. 1, p. 012024). IOP Publishing.
- Sharma, J. P. (2021). Regression approach to power transformer health assessment using health index. In *Advances in Electromechanical Technologies* (pp. 603-616). Springer, Singapore.
- Suwnansri, T. (2014, March). Asset management of power transformer: Optimization of operation and maintenance costs. In 2014 International Electrical Engineering Congress (iEECON) (pp. 1-4). IEEE.
- Tamma, W. R., & Prasojo, R. A. (2021). High voltage power transformer condition assessment considering the health index value and its decreasing rate. *High Voltage*, 6(2), 314-327.
- Vermeer, M., Wetzler, J., van der Wielen, P., de Haan, E., & de Meulemeester, E. (2015, June). Asset-management decision-support modeling, using a health and risk model. In 2015 IEEE Eindhoven PowerTech (pp. 1-6). IEEE.
- U.S. Energy Information Administration (2019). "International Energy Outlook 2019 with projections to 2050", <https://www.eia.gov/outlooks/ieo/pdf/ieo2019.pdf> (15.10.2022).
- Wang, M. V. A. J., Vandermaar, A. J., & Srivastava, K. D. (2002). Review of condition assessment of power transformers in service. *IEEE Electrical insulation magazine*, 18(6), 12-25.
- Wies, R. W., Johnson, R. A., Agrawal, A. N., & Chubb, T. J. (2005). Simulink model for economic analysis and environmental impacts of a PV with diesel-battery system for remote villages. *IEEE transactions on power systems*, 20(2), 692-700.
- Žarković, M., & Stojković, Z. (2017). Analysis of artificial intelligence expert systems for power transformer condition monitoring and diagnostics. *Electric Power Systems Research*, 149, 125-136.
- Zeinoddini-Meymand, H., Kamel, S., & Khan, B. (2021). An efficient approach with application of linear and nonlinear models for evaluation of power transformer health index. *IEEE Access*, 9, 150172-150186.
- Zhang, X., & Gockenbach, E. (2008). Asset-management of transformers based on condition monitoring and standard diagnosis. *IEEE Electrical Insulation Magazine*, 24(4), 26-40.
- Zuo, W., Yuan, H., Shang, Y., Liu, Y., & Chen, T. (2016). Calculation of a health index of oil-paper transformers insulation with binary logistic regression. *Mathematical problems in engineering*, 2016.


# BÖLÜM


## 5

### GÜÇ KALİTESİNDE YAPAY ZEKA SINIFLANDIRMA TEKNİKLERİ

**Ezgi GÜNEY**

*Dr. Öğr. Üyesi, Sinop Üniversitesi, eguney@sinop.edu.tr*

 0000-0003-4868-0626




## BÖLÜM 5

### GÜÇ KALİTESİNDE YAPAY ZEKA SINIFLANDIRMA TEKNİKLERİ

**Ezgi GÜNEY**

*Dr. Öğr. Üyesi, Sinop Üniversitesi, eguney@sinop.edu.tr*

 0000-0003-4868-0626

#### GİRİŞ

Elektrik enerjisinin insan hayatındaki öneminin artması, yani şehir merkezlerindeki nüfus artışı dolayısıyla yeni yerleşim alanları ve endüstri alanlarının artması, teknolojik gelişmelerle birlikte enerji tüketiminin artması gibi nedenler araştırmacıları enerjinin son kullanıcıya daha kaliteli ve güvenli iletilmesi ile ilgili çalışmalara yoğunlaştırmıştır. Artan talep ve şebekelerdeki büyüme neticesinde güç dengesinin korunması, sistemin kabul edilebilir sınırlarda çalıştırılabilir olması, dolayısıyla tüketiciye sağlanan enerjinin kaliteli, güvenilir ve kesintisiz olması kritik önem arz etmektedir. Günümüzde iletim ve dağıtım sistemlerinde güvenilirlik çok yüksek seviyelere erişmesine karşın sistemde meydana gelen arızalar hem tüketici tarafında hem de şebeke tarafında sorunlara sebep olmaktadır.

Elektrik güç sistemine bağlı cihazların ve son kullanıcı yüklerin zarar görmesine, arızalanmasına veya istenmeyen bir çalışma karakteristiğine neden olan gerilimin veya akımın genliğindeki, frekansındaki ve dalga formundaki değişimler, elektrik Güç Kalitesi Bozuklukları (GKB) olarak tanımlanmaktadır. Elektrik enerjisi dağıtım şebekelerinde, gerilim ve/veya akım dalga biçimlerini bozan Güç Kalitesi (GK) olaylarının tespiti ve sınıflandırılması, elektrik enerjisinin üretilmesi ve bu enerjinin kabul edilebilir bir gerilimde son kullanıcı ekipmanına iletilmesi için çok önemlidir.

GKB'lerin başlıca nedenleri; arıza, yük anahtarlama, kapasitör anahtarlama, yüksek anahtarlama frekanslı elektronik cihazlar, güç dönüştürücüler, ark ocakları ve transformatörlerdir. Yenilenebilir enerji kaynaklarının ve dağıtılmış üretimin geleneksel bir güç sistemine entegrasyonu da GK bozukluklarının ana kaynaklarından biridir. Anahtarlama cihazlarının artan uygulaması, doğrusal olmayan yükler, doğrultucular ve eviriciler, aydınlatma kontrolleri, bilgisayar ve veri işleme ekipmanları, koruma ve röle ekipmanları GK bozulmalarına neden olmaktadır (Khokhar ve ark., 2015).

GKB'lerin meydana gelmesi elektriksel cihazların arızalanmasına, ömürlerinin kısalmasına veya tamamen zarar görmesine, sistemin verimliliğinin düşmesine ve sistemin kararlılığının

bozulmasına neden olabilmektedir. Dolayısıyla GKB'lerin çözümlenebilmesi için öncelikle problemin çok iyi tanımlanması, sebeplerinin belirlenmesi ve sınıflandırılması gerekmektedir (Yeşilyurt, 2021). Başarılı bir sınıflandırma için sinyallerin işlenmesi ve çıkarılması büyük önem taşımaktadır.

Son otuz yıldır akademisyenler ve endüstri, GKB'lerin otomatik sınıflandırılması için yeni tekniklerin geliştirilmesine odaklanmış, GKB'lerin olumsuz etkilerini en aza indirmek için akıllı yöntemlerin geliştirilmesine yönelmişlerdir. Literatürdeki çalışmalarda, güç sistemlerinde meydana gelen GKB'lerin sınıflandırılması için birçok Yapay Zeka (YZ) yöntemleri yer almaktadır. Bu bölüm, GK olaylarının otomatik olarak tanınması için YZ algoritmalarına dayalı son teknoloji teknikler hakkında kapsamlı bir inceleme sağlamaktadır.

## **GÜÇ KALİTESİ BOZUKLUKLARI VE STANDARTLARI**

GK, güç sisteminin incelenen herhangi bir noktasında ideal sinüzoidal şekildeki gerilimin nominal genlik ve frekans değerlerini sürdürmesi olarak tanımlanabilir. Vazgeçilmez bir enerji kaynağı olan elektrik enerjisini üreten, ileten ve dağıtan kuruluşların görevi kesintisiz, ekonomik ve kaliteli bir hizmeti tüketicilerine sunmaktır. Ancak, güç sistemine bağlanan bazı elemanlar ve bunların yol açtığı olaylar sebebiyle tam sinüzoidal değişiminden sapmalar olabilmektedir.

IEEE 1159-1995 standartlarına göre güç kalitesi problemleri; geçici durumlar, kısa süreli gerilim değişimleri, uzun süreli gerilim değişimleri, gerilim dengesizlikleri, dalga şekli bozulmaları, gerilim salınımları ve frekans değişimleri olmak üzere yedi ana gruba ayrılmaktadır. Bu standartlar aynı zamanda çeşitli GK olayları için büyüklük ve zaman aralığının değişimini de belirtir. Gerilim büyüklüğü, zaman süresi ve spektral içeriğin değişimine dayalı olarak GK olay türleri kapsamlı olarak Tablo 1'de yer almaktadır (EN 50160, 2010; IEC 61000-4- 30, 2003; IEEE Standard 1159-2009, 2009).

Tablo 1'de yer alan geçici rejim olayları güç sistemlerinde fazlar arası, faz-toprak arızaları, anahtarlama olayları ve yıldırımdan kaynaklı durumlarda meydana gelebilen ns, µs mertebelerindeki ani değişikliklerdir. Salınımlı ya da darbe şeklinde karşımıza çıkabilir. Şebekedeki arızalardan kaynaklı kesinti, gerilim çökmesi ve gerilim yükselmesi ise kısa süreli değişimlerdir. Güç sistemlerindeki hatalar, ekipman yaşlanmaları, yanlış manevralar gibi nedenler kısa süreli değişimlere neden olmaktadır.

**Tablo 1.** GKB’lerin Farklı Parametreler Temelinde Sınıflandırılması

	Bozulma	Frekans Spektrumu	Olay Süresi	Genlik	
<b>Geçici Durum</b>	<b>Darbeli</b>	ns	5 ns yükselme	<50 ns	
		µs	1 µs yükselme	50 ns – 1 ms	
		ms	0.1 ms yükselme	> 1 ms	
	<b>Salınımlı</b>	Düşük frekans	<5 kHz	0.3 – 50 ms	
		Orta frekans	5- 500 kHz	20 µs	
		Yüksek frekans	0.5- 5 MHz	5 µs	
<b>Kısa Süreli Değişimler</b>	<b>Ani</b>	Çökme	0.5- 30 periyot	0.1 – 0.9 pu	
		Sıçrama	0.5- 30 periyot	1.1-1.8 pu	
		Kesinti	0.5- 30 periyot	<0.1 pu	
	<b>Kısa süreli</b>	Çökme	30 periyot 3 s	0.1 – 0.9 pu	
		Sıçrama	30 periyot 3 s	1.1 – 1.4 pu	
		Gerilim Dengesizliği	30 periyot 3 s	%2- %15	
	<b>Geçici</b>	Kesinti	> 3 s – 1 dk	<0.1 pu	
		Çökme	> 3 s – 1 dk	0.1 – 0.9 pu	
		Sıçrama	> 3 s – 1 dk	1.1 – 1.2 pu	
		Gerilim Dengesizliği	> 3 s – 1 dk	%2- %15	
		<b>Uzun Süreli Değişimler</b>	Kalıcı kesinti	> 1 dk	0.0 pu
			Düşük gerilim	> 1 dk	0.8 – 0.9 pu
Aşırı gerilim	> 1 dk		1.1 – 1.2 pu		
Aşırı akım	> 1 dk				
<b>Gerilim Dengesizliği</b>	Gerilim	Sürekli durum	% 0.5- % 5		
	Akım	Sürekli durum	% 1 - % 3		
<b>Dalga Şekli Bozulmaları</b>	Doğru akım bileşeni		Sürekli durum	%0- %0,1	
	Harmonikler	0 – 100. harmonik	Sürekli durum	%0- %20	
	Çentik	0 – 6 kHz	Sürekli durum		
	Gürültü	Geniş bant	Sürekli durum	%0- % 1	
<b>Gerilim Salınımları</b>		<25 Hz	Kesintili	0.2 – 2 P <sub>st</sub>	
<b>Güç Frekansı Değişimleri</b>			<10 s	± 20 Hz	

Güç frekansındaki etkin değer değişimlerinin 1 dakikadan uzun sürmesi uzun süreli değişimleri ifade eder. Sistemdeki yük değişiklikleri ile anahtarlamalardan kaynaklı bu değişimler; kesintiler, düşük gerilimler, aşırı gerilimler ve aşırı akımlar olarak karşımıza çıkmaktadır. 3 fazlı güç sistemlerinde her faza ait gerilim genlik değerleri birbirine eşit ya da çok yakın olmalıdır. Fazlar arasındaki gerilimlerin genlikleri arasında fark olması durumu gerilim dengesizliği olarak tanımlanmaktadır. Sağlıklı bir güç sisteminde gerilim ve akım dalga formları periyodik sinüzoidal formda olmalıdır. Şebeke frekansında, gerilim veya akım dalga şeklinin saf sinüzoidal halden sapması, çentik, gürültü, DA gerilim veya akım bileşenlerinin yer alması şeklinde ortaya çıkan bozulmalardır (Yeşilyurt, 2016).

Yaygın olarak görülen GKB'lerin birincil türleri, altta yatan nedenleri, tüketiciler üzerindeki olumsuz etkileri ve dalga formları Tablo 2'de verilmiştir (Khetarpal ve Tripathi, 2020; Soomro ve ark., 2021; Yalçın, 2019).

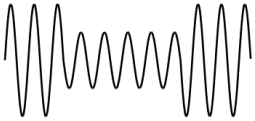
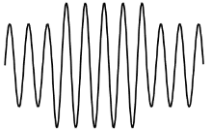
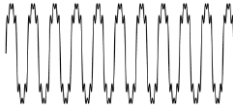
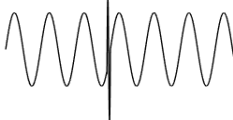
## GÜÇ KALİTESİNDE ÖZELLİK ÇIKARIM TEKNİKLERİ

GK bozulmalarının sınıflandırılması sinyal işleme, yapay zeka ve optimizasyon tekniklerinin uygulamalarına dayanmaktadır. Literatürde, GK bozukluklarının tanımlanması ve sınıflandırılması için sinyal işleme tabanlı öznelik çıkarımı, YZ tabanlı sınıflandırıcılar ve optimal öznelik seçimine dayalı sezgisel optimizasyon tekniklerinden oluşan çeşitli metodolojiler önerilmiştir. GK bozukluklarının otomatik sınıflandırmasında yer alan adımlar Şekil 1'de gösterildiği gibi bir akış şeması kullanılarak açıklanabilir.

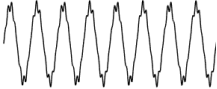






**Şekil 1.** GKB'lerin otomatik algılama ve sınıflandırma tekniklerinin blok diyagram gösterimi

**Tablo 2.** GKB'lerin Nedenleri, Etkileri ve Dalga Biçimleri

GKB	Tanım	Sebeup	Etkiler	Dalga Formu
Gerilim Çökmesi (Voltage Sag)	10ms-60s zaman aralığında sınırlı olmak kaydıyla, gerilimdeki 0.1-0.9 pu arasında meydana gelen azalma	İletim ve dağıtım hatlarında oluşan kısa devreler, büyük güçlü yüklerin anahtarlanması, kapasitörlerin devreden çıkarılması, aşırı yüklenmiş devreler, büyük güçlü motorların devreye girmesi	Aydınlatma kısma, bilgisayar kilitlenmeleri, röle ve kontaktör gürültüsü, tam kesinti, ekipman ve sistem kapatmaları, sahte ve açıklanamayan alarmlar	
Gerilim Yükselmesi (Voltage Swell)	Gerilimin rms değerinde 1.1 ile 1.8 pu arasında artış	Faz-toprak kısa devre arızası, büyük yüklerin anahtarlanması, büyük kapasitör banklarının enerjilendirilmesi	Başarısız güç kaynağı, değişken frekanslı sürücülerde aşırı gerilim kapatmaları ve alarmlar	
Harmonikler (Harmonics)	Besleme sisteminin normal çalışma frekansının (temel frekans) tam sayı katlarındaki sinüs biçimli gerilim ve akımlar	Anahtarlama güç kaynakları gibi doğrusal olmayan yükler, kesintisiz güç kaynağının dönüştürücü bölümleri, akü şarj cihazları, kaynakçılar, ark fırınları	Elektromekanik cihazlarda ve kablolarda ısınmalar, makinalarda mekanik titreşimler, ateşleme devrelerinde anormal çalışma, elektronik kart arızaları, güç kondansatörlerinde güç kayıpları, delinmeler ve patlamalar, kesici ve şalterlerde açmalar, enerji kayıpları	
Geçici Rejimler (Transient)	Güç sisteminde 50 ns'den 50 ms'ye kadar hem gerilim hem de akım dalga biçiminde meydana gelen sinüs dalgasındaki hızlı değişim	Şimşek çakması, kapasitörlerin anahtarlanması, elektrik kesintisinden sonra sistemlerin yeniden enerjilendirilmesi, büyük ekipmanın ani durması, kirli veya aşınmış kontaktörler	Lambalarda parlaklığın dalgalanması, manyetik çekirdeğe sahip cihazlarda arızalar ve elektrik motorlarında hız değişimleri	

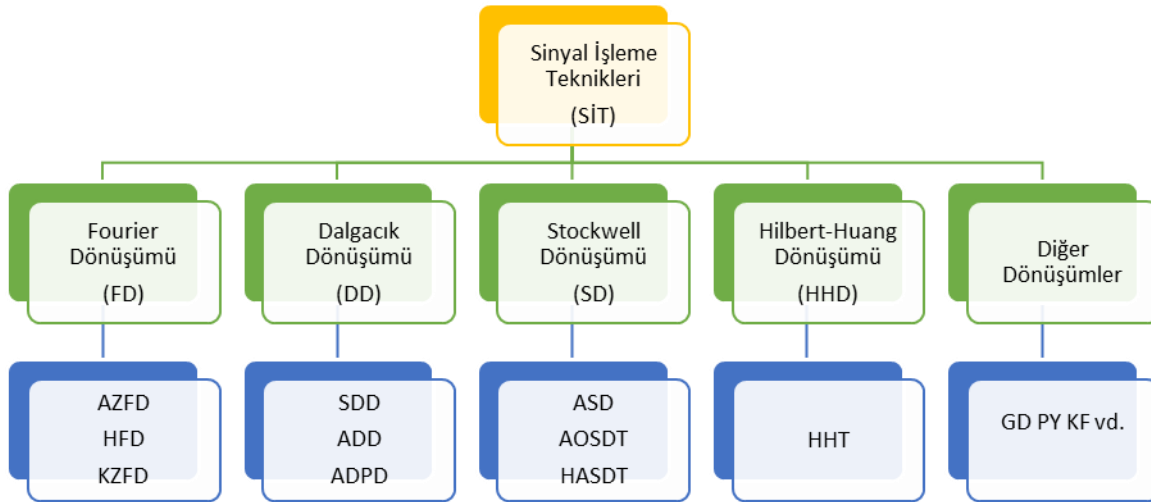


Kırpışma (Flicker)	Gerilim dalgalanmaları normalde 0.9 p.u. ile 1.1 p.u. seviyesini aşmayan rastlantısal veya sistematik gerilim değişiklikler	Şimşek, ana ekipmanı açma veya kapatma, anahtarlama	Açma, işleme hataları, veri kaybı, yanmış devre kartları	
Kesinti (Interruption)	Kaynak geriliminin ya da yük akımının bir dakikadan daha kısa süre için 0.1 pu'nun altına düşmesi	Güç sistemi arızaları (kısa devre arızaları), ekipmanların gereksiz çalışması, izolatörün bozulması, yıldırımın etkisi, kontrol sistemi arızası	Ekipman tetiklenmesi, veri kaybı, bilgisayarların kapatılması, disk sürücüsü arızası	
Gürültü (Noise)	Gürültü güç sistemlerinde bulunana 200 kHz'den küçük bir frekans spektrumuna sahip işaretler olarak tanımlanır	Yanlış topraklama, güç elektroniği cihazları, kontrol devreleri, ark cihazları, yarıiletken doğrultuculu yükler, güç kaynaklarının anahtarlaması	Mikroişlemciler veya programlanabilir kontrolörlerin çalışmasında bozulmalar	
Gerilim Dengesizliği (Unbalanced)	Fazlar arasındaki gerilimlerin genlikleri arasında fark olması durumu	Üç fazlı panoların ayrı fazlarında dengesiz yükler, dengesiz şebeke kaynağı, tek fazlı kaynak, makinelerinin çalışması, açık üçgen transformatörler	Üç fazlı motorlar ve transformatörlerde aşırı ısınma	
Çentik (Notch)	Güç elektroniği aletlerinin normal çalışma şartlarında bir fazdan diğerine geçmeleri sırasında oluşan periyodik gerilim bozulmaları.	Doğrultucuları besleyen transformatör ve hat endüktanslarının anahtar akımını geciktirmesi	Faz-faz arası kısa devreler, yüksek frekanslı salınımlar, hassas elektronik elemanlarda hasarlar	

Şekil 1'e göre başlangıçta giriş bozulma sinyali, özellik çıkarma birimi olarak adlandırılan ön işleme birimi aracılığıyla işlenir. Bir sonraki adımda, çıkarılan öznelikler, en az sayıda öznelikle en ayırt edici, benzersiz ve optimum öznelik vektörünü sağlamak için öznelik seçim biriminden geçirilir. Daha sonra seçilen öznelik vektörü sonraki aşamada akıllı sınıflandırıcıya girdi olarak kullanılır. Akıllı sınıflandırıcının çıktısı, karar verme aşamasında nihai kararı vermek için kullanılır.

Öznelik çıkarma işlemi, orijinal sinyallerin elde edilen dönüşüm katsayılarından ayırt edici özellikleri bulmak için uygulanan örüntü tanıma sisteminin en önemli kısmıdır. Çıkarılan öznelikler daha sonra GK bozukluklarının sınıflandırılması için kullanılır. Bu bağlamda, özellik çıkarımı için Sinyal İşleme Teknikleri (Signal Processing Techniques - SİT) ve sınıflandırma için YZ teknikleri, GKB'lerin örüntü tanınmasının en önemli parçalarıdır (Zhu ve ark., 2004).

Özellikler ya orijinal sinyallerden çıkarılabilir ya da bazı zaman-frekans dönüşüm teknikleri ile oluşturulabilir. Literatürde özellik çıkarımı için Fourier Dönüşümü (Fourier Transform - FD), Dalgacık Dönüşümleri (Wavelet Transforms - DD), Stockwell Dönüşümü (Stockwell Transform - SD), Hilbert-Huang Dönüşümü (Hilbert-Huang Transform - HHD), Kalman Filtresi (Kalman Filter - KF), Gabor Dönüşümü (Gabor Transform - GD) ve bunların hibritleri gibi çeşitli SİT'ler yer almaktadır. GK bozukluklarının öznelik çıkarımı için kullanılan son teknoloji SİT'leri içeren gelişmiş bir taksonometri Şekil 2'de gösterilmektedir (Zhu ve ark., 2004).



**Şekil 2.** Özellik Çıkarımı İçin Kullanılan Çeşitli Dönüşümler

Bu dönüşümler zaman ve frekans alanlarında bilgi elde etmek için kullanılır. Sınıflandırmanın en yüksek doğruluğunu elde etmek için GK olaylarının en uygun özelliklerinin seçimi son derece önemlidir. Bir sınıflandırıcının performansı, çıkarılan öznitelik vektörüne bağlıdır (Erişti ve ark., 2013). Bu nedenle, karmaşık bir sınıflandırıcı tasarımı yerine, örüntülerin ayırt edici özellikleri örüntü tanıma sistemlerinin ana odak noktasıdır. GK bozukluklarının dönüştürülmüş katsayılarının istatistiksel parametreleri, veri boyutunu azaltmak ve GK bozukluklarının ayırt edici özelliklerini elde etmek için hesaplanabilir. GK bozukluklarının sınıflandırılması için en yaygın olarak kullanılan istatistiksel parametreler enerji, entropi, minimum, maksimum, standart sapma, ortalama, rms değeri vb. ve bunların kombinasyonlarıdır (Khokhar ve ark., 2015).

Literatürde yaygın olarak kullanılan YZ tabanlı sınıflandırıcılar, alt başlıklar halinde tartışılmaktadır.

### **Fourier Dönüşümü**

FD; tüm sinyallerin farklı sinüzoidal fonksiyonlarının toplamı şeklinde ifade edilebileceği üzerine kurulmuştur. Bu sayede, Fourier dönüşümü; bir sinyalin içinde bulunan farklı frekans bileşenlerini farklı sinüs fonksiyonları şeklinde tanımlayarak sinyali bileşenlerine ayırıştırır. FD, en temel sinyal işleme araçlarından biridir. Voltaj ve akım dalga biçimindeki harmonikleri (durağan GK olayları) ölçmek için en iyi araçtır, ancak durağan olmayan GK olayı için zaman ve frekansın ilişkili olmaması gibi bazı dezavantajları vardır. Fourier tekniği en iyi, zamansal bilginin gerekli olmadığı sonsuz durağan bir dalga durumunda kullanılır. Ancak dalgalanmalar gibi zamansal bilgiler gerekiyorsa Kısa Zamanlı Fourier Dönüşümü (Short Time FD- KZFD) kullanılabilir. FD, frekans dönüşümü için kullanılırken KZFD, zaman-frekans alanı için kullanılır. Spektral içerikler KZFD kullanılarak zamanın bir fonksiyonu olarak elde edilir. Frekans çözünürlüğü sabitlendiğinde, pencere boyutu tüm frekanslar için sabitlenebile, KZFD ile sinyallerin harmonikler açısından daha kolay yorumlanması sağlanır (Gu ve Bollen, 2000). KZFD'deki pencerenin boyutu, farklı bozulmaların dalgalanma oranından çok daha küçüktür. Bu nedenle, pencere boyutu seçimi KZFD'nin performansını ve çözünürlüğü etkiler. KZFD ile durağan olmayan sinyallerin analizi zordur (Addison, 2002; Jurado ve ark., 2002). Sürekli bir ayrık zamanlı sinyalin FD'sine Ayrık Zamanlı Fourier Dönüşümü (Discrete Time Fourier Transform- AZFD) denir. Öte yandan, sonlu ayrık zamanlı sinyalin FD'si Ayrık Fourier Dönüşümü (Discrete Fourier Transform - AFD) olarak adlandırılır. Örnek sayısı fazla olduğunda, AFD için aşırı hesaplama gerekir. Güç sinyalindeki değişimler genellikle periyodik değildir ve zamanla değişir, bu nedenle FD ve AFD bu durağan olmayan sinyaller için yeterli bir seçim değildir. AFD, spektral sızıntı ve çözünürlük etkileri gibi birçok eksikliğe sahiptir. Hızlı Fourier Dönüşümü (Fast Fourier Transform - HFD), AFD hesaplama süresini hızlandıran ve hesaplama sayısını azaltan bir algoritmadır. Pencere HFD, AZFD'nin zaman pencereyi bir versiyonudur. Ayrıntılı analiz için dar

pencere genişlikleri kullanılır ve arşivlenmiş güç kalitesi veri ölçümleri arasında hızla hareket etmek için geniş pencere genişlikleri kullanılır (Heydt ve ark., 1999). HFD, geleneksel olarak bireysel harmoniklerin çıkarılmasında (Lai ve ark., 1999), durağan koşullar altında iyi bir etkinliğe sahiptir ve basit yapısı nedeniyle tercih edilir. Ancak zamanla değişen koşullar altında doğruluğunu kaybeder. Duyarlılık sesi, HFD tabanlı yöntemlerin bir başka eksikliğidir (Girgis ve Ham, 1980). KZFD, FD'ye kıyasla daha iyi verim sağlar. KZFD, daha fazla sinyal analizi için sabit pencere boyutu sağladığı için durağan olmayan sinyaller için kullanılır (Choong ve ark., 2005). Bu nedenle, Pencere-HFD, pencere genişliğinin uygulamaya göre ayarlanabildiği Ayrık Zamanlı Fourier Dönüşümünün (AZFD) zaman pencere bir tekniğidir.

### **Dalgacık Dönüşümü**

Günümüzde DD, araştırmacılar tarafından zaman-frekans düzleminde karakteristikleri elde etmek için (GK olaylarının analizi için) kullanılan en popüler tekniktir. Böylece, GK analizinde olayın başlaması ve bitmesi için zaman ve frekans bilgisinin gerekli olduğu durumlarda DD yeterli bir seçim haline gelir. DD'de belirli bir sinyal, farklı çözünürlük seviyelerine sahip çoklu sinyallere ayrıştırılır. Sinyalin zaman alanından zaman ölçeği alanına olan bu ayrışmasına DD denir ve orijinal sinyalin ayrıştırılmış sinyallerden yeniden oluşturulmasının tersine işlemine ters DD denir. Bu iki süreç birlikte dalgacık dönüşüm çifti olarak adlandırılır (Santoso ve Hofmann, 1996). DD, bir sinyali ölçeklenmiş ve çevrilmiş form açısından ayrıştırır. DD'de Çoklu Çözünürlüklü Analiz (Multiresolution Analysis- ÇÇA) tekniği (Gaouda ve ark.,1999) kullanılır. ÇÇA'da bir sinyal, sırasıyla yüksek geçiren ve alçak geçiren filtreler kullanılarak yüksek frekans ve düşük frekans bantlarına ayrıştırılır, bu işlem istenen ayrıntı seviyesine ulaşmak için tekrarlanır. Her seviyede, bilgi miktarı sonraki seviyelere düşürülür. Bant geçiren filtreler kullanılarak, geçişler, enerjilenme olayları, anahtarlama işlemi ve voltajda hızlı yükselme veya düşme gibi ani değişimlerin olduğu yüksek frekanslı sinyaller algılanırken, düşük geçişli filtreler harmonikler gibi daha yavaş sinyallerin tespiti için kullanılır (Chen ve Urwin, 2001). FD'ye benzer şekilde, DD, sinyalin frekans bileşeni hakkında bilgi sağlar, ancak aynı zamanda zaman çözünürlüğü hakkında da bilgi sağlar. FD, kararlı durum olaylarını karakterize etmek için kullanılırken, DD geçici olaylara uygulanır (Santoso ve ark., 1996). DD'yi HFD'ye kıyasla kullanmanın avantajı, farklı frekanslarda zaman ve frekans çözünürlüğü arasındaki dengedir. Yüksek frekanslı geçici olaylar için, DD kısa zaman aralıklarına odaklanır ve düşük frekanslı bileşenler için uzun zaman aralıklarına odaklanır (Robertson ve ark., 1996). DD, durağan olmayan sinyaller için daha uygundur (Santoso ve Hofmann, 1996; Santoso ve ark., 1997).

### **Stockwell Dönüşümü**

SD, değişken pencereli KZFD'nin geliştirilmiş bir formu veya DD'nin bir uzantısı veya KZFD ve DD'nin bir kombinasyonudur (Rodriguez ve ark., 2011). Analiz penceresinin genişliği frekansla azaltılarak SD'de frekansa bağlı bir çözünürlük sağlar. SD ve DD, faz düzeltmenin yanı sıra genlik ve faz spektrumu dışında benzerdir (Gong ve Liao, 2020). SD, DD'nin çok çözünürlüklü analizi avantajına sahiptir ve KZFD gibi frekans değişkenlerini kullanabilir. SD, DD'ye kıyasla zaman-frekans spektrogramlarında daha iyi çözünürlüğe sahiptir ve kayıpsız ters dönüşüm gerçekleştirebilir (Huang ve ark., 2015). ST, DD gibi zaman-frekans çözünürlüğü sağlar. SD'de pencere frekansa bağlıdır. Daha yüksek frekanslarda pencere daralır ve düşük frekanslarda pencere genişler. SD'nin değiştirilmiş bir versiyonu olan İyileştirilmiş SD (Modified Stockwell Transform), normal SD'den daha iyi doğruluk sağlar ve ayrıca daha hızlı eğitilir (Stockwell ve ark., 1996).

SD, yüksek bir gürültü toleransına ve garantili örüntü tanımaya sahiptir. Daha iyi bir sınıflandırıcı elde etmek için SD, Karar Ağacı (Decision Tree- KA ile entegre edilebilir. GK olaylarının sınıflandırılması için bulanık tanıma sistemi (Chilukuri ve Dash, 2004) ve kural tabanlı yaklaşım (Rodríguez, 2012) ile bütünleşmiş SD tabanlı ÇÇA tekniği önerilir. ÇÇA, kullanıcı tarafından tanımlanan frekansa göre değişen bir değişken pencereye dayanır. Durağan olmayan GK bozukluklarının zaman lokalize spektral özelliklerinin doğru bir şekilde çıkarılması için Ayırık SD (Discrete SD - ASD) algoritmasının bir varyantıdır (Biswal ve Dash, 2013). Hiperbolik S-Dönüşüm ve GA tabanlı Bulanık C-ortalama (Fuzzy C-means - BCO) algoritması durağan olmayan GK sinyallerinin otomatik örüntü tanınması için önerilmektedir (Biswal ve ark., 2009). GK sinyallerinin ayırt edici özelliklerini çıkarmak için pencereli ayırık FD ve SD teknikleri de önerilir (Nguyen ve Liao, 2015). Maksimum benzerlik ilkesine dayalı Modül Zaman-Frekans Matrisi (Module Time-Frequency Matrix) ile S-dönüşümünün kısa süreli bozulma karakteristiklerini çıkarmak da mümkündür (Xiao ve ark., 2009).

### **Hilbert Huang Dönüşümü**

HHD iki adımdan oluşur. HHD, veriye ilk adımda ampirik biçim ayrıştırması ve ardından Hilbert tayf analizi yapılmasıyla gerçekleştirilir. HHD'de, güç sinyalleri önce Ampirik Mod Ayrıştırma (Empirical Mode Decomposition - AMA) yöntemiyle içsel mod fonksiyonlarına ayrıştırılır ve ardından sinyalin anlık frekansı ve genliği için HHT ile analiz edilir (Norman ve ark., 2012). HHT, harmoniklerin ve belirsizlik prensibinin getirdiği sınırlandırmalardan etkilenmez. Ampirik biçim ayrıştırma yöntemi, HHT'nin temel bileşenlerinden biridir ve tek başına HHT dışında da çok geniş bir uygulama alanına sahiptir. AMA' yı diğer tekniklerden, yani HFD veya DD'den ayıran özellik, temel işlevlerini sinyalin kendisinden türeterek, onu uyarlanabilir hale getirmesinde yatmaktadır (Shukla ve ark., 2009). Dinamik kablosuz güç aktarımındaki spektral sızıntı probleminin üstesinden gelmek ve güç

miktarlarını doğru bir şekilde tahmin etmek ve titreşimleri tespit etmek için HD algoritması aracılığıyla bir frekans kaydırmalı dalgacık ayrıştırması mümkün olabilir (Agarwa ve ark., 2017). Bir oktav içinde yer alan frekans modları orijinal AMA yöntemi ile ayırlamadığından, geliştirilmiş HHD tasarlanmıştır. Bu yeni yöntemin sinyallerde bozulan modları ayırdığı ispatlanmıştır (Senroy ve ark., 2007). Yinelemeli Hilbert Huang Dönüşümü olarak adlandırılan HHD'de iyileştirme içeren bu yöntem, dalga biçimindeki yakın frekans bileşenlerini algılama sorununu çözmektedir. Bu yöntem, GK olayından yararlı anlık frekans ve genlik elde edebilen, kendinden uyarlamalı dalga biçimine dayanmaktadır. GK'leri algılama ve sınıflandırma için HHD ve İleri Beslemeli Sinir Ağlarına (Feed Forward Neural Network- İBSA) dayalı bir hibrit algılama yöntemi ve sınıflandırma tekniği geliştirilmiştir (Alshahrani ve ark. 2016).

### **Diğer özellik çıkarma teknikleri**

GD, KZFD yönteminin geliştirilmiş bir fonksiyonudur. Giriş sinyali seçilecek olan bir zaman değişkeni ile oluşturulan pencere fonksiyonunun FD'si alınarak elde edilen zaman - frekans analizi olarak ifade edilir. KZFD'de olduğu gibi GD'nin de önemli eksikliği zaman- frekans çözünürlüğü arasında uyuma bulunmamasıdır. Eğer pencere kısa seçilirse, elde edilen bilgi zamana iyi yerleşmiş olacak fakat frekans çözünürlüğü zayıflayacaktır. Benzer şekilde daha büyük pencere kullanımı frekans çözünürlüğünü artırırken zaman çözünürlüğünün zayıflamasını da beraberinde getirmektedir (Abdullah ve ark., 2007). GT, zamanla değişen işaretler için frekans bölgesinde etkin görüntüleme sağlar. İşaretin çok hızlı değiştiği zaman aralıklarında, Gabor işlevi işarete daha çok odaklanır ve işaret özelliklerinin gösterimi için başarımlı diğer yöntemlere göre daha yüksektir (Huang ve ark., 1996). Güç şebekelerinde kısa süreli arızaların tespiti ve ölçümü için Gabor-Wigner dönüşüm yöntemi kullanılmaktadır. Gabor-Wigner dönüşüm yöntemi, GD ve Wigner dağıtım fonksiyonunun operasyonel bir birleşimidir. Bu yöntem, zaman ve frekans çözünürlüklerini artırmakla birlikte, Wigner dağılım yöntemini çapraz terim sorunu ve GD'nin düşük çözünürlük sorununu çözmektedir. Sabit olmayan bir güç bozulması dalga şekline dayalı, temel frekansın değişken olarak ele alındığı bazı yöntemler önerilmiştir. Genlik ve frekans hesaplamalarının hem hızlı bir şekilde hem de yüksek doğruluk payı ile yapılabilmesi için doğrusal olmayan bir dizi eğri uydurma ve sınırsız en iyileme aracı da kullanılabilir (Cho ve ark., 2009). Prony Yöntemi (PY), izlenen işaretin içerdiği genliği, sönüm faktörleri, frekans ve fazları tanımlamaktadır. Bu yöntem, güç sistemindeki geçici harmonikleri veya zamanla değişim gösteren harmonikleri izlemek için kullanılır. Sabit olmayan bozuklukların olduğu ortamlarda GK ölçütünün hesaplanmasını, gerilim düşme ve yükselmenin saptanmasını PY sağlar (Andreotti vd, 2008). Ani gerilim kademesi değişikliklerinin hesaplanması için kullanılan eğri uydurma yöntemleri arasında; KF, Tekrarlı En Küçük Kareler Algoritması (Iterated Reweighted Least Squares), Tekrarsız Newton Türü Algoritma ve YSA sayılabilir. KF, harmoniklerin gerçek zamanlı izlenmesi, güç sistemi

koruma düzeneğindeki gerilim ve akım değişkenlerinin belirlenmesi ve güç iniş-çıkış değişkenlerinin hesaplanması gibi birçok sistem uygulamasında yararlı araçlardır (Bollen ve Gu, 2006). Temel sistem modelinin doğrusal olmadığı koşullarda, kapsamlı KF olarak bilinen bir doğrusallaştırma işlemi uygulanarak KF genişletilmelidir. Kapsamlı KF, bozulan işaretteki genlik, frekans, faz ve harmonik içeriğindeki değişikliklerin doğru izlenmesinde kullanılır (Dash ve Chilukuri, 2004). Doğrusal öngörü teknikleri, tekil değer çözümlenmesi, Burgh algoritması, Marple algoritması vb. yoluyla modellerin değişkenlerinin saptanmasında uygulanan parametrik yöntemler yüksek hesaplama kaynakları ve işlem süreleri gerektirmektedir (Li ve ark., 2007).

GKB 'lerde özellik çıkarma amacıyla kullanılan SİT'nin temel faydalarını ve olumsuzluklarını içeren gelişmiş bir taksonomisi Tablo 3'te sunulmaktadır (Beniwal ve ark., 2021; Chawda ve ark., 2020; Khetarpal ve ark., 2020; Mishra, 2019).

**Tablo 3-** SİT'lerin Temel Üstünlükleri ve Olumsuzlukları

SİT	Üstünlükleri	Olumsuzlukları
<b>AFD</b>	En yaygın kullanılan hesaplama algoritma, durağan sinyallerin kararlı durum analizi, durağan GK olayları için uygunluk	GK bozukluklarındaki ani değişimleri algılayamama
<b>HFD</b>	AFD'ye oranla daha hızlı yürütme süresi, Yaygın GKB harmonik çalışması uygulamaları	HFD'nin oluşturduğu sızıntı ve örtüşme etkilerinden kaynaklı, genlik frekansları ve fazlar gibi sinyal bilgilerinin doğru şekilde alınamaması
<b>KZFD</b>	Dalga biçimlerinin zaman içinde değişimindeki frekans ve faz bilgilerini belirleme, hareketli pencere kullanımı ile zaman ve frekans değişimi arasındaki ilişkiyi tanıma, değişmeyen sinyaller için iyi sonuçlar, basit uygulanabilirlik	Durağan olmayan sinyalin analizinde zorlanma, sınırlı zaman-frekans çözünürlüğü, GK olaylarını IEEE-1159 standardına göre kategorize etmede kesin olmayan zaman ve frekans bilgisi, sabit pencere genişliği zamanla değişen sinyal sınırlaması için yeterli olamama
<b>DD</b>	Sinyalin zaman ve frekans bilgisini aynı anda sunabilme, bant aralığının daha iyi ayarlanabilmesi, frekans alanında olduğu kadar zaman içinde de yerleştirme	Sinyal ayrışmasının artan seviyeleri nedeniyle yüksek hesaplama yükü, gürültülü ortamdan aşırı etkilenme, spektral sızıntı ve daraba etkilerinden kaynaklı düşük performans
<b>GD</b>	Doğru fazör tahmini, başarılı zaman-frekans bilgisi tespiti, yüksek sinyal-gürültü oranı, iyi zaman-frekans çözünürlüğü	Örnekleme frekansına bağlı hesaplama yükü ve hesaplama karmaşıklığı, Wigner dağılımı kaynaklı yanlış frekans bileşenlerini destekleyen kritik çapraz girişi, yüksek frekanslarda sınırlı kullanım

<b>SD</b>	Gelişmiş bir zaman ve frekans gösterimi, zaman eksenine göre sabit modülasyonlu sinüzoidlerin ölçeklenebilmesi, hareketli Gauss pencere özellikleri, GK olaylarının daha iyi tanınması, zaman alanından frekans alanına dönüştürülebilir olması, başarılı bir gerçek/hayali spektrum bileşeni zaman lokalizasyonu	Geniş frekans pencereleri, harmoniklerin uygun olmayan bir ölçümüne neden olan merkezi frekanslarıyla doğrudan ilişkili olması dolayısıyla pratik uygulamada uygun olmama, sabit Gauss penceresi nedeniyle sınırlı sinyal için uygunluk, diğer SİT'ler ile daha zıt işlem süresi, gerçek zamanlı uygulamalarda yetersizlik, yanlış harmonik tahmini
<b>KF</b>	Başarılı sinyal frekans, genlik ve harmonik içeriğinin değişimini tahmin, başarılı frekans, genlik ve harmonik değişim oranı tahmini, yüksek sinyal-gürültü oranı	Doğrusal olmayan durum gözlemi, kötü seçilmiş bazı başlangıç koşullarında sapma olasılığı, gürültülü ortamlarda sinyalin temel ve harmonik bileşenlerinin hatalı değerlendirilmesi, doğrusallaştırma ve hatalı parametreler, Jacobian matrislerinin pahalı hesaplamaları ve yaklaşık değerlerin önyargılı doğası, kararsızlığı nedeniyle temel ve harmonik bileşenlerin yanlış tahmini, hem zaman hem de frekans alanlarında ayırışma olmaması
<b>HHT</b>	Durağan olmayan ve doğrusal olmayan zaman serisi verilerinin analizi, faz ve büyüklük değerlendirme kolaylığı	Dar bant sinyallerinde farklı bileşenlerinde sınırlı ayırma, sadece dar banda uygulanabilirlik

## GÜÇ KALİTESİNDE YAPAY ZEKA SINIFLANDIRMA TEKNİKLERİ

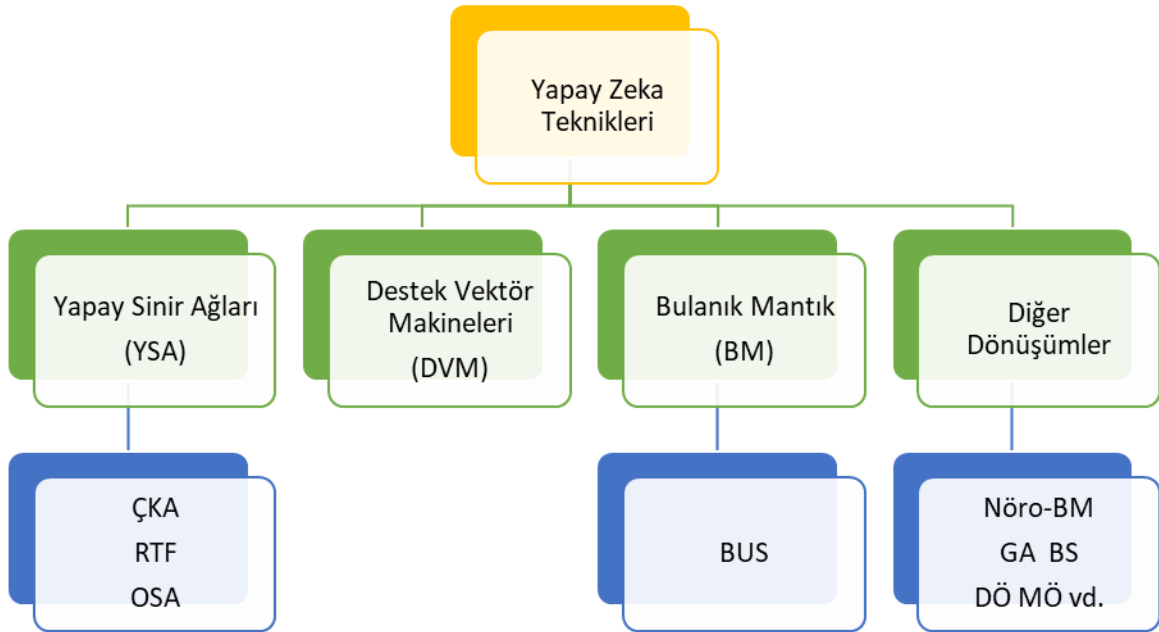
YZ, genel olarak karar verme, problem çözme, öğrenme, algılama ve akıl yürütme gibi insan düşüncesiyle ilişkili faaliyetlerin otomasyonu olarak tanımlanır. Öznitelik seçimi ve sınıflandırma yönteminin belirlenmesi, GKB'nin sınıflandırmasının önemli bir parçasıdır. Literatürde sınıflandırma sorununu çözmek için birçok yöntem sunulmuştur. Elektrik enerjisi topluluğunun ilgilendiği YZ araçları arasında Bulanık Mantık (Fuzzy Logic - BM), Uyarlanabilir Bulanık Mantık (Adaptive Fuzzy Logic ), Uzman Sistemler (Expert Systems - ES), YSA, Genetik Algoritmalar (Genetic Algorithm - GA), Makine Öğrenmesi (Machine Learning - MÖ) ve Derin Öğrenme (Deep Learning - DÖ) bulunur. YZ, MÖ ve DÖ kavramları akıllı uygulama yazılımlarında sıklıkla birbirlerinin yerine kullanılmaktadır. Fakat aralarında farklılıklar vardır. DÖ, MÖ'nün bir alt kümesidir. Şekil 3'te görüldüğü üzere, MÖ de akıllı uygulamalar yürüten YZ'nın alt kümesidir, yani tüm makine öğrenmesi uygulamaları YZ olarak sayılır (Aylak ve ark., 2021).





**Şekil 3.** Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme Kapsamı

MÖ, bilgisayarların açıkça programlanmadan, örnekler ve öğretilen verilerden yola çıkarak bilişsel işlemler yapmasına olanak veren algoritmalar olarak tanımlanabilir. DÖ, sayısı değişebilen gizli katmanlardan oluşan ve MÖ algoritmalarını kapsayan çalışma alanıdır. Karmaşık problemler için gözlem yapma, analiz etme ve karar verme noktalarında insan beyni gibi davranmayı hedefleyen makine öğrenmesi olarak da tanımlanabilir. GKB'lerin sınıflandırılmasında kullanılan YZ tabanlı sınıflandırma teknikleri Şekil 4' te verilmiştir (Khokhar ve ark., 2015). Bu sınıflandırıcılar, her bir olayı karakterize etmek için bir dizi farklı özellik veya parametre kullanır. Bu teknikler alt başlıklarda detaylı olarak açıklanmıştır.



**Şekil 4.** GKP'nin Sınıflandırılmasında kullanılan YZ teknikleri

## Yapay Sinir Ağları

Yapay sinir ağları, genel olarak insan beyninin ya da merkezi sinir sisteminin çalışma prensiplerini taklit eden bilgi işleme sistemidir. Bu konu üzerindeki çalışmalar ilk olarak beyni oluşturan biyolojik üniteler olan nöronların modellenmesi ve bilgisayar sistemlerinde uygulanması ile başlamıştır. Yapay sinir hücresi, biyolojik sinir hücresinin en basit halidir ve temel olarak giriş, ağırlık, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış bileşenlerinden oluşmaktadır (Çavuş ve Sarıkaya, 2021). Nöronlar bağlantılarla birbirine bağlanır ve her bağlantı, girdisinin gücünü veya diğer bir deyişle önemini ifade eden sayısal bir ağırlığa sahiptir. Ağırlıklar, YSA'lardaki uzun süreli belleğin temel aracıdır. Bir sinir ağında, bu ağırlıkların tekrar tekrar ayarlanması yoluyla öğrenme gerçekleşir (Lin ve ark., 2019). YSA'nın genelleme yeteneği ağın topolojinin doğru seçilmesi ile birebir ilişkilidir. Ağ için en uygun mimari, problemi öğrenmek için yeterince büyük, genelleme yapabilmek için ise bir o kadar küçük olmalıdır. En uygun mimariden daha küçük bir ağ problemi iyi öğrenemez diğer tarafından daha büyük bir ağ ise eğitim verisini aşırı öğrenir ki bu da ezberlemesine neden olduğundan genelleme yeteneği zayıf kalır. (Ayşe ve Berberler, 2017). Sinir Ağı (Neural Network – SA), temel doğrusal olmayan istatistiksel veri modelleme araçlarından biridir. Güç sistemi bozukluklarının istatistiksel tabanlı kategorizasyonu için hayati bir araçtır. Sinir ağlarını kullanarak sınıflandırma, yeterli veri mevcut olduğunda iyi bir alternatiftir. YSA'ler, örüntü tanıma, sınıflandırma, fonksiyon yaklaşımı, optimizasyon ve veri kümeleme gibi çeşitli uygulamalar için çok iyidir. Güç sistemi arızalarının sınıflandırılması için Çok Katmanlı Algılayıcı (Multi-Layer Perceptron- ÇKA), Radyal Temel Fonksiyon (Radial Basis Function - RTF) ve Olasılıklı Sinir Ağları (Probabilistic Neural Network - OSA) gibi çeşitli YSA varyantları kullanılır. ÇKA, bir dizi girdiden bir dizi çıktı üreten bir ileri beslemeli YSA sınıfıdır. ÇKA, sinyallerin matematiksel olarak ifade edilemediği durumlarda öğrenme ve sınıflandırma becerileri ile tanınmaktadır. Tersine, ÇKA'nin uygun bir mimari (gizli katman ve düğüm sayısı), zaman alıcı ve aşırı yavaş tanımlama gibi çeşitli sorunları vardır. Bir RBF, tek gizli katmanlı ileri beslemeli YSA kategorisidir. ÇKA tabanlı SA, genelleme yeteneği ve sağlamlık gibi geri yayılım ağlarıyla benzer özellikler gösterir. Ayrıca, hızlı öğrenme ve tahmin sırasında aykırı değerleri belirleme yeteneği gibi bazı ekstra üstünlükleri vardır. Bir OSA, radyal tabanlı fonksiyon ağlarının değiştirilmiş bir versiyonudur. Radyal temel katman ve rekabetçi katmandan oluşur. (Ghosh ve Lubkeman, 1995)'de yazarlar, güç sistemi bozulma dalga biçimlerinin sınıflandırılması için İBSA ve Zaman Gecikmeli Sinir Ağından oluşan (Time Delay Neural Networks- ZGSA) ki YSA paradigması yaklaşımı önermiş ve uygulamıştır. Lee ve Nam (1998), HFD, DDD ve ÇKA sinir ağına (ÇKA SA) dayalı hibrit bir GKB yaklaşımı önermişlerdir. Benzer şekilde, Monedero ve ark (2007), GK dalga formlarının gerçek zamanlı tespiti ve sınıflandırılması için üç gizli katmana sahip DD tabanlı bir ÇKA SA sunmuştur. Uyar ve ark. (2009), GK bozulmalarını sınıflandırmak için SD tabanlı girdi öznitelik vektörü üzerinde ÇKA SA'yi

uygulamıştır. Müdahaleci olmayan harmonik kaynak tanımlamasına YSA tabanlı yaklaşım (Srinivasan ve ark., 2005)'da önerilmiştir. (Silva ve ark., 2006)'de yazarlar, iletim hattı arıza tespiti ve osilografik verileri kullanarak sınıflandırma için dalgacık ve YSA'ye dayalı yeni bir yöntem önermişlerdir. Hem titreşim, harmonikler gibi düşük frekanslı bozuklukların hem de geçici ve sarkmalar gibi yüksek frekanslı bozulmaların tespiti ve tanımlanması için ayrık DD'ye dayalı bazı modeller incelenmiştir. Güç kalitesi bozukluklarını tanımak için dalgacık tabanlı bir yapay sinir ağı sınıflandırıcı uygulanmış ve (Chandel ve ark., 2008)'de test edilmiştir. Dalgacık tabanlı SA sınıflandırıcının yanı sıra GKB sınıflandırması için gerçek zamanlı veri tabanlı analiz (Monedero ve ark., 2007)'te sunulmuştur. GK olaylarının SD ve olasılıksal SA'ye dayalı sınıflandırması (Huang ve ark., 2015)'de sunulmuştur. (Camarena-Martinez ve ark., 2014)'te tek ve birleşik GK bozukluklarını tespit etmek ve sınıflandırmak için çift sinir ağı tabanlı bir metodoloji önerilmiştir. GK olaylarının tanınması ve sınıflandırılması için ÇKA SA (Jayasree ve ark., 2009)'da sunulmuştur. Gerilim dalga biçimi imzasının ortak varyans analizi (Gerek ve ark., 2006), gürültülü ve gürültülü olmayan ortamlı Modüler Sinir Ağı (Modular Neural Network) sınıflandırıcısı (Bhende ve ark., 2008), ÇKA ağı (Silva ve ark., 2017), geri yayılım tabanlı YSA (Khadse ve ark., 2016), GKB sınıflandırmasının daha iyi anlaşılması için SA yapısı (Valtierra-Rodriguez ve ark., 2014) ve DD donanım çerçevesi (Huang ve ark., 2015) rapor edilmiştir. Ayrıca, YSA, BM sistemi, GA ve Destek Vektör Makineleri (Support Vector Machine-D) gibi istatistikeldir. Kamu hizmeti şebekesine SPV penetrasyonunun neden olduğu çeşitli GKB'ler Kow ve ark., (2016) 'da tartışılmış ve MOSA, DVM ve LSDVM sınıflandırıcısı kullanılarak sınıflandırılmıştır (Ray ve ark., 2013).

### **Destek Vektör Makineleri**

Son yıllarda, sınıflandırma problemlerinin çözümü için geliştirilmiş en başarılı makine öğrenimi algoritmalarından biri DVM'dir. DVM, birçok sınıflandırma probleminin çözümünde başarıyla uygulanmış ve genelleme performansı yüksek ve etkin makine öğrenimi algoritmalarından biri olarak literatürdeki yerini almıştır. DVM'nin sınıflandırma doğruluğu, eğitim verilerine, çekirdek parametrelerine ve özellik seçimine bağlıdır. Birçok araştırmacı, sınıflandırma problemlerinin örüntü tanımını çözmeye yeteneği nedeniyle DVM'yi tercih etmiştir (Chawda ve ark., 2020). DVM'lerin en önemli avantajı, sınıflandırma problemini kareli optimizasyon problemine dönüştürüp çözmeye yatkındır. Böylece problemin çözümüne ilişkin öğrenme aşamasında işlem sayısı azalmakta ve diğer teknik/algoritmalara göre daha hızlı çözüme ulaşılmaktadır (Osowski, Siwekand ve Markiewicz, 2004). Teknik bu özelliğinden dolayı, özellikle büyük hacimli veri setlerinde büyük avantaj sağlamaktadır. Ayrıca optimizasyon temelli olduğundan sınıflandırma performansı, hesaplama karmaşıklığı ve kullanılabilirlik açısından diğer tekniklere göre daha başarılıdır (Nitze, Schulthess ve Asche, 2012). Birçok çalışmada DVM'nin uygulanması sürecinde çekirdek fonksiyonu seçimi için literatürdeki çalışmalar dikkate alınmış ve radyal tabanlı fonksiyonun kullanıldığı görülmüştür. Ancak

radyal tabanlı çekirdek fonksiyonun her alandaki problemin çözümü için uygun olup olmadığı bilgisi bulunmamaktadır. Çekirdek fonksiyonlarının performansı veri setlerine ve probleme göre değişkenlik gösterebilmektedir. DVM'nin doğrusal, polinom çekirdek fonksiyonlarını kullanma yeteneği (Ayhan ve Erdoğan, 2014) 'te tartışılmaktadır. (Biswal ve ark., 2013)'te, DVM ve gelişmiş bağışıklık algoritması kullanan optimizasyon, önemli olasılıkları tahmin etmek için en küçük kareler DVM tabanlı sınıflandırıcı kullanmıştır. (Son ve ark., 2016)'de standart bir IEEE-39 veri yolu sisteminde DVM tekniğine genel bir bakış ve gerçek dünya mühendislik problemlerinde uygulanabilirliği (Salcedo-Sanz ve ark., 2014)'de sunulmuştur. Solar-Fotovoltaik varlığında GKB'leri tanımlamak için çok sınıflı DVM mimarisi geliştirilmiştir (Prakash ve ark., 2020). (De Yong ve ark., 2015)'de, GK bozukluklarını sınıflandırmak için DD tabanlı çok sınıflı DVM önerilmiştir. (Janik ve Lobos, 2006)'ta yazarlar, özellik çıkarımı için üç fazlı voltaj sinyallerine uygulanan uzay fazör tekniğini ve sınıflandırma tekniği olarak DVM'yi kullanarak yeni bir GK bozulma tespiti tekniği önerdiler. Lin ve ark., (2008), karmaşık GKB'leri sınıflandırabilen çok sınıflı DVM'yi geliştirmek için doğrusal DVM ve bozulmalara karşı normal yaklaşımının bir kombinasyonunu uygulamışlardır. Erişti ve Demir, (2010), üç fazlı GKB sinyallerinin sınıflandırılması için dalgacık ve DVM tabanlı yeni bir otomatik sınıflandırma tekniği sunmuşlardır. Huang ve ark. (2012), dalgacık paket enerji entropisi ve ağırlıklı DVM kullanan otomatik bir GKB sınıflandırma tekniği önermiştir. Ayrıca, literatürde otomatik algılama ve sınıflandırmalar için DD ve DVM sınıflandırıcısına dayalı birkaç teknik daha sunulmuştur. (Hu ve ark., 2008; Biswal ve ark., 2013; Mishra ve ark., 2014). (Biswal ve ark., 2013), GK bozulmalarını sınıflandırmak için TT dönüşümüne dayalı özellik vektörüne çekirdek tabanlı bir DVM uygulamıştır. Öznitelik çıkarma için ayrı DD'yi, sınıflandırma işlemi için en küçük kareler DVM'yi (Least Squares Support Vector Machine – EKK-DVM) karşılaştıran etkili bir akıllı GK algılama tekniği (Erişti ve ark., 2013)'te verilmiştir. (Ozgonenel ve ark., 2013), karar verme birimi için radyal tabanlı ( $\sigma = 1$ ) çekirdek fonksiyonuna sahip DVM kullanılmış ve diğer sınıflandırıcılar arasında yüksek doğruluk sunmuştur. Pratik uygulamalar, önerilen hibrit algoritmanın güç kalitesi izleme yazılımında kullanılabileceğini göstermiştir. Çalışmada sunulan analiz ve sonuçlar, önerilen hibrit algoritmanın bozulmuş GK dalga formlarını sınıflandırmadaki potansiyel kapasitesini desteklemiştir.

### **Bulanık Mantık**

Bulanık sınıflandırma sistemi, dilsel değişken girdileri tarafından sağlanan bilgileri değerlendirmek için Mamdani tipi kurallara dayanmaktadır (Chacon ve ark., 2007). Bulanık mantık, insan bilgi tecrübelerinden yararlanarak, bunların kural tabanlı halinde işleyip her bir kural tabanının belirli bir matematik fonksiyona karşılık gelecek şekilde sonuç çıkarılmasıdır. Bulanık mantık temel amacı, insanların tam ve kesin olmayan bilgiler ışığında, tutarlı ve doğru kararlar vermelerini sağlayan, düşünme ve karar verme mekanizmalarının modellenmesidir. Temel olarak

mantık, olasılık, YZ, YSA alanları ile ilişkilidir. Bulanık sınıflandırma tekniğinde bir örnek, farklı değerlere veya derecelere sahip birçok farklı sınıfın üyesi olabilir. Genel olarak, belirli bir örnek için üyelik değerleri, belirli bir örnek için tüm üyelik değerlerinin toplamı 1'e eşit olacak şekilde sınırlandırılır. Bilgi tabanı, GK bozulmalarını analiz etmek için doğru üyelik fonksiyonunun seçiminde ve gerekirse yeni kuralların eklenmesinde uzmanlık gerektirir. Yeni bulanık C-ortalama kümeleme tabanlı algoritma, sınıflandırma süresini azaltır ve daha yüksek doğruluk sağlar (Sahu ve ark., 2017). Diğer Bulanık Uzman Sistem (Fuzzy Expert System - BUS) tabanlı sınıflandırma algoritmaları arasında bulanık akıl yürütme yaklaşımı (Zhu ve ark., 2004), Takagi-Sugeno bulanık mantık (Xiaosheng and Bo, 2015), değiştirilmiş bulanık minimum-maksimum kümeleme SA (Seera ve ark., 2015), temel bulanık mantık (Chawda ve Shaik, 2018), ve SD kullanılarak GK zaman serisi veri madenciliği için BUS sınıflandırıcı bulunur (Behera ve ark., 2010). GKB'lerin hızlı tanınması ve sınıflandırılması için sınıflandırma verimliliğini artırmak için özellik optimizasyonu için bulanık mantık tekniğine (Liu ve ark., 2016) dayalı bir dilsel model kullanılır. (Meher ve ark., 2010), dalgacıklar ve bulanık kümeler teorisini kullanarak GK parametrelerini ölçmek için bir aracın tasarımını önermişlerdir. Doğrusal bir KF ve bir bulanık-uzman sistem kullanarak GK olaylarını karakterize etmek için hibrit bir teknik (Abdelsalam ve ark., 2012)'de sunulmuştur. Bulanık mantık ve bir parçacık sürüsü optimizasyon algoritması kullanılarak tekli ve birleşik GK bozukluklarının tespiti ve sınıflandırılması için bir yaklaşım (Hooshmand ve Enshae, 2010)'de önerilmiştir. (iswal ve ark., 2012)'de yazarlar, karar ağacı ve kemo-taktik diferansiyel evrime dayalı bulanık kümeleme kullanarak GK verilerinin sınıflandırılması için bir yaklaşım sunmuştur. S-dönüşüm tabanlı BUS kullanan GK zaman serisi veri madenciliği için bir yaklaşım (Behera ve ark., 2010)'da sunulmuştur. (Biswal ve ark., 2009)'da yazarlar, çeşitli pencereleme teknikleri kullanarak çeşitli durağan olmayan güç sinyallerinin görsel lokalizasyonu, tespiti ve sınıflandırılması için bir yaklaşım sunmuştur. (Dash ve ark., 2003)'de, bir güç sisteminde geçici bozulma dalga formlarının sınıflandırılması için bir Fourier lineer birleştirici ve bir BUS kullanan bir hibrit şema sunulmaktadır. (Zhu ve ark., 2004)'de yazarlar dalgacık tabanlı genişletilmiş bulanık bir akıl yürütme önermişlerdir. Elektrik sistemlerinin anormal çalışmasının tespiti için uyarlanabilir bulanık kendi kendine öğrenme tekniği (İbrahim ve Morcos, 2005)'de sunulmuştur. Sunulan uyarlanabilir bulanık mantık kullanan güç dalgası formu için bir veri sıkıştırma tekniğidir. Ayrıca, literatür, hibrit BUS'in (BUS'in diğer sınıflandırıcılarla kombinasyonu), bireysel BUS ile karşılaştırıldığında mükemmel sonuçlar verdiğini ortaya koymaktadır (Chawda ve ark., 2020).

### **Diğer Sınıflandırma Teknikleri**

#### **Nöro-Bulanık Mantık**

Nöro-bulanık tabanlı yöntemler, her türlü bilgiyi işleme, kesin olmayan, kısmi ve belirsiz veya kusurlu bilgileri yönetme avantajlarına sahiptir. Bu yöntemlerin ayrıca iş birliği ve toplama, kendi

kendine öğrenme, kendi kendini organize etme ve kendi kendine ayarlama yetenekleriyle çatışmaları çözme avantajları vardır. Ayrıca, veri ilişkisi, insan karar verme sürecini taklit etme ve bulanık sayı işlemlerini kullanarak hızlı hesaplama hakkında önceden bilgi sahibi olmaya gerek yoktur (Ajil ve ark., 2010). Nöro-Bulanık Sistem (Neuro-Fuzzy System – NBS), veri örneklerini işleyerek ve sinir ağı teorisinden esinlenen bir öğrenme algoritması kullanarak bulanık kümeleri ve bulanık kuralları belirleyen bir bulanık sistemdir. Gelişmiş nöro-bulanık, benzersiz çok katmanlı ileri beslemeli sinir ağları olarak tasarlanan ANFIS, bulanık kural ağı ve GARIC'i sever. Bu NBS'de, aktivasyon fonksiyonları ve ağırlıkları standart SA tabanlı ara yüzden farklıdır ve bu ağ aynı zamanda sayısal, dilsel, mantıksal vb. bilgiler de sağlar. (Pires ve ark., 2011)'de yazarlar NBS tabanlı 3 boyutlu temel bileşen analizi (PCA) önerdiler. GKB'lerin otomatik sınıflandırılması için NBS kullanarak gelişmiş bir denetleyici güç sistemi kararlılık denetleyicisinin tasarımı (Sallama ve ark., 2014)'de sunulmuştur. 2000'den bugüne kadar tekli ve çoklu GKB'leri (Ferreira ve ark., 2015) sınıflandırmak ve NBS'lerin öğrenme algoritması, bulanık yöntemi ve yapısına göre sınıflandırılması için Emperyalist Rekabetçi Algoritma (Imperialist Competitive Algorithm) (Shihabudheen ve Pillai, 2018)'de açıklanmıştır. Ayrıca, rüzgar enerjisi kaynaklarının, değiştirilmiş ADALINE ve uyarlanabilir bir nöro-bulanık bilgi sistemi kullanan dağıtık nesil destekli ağlarda GKB sınıflandırması üzerindeki etkisi (Patnaik ve Dash, 2015)'de sunulmuştur. (Frenao ve ark., 2011)'de, 3 boyutlu uzay referans gösterimi, temel bileşen analizi ve nöro-bulanık tabanlı otomatik sınıflandırmayı birleştiren dört adımlı bir algoritmaya dayalı bir yaklaşım sunulmaktadır. Uyarlamalı-nöro-bulanık çıkarım sistemi yaklaşımı veya iletim hattı arıza sınıflandırması ve konumu (Reddy ve Mohanta, 2008; Reddy ve ark., 2008)'de sunulmuştur. Parçacık sürüsü optimizasyonu tabanlı uyarlanabilir nöro-bulanık sistem ile faz atlamaları ile voltaj düşüşlerinin azaltılması için bir yöntem (Siva ve ark., 2011)'de sunulmuştur.

### **Genetik Algoritma**

GA, doğal seçilim ve doğal genetiğin mekaniğine dayalı bir arama algoritmasıdır. Sicim yapıları arasında en uygun olanın hayatta kalmasını, insan aramasının bazı yenilikçi yetenekleriyle bir arama algoritması oluşturmak için yapılandırılmış ancak rastgele bir oluşum alışverişi ile birleştirir (Goldberg, 1989). GA, çok noktalı, olasılıklı, rastgele ve güdümlü bir arama mekanizması kullanan optimizasyon için mükemmel bir akıllı paradigma olarak kabul edilir (Levitin ve ark., 2000). (Kung ve ark., 1998)'de yazarlar, güç ve RMS voltajının ve GA kullanan akımın ölçülmesine yönelik yenilikçi ve bulanık tabanlı bir uyarlamalı yaklaşımı tanımlamışlardır. GA kullanan GK değerlendirme uygulamaları için güç sistemi modeli doğrulaması (El-Zonkoly, 2005)'de sunulmuştur. GA, güç sistemlerinin dinamik performansı nedeniyle oluşan güç sistemi bozulmalarını izlemek ve denetlemek için güçlü bir araç olarak tanıtılmıştır (El-Naggar ve Al-Hasawi, 2006)'da güç voltajı kontrol sistemlerini optimize etmek için hiyerarşik GA formatında bir atlama genleri paradigması önerilmiştir.

GK monitörlerinin yerleştirilmesi için geliştirilmiş GA kullanan yeni bir yöntem (Hong ve Chen, 2011)'te önerilmiştir. Genişletme GA ve DD dönüşümü kullanan bir analitik güç kalitesi yöntemi (Wang ve Tseng, 2011)'de sunulmuştur. (Sánchez ve ark., 2013)'te yazarlar, elektrik sinyallerindeki bozulmaların analizi ve sınıflandırılması için S-dönüşümünü optimize eden bir GA tasarımını tanımlamışlardır.

### **Bayes Sınıflandırıcı**

Bayes ağları, bir dereceye kadar belirsizliği çözmek için en etkili tekniklerden biridir. Bayes Sınıflandırıcısı (Bayesian Classifier- BS), çalışmada toplanan yeni bilgi ve kanıtları Bayes teoremi aracılığıyla toplamak ve birleştirmek için genel bir çıkarım mekanizması kullanır. Bu şekilde, BS, gözlemlenen gerçeklere ve BS yapısına göre bir dizi olay olasılığını günceller. (Luo ve ark., 2017)'de yazarlar, rahatsız edici sinyalleri ayırtmak için dalgacık kullandılar ve hata sinyaline ilişkin ölçeklendirilmiş sinyalin enerji içeriği ile ilgili öznelikler çıkarmışlardır. BS ayrıca sınıflandırma için bu enerji özelliklerini kullanır. Bu doğru sınıflandırma için OSA, BS (Mishra ve ark., 2008)'in yakınsaması için gerekli yeterli eğitim verilerini sağlar. GK bozulmalarının donanım açıklaması için BC ve DVM kombinasyonu (Gunal ve ark., 2009)'da tartışılmıştır. Naive-BS'de tekli ve çoklu GK olaylarının olasılık yoğunluk fonksiyonunun önceden tanımlanması gerekmesine rağmen, (Khan ve ark., 2015)'te farklı GK bozukluklarını sınıflandırmak için uygulanan sinyal paternlerinin tanımlanması için faydalıdır. BC ağlarının güneş termal, jeotermal, hidroelektrik enerjiler, rüzgar enerjisi ve biyokütle gibi yenilenebilir enerji kaynaklarında uygulanması (Borunda ve ark., 2016)'da açıklanmıştır.

### **Derin Öğrenme**

Son yıllarda Derin Öğrenme (Deep Learning- DÖ) algoritmaları üzerine yapılan araştırmalar araştırmacılar tarafından büyük ilgi görmektedir. Konuşma tanıma, insan yüzü tanıma, bilgisayarla görme, sinyal, görüntü ve bilgi işleme gibi çeşitli araştırma alanlarında etkin bir şekilde kullanılmıştır. DÖ algoritmaları, orijinal giriş sinyalinden en uygun özellikleri otomatik olarak öğrenme özelliğine sahiptir. Bu nedenle, bu teknikte diğer özellik mühendisliğinde öznelik çıkarma işlemi için harcanan zamandan kaçınılmıştır (Wang ve Chen, 2019). DÖ algoritmalarının otomatik güç sistemi arıza tespiti ve sınıflandırma yaklaşımlarına uygulanması önceki çalışmalarda çeşitli yazarlar tarafından çalışılmıştır. (Ma ve ark., 2017), otomatik GKB sınıflandırması için GK bozulma sinyallerinden gelişmiş özellikler çıkarmak için bir DÖ mimarisi olarak yığılanmış otomatik kodlayıcı (SAE) önermişlerdir. Ayrıca, GKB sınıflandırma sürecini desteklemek için sinyal varyansları ve bir Parçacık Sürü Optimizasyonu (Particle Swarm Optimization – PSO) algoritması kullanılmıştır. (Liu ve ark., 2018), tekil spektrum analizine, eğricik dönüşümüne ve derin evrişimli sinir ağlarına dayanan yeni bir GKB sınıflandırma yöntemi sunmuştur. (Bagheri ve ark., 2018)'de derin Evrişimli Sinir Ağları

(Convolutional Neural Networks- ESA), otomatik özellik çıkarma ve voltaj düşüşlerinin sınıflandırılması için kullanılır. DÖ algoritmalarının GK olaylarını tespit etme ve sınıflandırma yetkinliği (Mohan ve ark., 2017) tarafından incelenmiştir. (Liao ve ark., 2018)'de derin ESA kullanan derin öğrenme yöntemi, güç sisteminde seyrek olarak izlenen veri yollarında gerilim çökme büyüklüğü tahmini için önerilmiştir. Farklı DL araçlarının kullanılabilirliğini bilmek için, ESA, Tekrarlayan Sinir Ağı (Recurrent Neural Network-TSA), Uzun Kısa Süreli Bellek (Long Short-Term Memory UKSB), kapılı tekrarlayan birimler gibi çeşitli mimariler ele alınmıştır. (Balouji ve ark., 2018)'de, otomatik voltaj çökmesi tanıma için DÖ tabanlı bir yaklaşım sunulmuştur. (Deng ve ark., 2018)'da TSA'ların bir çeşidi olan güçlü bir UKSB mimarisi GKP analizi için kullanılmıştır. Bu mimaride bozulma sinyali önce gri ölçekli bir görüntüye dönüştürülür ve ardından özellikleri otomatik olarak öğrenmek için derin öğrenme modeli eğitilir. Son olarak, GKB sınıflandırılır. Derin öğrenme tabanlı yöntemlerin eksiklikleri, büyük ölçekli verilere bağımlı olmaları ve bunun için etkili ve ölçeklenebilir paralel algoritmalar ve yüksek hızlı grafik işlem birimi gerektiren yüksek bilgi işlem gücü gereksinimleridir (Deng ve ark., 2014)

### **Makine Öğrenmesi**

YZ ile MÖ anlam açısından benzerlikler gösterse de farklı kavramlardır. YZ, bilgisayarların insan zekasını taklit etmesini sağlamayı hedeflemektedir. MÖ ise kendisine sunulan veriler ve parametreler ile kendini eğitip insanların yapabileceğinden daha iyi çıkarımlar yapabilen sistemlerdir. MÖ yaklaşımlarının kullanımı, GK verilerinden otomatik izleme sistemleri oluşturmaya bir alternatif olarak ortaya çıkmaktadır. Böylece operatörler, arızalara yanıt veren nedenleri bulmak için acil veya orta vadeli eylemler gerçekleştirebileceklerdir (Valencia-Duque ve Orozco-Gutiérrez, 2019). (Khokhar ve ark., 2013)'de, GK olaylarının otomatik olarak tanımlanmasını amaçlayan bir makine öğrenimi metodolojisi önerilmiştir. Zaman ve frekans alanlarında istatistiksel parametreler, temsil alanını azaltmak için denetimli Relief algoritmasına dayalı bir özellik seçim algoritması kullanılmıştır. Sonuçlar, sınıflandırıcılarla oldukça yüksek doğruluk elde edildiğini göstermiştir. (Karasu ve Saraç, 2020)'de YZ yöntemlerinden ÇKA ve MÖ yöntemlerinden k-En Yakın Komşu (K-Nearest Neighbors) sınıflandırma yöntemi ile modeller oluşturulmuş, sentetik veriler ve deneysel düzenekten alınan veriler kullanılarak sınıflandırma başarımları ölçülmüştür. Farklı gürültülü durumlarda ve tekli, çoklu bozulmalar için de başarımlarının yüksek olduğu görülmüştür. (Elbouchikhi ve ark., 2021)'de spesifik olarak, bozulma karakterizasyonu için gelişmiş sinyal işleme ve MÖ yaklaşımlarını kullanarak GK izlemeye odaklanılmıştır. Güç sistemi izleme ve şebeke bozulma sınıflandırması amacıyla sinyal işleme yaklaşımları ve MÖ teknikleri ile ilgilenen araştırmacılar ve mühendisler için değerli bir rehber olarak kabul edilmiştir. Narduzzi ve ark. (2018), gürültünün performans üzerindeki etkisini araştırarak, GK olaylarının otomatik sınıflandırılması için dijital sinyal işleme ve MÖ tekniklerinin



kapsamlı bir incelemesini sunmuştur. (Mishra, 2019)'de, arıza tespiti için dijital sinyal işleme yöntemleri ve arıza sınıflandırması ve nedenlerin tanımlanması için MÖ hakkında kapsamlı bir inceleme sunulmuştur. Özellikle, yenilenebilir enerji sistemlerinde ve dağıtılmış jeneratörlerde güç elektroniği teknolojisinin kullanılmasının GK sorunları riskini artırdığı mikro şebeke uygulamaları düşünülmüştür. Khetarpal ve Tripathi (2020), güç kalitesi bozulma tespiti ve sınıflandırması alanında kullanılan sinyal işleme teknikleri ve makine öğrenimi yaklaşımlarını gözden geçirmiştir.

Yukarıda tartışılan tekniklerin dışında, ek sınıflandırma algoritmaları da GK izlemede önemli bir rol oynamıştır. Bu algoritmalar, güç kalitesi değerlendirmesindeki etkinlikleri açısından çeşitli kategori altında incelenir. Bunlar, uzman sistemin donanım ve yazılım mimarisini, kurula dayalı modeli (Rodriguez-Guerrero ve ark., 2018), geliştirilmiş genelleştirilmiş Uyarlanabilir Rezonans Teorisini (Adaptive Resonance Theory) (Yap ve ark., 2011), tekrarlama niceleme analizini (Moravej ve ark., 2011), kodlanmış en hızlı sınıflandırma ile stokastik sıralama teorisini (Lin ve ark., 2018) içerir. (Lin ve ark., 2019)'de GKB analizi için görüntü iyileştirmeye dayalı yeni bir teknik kullanılmıştır. GKB sinyalleri gri görüntülere dönüştürülür. Bu gri GKB görüntüler, kenar algılama, gama düzeltme ve tepe algılama yöntemleri kullanılarak geliştirilmiştir. Optimal özellikler, geliştirilmiş görüntülerden çıkarılır. Son olarak, görüntüler rastgele orman (RF) algoritması kullanılarak sınıflandırılır. (Chakravorti ve Dash, 2018)'de yazarlar, YSA'ya kıyasla hızlı öğrenme kabiliyetine ve daha iyi genelleme kabiliyetine sahip çekirdek fonksiyonu tabanlı Aşırı Öğrenme Makinesi (Extreme Learning Machines) tekniğini kullanmışlardır. (Das ve ark., 2018)'te, geleneksel GKB sınıflandırma teknikleri ile karşılaştırıldığında hesaplama Arındırılmış Dalgalanma Analizi (Detrended Fluctuation Analysis- ADA) kullanımıyla azaltılmıştır. ADA, sinyalin kendine yakınlığını kontrol etmek ve durağan olmayan bozuklukları tespit etmek için sinyalin otomatik korelasyon özelliklerini kullanır. (Rodriguez-Guerrero ve ark., 2017)'de, PSO ve GA'yı içeren hibrit yaklaşım kullanılarak çok çeşitli GK bozuklukları bulunmuştur. (Chen ve ark., 2019)'da çoklu GKB'nin sınıflandırılması için modifiye aşırı öğrenme makinesi tekniği kullanılmıştır. Bu teknik, bazı değişikliklerle iki katmanlı Aşırı Öğrenme Makinesini (Extreme Learning Machines - AÖM) önermektedir. AÖM temel olarak ileri beslemeli sinir ağıdır, ancak geleneksel sinir ağlarının aksine AÖM ile yüksek öğrenme hızı elde edilir. AÖM'de yüksek öğrenme hızının elde edilmesinin nedeni, gizli düğüm parametrelerine rastgele değerler atanması ve çıktı ağırlıklarının da en küçük kareler çözümü ile belirlenmesidir. Bu yöntemde, gizli düğümlere değer atamak için rastgele bir ayırt edici izdüşüm modeli önerilmiş ve genellenebilirliği geliştirmek için ikinci katmana radyal tabanlı fonksiyon çekirdeği eklenmiştir. Son olarak, optimum parametre seçimini sağlamak için PSO uygulanır. (Xiao ve Ai, 2019)'da elektrik şebekesi ve cihazlarda GK bozulmasını belirlemek ve tahmin etmek için Markov modelinin bir çeşidi kullanılmıştır. Yazarlar, rahatsızlıkları belirlerken hava koşullarını da dikkate almışlardır. Şebekeye bağlı dağıtılmış üretim

sistemdeki GK bozulmalarının varyasyonel mod ayrıştırması ve karar ağacı tabanlı algılama ve sınıflandırma yöntemi (Achlerkar ve ark., 2016)'da önerilmiştir. (Oubrahim ve ark., 2017)'de, model sırası seçimine dayalı olarak üç fazlı dengesiz dalga biçiminde şişme ve sarkmayı sınıflandırmak için yeni bir yöntem önerilmiştir. Bu yöntemde, maksimum olabilirlik ön sınıflandırıcı ve yaklaşık (Uygulama) ön sınıflandırıcı olarak bilinen iki yeni ön sınıflandırıcı türü önerilmiştir. Bu yöntem, MÖ tekniklerinden daha düşük hesaplama karmaşıklığına sahiptir. Bu yöntemde eğitim ve parametre ayarı yapılmadığı için eğitim veri tabanı da gerekli değildir.

## TARTIŞMA VE SONUÇ

Bu bölümde, güç kalite bozukluklarının tespiti ve sınıflandırması alanında mevcut olan literatürün kapsamlı bir incelemesini sunmuştur. Bu bağlamda, öncelikle güç kalite olaylarının türleri, neden-sonuç ilişkileri ve standartları incelenmiştir. Ardından bozulma sinyallerinden optimal özneliklerin çıkarılması için kullanılan sinyal işleme teknikleri tartışılmıştır. Bunların başlıcaları; Fourier Dönüşümü (FD), Hilbert-Huang Dönüşümü (HHD), S Dönüşümü (SD), Dalgacık Dönüşümü (DD) ve çeşitleri ile diğer dönüşüm yöntemleridir. Çıkarılan özelliklerin sınıflandırılmasında kullanılan Yapay Zeka (YZ) teknikleri incelenmiş, bozuklukları sınıflandırmak için kullanılan Yapay Sinir Ağı (YSA), Destek Vektör Makinesi (DVM), Nöro-Bulanık Mantık (Nöro-BM) teknikleri, Genetik Algoritma (GA) vb. gibi yapay zeka teknikleri tartışılmıştır. Bunların yanında, YZ tekniklerinin alt kümesi olan Makine Öğrenmesi (MÖ) ve Derin Öğrenme (DÖ) teknikleri de tartışılmıştır.

İncelemeden, GKB analizi alanında öznelik çıkarımı için yaygın olarak kullanılan tekniklerin DD, SD, HHD ve FD olduğu sonucuna varılabilir. Çıkarılan öznelikler aracılığıyla çeşitli bozulmaları analiz etmek için sınıflandırıcılar önemli bir rol oynar.

GK olaylarının sınıflandırması için YZ tabanlı sınıflandırma tekniklerinden YSA, DVM, BM, GA, PSO 'nun yaygın olarak kullanılan sınıflandırma teknikleri olduğu bulunmuştur. GKB analizi için DÖ'ye dayalı teknikler de popüler hale gelmektedir. Bu yöntemlerin başlıca üstünlükleri, olumsuzlukları ve etkinlikleri, araştırmacıların gerekli özel uygulama için belirli bir tekniği seçmelerine yardımcı olacak GK olay tespiti ve sınıflandırma alanındaki uygulamaları için de tartışılmıştır. Tablo 4, referans makalelerden alınan, yazarlar tarafından kullanılan GKB'nin sınıflandırılma algoritmalarının analizini özetlemektedir (Beniwal ve ark., 2021; Khetarpal ve Tripathi, 2020; Mishra, 2019; Yalçın, 2019). Tabloda yer alan çalışmalara ait veriler çoğunlukla sentetik veriler olup, yazarlar tarafından sistemi test etmek ve doğrulamak için kullanılmıştır. Gerçek sinyallere kıyasla sentetik sinyallerde sınıflandırma oranı genellikle yüksektir. Gürültünün varlığı sınıflandırma performansını etkiler. Sinyal-gürültü oranı daha düşükse, verimlilik de daha az olur. Hızlı yanıt elde etmek ve gürültü etkilerinden kurtulmak için çeşitli yazarlar tarafından formüle edilmiş algoritmalar tercih edilebilir.

Farklı yaklaşım türlerinin üstünlükleri ve sınırlamaları, kolay anlaşılması için tablo şeklinde karşılaştırılmıştır.

**Tablo 4-** GKB'lerin Belirlenmesi İçin Kullanılan YZ Tekniklerinin Analizi

Yöntem	Üstünlükleri	Olumsuzlukları
<b>NN</b>	Karışık PQ bozuklukları için yüksek sınıflandırma doğruluğu	Gürültülü koşullarda daha az verim
<b>YSA</b>	Gerçek zamanlı uygulamalar için yüksek doğruluk ve matematiksel esneklik	Minimize edilecek hata işlevi, ağ için seçilen mimariye, ağırlık uyarlama algoritmasına ve verilerdeki gürültü miktarına bağlı geç öğrenme, düşük yakınsama hızı, gürbüzlük ve duyarlık, yeni tür bozukluklara uyarlanamama
<b>BM</b>	Kurala bağlı BM kullanımı, karmaşık sistemlerin modellenmesi ve analiz edilmesinde karşılaşılan zorlukları azaltma, belirsizlikler ve karışıklıkların üstesinden gelmesine yardımcı olma, karmaşık sistemleri doğru modelleme ve analiz etme	Yeni tür bozukluklara göre uyarlanamama, varsayılan her durum için bir alıştırma kümesi kullanımı gerekliliği, her vaka için sabit eğitim seti, yeni tür bozukluklara uyarlanamama
<b>DVM</b>	Büyük özellikleri işleme potansiyeli, ikinci dereceden optimizasyon için kararlı çözüm, yüksek öğrenme süreçleri, yoğun öğrenme sürecine normalleştirilmiş yöntem sayesinde iyi bir genelleme, çok geniş ve özellikli alanlarda işlem olanağı	Eğitim örnekleri minimum olduğunda zayıf sınıflandırma doğruluğu, bu sistemler için hazırlık gerektiğinden hazırlık örnekleri yeterli olmadığı takdirde zayıf sınıflandırma duyarlık oranı
<b>GA</b>	Güç sisteminin dinamik performansı ve sönümlü alt harmonik sinyaller nedeniyle oluşan PQ bozulmalarını doğru bir şekilde sınıflandırma	Yüksek hesaplama süresi
<b>ES</b>	Sınırlı veri ile veya veri olmadan kullanılabilir olma	Pahalı sistem, yürütmede yavaş, varsayımlar ve gerçek durumların tam olarak eşleşememe durumunda sonuç çıkarmada zorlanma
<b>BS</b>	Gauss olasılık yoğunluk işlevlerinde iyi sonuç elde etme	Her olayın olasılık yoğunluk işlevini önceden bilinmesi gerekliliği, Çoğu koşulda kısıtlı veri örnek dizisi, yüksek hesaplama maliyeti, pratikte uygulanmalarını olanaksızlığı
<b>En Yakın Komşuluk</b>	Birleşik GK sorunları için iyi sınıflandırma doğruluk yüzdesi	Özellikle gürültülü koşullarda K-ortalama kümeleme yöntemine kıyasla daha az duyarlılık

**KAYNAKÇA**

- Abdelsalam, A. A., Eldesouky, A. A., & Sallam, A. A. (2012). Characterization of power quality disturbances using hybrid technique of linear Kalman filter and fuzzy-expert system. *Electric power systems Research*, 83(1), 41-50.
- Abdullah, A. R., Sha'ameri, A. Z., & Saad, N. M. (2007, December). Power quality analysis using spectrogram and gabor transformation. In *2007 Asia-Pacific Conference on Applied Electromagnetics* (pp. 1-5). IEEE.
- Achlerkar, P. D., Samantaray, S. R., & Manikandan, M. S. (2016). Variational mode decomposition and decision tree based detection and classification of power quality disturbances in grid-connected distributed generation system. *IEEE Transactions on Smart Grid*, 9(4), 3122-3132.
- Addison Paul, S. (2002). *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. Institute of Physics publishing.
- Agarwal, R. K., Hussain, I., & Singh, B. (2017). Application of LMS-based NN structure for power quality enhancement in a distribution network under abnormal conditions. *IEEE transactions on neural networks and learning systems*, 29(5), 1598-1607.
- Alshahrani, S., Abbod, M., & Taylor, G. (2016, September). Detection and classification of power quality disturbances based on Hilbert-Huang transform and feed forward neural networks. In *2016 51st international universities power engineering conference (UPEC)* (pp. 1-6). IEEE.
- Andreotti, A., Bracale, A., Caramia, P., & Carpinelli, G. (2008). Adaptive prony method for the calculation of power-quality indices in the presence of nonstationary disturbance waveforms. *IEEE Transactions on Power Delivery*, 24(2), 874-883.
- Ayhan, S., & Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- AYLAK, B. L., Okan, O. R. A. L., & YAZICI, K. Yapay Zeka ve Makine Öğrenmesi Tekniklerinin Lojistik Sektöründe Kullanımı. *El-Cezeri*, 8(1), 74-93.
- Ayşe, A. R. I., & Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, 1(2), 55-73.
- Beniwal, R. K., Saini, M. K., Nayyar, A., Qureshi, B., ve Aggarwal, A. (2021). A critical analysis of methodologies for detection and classification of power quality events in smart grid. *IEEE Access*, 9, 83507-83534.
- Bhende, C. N., Mishra, S., ve Panigrahi, B. K. (2008). Detection and classification of power quality disturbances using S-transform and modular neural network. *Electric power systems research*, 78(1), 122-128.
- Behera, H. S., Dash, P. K., & Biswal, B. J. A. S. C. (2010). Power quality time series data mining using S-transform and fuzzy expert system. *Applied SoFD Computing*, 10(3), 945-955.
- Biswal, B., Dash, P. K., & Panigrahi, B. K. (2008). Power quality disturbance classification using fuzzy C-means algorithm and adaptive particle swarm optimization. *IEEE Transactions on Industrial Electronics*, 56(1), 212-220.
- Dash, P. K., Mishra, S., Salama, M. A., & Liew, A. C. (2000). Classification of power system disturbances using a fuzzy expert system and a Fourier linear combiner. *IEEE Transactions on power Delivery*, 15(2), 472-477.
- Biswal, B., Dash, P. K., & Panigrahi, B. K. (2009). Non-stationary power signal processing for pattern recognition using HS-transform. *Applied SoFD Computing*, 9(1), 107-117.
- Biswal, B., Biswal, M. K., Dash, P. K., & Mishra, S. (2013). Power quality event characterization using support vector machine and optimization using advanced immune algorithm. *Neurocomputing*, 103, 75-86.
- Biswal, M., & Dash, P. K. (2013). Detection and characterization of multiple power quality disturbances with a fast S-transform and decision tree based classifier. *Digital Signal Processing*, 23(4), 1071-1083.
- Bollen, M. H., & Gu, I. Y. (2006). *Signal processing of power quality disturbances*. John Wiley ve Sons.
- Borunda, M., Jaramillo, O. A., Reyes, A., & Ibarquengoytia, P. H. (2016). Bayesian networks in renewable energy systems: A bibliographical survey. *Renewable and Sustainable Energy Reviews*, 62, 32-45.
- Balouji, E., Gu, I. Y., Bollen, M. H., Bagheri, A., & Nazari, M. (2018, May). A UKSB-based deep learning method with application to voltage dip classification. In *2018 18th International Conference on Harmonics and Quality of Power (ICHQP)* (pp. 1-5). IEEE.
- Bagheri, A., Gu, I. Y., Bollen, M. H., & Balouji, E. (2018). A robust transform-domain deep convolutional network for voltage dip classification. *IEEE Transactions on Power Delivery*, 33(6), 2794-2802.
- Camarena-Martinez, D., Valtierra-Rodriguez, M., Garcia-Perez, A., Osornio-Rios, R. A., & Romero-Troncoso, R. D. J. (2014). Empirical mode decomposition and neural networks on FPGA for fault diagnosis in induction motors. *The Scientific World Journal*, 2014.

- Chandel, A. K., Guleria, G., & Chandel, R. (2008, April). Classification of power quality problems using wavelet based artificial neural network. In 2008 IEEE/PES Transmission and Distribution Conference and Exposition (pp. 1-5). IEEE.
- Chacon, M. I., Duran, J. L., & Santiesteban, L. A. (2007, April). A wavelet-fuzzy logic based system to detect and identify electric power disturbances. In 2007 IEEE Symposium on Computational Intelligence in Image and Signal Processing (pp. 52-57). IEEE.
- Chawda, G. S., & Shaik, A. G. (2018, June). Fuzzy logic based control algorithm for dstatcom connected to weak ac grid. In 2018 2nd International Conference on Power, Energy and Environment: Towards Smart Technology (ICEPE) (pp. 1-6). IEEE.
- Chakravorti, T., & Dash, P. K. (2018). Multiclass power quality events classification using variational mode decomposition with fast reduced kernel extreme learning machine-based feature selection. *IET Science, Measurement ve Technology*, 12(1), 106-117.
- Chawda, G. S., Shaik, A. G., Shaik, M., Padmanaban, S., Holm-Nielsen, J. B., Mahela, O. P., & Kaliannan, P. (2020). Comprehensive review on detection and classification of power quality disturbances in utility grid with renewable energy penetration. *IEEE Access*, 8, 146807-146830.
- Chen, Z., & Urwin, P. (2001, September). Power quality detection and classification using digital filters. In 2001 IEEE Porto Power Tech Proceedings (Cat. No. 01EX502) (Vol. 1, pp. 6-pp). IEEE.
- Chilukuri, M. V., & Dash, P. K. (2004). Multiresolution S-transform-based fuzzy recognition system for power quality events. *IEEE Transactions on power delivery*, 19(1), 323-330.
- Cho, S. H., Jang, G., & Kwon, S. H. (2009). Time-frequency analysis of power-quality disturbances via the Gabor-Wigner transform. *IEEE transactions on power delivery*, 25(1), 494-499.
- Choong, F., Reaz, M. B. I., & Mohd-Yasin, F. (2005). Advances in signal processing and artificial intelligence technologies in the classification of power quality events: a survey. *Electric Power Components and Systems*, 33(12), 1333-1349.
- Çavuş, V., Sarıkaya, M (2021). Yapay Sinir Ağları ve Güneş Enerji Sistemlerinde Uygulamaları. Volkan ÇAVUŞ (Ed.), *Yapay Zeka Uygulamalarında Güncel Konular ve Araştırmalar içinde* (ss. 7-22). Konya, Çizgi Kitabevi Yayınları.
- Dash, P. K., Panigrahi, B. K., & Panda, G. (2003). Power quality analysis using S-transform. *IEEE transactions on power delivery*, 18(2), 406-411.
- Dash, P. K., & Chilukuri, M. V. (2004). Hybrid S-transform and Kalman filtering approach for detection and measurement of short duration disturbances in power networks. *IEEE Transactions on Instrumentation and Measurement*, 53(2), 588-596.
- De Yong, D., Bhowmik, S., & Magnago, F. (2015). An effective power quality classifier using wavelet transform and support vector machines. *Expert Systems with Applications*, 42(15-16), 6075-6081.
- Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends® in signal processing*, 7(3-4), 197-387.
- Deng, Y., Jia, H., Li, P., Tong, X., & Li, F. (2018). A deep learning method based on long short term memory and sliding time window for type recognition and time location of power quality disturbance. In 2018 Chinese Automation Congress (CAC) (pp. 1764-1768). IEEE.
- El-Zonkoly, A. M. (2005). Power system model validation for power quality assessment applications using genetic algorithm. *Expert Systems with Applications*, 29(4), 941-944.
- El-Naggar, K. M., & Al-Hasawi, W. M. (2006). A genetic based algorithm for measurement of power system disturbances. *Electric power systems research*, 76(9-10), 808-814
- Elbouchikhi, E., Zia, M. F., Benbouzid, M., & El Hani, S. (2021). Overview of signal processing and machine learning for smart grid condition monitoring. *Electronics*, 10(21), 2725.
- Erişti, H., & Demir, Y. (2010). A new algorithm for automatic classification of power quality events based on wavelet transform and DVM. *Expert systems with applications*, 37(6), 4094-4102.
- Erişti H, Yıldırım Ö, Erişti B, & Demir Y. (2013). Optimal feature selection for classification of the power quality events using wavelet transform and least squares support vector machines. *Int J Electr Power Energy Syst*, 49, 95-103.
- Ferreira, D. D., de Seixas, J. M., & Cerqueira, A. S. (2015). A method based on independent component analysis for single and multiple power quality disturbance classification. *Electric Power Systems Research*, 119, 425-431.
- Gerek, O. N., Ece, D. G., & Barkana, A. (2006). Covariance analysis of voltage waveform signature for power-quality event classification. *IEEE Transactions on Power Delivery*, 21(4), 2022-2031.

- Gaouda, A. M., Salama, M. M. A., Sultan, M. R., & Chikhani, A. Y. (1999). Power quality detection and classification using wavelet-multiresolution signal decomposition. *IEEE Transactions on power delivery*, 14(4), 1469-1476.
- Goldberg, D. E. (1989). *Genetic algorithm in search optimization and machine learning*. Addison Wesley.
- Gunal, S., Gerek, O. N., Ece, D. G., & Edizkan, R. (2009). The search for optimal feature set in power quality event classification. *Expert Systems with Applications*, 36(7), 10266-10273.
- Ghosh, A. K., ve Lubkeman, D. L. (1995). The classification of power system disturbance waveforms using a neural network approach. *IEEE Transactions on Power Delivery*, 10(1), 109-115.
- Girgis, A. A. ve Ham, F. M. (1980). A quantitative study of pitfalls in the HFD. *IEEE Transactions on Aerospace and Electronic Systems*, (4), 434-439.
- Gong, R., & Liao, G. (2020). An efficient and accurate method for detection and classification of power quality disturbances. *IEEE Transactions on Electrical and Electronic Engineering*, 15(8), 1139-1146.
- Gu, Y. H. ve Bollen, M. H. (2000). Time-frequency and time-scale domain analysis of voltage disturbances. *IEEE Transactions on Power Delivery*, 15(4), 1279-1284.
- Heydt, G. T., Fjeld, P. S., Liu, C. C., Pierce, D., Tu, L., & Hensley, G. (1999). Applications of the windowed HFD to electric power quality assessment. *IEEE Transactions on Power Delivery*, 14(4), 1411-1416.
- Hooshmand, R., & Enshae, A. J. E. P. S. R. (2010). Detection and classification of single and combined power quality disturbances using fuzzy systems oriented by particle swarm optimization algorithm. *Electric Power Systems Research*, 80(12), 1552-1561.
- Hong, Y. Y., & Chen, Y. Y. (2011). Placement of power quality monitors using enhanced genetic algorithm and wavelet transform. *IET Generation, Transmission ve Distribution*, 5(4), 461-466.
- Hu, G. S., Zhu, F. F., & Ren, Z. (2008). Power quality disturbance identification using wavelet packet energy entropy and weighted support vector machines. *Expert Systems with Applications*, 35(1-2), 143-149.
- Huang, N., Zhang, S., Cai, G., & Xu, D. (2015). Power quality disturbances recognition based on a multiresolution generalized S-transform and a PSO-improved decision tree. *Energies*, 8(1), 549-572.
- Huang, N., Xu, D., Liu, X., ve Lin, L. (2012). Power quality disturbances classification based on S-transform and probabilistic neural network. *Neurocomputing*, 98, 12-23.
- Huang, S. J., Huang, C. L., & Hsieh, C. T. (1996). Application of Gabor transform technique to supervise power system transient harmonics. *IEEE Proceedings-Generation, Transmission and Distribution*, 143(5), 461-466.
- Ibrahim, W. R. A., & Morcos, M. M. (2005). Novel data compression technique for power waveforms using adaptive fuzzy logic. *IEEE Transactions on power delivery*, 20(3), 2136-2143.
- IEC, E. (2003). 61000-4-30: Testing and measurement techniques—Power quality measurement methods. *Inter IEEE Std. 1159-2009 (Revision of IEEE Std. 1159-1995) Recommended Practice for Monitoring Electric Power Quality*, IEEE Std., 2009.
- Janik, P., & Lobos, T. (2006). Automated classification of power-quality disturbances using DVM and RBF networks. *IEEE Transactions on Power Delivery*, 21(3), 1663-1669.
- Jayasree, T., Devaraj, D., & Sukanesh, R. (2009). Power quality disturbance classification using S-transform and radial basis network. *Applied Artificial Intelligence*, 23(7), 680-693.
- Jurado, F., Acero, N., & Ogayar, B. (2002, May). Application of signal processing tools for power quality analysis. In *IEEE CCECE2002. Canadian Conference on Electrical and Computer Engineering. Conference Proceedings (Cat. No. 02CH37373) (Vol. 1, pp. 82-87)*. IEEE.
- KARASU, S., & SARAÇ, Z. (2020). Güç kalitesi bozulmalarının hilbert-huang dönüşümü, genetik algoritma ve yapay zeka/makine öğrenmesi yöntemleri ile sınıflandırılması. *Politeknik Dergisi*, 23(4), 1219-1229.
- Khadse, C. B., Chaudhari, M. A., & Borghate, V. B. (2016). Conjugate gradient back-propagation based artificial neural network for real time power quality assessment. *International Journal of Electrical Power ve Energy Systems*, 82, 197-206.
- Khan, M. R., Padhi, S. K., Sahu, B. N., & Behera, S. (2015, October). Non stationary signal analysis and classification using FDT transform and Naive Bayes classifier. In *2015 IEEE Power, Communication and Information Technology Conference (PCITC) (pp. 967-972)*. IEEE.
- Khetarpal, P., & Tripathi, M. M. (2020). A critical and comprehensive review on power quality disturbance detection and classification. *Sustainable Computing: Informatics and Systems*, 28, 100417
- Khokhar, S., Zin, A. M., Mokhtar, A. S., Ismail, N. M., & Zareen, N. (2013, December). Automatic classification of power quality disturbances: A review. In *2013 IEEE Student Conference on Research and Development (pp. 427-432)*. IEEE.

- Khokhar, S., Zin, A. A. B. M., Mokhtar, A. S. B. ve Pesaran, M. (2015). A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances. *Renewable and Sustainable Energy Reviews*, 51, 1650-1663.
- Kung, C. H., Devaney, M. J., Huang, C. M., & Kung, C. M. (1998). Fuzzy-based adaptive digital power metering using a genetic algorithm. *IEEE Transactions on Instrumentation and Measurement*, 47(1), 183-188.
- Kow, K. W., Wong, Y. W., Rajkumar, R. K., & Rajkumar, R. K. (2016). A review on performance of artificial intelligence and conventional method in mitigating PV grid-tied related power quality events. *Renewable and Sustainable Energy Reviews*, 56, 334-346.
- Lai, L., Chan, W. L., Tse, C. T., & So, A. T. P. (1999). Real-time frequency and harmonic evaluation using artificial neural networks. *IEEE Transactions on power delivery*, 14(1), 52-59.
- Lee, C. H., & Nam, S. W. (1998). Efficient feature vector extraction for automatic classification of power quality disturbances. *Electronics Letters*, 34(11), 1059-1061.
- Lin, W. M., Wu, C. H., Lin, C. H., & Cheng, F. S. (2008). Detection and classification of multiple power-quality disturbances with wavelet multiclass DVM. *IEEE transactions on power delivery*, 23(4), 2575-2582.
- Lin, L., Wang, D., Zhao, S., Chen, L., & Huang, N. (2019). Power quality disturbance feature selection and pattern recognition based on image enhancement techniques. *IEEE Access*, 7, 67889-67904.
- Lin, S. C., Liu, C. C., Hsieh, M. Y., Su, S. T., & Chung, W. H. (2018). Coded quickest classification with applications in bandwidth-efficient smart grid monitoring. *IEEE Transactions on Information Forensics and Security*, 13(12), 3122-3136.
- Liu, X., Liu, B., & Xu, D. (2016). Recognition and classification of power quality disturbances on the basis of pattern linguistic values. *Journal of Electrical Engineering and Technology*, 11(2), 309-319.
- Liu, H., Hussain, F., Shen, Y., Arif, S., Nazir, A., & Abubakar, M. (2018). Complex power quality disturbances classification via curvelet transform and deep learning. *Electric Power Systems Research*, 163, 1-9.
- Levitin, G., Kalyuzhny, A., Shenkman, A., & Chertkov, M. (2000). Optimal capacitor allocation in distribution systems using a genetic algorithm and a fast energy loss computation technique. *IEEE Transactions on Power Delivery*, 15(2), 623-628.
- Liao, H., Milanović, J. V., Rodrigues, M., & Shenfield, A. (2018). Voltage sag estimation in sparsely monitored power systems based on deep learning and system area mapping. *IEEE transactions on power delivery*, 33(6), 3162-3172.
- Luo, Y., Li, K., Li, Y., Cai, D., Zhao, C., & Meng, Q. (2017). Three-layer Bayesian network for classification of complex power quality disturbances. *IEEE Transactions on Industrial Informatics*, 14(9), 3997-4006.
- Meher, S. K., Pradhan, A. K. (2010). Fuzzy classifiers for power quality events analysis. *Electric power systems Research*, 80(1), 71-76.
- Mohan, N., Soman, K. P., & Vinayakumar, R. (2017, December). Deep power: Deep learning architectures for power quality disturbances classification. In 2017 international conference on technological advancements in power and energy (TAP Energy) (pp. 1-6). IEEE.
- Moravej, Z., Pazoki, M., & Abdoos, A. A. (2011). Wavelet transform and multi-class relevance vector machines based recognition and classification of power quality disturbances. *European transactions on electrical power*, 21(1), 212-222.
- Monedero, I., Leon, C., Roperro, J., Garcia, A., Elena, J. M., & Montano, J. C. (2007). Classification of electrical disturbances in real time using neural networks. *IEEE Transactions on Power Delivery*, 22(3), 1288-1296.
- Mishra, M. (2019). Power quality disturbance detection and classification using signal processing and soFD computing techniques: A comprehensive review. *International transactions on electrical energy systems*, 29(8), e12008.
- Nitze, I., Schulthess, U., & Asche, H. (2012). Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. *Proceedings of the 4th GEOBIA, Rio de Janeiro, Brazil*, 79, 3540.
- Nguyen, T., & Liao, Y. (2009). Power quality disturbance classification utilizing S-transform and binary feature matrix method. *Electric power systems research*, 79(4), 569-575.
- Narduzzi, C.; Bertocco, M.; Frigo, G.; Giorgi, G. (2018). Fast-TFM—Multifrequency phasor measurement for distribution networks. *IEEE Trans. Instrum. Meas*, 67, 1825–1835.
- Norman, C. F., Chan, J. Y., Lau, W. H., & Lai, L. L. (2012). Hybrid wavelet and Hilbert transform with frequency-shifting decomposition for power quality analysis. *IEEE Transactions on Instrumentation and Measurement*, 61(12), 3225-3233.

- Oubrahim, Z., Choqueuse, V., Amirat, Y., & Benbouzid, M. E. H. (2017). Disturbances classification based on a model order selection method for power quality monitoring. *IEEE Transactions on Industrial Electronics*, 64(12), 9421-9432.
- Ozgonenel, O., Yalcin, T., Guney, I., & Kurt, U. (2013). A new classification for power quality events in distribution systems. *Electric Power Systems Research*, 95, 192-199.
- Osowski, S., Siwek, K., & Markiewicz, T. (2004, June). ÇKA and DVM networks-a comparative study. In *Proceedings of the 6th Nordic Signal Processing Symposium, 2004. NORSIG 2004.* (pp. 37-40). IEEE.
- Patnaik, R. K., & Dash, P. K. (2015). Impact of wind farms on disturbance detection and classification in distributed generation using modified Adaline network and an adaptive neuro-fuzzy information system. *Applied SoFD Computing*, 30, 549-566.
- Pires, V. F., Amaral, T. G., & Martins, J. F. (2011). Power quality disturbances classification using the 3-D space representation and PCA based neuro-fuzzy approach. *Expert Systems with Applications*, 38(9), 11911-11917.
- Prakash, S., Purwar, S., & Mohanty, S. R. (2020). Adaptive detection of islanding and power quality disturbances in a grid-integrated photovoltaic system. *Arabian Journal for Science and Engineering*, 45(8), 6297-6310.
- Rodriguez-Guerrero, M. A., Jaen-Cuellar, A. Y., Carranza-Lopez-Padilla, R. D., Osornio-Rios, R. A., Herrera-Ruiz, G., & Romero-Troncoso, R. D. J. (2017). Hybrid approach based on GA and PSO for parameter estimation of a full power quality disturbance parameterized model. *IEEE Transactions on Industrial Informatics*, 14(3), 1016-1028.
- Reddy, M. J., & Mohanta, D. K. (2008). Adaptive-neuro-fuzzy inference system approach for transmission line fault classification and location incorporating effects of power swings. *IET generation, transmission and distribution*, 2(2), 235-244.
- Robertson, D. C., Camps, O. I., Mayer, J. S., & Gish, W. B. (1996). Wavelets and electromagnetic power system transients. *IEEE Transactions on Power Delivery*, 11(2), 1050-1058.
- Rodriguez, A., Ruiz, I. E., Aguado, J., Lopez, J. J., Martin, F. I., & Muñoz, F. (2011, May). Classification of power quality disturbances using S-transform and artificial neural networks. In *2011 International Conference on Power Engineering, Energy and Electrical Drives* (pp. 1-6). IEEE.
- Rodríguez, A., Aguado, J. A., Martín, F., López, J. J., Muñoz, F., & Ruiz, J. E. (2012). Rule-based classification of power quality disturbances using S-transform. *Electric power systems Research*, 86, 113-121.
- Sahu, G., Biswal, B., & Choubey, A. (2017). Non-stationary signal classification via modified fuzzy C-means algorithm and improved bacterial foraging algorithm. *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, 30(2), e2181.
- Sallama, A., Abbod, M., & Taylor, G. (2014, September). Supervisory Power System Stability Control using Neuro-fuzzy system and particle swarm optimization algorithm. In *2014 49th International Universities Power Engineering Conference (UPEC)* (pp. 1-6). IEEE.
- Sánchez, P., Montoya, F. G., Manzano-Agugliaro, F., & Gil, C. (2013). Genetic algorithm for S-transform optimisation in the analysis and classification of electrical signal perturbations. *Expert Systems with Applications*, 40(17), 6766-6777.
- Santoso, S., Powers, E. J., Grady, W. M., & Hofmann, P. (1996). Power quality assessment via wavelet transform analysis. *IEEE transactions on Power Delivery*, 11(2), 924-930.
- Seera, M., Lim, C. P., Loo, C. K., & Singh, H. (2015). A modified fuzzy min-max neural network for data clustering and its application to power quality monitoring. *Applied SoFD Computing*, 28, 19-29.
- Senroy, N., Suryanarayanan, S., & Ribeiro, P. F. (2007). An improved Hilbert-Huang method for analysis of time-varying waveforms in power quality. *IEEE Transactions on Power Systems*, 22(4), 1843-1850.
- Shihabudheen, K. V., & Pillai, G. N. (2018). Recent advances in neuro-fuzzy system: A survey. *Knowledge-Based Systems*, 152, 136-162.
- Shukla, S., Mishra, S., & Singh, B. (2009). Empirical-mode decomposition with Hilbert transform for power-quality assessment. *IEEE transactions on power delivery*, 24(4), 2159-2165.
- Silva, K. M., Souza, B. A., & Brito, N. S. (2006). Fault detection and classification in transmission lines based on wavelet transform and YSA. *IEEE Transactions on power delivery*, 21(4), 2058-2063.
- Silva, I. N. D., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & Reis Alves, S. F. D. (2017). Recognition of disturbances related to electric power quality using ÇKA networks. In *Artificial Neural Networks* (pp. 241-246). Springer, Cham.
- Soomro, A. H., Larik, A. S., Mahar, M. A., Sahito, A. A., Soomro, A. M. & Kaloi, G. S. (2021). Dynamic voltage restorer—A comprehensive review. *Energy Reports*, 7, 6786-6805.
- Srinivasan, D., Ng, W. S., & Liew, A. C. (2005). Neural-network-based signature recognition for harmonic source identification. *IEEE transactions on power delivery*, 21(1), 398-405.



- Standard E. European Standard EN 50160. Voltage characteristics of electricity supplied by public electricity networks. CENELEC. 2010.
- Stockwell, R. G., Mansinha, L., & Lowe, R. P. (1996). Localization of the complex spectrum: the S transform. *IEEE transactions on signal processing*, 44(4), 998-1001.
- Uyar, M., Yildirim, S., & Gencoglu, M. T. (2009). An expert system based on S-transform and neural network for automatic classification of power quality disturbances. *Expert Systems with Applications*, 36(3), 5962-5975.
- Valencia-Duque, A. F., Meza, A. Á., & Orozco-Gutiérrez, A. A. (2019). Automatic identification of power quality events using a machine learning approach. *Scientia Et Technica*, 24(2), 183-189.
- Wang, M. H., & Tseng, Y. F. (2011). A novel analytic method of power quality using extension genetic algorithm and wavelet transform. *Expert Systems with Applications*, 38(10), 12491-12496.
- Wang, S., & Chen, H. (2019). A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network. *Applied energy*, 235, 1126-1140.
- Xiao, X., Xu, F., & Yang, H. (2009). Short duration disturbance classifying based on S-transform maximum similarity. *International Journal of Electrical Power ve Energy Systems*, 31(7-8), 374-378.
- Xiaosheng, L., & Bo, L. (2015, September). Recognition of power quality disturbances based on TS fuzzy logic. In 2015 FiFDh International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCCC) (pp. 302-305). IEEE.
- YALÇIN, T., & ÖZDEMİR, M. Güç Kalite Bozukluklarında Örüntü Çıkarımı ve Tanısı için Bir Yaklaşım.
- Yeşilyurt, T. (2021). Yapay zeka yöntemleri kullanılarak elektrik tesislerinde güç kalitesi problemlerinin sınıflandırılması [Yayımlanmamış yüksek lisans tezi]. Konya Teknik Üniversitesi.
- Zhu, T. X., Tso, S. K., & Lo, K. L. (2004). Wavelet-based fuzzy reasoning approach to power-quality disturbance recognition. *IEEE Transactions on Power Delivery*, 19(4), 1928-1935.


# BÖLÜM

## 6

### İNSANSIZ HAVA ARAÇLARINDA GÖRÜNTÜ İŞLEME UYGULAMALARI


**Alperen Mehmet SEVİNÇ**

*Öğr. Gör., Türk Hava Kurumu Üniversitesi, Ankara Havacılık Meslek Yüksekokulu,  
Motorlu Araçlar ve Ulaştırma Teknolojileri Bölümü, Uçak Teknolojisi Programı msevinc@thk.edu.tr*

 0000-0001-5022-2961

**Çağrı Vakkas YILDIRIM**

*Doç. Dr., Erciyes Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Uçak Gövde ve Motor Bakımı  
Bölümü, cvyildirim@erciyes.edu.tr*


 0000-0002-0763-807X

## BÖLÜM 6

### İNSANSIZ HAVA ARAÇLARINDA GÖRÜNTÜ İŞLEME UYGULAMALARI


**Alperen Mehmet SEVİNÇ**

*Öğr. Gör., Türk Hava Kurumu Üniversitesi, Ankara Havacılık Meslek Yüksekokulu,  
Motorlu Araçlar ve Ulaştırma Teknolojileri Bölümü, Uçak Teknolojisi Programı msevinc@thk.edu.tr*

 0000-0001-5022-2961

**Çağrı Vakkas YILDIRIM**

*Doç. Dr., Erciyes Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Uçak Gövde ve Motor Bakımı Bölümü,  
cvyildirim@erciyes.edu.tr*

 0000-0002-0763-807X

#### 1. GİRİŞ

İnsansız hava araçları (İHA'lar), yerden bir pilot yardımıyla kontrol edilebilen hava araçlarıdır. Yerden kontrol edilmesi dolayısıyla insanlığa ve teknolojiye en büyük katkısı insan canı riskini ortadan kaldırmasıdır. İnsansız hava araçlarının hayatımıza ilk girişi, 1849 yılındaki Venedik savaşı sırasında Avusturya ordusunun 200 civarında yangın balonunun insansız hava araçları aracılığıyla havadan şehre atılmasıyla olmuştur (Koç., 2020). Gelişmekte olan teknoloji ile birlikte insansız hava araçları hayatımızdaki yerini gün geçtikçe genişletmektedir. Son yıllarda, düşük ağırlıklı yüksek mukavemetli malzemeler, çok yönlü sensörler, minyatür tahrik sistemleri, taşınabilir güçlü bilgi işlem sistemleri ve mikroelektronikler sayesinde insansız hava araçları, tarımsal ilaçlama, çevresel izleme, hassas tarım, endüstriyel denetim, elektrik hattı ve telekomünikasyon kulesi denetimi, hava kargoculuğu, tıp, gözetim ve keşif faaliyetleri gibi çeşitli sektörlerde önem kazanmaktadır (Sankarasrinivasan ve ark., 2015). Son dönemde insansız hava araçlarının kullanılmasında görüntü işleme ile veri analizi yapmak oldukça popüler hale gelmiştir.

Görüntü işleme, geliştirilmiş bir görüntüyü veya bu geliştirilmiş görüntünün yararlı bilgilerini elde etmek için bir görüntünün üzerinde ilgili uygulamaları gerçekleştirme sürecidir. Girdinin bir görüntü dosyası olduğu ve çıkışın bu görüntü veya bu görüntüyle benzer özellikleri olabileceği bir sinyal işleme türüdür. Günümüzde görüntü işleme hızla gelişen teknolojiler arasında yer almaktadır. Mühendislik ve bilgisayar bilimi disiplinlerinde de çekirdek araştırma alanını oluşturur. Görüntü işleme temelde aşağıdaki üç adımı içerir:

- Görüntü elde edip görüntüyü içe aktarma;
- Görüntüyü analiz ve manipüle etme;
- Sonuç olarak, görüntü analizine bağlı şekilde görüntü veya raporun değiştirilebileceği çıktıdır (Univercity of Tartu, 2014).

Uzun yıllardır hayatımızı kolaylaştıran görüntü işleme teknolojisinin temel teknikleri Image Segmentation, Classification, Image Restoration, Image Compression, Image Enhancement'tir. Son yıllarda, en yaygın kullanılan teknikleri yapay zeka, derin öğrenme ve makine öğrenmesidir. Bu yapay zeka, derin öğrenme ve makine öğrenmesi tekniklerinin yaygın olarak kullanılan algoritmaları ve yöntemleri ise CNN, RNN, Faster R-CNN, FCN, YOLO, MIR, Lucas-Kanade Optical Flow, Inception v3, DenseNet 121, Resnet 50, Xception, AlexNet, GoogLeNet, ResNet, MobileNet, EfficientNet, VGG, VggNet, LeNet, ODC, ABC, GAN, ACF, LSD, DCP, SGD, ACO, Meta-Heuristic, Genetic, ANN vb. olarak bilinmektedir.

Bilim ve teknoloji alanında önemli bir yere sahip olan ve gelecekte çok fazla alana evrileceği düşünülen insansız hava aracı ve görüntü işlemenin günümüzde beraber olarak kullanıldığı yaygın alanlar ise askeri hava savunma ve askeri hava saldırı, tarım, fotogrametrik, topografya, nesne tespiti, tren yolu çatlak tespiti, köprü çatlak tespiti, bina hasar tespiti, keşif, arama-kurtarma, otonom iniş olarak söylenebilir. Bu çalışmada, insansız hava araçları, görüntü işleme ve bunların beraber kullanıldığı uygulamalar üzerinde bir derleme yapılmıştır. İlgili bilgiler aşağıda bölümler halinde verilmiştir.

## 2. İNSANSIZ HAVA ARAÇLARI

Drone olarak da bilinen insansız hava araçları (İHA'lar), çeşitli operasyonlarda gelişmiş stabilite ve dayanıklılıkları nedeniyle askeri ve sivil hizmetlerin farklı disiplinlerinde çok önemli bir ilgi ve rağbet görmüştür. İnsansız hava araçlarının uygulamaları, nesnelere interneti (IoT), 5G ve B5G'deki gelişmiş kullanımları nedeniyle olağanüstü bir şekilde genişlemektedir. İnsansız hava araçları, son on yılda nesne algılama ve izleme, kamu güvenliği, trafik gözetimi, askeri operasyonlar, gizli veya tehlikeli alanların keşfi, iç veya dış mekan navigasyonu, atmosferik algılama, afet sonrası operasyonlar, sağlık, veri paylaşımı, altyapı yönetimi, acil durum ve kriz yönetimi, yük taşımacılığı, orman yangını izleme ve lojistik dahil olmak üzere çeşitli uygulamalarda kullanılmıştır (Hassija ve ark., 2019).

İnsansız hava araçları azami kalkış ağırlıklarına göre Sivil Havacılık Genel Müdürlüğüne 4 gruba ayrılırlar. Bu dört farklı insansız hava aracı kategorisi, Tablo 1'de gösterildiği gibi İHA0, İHA1, İHA2 ve İHA3 olmak üzere sınıflandırılmıştır (SHGM, 2013).

**Tablo 1.** Azami kalkış ağırlığına göre insansız hava araçlarının sınıflandırılması

Türü	Azami Kalkış Ağırlığı
İHA0	500 gr (dahil) – 4 kg
İHA1	4 kg (dahil) – 25 kg
İHA2	25 kg (dahil) – 150 kg
İHA3	150 kg (dahil) ve üzeri ağırlıkta olan insansız hava araçları

(SHGM, 2013). Piyasada insansız hava araçları farklı sayıda rotor veya pervane ile bulunmaktadır. İnsansız hava araçları aynı zamanda farklı motor ve kanat yapıları ile geliştirilmiştir. Motor ve kanat tipine göre dört farklı insansız hava aracı kategorisi, Tablo 2'te gösterildiği gibi Octocopter, Hexacopter, Quadcopter ve Tricopter olmak üzere sınıflandırılmıştır. İnsansız hava araçları hem kısa hem de uzun menzilli kablosuz teknolojileri kullanarak haberleşebilir ve boyutları nano, mikro veya large olarak sınıflandırılabilir (Mohsan ve ark., 2022).

**Tablo 2.** Pervane sayısına göre insansız hava araçlarının sınıflandırılması.


İHA Türleri	Pervane Sayısı
Octocopter	8
Hexacopter	6
Quadcopter	4
Tricopter	3

Mohsan ve ark. kanat ve rotor tipine göre dört farklı insansız hava aracı kategorisini sabit kanatlı, sabit kanatlı hibrit, tek rotorlu ve çok rotorlu olmak üzere sınıflandırılmıştır (Tablo 3) (Mohsan ve ark., 2022).

**Tablo 3.** Kanat ve rotor tipine göre insansız hava araçlarının sınıflandırılması

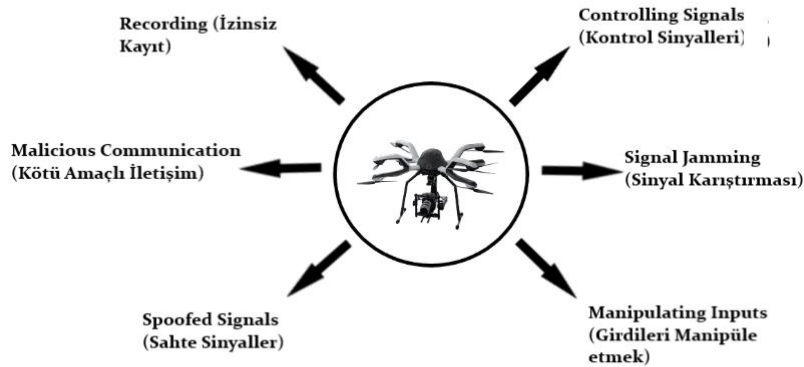
İHA Türleri	Ana Özellikleri
Sabit Kanat	Yüksek hız, uzun süre seyir
Sabit Kanat Hibrit	Uzun süre seyir, dikey kalkış ve iniş
Tek Rotorlu	Uzun süre seyir, dikey kalkış ve iniş, havada sabit kalma
Çok Rotorlu	Kısa süre seyir, dikey kalkış ve iniş, havada sabit kalma

İnsansız hava araçları kullanım alanlarına göre tercih edilen kanat ve rotor tipleri değişmektedir. Şekil 1a'da sabit kanat bir insansız hava aracı görülmektedir. Bu insansız hava araçları güç hattı incelemeleri ve havadan haritalama için yaygın olarak kullanılır. Şekil 1b, sabit kanatlı hibrit insansız hava aracı göstermektedir. Bu insansız hava araçları ileri uçuşta ve havada asılı durmada kullanışlı değildir. Şekil 1c, tek rotorlu bir insansız hava aracı örneğini göstermektedir. Tek rotorlu insansız hava aracı pahalıdır ve operasyon için beceri eğitimi gerektirir. Şekil 1d, çok rotorlu insansız hava aracı gösterilmiştir. Şekilde 1d'de olduğu gibi heksakopter veya trikoopter, quadcopter, oktokoopter olabilir.



Şekil 1. Kanat ve rotor tipine göre sınıflandırılmış insansız hava araçları

Teknolojinin ilerlemesi ile günümüz dünyası bir dizi çığır açan gelişmelere şahit olmuştur. Bu gelişmelerin günlük hayatımızda daha güvenilir, ulaşılabilir ve ekonomik olduğu kanıtlanmıştır. Bununla birlikte, insanlar artık sosyal çevrelerinde sportif havacılık gibi yeni yollarla birbirleriyle etkileşime girmektedirler. Ek olarak, insansız hava araçları, askeri bağlamda yoğun olarak kullanılmasının yanı sıra hem ticari hem de özel amaçlar için kullanılmaktadır. Ancak her teknolojiye ve gelişmeye olduğu gibi insansız hava araçları da olumlu gelişmeleriyle beraber bazı problemleri de birlikte getirmiştir. Bu problemlerin başlıcasıysa güvenlik ve kontrol modülü oluşturmaktır. Son yıllarda olumlu gelişmeler gerçekleşmiş olsa da insansız hava araçları için tamamen kusursuz bir güvenlik kontrol modülü oluşturmak hala mümkün görünmemektedir. Şekil 2'de insansız hava araçlarının güvenlik ve gizlilik tehditleri gösterilmiştir (Abro ve ark.,2022).



Şekil 2. İnsansız hava araçları güvenlik ve gizlilik tehditleri

İnsansız hava araçları hem sivil hem de askerî açıdan pek çok faydası olduğu için büyük bir öneme sahiptir ve kullanımını giderek artmaktadır. Ancak, kullarındaki bu ciddi artışla birlikte önemli ölçüde gizlilik ve güvenlik endişeleri de ortaya çıkmaktadır. Örneğin; insansız hava araçları terör saldırıları için kullanılabilir. İnsansız hava araçlarının herhangi bir terör saldırısında seçilmesinin en büyük nedeni, kolayca temin edilebilmeleri ve maliyetinin ucuz olmasıdır (Abro ve ark.,2022).

### **3. GÖRÜNTÜ İŞLEME**

Görüntü işleme, bir görüntüyü dijital bir forma dönüştürme ve ondan bazı yararlı bilgiler elde etmek için belirli adımları gerçekleştirme işlemidir. Görüntü işleme sistemi, önceden belirlenmiş belirli sinyal işleme yöntemlerini uygularken genellikle tüm görüntüleri 2B sinyaller olarak ele alır. Temelde 2 çeşit görüntü işleme vardır. Bunlar analog ve dijital görüntü işlemedir. Çıktılar ve fotoğraflar gibi basılı kopyalar için analog teknikler kullanılarak görüntü işleme yapılabilir. Bilgisayar aracılığıyla dijital görüntülerin dijital teknikler kullanılarak görüntü işleme yapılabilir. Günümüzde görüntü işleme denildiği zaman dijital görüntü işleme kastedilmektedir.

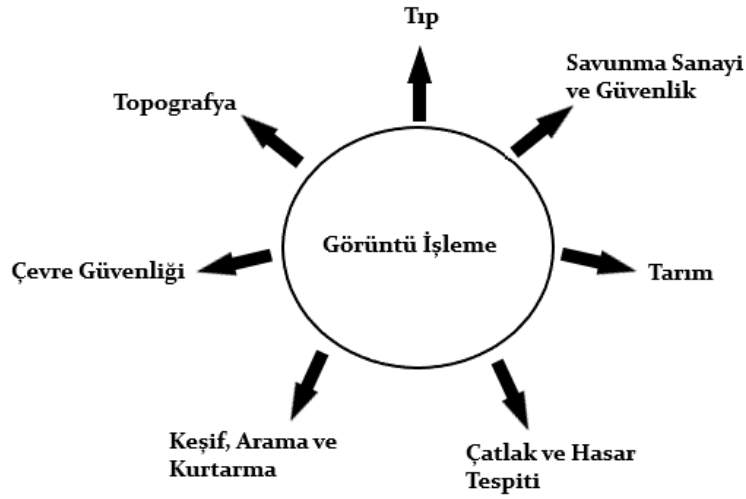
#### **3.1. Görüntü İşlemenin Amacı**

Görüntü işlemenin amacı görüntü kalitesini arttırmak, iyileştirme yapmak, gürültülerden arındırmak, bir kısmı görünmeyen görsellerin görünmesini sağlamak, çözünürlüğü yükseltmek, şekil veya nesne tanımak ve tespit etmektir. Sonuç olarak görüntü işlemenin amacı 5 ana gruba ayrılır:

- I. Halüsinasyon
- II. Görüntü restorasyonu ve keskinleştirme
- III. Görüntüye yeniden sahip olma
- IV. Desen ölçümü
- V. Görüntü onayı (Basavaprasad ve ark., 2014).

#### **3.2. Görüntü İşlemenin Kullanım Alanları**

Görüntü işlemenin kullanım alanı oldukça geniştir. Fonksiyonel ve kullanışlı yapısı sayesinde teknoloji ve bilim dünyasında sıklıkla karşımıza çıkmaktadır. Bunlar tıp, topografya, çevre güvenliği, keşif arama-kurtarma, çatlak ve hasar tespiti, tarım, savunma sanayi ve güvenlik olarak söylenilebilir. Şekil 3'te kullanım alanları verilmiştir.



**Şekil 3.** Görüntü işleme kullanım alanları

### 3.2.1. Tıp

Görüntü işlemenin en yaygın kullanıldığı alanlardan birisi tıptır. Görüntü işleme ile birçok hastalığın erken teşhisi kolaylaşmaktadır. Manyetik rezonans, laboratuvar, nükleer tıp, ultrason, göğüs kanseri teşhisi, tümör tespiti, tomografi, röntgen ve son yıllarda ortaya çıkan korona virüsün tespiti için de kullanılmaktadır. Kullanım kolaylığı ve yüksek doğrulukta tahmin yaptığı için tıp alanında kullanımı giderek artmaktadır (Bhattacharya ve ark., 2021).

### 3.2.2. Savunma Sanayi ve Güvenlik

Görüntü işleme kompleks kullanımı sayesinde savunma teknolojilerinde de sıkça kullanılmaktadır. İnsan, araç, nesne vb.nin hedefe konularak takibi, tespiti veya izlenmesi için sıkça kullanılmaktadır. Görüntü işleme insan yüzü tespitinde oldukça başarılıdır (Kumar ve ark., 2019). Ayrıca, izinsiz veya kötü niyetli drone kullanımını tespit ve takip etmek için de kullanılmaktadır (Schuman ve ark., 2018).

### 3.2.3. Tarım

Görüntü işlemenin insansız hava aracı ile kullanımda en popüler olduğu alanların başında tarım gelmektedir. Tarımsal ilaçlama, haşere tespiti, tarla verim hesabı, yabancı ot tespiti, mahsul sayımı, ürün sınıflandırması, çürük ve kuru ürün tespiti gibi işlemler tüm tarım mahsullerinde yaygın olarak kullanılmaktadır.

### 3.2.4. Çatlak ve Hasar Tespiti

Görüntü işleme sayesinde birçok hasar ve çatlak hızlı ve kolayca tespit edilmektedir. Sivil binalar, asfalt, yol, tren rayı, köprü, madencilik, iş makineleri alanlarında insansız hava aracı yardımıyla çatlak ve hasar tespitinde kullanılmaktadır. İnsansız hava aracı yardımıyla çatlak tespiti hızlı ve ekonomik olarak yapılmaktadır. Sonuç olarak maliyeti düşük bir şekilde ve hızlıca büyük bir felaketin önüne geçilebilmektedir (Mahon ve Poobal, 2018).



### 3.2.5. Keşif, Arama ve Kurtarma

Görüntü işleme teknolojisi sivil veya askeri personelin keşif, arama ve kurtarma alanında da kullanılmaktadır. İnsansız hava araçları sayesinde görüntü işleme teknolojisi ormanlık alanda kaybolan insanlar veya askeri operasyonlarda yaralanan askeri personellerin bulunmasında yardımcı olmaktadır (Linh ve Tuyen, 2022). Yaralı askeri personelin bulunmasında ve yaralıya müdahalenin hızlandırılmasında fayda sağlamaktadır. Ayrıca yaralı askeri personel aranırken diğer personellerin can güvenliğinin tehlikeye atılmasını önlemektedir.

### 3.2.6. Çevre Güvenliği

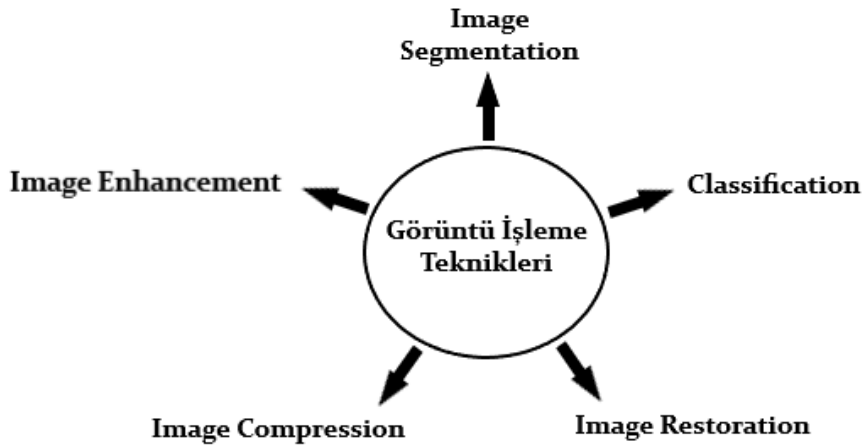
Görüntü işleme çevre temizliği için de kullanılmaktadır. Küresel bir sorun haline gelen çevre kirliliğini engellemek için sosyal projeler ve çalışmalar yapılmaktadır. Çevre kirliliğini önlemek, bölgesel olarak çevre kirliliği oranını tespit etmek için kullanılan yöntemlerden birisiyse görüntü işlemedir (Vaseashta ve ark., 2007).

### 3.2.7. Topografya

Topografya, arazi yüzeyinin incelenmesi bilimidir. Özellikle, bir peyzajın temelini oluşturur. Örneğin topografya, yüzeydeki dağları, vadileri, nehirleri veya kraterleri ifade eder. Topografyanın çıkarılmasında uydudan veya insansız hava araçlarından alınan görüntülerin kullanımı oldukça yaygındır (James ve Robson, 2014).

## 3.3. Görüntü İşleme Teknikleri

Bir görüntü işlenirken yapılması hedeflenen işleme göre farklı görüntü işleme yöntemleri uygulanmaktadır. Amacına göre kullanılan görüntü işleme teknikleri Image Segmentation, Classification, Image Restoration, Image Compression, Image Enhancement'tir. Şekil 4'te verilmiştir.



Şekil 4. Görüntü İşleme Teknikleri

### 3.3.1. Image Segmentation

Bir görüntüyü bileşen bölgelerine veya nesnelere bölme işlemi bir görüntünün temsilini, bir görüntünün ilgilenilen bölgesi hakkında daha fazla bilgi almak için analiz edilmesi daha kolay bir şeye dönüştürmek için ek açıklamaya yardımcı olan nesne sahnesine görüntü segmentasyonu denir. Segmentasyon, görüntü işlemenin en zor adımlarından biridir. Bir görüntüyü oluşturan parçalara veya nesnelere ayırmayı içerir. Görüntünün içeriğini dikkatlice tanımlamak için görüntü segmentasyonuna ihtiyaç vardır. Bu bağlamda kenar algılama, görüntü segmentasyonu için temel bir araçtır. Görüntü segmentasyonu için çeşitli genel amaçlı algoritmalar ve teknikler geliştirilmiştir (Kuruvilla ve ark., 2016).

Segmentasyon şu şekilde sınıflandırılabilir:

- Region Based
- Edge Based
- Threshold
- Feature Based Clustering
- Model Based (Kuruvilla ve ark., 2016).

#### 3.3.1.1. Region Based

Bu teknik, segmentasyon için kullanılan seçili nesnelere bir araya toplar. Bu yöntemle kullanılan bölge bazlı segmentasyon tekniğidir. Similarity based segmentasyon olarak da bilinir. Sınırlar, segmentasyon yapmak için tanınır. Her adım, işlemek asgari bir piksel alır. Proses uygulandıktan sonra görüntünün rengi ve dokusu değiştirilir ve daha sonra kenar akışından bir vektör oluşturulur. Daha sonra bu kenarlara daha fazla işlem uygulanır (Ma ve Manjunath, 1997).

#### 3.3.1.2. Edge Based

Görüntü segmentasyon algoritmaları genellikle süreksiz yoğunluk değerlerine ve benzer yoğunluk değerlerine dayanır. Süreksiz yoğunluk değerleri durumunda, yaklaşım, görüntüyü, görüntüdeki kenarlar gibi, yoğunluktaki ani değişikliklere dayalı olarak bölmektir. Edge Detection dayalı segmentasyon, görüntünün yoğunluk veya parlaklık değerinde ani bir değişikliğin olduğu sınırları ifade eder. Segmentasyon işlemi kenarlar tarafından da gerçekleştirilebilir. Kenarlar birbirine kapalı olmadığından kenarlar arasında boşluklar vardır. Dolayısıyla, kenarlarının algılanmasıyla, nesne görüntüden bölümlere ayrılabilir. Edge Detection algoritması uygulanarak alınan çıktı ikili bir görüntüdür. Kenar algılamada üç temel adım vardır (Kuruvilla ve ark., 2016). Bunlar:

- Filtering&Enhancement
- Detection of Edge Points
- Edge Localization.

### **3.3.1.3. Threshold**

Threshold yoluyla görüntü segmentasyonu, gölgeli arka plan üzerinde hafif nesnelere bulunan görüntüleri bölmek için basit ve güçlü bir tekniktir. Threshold işlemi, uygun bir eşik T seçerek çok seviyeli bir görüntüyü ikili bir görüntüye dönüştürerek nesnelere ayırmasını yapar. Histogramın değeri, kenarların tespiti ile hesaplanır. Bu nedenle, eşik değeri ancak kenarların tespiti doğruysa doğrudur. Eşikleme yoluyla yapılan segmentasyon, diğer yöntemlere göre daha az hesaplamaya sahiptir. Bu teknik, karmaşık ortamlarda uygun sonuçlar vermemektedir (Baradez ve ark., 2004).

### **3.3.1.4. Feature Based Clustering**

Clustering, bazı benzer özelliklere dayalı olarak nesnelere bir arada gruplandırma işlemidir, böylece her clustering, diğer clusteringlerin nesnelereinden farklı olan benzer nesnelere içerir. Renkli görüntünün pikselleri, denetimsiz bir bulanık C tekniği kullanılarak bölütleme için kümelenebilir. Bu, sıradan görüntüler için uygulanır. Gürültülü bir görüntü ise, parçalanmaya neden olur (Rani, 2017).

### **3.3.1.5. Model Based**

Bu teknik, Markov rastgele alanına dayanmaktadır. Renk segmentasyonu için dahili bölge kısıtlaması kullanılır. Kenarların doğruluğunu tanımlamak için MRF, kenar algılama ile birleştirilir (Luo ve ark., 1998).

### **3.3.2. Classification**

Görüntülerin sınıflandırılması, görüntülerdeki bilgileri, etiketleri ve pikselleri görüntülerden çıkarmak için kullanılır. Sınıflandırmayı gerçekleştirmek için aynı nesnelere birçok görüntüsüne ihtiyaç vardır. Uygun bir sınıflandırma şeması ve yeterli miktarda eğitim örneği, etkili bir sınıflandırma için temeldir. Temel olarak, sınıflandırma sistemi kasıtlı olarak kullanıcıların gereksinimlerine bağlıdır (LU ve Weng, 2014).

### **3.3.3. Image Restoration**

Image Restoration, bozuk/gürültülü bir görüntü alır ve temiz, orijinal görüntüyü tahmin eder. Bozulma, hareket bulanıklığı, gürültü ve kameranın yanlış odaklanması gibi birçok biçimde ortaya çıkabilir. Görüntü restorasyonunun amacı, bozulmuş görüntüleri geri yüklemektir. Görüntü iyileştirmeye benzer, ancak daha objektiftir. Görüntünün gürültü nedeniyle bozulduğu durumlarda, yapabileceğimiz en iyi şey, gürültünün neden olduğu bozulmayı telafi etmektir. Image Restoration, görüntü iyileştirmeden farklıdır. Görüntü iyileştirme, görüntünün gözlemci için daha hoş olmasını sağlayan, ancak bilimsel bir bakış açısından gerçekçi veriler üretmesi gerekmeyen görüntü özelliklerine vurgu yapmak için tasarlanmıştır (Ma ve Manjunath, 1997).

### **3.3.4. Image Enhancement**

Bir grafik ekranı görüntüleme ve analiz için daha kullanışlı hale getirmek için sınırlar veya kontrast gibi görüntü özelliklerinin vurgulanması veya keskinleştirilmesi anlamına gelir. Bu işlem,

verilerdeki doğal bilgi içeriğini artırmaz. Gri seviyesi ve kontrast manipülasyonu, gürültü azaltma, kenar keskinleştirme ve keskinleştirme, filtreleme, enterpolasyon ve büyütme, sahte renklendirme vb. içerir (Kuruvilla ve ark., 2016).

### **3.3.5. Image Compression**

Image Compression, dijital görüntüler arasında kayıtların sıkıştırılması anlamına gelir. Image Compression, verilerin etkili bir şekilde depolanması ve iletilmesi için kopyalanmasını ortadan kaldırır. Image Compression kayıplı ve kayıpsız olabilir (Kavita ve ark., 2013). Kayıpsız sıkıştırma, arşiv nedenleriyle ve sıklıkla tıbbi görüntü işleme, teknik çizimler vb. için tercih edilir (Kuruvilla ve ark., 2016).

## **4. İNSANSIZ HAVA ARAÇLARINDA GÖRÜNTÜ İŞLEME UYGULAMALARI**

Görüntü işleme, özellikle derin öğrenme ve derin öğrenmeli görüntü işleme, son zamanlarda büyük bir hız elde etmiştir. Dinamik olarak gelişen ve ilerleyen derin öğrenmeli görüntü işleme dalında bazı teknikler artık eskimiş ve kullanılmaz durumdadır. Bu sebeple güncel kalabilmek için akademik çalışmalar, bilimsel makaleler, bildiriler, projeler, saha çalışmaları ve sempozyumları takip etmek gerekmektedir. İnsansız hava araçları günümüzde oldukça önemli hale gelmiştir. Hava araçlarının insansız olarak kullanılması konusunda önemli çalışmalar artarak devam etmektedir. İnsansız hava araçlarının öneminin artması insan hayatının korunması ve kolaylaşması için gerekli olduğu kabul edilmekte ve bu çerçevede uğraşları artırmaktadır. Hava araçları insan hayatında en önemli alanlardan biridir. Savunma sanayi ve askeri açıdan insansız hava aracı sistemlerinin kullanılması oldukça fazla alanda üstünlük sağlamaktadır. Düşman ile mücadele sırasında personel riski oluşturmadan düşman tespiti, mühimmat bilgisi, dost tespiti, yaralı personelin konum bilgisi vb. konularda hakimiyet kurmak askerî açıdan büyük bir üstünlüktür. Çünkü bu istihbarat bilgilerini elde edebilmek için birçok personel yaralanmakta, esir düşmekte ve hayatını kaybetmektedir. Tarımsal alanlarda insansız hava aracı destekli görüntü işleme de oldukça kullanışlıdır. Birlikte kullanımda ürün verimi, istenmeyen ot tespiti, mahsul sayımı, bitki yaprak gelişimi, çürük veya kuruma tespiti gibi alanlarda büyük bir hız artışı ve ürün kalitesini arttırarak maliyet azaltılmasına yardımcı olmaktadır. İnsansız hava aracıyla tarımsal ilaçlama da yaygın olarak kullanılmaktadır. Tarımsal ilaçlama uygulamalarında tarım alanına traktör veya insan gücüyle çalışan ilaçlama araçları yerine insansız hava aracı kullanımı aynı şekilde hızı arttırmakta, tarlanın ezilerek zarar görmesini azaltmakta ve yine maliyeti düşürmektedir. İnsansız hava aracı destekli görüntü işleme uygulamalarında yaygın olarak kullanılan diğer bir alanda bina, köprü, tren rayı ve asfaltlarda çatlak ve hasar tespitidir. Çalışmanın bu bölümünde görüntü işleme ve derin öğrenme teknikleri ile detaylı sınıflandırmada karşılaştırma, nesne tespiti ve takibi, farklılıkları bulmak, dost-düşman ayrımı yapmak, çatlak tespiti, tarım alanı uygulamaları için literatür taraması yapıldığında mevcut çalışmalar incelenmiş ve bu çalışmalardan

bazıları paylaşılmıştır. Örneğin; Vinay ve ark. araştırmalarında yerde ve havada makine görme ve makine öğrenimini kullanan ağaç düzeyinde narenciye verimi tahmini yapmışlardır. Narenciye verimi tahmini için 3 model deneyerek karşılaştırmışlardır. Bu modellerin, olgunlaşmamış meyvelerden alınan görüntüleri önermişlerdir (Vijayakumar ve ark., 2023). Ivan ve ark. CNN kullanarak şeker kamışı yaprak biti yoğunluğunun görüntü sınıflandırmasını gerçekleştirmişlerdir. Şeker kamışı tarlasından topladıkları toplam 5.048 görüntü kullanarak ve dört farklı derin öğrenme sınıflandırma modelinin performansını değerlendirmişlerdir. Bunlar: Inception v3, DenseNet 121, Resnet 50 ve Xception modelleridir. Bu modeller arasından Inception v3 ve Xception, %86'lık genel doğrulukta ve daha az sayıda yanlış sınıflandırılmış görüntü ile en iyi performansı gösterdiğini söylemişlerdir. Daha da önemli olarak, modellerin yaprak bitlerini çalışmaların %97'sinde eşik püskürtme yoğunluğunun üstünde veya altında olarak doğru bir şekilde sınıflandırdığını vurgulamışlardır (Grijalva ve ark., 2023). Zhu ve ark. araştırmalarında insansız hava aracı aracılığıyla alınan görüntülerde CNN kullanarak kaldırım tehlikesi tespiti yapmışlardır. Son teknoloji nesne algılama algoritmalarından Faster R-CNN, YOLOv3 ve YOLOv4, veri kümesini kullanarak tahmin performansı karşılaştırması yapmışlardır. Bu üç algoritma arasından, YOLOv3'ün tahmin performansı, %56,62'lik bir MAP ile en iyisi olduğunu vurgulamışlardır (Zhu ve ark., 2022). Jeong ve ark. çalışmalarında insansız hava araçları tarafından elde edilen gelişmiş görünürlük görüntüleri ile Evrişimli Sinir Ağı (CNN) tabanlı makine öğrenimini kullanan yeni bir köprü denetim protokolünü tanıtmayı amaçlamışlardır. Hasar tespiti sırasında, CNN tabanlı makine öğrenimi yoluyla görsel olarak tespit edilen çeşitli hasar türleri sınıflandırmışlardır. Görüntü görünürlüğünü iyileştirmek, hasarı etkili bir şekilde belirlemek ve ölçmek için hasarlı her görüntüyü uygun parlaklık, kontrast ve keskinlik ayarıyla işlemişlerdir. Önerilen protokol ile doğrudan ölçümlere kıyasla ortalama %9,12 hata ile köprü hasar tespiti ve ölçümü yapabildiğini söylemişlerdir (Jeong ve ark., 2022). Xing ve ark. YOLOv5'e dayalı arama ve kurtarma için çoklu insansız hava aracı iş birliği sistemi geliştirmişlerdir. İnsansız hava aracı ve hedef tespit teknolojilerini kullanarak arama kurtarma (SAR) süresini kısaltmayı ve başarı oranını artırmayı amaçlamışlardır. YOLOv5'e dayalı SAR için çoklu insansız hava aracı iş birliği sistemi önermişlerdir. İnsansız hava aracı uçuşunun güvenliğini ve konumlandırmanın doğruluğunu artırmak için, yüksek hassasiyetli DEM (digital elevation model)'i tanıtmak gerektiğine dikkat çekmişlerdir. Bu sistemin performansı, simüle edilmiş birkaç arama ve kurtarma görevi ile test edilmiştir. Sonuçlar, sistemin arama ve kurtarma operasyonlarının gereksinimlerini karşılayabileceğini kanıtlamıştır (Xing ve ark., 2022). Sarwar ve ark. yer gerçeği verileri olarak centroidleri kullanan insansız bir hava aracı tarafından çekilen hava görüntülerini FCN (fully connected network) kullanarak canlı hayvan tespiti yapmışlardır. Performans değerlendirmesi ve karşılaştırma için tek katmanlı ve yedi katmanlı bir CNN ağı önerilmiştir. Önerilen bu ağlar, en gelişmiş yöntem olan Region-based CNN kullanılarak eğitilmiştir. AlexNet, GoogLeNet, VGG16, VGG19 ve ResNet50'de canlı hayvan tespiti için ince ayar

yapılmıştır. FCN (Fully Connected Network)'nin sonuçlarını ve önerilen ağlardan birinin sonuçları, tüm sistemin geri çağrılmasını %90'dan %98'e çıkarmak için birleştirildiğini söylemişlerdir (Sarwar ve ark., 2021). Kako ve ark. araştırmalarında küresel bir endişe kaynağı haline gelen plastik deniz atıkları sorununu çözmeye yardımcı olmak, hacimlerini tahmin etmek için insansız hava aracı incelemeleri ve derin öğrenmeye dayalı görüntü işlemenin bir kombinasyonunu kullanarak yeni bir yaklaşım önemişlerdir. İnsansız hava araçlarından türetilen veriler kullanılarak Structure from Motion yazılımı aracılığıyla oluşturulan bir plajın üç boyutlu modeli ve ortoskopik görüntüsü, görüntü işleme yoluyla kenar algılama yoluyla plastik deniz atıkların hacimlerinin hesaplanmasını sağlamıştır. Yöntemin doğruluğu, bilinen boyut ve şekillerde bir kumsala yerleştirilen test kalıntılarının hacimleri tahmin edilerek doğrulanmıştır. Önerilen yaklaşım, <math>5\%</math>'lik bir hatayla PMD hacimlerini tahmin etme potansiyelini göstermiştir (Koka ve ark., 2020). Jahanbakhshi ve ark. gated pooling fonksiyonu aracılığıyla evrişimli sinir ağlarını (CNN) geliştirerek sahtekarlığı tespit etmek için zencefil tozu görüntülerini sınıflandırmışlardır. CNN'yi iyileştirmeye yönelik ana yaklaşımları, average pooling ve max pooling'i birleştiren bir pooling fonksiyonu kullanarak vurgulamışlardır. Sınıflandırma sonuçlarını iyileştirmek için CNN'de Batch Normalization (BN) tekniği kullanılmıştır. Önerilen CNN sonuçlarını diğer sınıflandırıcılarla karşılaştırmak için MLP, Fuzzy, SVM, GBT ve EDT algoritmaları kullanılmışlardır. Sonuçlar ise, gated pooling'e dayalı toplu normalleştirmeyi kullanarak, önerilen CNN'nin zencefil tozu görüntülerini diğer sınıflandırıcılara kıyasla %99.70 doğrulukla derecelendirebildiğini söylemişlerdir (Jahanbakhshi ve ark., 2021). Erkan ve ark. çalışmalarında bitki türlerinin tanımlanması için derin CNN'nin hiperparametre optimizasyonu için optimal deep CNN (ODC) sınıflandırıcısı olarak adlandırılan yapay arı kolonisi (ABC) algoritmasına dayalı bir optimizasyon şeması önermişlerdir. Önerilen şemayı doğrulamak için, MNIST sayısal görüntü veri seti aracılığıyla genetic, particle swarm and firefly algoritmaları gibi optimizasyon tabanlı çalışmalarla bir kıyaslama yapmışlardır. ODC, yaprak görüntüleri en iyi %98,99 ve %99,21 doğrulukta tahmin etmişlerdir. Bu nedenle önerilen ODC, ABC algoritması sayesinde optimal bir CNN elde etmede etkili ve kullanışlı olduğunu söylemişlerdir (Erkan ve ark., 2022). Sung ve ark. araştırmalarında Generative Adversarial Network (GAN) kullanarak gerçekçi sonar görüntülerini sentezleyen bir yöntem üzerinde çalışmışlardır. Birkaç nesne için üretilen gerçekçi görüntüler ile gerçek sonar görüntüleri arasındaki benzerliği ölçerek yöntemi değerlendirmişlerdir. Önerilen yöntemi, gemi enkazı araştırması, mayın temizleme ve dönüm noktası tabanlı navigasyon gibi sualtı görevlerini otomatikleştirmek için gerekli olan derin öğrenme tabanlı nesne algılamaya uygulamışlardır. Tespit sonuçlarında, önerilen yöntemin, hedef nesnelerin eğitim görüntüleri olarak kullanılabilir kadar gerçekçi görüntüler üretebileceğini göstermişlerdir. Önerilen yöntem, deniz denemeleri olmadan çeşitli açılardan ve koşullardan gerçekçi eğitim görüntülerini sentezleyerek nesne tespitini basit ve sağlam hale getirmiştir. Gerçekçi sonar görüntülerini üretmek için önerilen yöntem, nesne algılamanın yanı sıra diğer sonar görüntü tabanlı

algoritmalara da uygulanabildiğini vurgulamışlardır (Sung ve ark., 2020). Kwak ve Ryu çalışmalarında daha önce duman giderme için kullanılan bir algoritma olan dark channel prior'ı dumanın bulunabileceği alanları tespit etmek için kullanmışlardır. Dark channel prior ile arka plandaki paraziti veya gürültü içeren duman alanını etkili bir şekilde algılamayı mümkün kılmıştır. Yangından çıkan dumanın yüksek sıcaklıklarda yoğunluk farkından dolayı yükselme özelliğinin tespit edilebilmesi için Lucas-Kanade yöntemine dayalı optik akış (Optical Flow) tekniği kullanılarak dumanın alanı tespit edilmiştir. Sonuç olarak ise, görüntü ön işleme olmadan algılama gerçekleştiren nesne algılama modellerine kıyasla doğruluk ve hassasiyetin sırasıyla %4 ve %7 oranında iyileştirildiği doğrulanmıştır (Kwak ve Ryu, 2022). Likhita ve Anand puslu ve net görüntülerin sınıflandırılması için makine öğrenimi ve derin öğrenme modelleri arasında karşılaştırmalı bir analiz olmak üzere iki amaç sunmaktadır. Daha sonra da puslu görüntüleri kaldırma işlemi içinse sağlam bir derin sinir ağı aracılığıyla işlemişlerdir. Sınıflandırmak içinde SVM ve Lojistik Regresyon olmak üzere iki ML algoritması ve iki CNN standart model Resnet, Vgg'de kullanarak problemin en iyi sınıflandırma algoritmasını elde etmek için performansları karşılaştırmışlardır. Sınıflandırma modelinde, standart CNN modelleri, daha doğru olduğunu kanıtlayarak Makine Öğrenimi modellerinden büyük bir farkla daha iyi performans göstermiştir. Benzer şekilde, dehazing için de önerilen bir CNN de-hazing ağı ile DCP Görüntü işleme algoritması uygulanmıştır. Nispeten CNN modeli, daha yüksek görüntü kalitesi ölçümleri elde ederek DCP algoritmasından daha iyi performans gösterdiğini söylemişlerdir (Likhita ve Anand, 2021).

## 5. SONUÇ VE ÖNERİLER

Bu çalışmada, öncelikle insansız hava aracı ve görüntü işleme ile alakalı Türkiye'de ve dünyada yapılmış çalışmaların literatür bilgileri sunulmuştur. Ardından insansız hava aracı destekli görüntü işleme uygulamalarından örnek teşkil edecek şekilde özet bilgileri sunulmuştur. Literatür çalışmaları ve uygulama örnekleri değerlendirildiği zaman insansız hava araçlarının görüntü işleme üzerinde çok faydalı olduğu anlaşılmıştır. İncelenen çalışmalarda tarladaki mahsulün verimini tahmin etmek, istenmeyen yabancı otları tespit etmek, mahsulün büyüme hızını hesaplamak, çürük veya solgun yaprakları ayırt etmek, bölgesel olarak bulunan haşereleri tespit etmek, nesne veya insanın tespit ve takibini yapmak, nesne veya insanın konumunu tespit etmek, binalarda hasar tespit etmek, tren raylarında çatlak tespit etmek, köprülerde çatlak tespit etmek, asfaltlarda çatlak veya çökme tespit etmek, hava kargo, insansız hava araçlarında otonom iniş gibi hassas konularda insansız hava aracı destekli görüntü işleme uygulamalarının oldukça faydalı olduğu görülmektedir. Bilim ve teknolojiye bu kadar fayda sağlayan insansız hava araçlarının en önemli sorunlarından olan güvenlik ve gizlilik ile ilgili olumlu yönde gelişmeler görülmektedir ve yeni iyileştirmeler beklenmektedir. Tüm bu olumlu gelişmelerle birlikte, birçok alanda kullanılan ve büyük faydalar sağlayan insansız hava araçlarının

gelecekte çok daha aktif kullanılacağı tahmin edildiği için iyileştirme ve gelişmelere ihtiyaç duyduğu görülmektedir. Bu iyileştirme sürecinde açık kaynak kütüphanelerden ziyade insansız hava araçları aracılığıyla elde edilen deneysel çalışma verileri daha verimli olacaktır.



**KAYNAKÇA**

- Koç, M. (2020). Derin öğrenme kullanarak iha ile hareketli bir hedefin otonom olarak yakalanması (Yüksek lisans tezi, İstanbul Sabahattin Zaim Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Bilimleri ve Mühendislik Anabilim Dalı).
- Sankarasrinivasan, S., Balasubramanian, E., Karthik, K., Chandrasekar, U., & Gupta, R. (2015). Health monitoring of civil structures with integrated UAV and image processing system. *Procedia Computer Science*, 54, 508-515.
- University of Tartu.(01,01,2014). Digital Image Processing. <https://sisu.ut.ee/imageprocessing/book/1>
- Hassija, V., Saxena, V., & Chamola, V. (2020). Scheduling drone charging for multi-drone network based on consensus time-stamp and game theory. *Computer Communications*, 149, 51-61.
- SHGM. (11,08,2004). İnsansız Hava Aracı Sistemlerinin Tescil, Operasyon, Seyrüsefer, Bakım ve Uçuşa Elverişlilik Usul ve Esaslarına İlişkin Talimat. <https://web.shgm.gov.tr/documents/sivilhavacilik/files/mevzuat/sektorel/taslaklar/SHT-IHA.pdf>
- Mohsan, S. A. H., Khan, M. A., Noor, F., Ullah, I., & Alsharif, M. H. (2022). Towards the unmanned aerial vehicles (UAVs): A comprehensive review. *Drones*, 6(6), 147.
- Abro, G. E. M., Zulkifli, S. A. B., Masood, R. J., Asirvadam, V. S., & Laouti, A. (2022). Comprehensive Review of UAV Detection, Security, and Communication Advancements to Prevent Threats. *Drones*, 6(10), 284.
- Basavaprasad, B., & Ravi, M. (2014). A study on the importance of image processing and its applications. *IJRET: International Journal of Research in Engineering and Technology*, 3(1).
- Bhattacharya, S., Maddikunta, P. K. R., Pham, Q. V., Gadekallu, T. R., Chowdhary, C. L., Alazab, M., & Piran, M. J. (2021). Deep learning and medical image processing for coronavirus (COVID-19) pandemic: A survey. *Sustainable cities and society*, 65, 102589.
- Kumar, A., Kaur, A., & Kumar, M. (2019). Face detection techniques: a review. *Artificial Intelligence Review*, 52(2), 927-948.
- Schumann, A., Sommer, L., Müller, T., & Voth, S. (2018, October). An image processing pipeline for long range UAV detection. In *Emerging Imaging and Sensing Technologies for Security and Defence III; and Unmanned Sensors, Systems, and Countermeasures (Vol. 10799, pp. 186-194)*. SPIE.
- Mohan, A., & Poobal, S. (2018). Crack detection using image processing: A critical review and analysis. *Alexandria Engineering Journal*, 57(2), 787-798.
- Linh, V. T., & Tuyen, C. M. Applying UAV Aviation Image Processing Technology Based on Multi-Integrated Feature Histogram for Scouting, Search and Rescue.
- Vaseashta, A., Vaclavikova, M., Vaseashta, S., Gallios, G., Roy, P., & Pummakarnchana, O. (2007). Nanostructures in environmental pollution detection, monitoring, and remediation. *Science and Technology of Advanced Materials*, 8(1-2), 47.
- James, M. R., & Robson, S. (2014). Mitigating systematic error in topographic models derived from UAV and ground-based image networks. *Earth Surface Processes and Landforms*, 39(10), 1413-1420.
- Kuruvilla, J., Sukumaran, D., Sankar, A., & Joy, S. P. (2016, March). A review on image processing and image segmentation. In *2016 international conference on data mining and advanced computing (SAPIENCE)* (pp. 198-203). IEEE.
- Ma, W. Y., & Manjunath, B. S. (1997, June). Edge flow: a framework of boundary detection and image segmentation. In *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition* (pp. 744-749). IEEE.
- Baradez, M. O., McGuckin, C. P., Forraz, N., Pettengell, R., & Hoppe, A. (2004). Robust and automated unimodal histogram thresholding and potential applications. *Pattern Recognition*, 37(6), 1131-1148.
- Rani, N. (2017). *Image Processing Techniques: A Review*.
- Luo, J., Gray, R. T., & Lee, H. C. (1998, October). Incorporation of derivative priors in adaptive Bayesian color image segmentation. In *Proceedings 1998 International Conference on Image Processing. ICIP98 (Cat. No. 98CB36269)* (pp. 780-784). IEEE.
- Nath, S. S., Mishra, G., Kar, J., Chakraborty, S., & Dey, N. (2014, July). A survey of image classification methods and techniques. In *2014 International conference on control, instrumentation, communication and computational technologies (ICCICCT)* (pp. 554-557). IEEE.
- Kavita, R. S., Bala, R., & Siwach, S. (2013). Review paper on overview of image processing and image segmentation. *International journal of Research in Computer applications and Robotics*, 1(7), 113.
- Vijayakumar, V., Ampatzidis, Y., & Costa, L. (2023). Tree-level citrus yield prediction utilizing ground and aerial machine vision and machine learning. *Smart Agricultural Technology*, 3, 100077.

- Grijalva, I., Spiesman, B. J., & McCornack, B. (2023). Image classification of sugarcane aphid density using deep convolutional neural networks. *Smart Agricultural Technology*, 3, 100089.
- Zhu, J., Zhong, J., Ma, T., Huang, X., Zhang, W., & Zhou, Y. (2022). Pavement distress detection using convolutional neural networks with images captured via UAV. *Automation in Construction*, 133, 103991.
- Jeong, E., Seo, J., & Wacker, J. P. (2022). UAV-aided bridge inspection protocol through machine learning with improved visibility images. *Expert Systems with Applications*, 197, 116791.
- Xing, L., Fan, X., Dong, Y., Xiong, Z., Xing, L., Yang, Y., ... & Zhou, C. (2022). Multi-UAV cooperative system for search and rescue based on YOLOv5. *International Journal of Disaster Risk Reduction*, 76, 102972.
- Sarwar, F., Griffin, A., Rehman, S. U., & Pasang, T. (2021). Detecting sheep in UAV images. *Computers and Electronics in Agriculture*, 187, 106219.
- Kako, S. I., Morita, S., & Taneda, T. (2020). Estimation of plastic marine debris volumes on beaches using unmanned aerial vehicles and image processing based on deep learning. *Marine Pollution Bulletin*, 155, 111127.
- Jahanbakhshi, A., Abbaspour-Gilandeh, Y., Heidarbeigi, K., & Momeny, M. (2021). Detection of fraud in ginger powder using an automatic sorting system based on image processing technique and deep learning. *Computers in Biology and Medicine*, 136, 104764.
- Erkan, U., Toktas, A., & Ustun, D. (2022). Hyperparameter optimization of deep CNN classifier for plant species identification using artificial bee colony algorithm. *Journal of Ambient Intelligence and Humanized Computing*, 1-12.
- Sung, M., Kim, J., Lee, M., Kim, B., Kim, T., Kim, J., & Yu, S. C. (2020). Realistic sonar image simulation using deep learning for underwater object detection. *International Journal of Control, Automation and Systems*, 18(3), 523-534.
- Kwak, D. K., & Ryu, J. K. (2022). A study on the dynamic image-based dark channel prior and smoke detection using deep learning. *Journal of Electrical Engineering & Technology*, 17(1), 581-589.
- Likhिता, P. S., & Anand, R. (2021, July). A Comparative Analysis of Image Dehazing using Image Processing and Deep Learning Techniques. In 2021 6th International Conference on Communication and Electronics Systems (ICCES) (pp. 1611-1616). IEEE.

# MÜHENDİSLİK ALANINDA YAPAY ZEKA

## EDİTÖRLER

Doç. Dr. Murat SARIKAYA

Dr. Öğr. Üyesi Mustafa Kemal BALKI

Öğr. Gör. Volkan ÇAVUŞ