

ÇANKIRI KARATEKİN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME ALGORİTMALARINI KULLANARAK KUMAŞ  
KUSURLARININ TESPİTİ VE SINIFLANDIRILMASI

Recep Ali GEZE

ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI  
2024

Her hakkı saklıdır

## TEZ ONAYI

Recep Ali GEZE tarafından hazırlanan “**Derin Öğrenme Algoritmalarını Kullanarak Kumaş Kusurlarının Tespiti ve Sınıflandırılması**” adlı tez çalışması 18/01/2024 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Mühendisliği Anabilim Dalında **Yüksek Lisans Tezi** olarak kabul edilmiştir.

**Danışman** : Dr. Öğr. Üyesi Ayhan AKBAŞ

**Eş Danışman** : Dr. Öğr. Üyesi Abdulkadir KÖSE

**Jüri Üyeleri** :

**Başkan** : Dr. Öğr. Üyesi Ayhan AKBAŞ  
İletişim Sistemleri Enstitüsü  
Çankırı Karatekin Üniversitesi

**Üye** : Dr. Öğr. Üyesi Taha ETEM  
Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı  
Çankırı Karatekin Üniversitesi

**Üye** : Doç. Dr. Selim BUYRUKOĞLU  
Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı  
Çankırı Karatekin Üniversitesi

**Yukarıdaki sonucu onaylarım**

**Prof. Dr. Hamit ALYAR**  
**Enstitü Müdürü**

## ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum “**Derin Öğrenme Algoritmalarını Kullanarak Kumaş Kusurlarının Tespiti ve Sınıflandırılması**” konulu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, tezin Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü’nden başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve bu çalışmanın Çankırı Karatekin Üniversitesi tarafından kullanılan “Bilimsel İntihal Tespit Programı”yla tarandığını, “intihal içermediğini” beyan ederim. Çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması halinde ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm. Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim (18/01/2024).

**Recep Ali GEZE**

## ÖZET

Yüksek Lisans Tezi

### DERİN ÖĞRENME ALGORİTMALARINI KULLANARAK KUMAŞ KUSURLARININ TESPİTİ VE SINIFLANDIRILMASI

Recep Ali GEZE

Çankırı Karatekin Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Ayhan AKBAŞ  
Eş Danışman: Dr. Öğr. Üyesi Abdulkadir KÖSE

Tekstil sektörünün en önemli ham maddesi olan kumaşın üretimi birçok aşamadan meydana gelmektedir. Bu üretim aşamalarının fazlalığı ve karmaşıklığından dolayı kumaşlarda bazı hatalar meydana gelebilmektedir. Hataların tespit edilmesinde; sektörün pazar payının büyüklüğü ve üretimin çok hızlı olmasının nedeniyle insan kontrolü ile tespit etmek hem zaman kaybına hem de hata tespit oranının %60 seviyelerine kadar düşmesine neden olmaktadır. Bundan dolayı son yıllarda teknolojinin gelişmesiyle paralel kumaşların hata tespitinde daha çok akıllı sistemler geliştirilmeye başlanmıştır. Günümüzde yapay zekâ teknolojisinin hızla gelişmesiyle bu sektörde de görüntü işleme teknikleri uygulamalar başlamıştır. Bu çalışmada derin öğrenme teknikleri kullanarak kumaş üzerinde gerçek zamanlı hata tespit sistemi geliştirilmiştir. Veri seti olarak halka açık sunulan Tilda veri seti ve kendi oluşturduğumuz veri seti kullanılmıştır. Yapılan çalışmada ilk olarak açık kaynaklı bir sinir ağı kütüphanesi olan Evrişimsel Sinir Ağı (CNN) ile bir ağ modeli oluşturulmuş ve bu yöntemle %89 doğruluk elde edilmiştir. Çalışmayı daha iyi hale getirmek için kumaşları hatalı ve hatasız başlığı altında iki sınıfta sınıflandırıp önceden eğitilmiş CNN modellerinden olan VGGNet16 mimarisi ile %86, InceptionV3 mimarisi ile %90 oranında doğruluğa ulaşılmıştır. ResNet50 yaklaşık %95 doğruluk oranıyla diğer modellere göre çok daha iyi bir model yapısına sahip olduğunu ispatlamıştır. Bu sayede kumaş hataları daha tutarlı bir şekilde bulunabilir.

**2024, 69 sayfa**

**ANAHTAR KELİMELER:** Görüntü işleme, Kumaş hatası tespiti, Tekstil, Derin öğrenme

## ABSTRACT

Master of Science Thesis

### DETECTION AND CLASSIFICATION OF FABRIC DEFECTS USING DEEP LEARNING ALGORITHMS

Recep Ali GEZE

Çankırı Karatekin University  
Graduate School of Natural and Applied Sciences  
Department of Electronics and Computer Engineering

Advisor: Asst. Prof. Dr. Ayhan AKBAŞ  
Co-Advisor: Asst. Prof. Dr. Abdulkadir KÖSE

The production of fabric, which is the most important raw material of the textile industry, consists of many stages. Due to the excess and complexity of these production stages, some defects may occur in fabrics. In the detection of defects; due to the size of the market share of the sector and the very fast production, detection with human control causes both loss of time and error detection rate to drop to 60%. Therefore, in parallel with the development of technology in recent years, more and more intelligent systems have started to be developed in the error detection of fabrics. Today, with the rapid development of artificial intelligence technology, image processing techniques have started to be applied in this sector. In this study, a real-time defect detection system has been developed on fabric using deep learning techniques. The publicly available Tilda dataset and the dataset we created ourselves were used as datasets. First, a network model was created with Convolutional Neural Network (CNN), an open source neural network library, and 89% accuracy was achieved with this method. In order to improve the study, we classified the fabrics into two classes as defective and non-defective and achieved 86% accuracy with the VGGNet16 architecture and 90% accuracy with the InceptionV3 architecture, which are pre-trained CNN models. ResNet50 has proven to have a much better model structure than other models, with an accuracy of about 95%. This means that fabric defects can be found more consistently.

**2024, 69 pages**

**Keywords:** Image processing, Fabric defect detection, Deep learning, Textile

## ÖNSÖZ VE TEŞEKKÜR

Bu çalışmanın her safhasında çok değerli bilgi ve birikimleri ile beni yönlendiren, her türlü yardımını esirgemeyen, her zaman destekleyen ve inanılmaz bir anlayış gösteren değerli hocam tez danışmanım Sayın Dr. Ayhan AKBAŞ'a teşekkürü bir borç bilirim. Ayrıca hayatımın her anında olduğu yüksek lisans eğitimim boyunca maddi ve manevi desteklerini esirgemeyen sevgili eşim Saadet Geze'ye, bilimsel araştırmalarım ışık tutan Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Mühendisliği Bölümü hocalarıma, akademik desteklerinden dolayı Samsun Bilgisayar Mühendisleri Odası adına Sn. Akın Ömür'e ve veri seti destekleri için Samsun Samteks firması'na teşekkür eder ve minnetlerimi sunarım.

**Recep Ali GEZE**

**Çankırı, Ocak 2024**

## İÇİNDEKİLER

ÖZET.....	i
ABSTRACT .....	ii
İÇİNDEKİLER .....	i
ŞEKİLLER DİZİNİ .....	iv
ÇİZELGELER DİZİNİ .....	vi
1. GİRİŞ .....	1
1.1 Literatür Özeti.....	4
2. KUMAŞ HATALARI .....	8
2.1 Kumaşlarda Hata Çeşitleri .....	8
2.2 Çözümlenemedeki Hatalar.....	10
2.2.1 Çözüm kaçığı.....	10
2.2.2 Çift çözüm .....	11
2.2.3 Gevşek çözüm .....	11
2.2.4 Yüzen iplik (atlama hatası) .....	12
2.3 Atkı Yönündeki Hatalar .....	12
2.3.1 Atkı kaçığı.....	12
2.3.2 Gevşek atkı.....	13
2.3.3 Çift atkı .....	13
2.4 Diğer Kumaş Hataları.....	14
2.4.1 Şantuk hatası .....	14
2.4.2 Düğümlenme hatası.....	14
2.4.3 Yabancı madde hatası.....	14
2.4.4 Yağ lekesi ve delik hataları .....	15
3. YAPAY ZEKÂ .....	16
3.1 Yapay Zekânın Gelişiminde Makine Öğrenmesi .....	21
3.2 Makine Öğrenmesi.....	22
3.2.1 Makine öğrenmesi çeşitleri.....	23
3.3 Derin Öğrenme .....	25
3.3.1 Derin öğrenmenin avantajları.....	26
3.3.2 Derin öğrenmede rol oynayan temel kavramlar .....	28

3.3.3 Evrişimsel sinir ağı.....	31
3.3.4 Evrişimsel sinir ağları modellerinin tasarlanması .....	34
3.3.5 Aktarımlı öğrenme .....	34
4. MATERYAL YÖNTEM .....	36
4.1 Veri Setleri .....	36
4.1.1 Tilda veri seti .....	37
4.1.2 Veri seti üretme .....	38
4.2 Algoritma .....	40
4.2.1 VGGNet 16.....	41
4.2.2 InceptionV3.....	41
4.2.3 ResNet50.....	42
4.3 Sınıflandırma .....	43
4.3.1 Destek vektör makineleri (SVM) .....	43
4.3.2 K en yakın komşu (KNN) .....	44
5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	46
5.1 Sistem Özellikleri .....	46
5.2 Uygulanan sistem .....	46
5.3 Veri Setlerinin Hazırlanması .....	47
5.3.1 Görüntü kaydırma .....	48
5.3.2 Görüntü çevirme .....	49
5.3.3 Görüntü rastgele çevirme .....	49
5.3.4 Görüntü rastgele parlaklık tekniği .....	50
5.3.5 Görüntü rastgele yakınlaştırma.....	50
5.3.6 Görüntü renk ayarları .....	51
5.4 Programlama aşaması .....	52
5.4.1 Yeniden boyutlandırma .....	52
5.4.2 Eğitim ve test dosyalarının oluşturulması .....	52
5.4.3 Önceden eğitilmiş modellerden özellik çıkarma .....	52
5.4.4 Sınıflandırma işlemi.....	53
5.5 Modellerin Birbirleriyle Karşılaştırılması.....	53
5.6 Sonuçların Değerlendirilmesi.....	58
5.7 Tartışma .....	59

<b>6. SONUÇ VE ÖNERİLER.....</b>	<b>61</b>
<b>6.1 Sonuç .....</b>	<b>61</b>
<b>6.2 Öneri.....</b>	<b>63</b>
<b>KAYNAKLAR .....</b>	<b>64</b>
<b>ÖZGEÇMİŞ.....</b>	<b>69</b>



## ŞEKİLLER DİZİNİ

Şekil 2.1 Çözümlü kaçığı .....	10
Şekil 2.2 Çift çözgü.....	11
Şekil 2.3 Gevşek çözgü.....	11
Şekil 2.4 Yüzen iplik.....	12
Şekil 2.5 Atkı kaçığı.....	13
Şekil 2.6 Gevşek atkı.....	13
Şekil 2.7 Çift atkı .....	14
Şekil 3.1 Biyolojik beyin nöron yapısı.....	16
Şekil 3.2 Çok katmanlı ysa çalışma fonksiyonu .....	17
Şekil 3.3 İleri yönlü yapay sinir ağı katman yapısı .....	18
Şekil 3.4 Sigmoid fonksiyonunun gösterimi.....	19
Şekil 3.5 Klasik makine öğrenmesi (Kotsiantis <i>et al.</i> 2006).....	22
Şekil 3.6 Derin sinir ağı (Mira 1995).....	26
Şekil 3.7 Makine öğrenmesi ile derin öğrenme karşılaştırılması.....	27
Şekil 3.8 Derin öğrenme algoritması .....	28
Şekil 3.9 Aktivasyon Fonksiyonları .....	30
Şekil 3.10 ESA mimarisi katmanları.....	32
Şekil 3.11 Evrişim katmanı .....	33
Şekil 3.12 Filtreleme işlemi .....	33
Şekil 4.1 Tilda veri seti .....	37
Şekil 4.2 Desensiz kumaş örnekleri .....	38
Şekil 4.3 Desenli kumaş örnekleri .....	38
Şekil 4.4 Oluşturulan hatasız veri seti klasörü .....	39
Şekil 4.5 Oluşturulan hatalı veri seti klasörü .....	39
Şekil 4.6 VGGNet16 mimarisi .....	41
Şekil 4.7 Inception mimarisi .....	42
Şekil 4.8 ResNet mimarisi (Ala ve İkiz 2015) .....	42
Şekil 4.9 SVM yapısı .....	43
Şekil 4.10 KNN yapısı .....	44
Şekil 5.1 Uygulanan yöntem .....	47
Şekil 5.2 Görüntüyü kaydırma tekniği .....	48
Şekil 5.3 Görüntüyü dikey çevirme tekniği .....	49
Şekil 5.4 Görüntü rastegele çevirme tekniği .....	49
Şekil 5.5 Görüntüyü rastgele parlatma tekniği.....	50
Şekil 5.6 Görüntüyü rastgele yakınlaştırma tekniği.....	50
Şekil 5.7 Görüntüyü gri tonlamaya çevirme tekniği .....	51
Şekil 5.8 Görüntüyü daha canlı renklere çevirme tekniği.....	51
Şekil 5.9 Performans karşılaştırılması.....	55
Şekil 5.10 Performans karşılaştırılması.....	56

Şekil 5.11 Performans karşılaştırılması.....	57
Şekil 5.12 Sınıflandırma süreleri .....	58



## ÇİZELGELER DİZİNİ

Çizelge 2.1 Kumaşlarda görülen hata ve miktarları (Ala ve İkiz 2015) .....	9
Çizelge 4.1 Kumaşlar için oluşturulmuş halka açık veri setleri (Kahraman 2022) .....	36
Çizelge 4.2 Modellerin parametreleri (Uçar 2021) .....	40
Çizelge 5.1 Çalışmada kullanılan bilgisayarın özellikleri .....	46
Çizelge 5.2 Veri setleri.....	51
Çizelge 5.3 Eğitim seti ve test seti .....	52
Çizelge 5.4 Tilda veri seti kullanılarak elde edilen sonuçlar .....	55
Çizelge 5.5 Kendi veri setimizi kullanılarak elde edilen sonuçlar.....	56
Çizelge 5.6 Arttırılmış kendi veri setimizi kullanılarak elde edilen sonuçlar.....	57
Çizelge 5.7 Sınıflandırma süreleri.....	58
Çizelge 5.8 Sonuçların değerlendirilmesi .....	59

## 1. GİRİŞ

Devlet Planlama Teşkilatı (DPT) 2001 yılı raporuna göre, 2000 yılında Dünya tekstil ticareti, toplamda 200 milyar dolarlık bir ihracat hacmine ulaşmıştır. Avrupa Birliği (AB) ekonomisinde tekstil ve konfeksiyon sanayii hem global alanda hem de bölgesel çerçevede mühim bir rol oynamaktadır. AB, bu sektörde doğrudan 2 buçuk milyon, dolaylı olarak ise yaklaşık 4 milyon kişiyi istihdam ederek, sanayi istihdamının %9'luk bir kısmını oluşturmaktadır. Dünya çapında, tekstil ürünlerinin ithalatı genel ithalatın %15'ini, ihracatın ise %16'sını temsil etmektedir (DPT 2001).

Dış Ticaret Müsteşarlığı'nın 2001 yılında yayımlanan raporuna göre, Economist Intelligence Unit (EIU) tarafından gerçekleştirilen bir araştırma, AB içerisinde kişi başına düşen tekstil ve konfeksiyon ürünleri tüketiminin 1992 yılında 19 kg/yıl iken, 2004 yılında 25 kg/yıl'a yükseldiğini ortaya koymaktadır. Aynı çalışmada, AB dışındaki diğer Avrupa ülkelerinde ise bu oranın kişi başına 10 kg/yıl seviyesine ulaştığı belirtilmiştir (DTM 2001).

Hazır giyim sektörünün, ekonomik göstergeler açısından incelendiğinde, oldukça büyük bir hacim oluşturduğu açıktır. Bu sektör sadece giyimle sınırlı kalmayıp, kumaş üretimi, kumaş imalatı, boyama işlemleri, mobilya kaplamaları için kullanılan tekstiller, havlu, perde ve diğer ev aksesuarlarını da kapsamaktadır. Bu çeşitlilik, insanların tekstil ürünlerine olan yoğun ilgisini ve sektörün geniş kapsamını ortaya koymaktadır.

Tekstil ürünlerinin kullanım alanı, Çedikçi tarafından belirtildiği üzere, hazır giyimden ev aksesuarlarına ve hatta ulusal bayraklar gibi sembolik değer taşıyan ürünlere kadar geniş bir yelpazeyi kapsamaktadır (Çedikçi 2008). Bu çeşitlilik, hazır giyim sektörü altında bir araya gelmektedir. Akyol'un çalışmalarına göre, bu sektör dünya genelinde ve Türkiye özelinde geniş bir ekonomik hacme sahip olup, planlayıcılar, üreticiler, satış noktaları ve diğer çalışanlar dâhil olmak üzere geniş bir kitleye ekonomik fayda sağlamaktadır (Akyol 2001). Ayrıca, moda gibi trendlerin gelişimine ön ayak olmakla beraber insan hayatına katkı sunan kurum ve kuruluşlarla etkileşim içinde bulunmaktadır.

Türkiye’de ve dünyanın birçok ülkesinde, tekstil sanayii ilk kurulan ve gelişen sanayi dallarından biri olarak görülmektedir.

Hazır giyim, tekstil ve konfeksiyon sektörünün kritik bir parçası olarak, modern insanın günlük yaşantısının vazgeçilmez bir unsuru haline gelmiştir. Geleneksel giysilerden günümüzün modern tasarımlarına kadar bir evrim geçiren giysiler, farklı boy, beden ve modellerle tasarlanmıştır. Bu süreçte, insanlığın çağdaş ihtiyaçlarına uyum sağlayarak, özel tasarımlardan hazır giyime uzanan geniş bir sektörel yapıyı ortaya çıkarmıştır.

Kumaş kalitesi, tekstil ve hazır giyim sektörü için büyük önem taşımaktadır. Bu sektörlerde kullanılan kumaşlar, ürünün kalitesi, dayanıklılığı, estetiği ve konforu üzerinde doğrudan etkili olmaktadır.

Bu konuda, Rejeb et al. şöyle belirtmektedir: "Tekstil ve hazır giyim sektöründe, müşteriler ürünlerin kalitesine büyük önem vermektedirler. Ürün kalitesi, kumaşın kalitesiyle doğrudan ilişkilidir ve bu nedenle, kumaş kalitesi ürünlerin satın alma kararlarında belirleyici bir faktör" olarak değerlendirmektedir (Rejeb *et al.* 2018).

Benzer şekilde, Taşçıoğlu şu ifadeleri kullanmaktadır: "Kumaş kalitesi, müşteri memnuniyeti ve şirketin marka değeri için kritik önem taşımaktadır. Kumaş kalitesi, ürünlerin dayanıklılığı, rahatlığı, estetiği ve kullanım ömrü üzerinde doğrudan etkili olmaktadır." (Taşçıoğlu 2017).

Sonuç olarak, tekstil ve hazır giyim sektörlerinde faaliyet gösteren firmaların, ürünlerinde kullanacakları kumaşların kalitesine dikkat etmeleri ve müşterilerine yüksek kaliteli ürünler sunmaları gerekmektedir. Bu, müşteri memnuniyetini artıracak, şirketlerin marka değerini yükseltecek ve sektörde rekabet avantajı sağlayacak unsurlar olarak görülmektedir.

Kumaş kalitesi, tekstil ve hazır giyim sektörü için son derece önemlidir. Ürün kalitesini etkileyen en önemli faktörlerden biri kumaş kalitesidir. Kaliteli kumaşlar, dayanıklı,

estetik ve konforlu ürünlerin üretiminde kullanılırken, kalitesiz kumaşlar ise ürünün dayanıklılığı ve estetiğini olumsuz yönde etkileyebilir.

Kumaş kalitesinin tespiti, kumaş hatalarının doğru bir şekilde tespit edilmesiyle mümkündür. Kumaş hataları, kumaşın dokusunda, deseninde veya renginde oluşan her türlü kusur veya bozukluklardır. Kumaş hataları üretim sürecinde oluşabileceği gibi, depolama, taşıma veya kesim aşamalarında da meydana gelebilir.

Kumaş hatalarının tespiti genelde el ile yapılan incelemeyle mümkündür. Ancak bu yöntem zaman alıcıdır ve hataların tespit edilmesinde %100 doğruluk sağlamayabilir. Bu nedenle, son yıllarda yapay zekâ teknolojileri kullanılarak otomatik kumaş hata tespiti yöntemleri geliştirilmeye başlanmıştır.

Birçok çalışmada, kumaş hatalarının tespiti için yapay zekâ algoritmaları kullanılmıştır. Örneğin, Zhang ve arkadaşları Gabor filtreleri ve PCA algoritması kullanarak kumaş hatalarının tespitini gerçekleştirmişlerdir (Zhang *et al.* 2014). Liu ve arkadaşları ise SVM algoritmasını geliştirerek daha doğru bir kumaş hata tespit sistemi oluşturmuşlardır (Liu *et al.* 2017).

Kumaş hatalarının tespiti, sadece ürün kalitesini artırmakla kalmaz, aynı zamanda üretim sürecinde zaman ve maliyet tasarrufu sağlamaktadır. Kumaş hatalarının otomatik olarak tespit edilmesi, manuel olarak yapılan tespit işleminin yerini alarak, üretim sürecinin hızlanmasına ve üretim maliyetlerinin azaltılmasına yardımcı olabileceğini düşündürmektedir.

Kumaş kalitesi ve kumaş hatalarının tespiti, tekstil ve hazır giyim sektörü için hayati önem taşımaktadır. Bu nedenle, bu konuya yönelik araştırmaların yapılması ve geliştirilen teknolojilerin sektörde kullanılması, ürün kalitesinin artırılması ve sektörün rekabet gücünün artırılmasına katkı sağlayacağı düşünülmektedir. Bu sebeple, tekstil sektörünün her geçen gün büyüyen yapısı ile kumaş hatalarının tespit edilerek bu kumaşlardan ürün yapımının önlenmesiyle büyük avantaj sağlayacağı ortaya çıkmaktadır. Kumaş

kalitesinde hata tespitinin yapay zekâ ile sağlanması hakkındaki literatüre bu çalışma ile katkı sağlanması planlanmaktadır. Çalışma literatüre katkı sağlaması yönüyle önemli görülmektedir..

## 1.1 Literatür Özeti

Kumaş hataları konusunda yapılan çalışmalar, tekstil endüstrisinde üretim kalitesini artırmak ve maliyetleri düşürmek amacıyla önemli bir yer tutmaktadır. Aşağıda, bu konuda yapılmış bazı önemli çalışmaların örnekleri verilmiştir:

Zhang ve arkadaşları çalışmalarında kumaş kusuru tespiti için Gabor filtreleri ve PCA (principal component analysis) algoritması temelli bir yaklaşımı ele almaktadır. Yazarlar, Gabor filtrelerinin kumaş kusurlarını tespit etmek için yararlı olduğunu ve PCA algoritmasının kumaş kusurlarını sınıflandırmak için etkili bir araç olduğunu savunmaktadırlar. Çalışmada, Gabor filtrelerinin kumaş yüzeyindeki kusurların farklı özelliklerini belirlemek için kullanıldığı açıklanmaktadır. Bu özellikler, kumaş yüzeyindeki desenlerin farklı yönlere ve frekanslara sahip olmasına dayanmaktadır. PCA algoritması ise, bu özelliklerin analizi için kullanılmaktadır. Yazarlar, bu yaklaşımın geleneksel yöntemlere kıyasla daha doğru sonuçlar verdiğini ve gerçek zamanlı uygulamalar için uygun olduğunu belirtmektedirler. Ayrıca, bu yaklaşımın kumaş kusurlarının tespit edilmesinde insan müdahalesine daha az ihtiyaç duyduğunu da vurgulamaktadırlar. Çalışma, Gabor filtreleri ve PCA algoritması temelli bir yaklaşımın, kumaş kusuru tespiti için etkili bir araç olduğunu göstermektedir (Zhang *et al.* 2014).

Liu ve arkadaşları, tekstil kusur tespiti için geliştirilmiş bir SVM (support vector machine) algoritmasını ele almaktadır. Yazarlar, SVM algoritmasının tekstil kusurlarını tespit etmek için etkili bir araç olduğunu, ancak bazı zorluklarla karşı karşıya kaldığını belirtmektedirler. Bu nedenle, SVM algoritmasını geliştirmek için bir dizi adım atılmıştır. Çalışmada, özellik çıkarma ve SVM sınıflandırması için yeni bir yöntem önerilmektedir. Özellik çıkarma aşamasında, kumaş yüzeyindeki desenlerin farklı özellikleri kullanılarak bir özellik vektörü oluşturulmaktadır. SVM sınıflandırması aşamasında ise, SVM algoritması önceki versiyonlarından farklı olarak, örneklerin sınıflandırılması için daha

az eğitim verisi gerektiren bir yaklaşım kullanmaktadır. Yazarlar, bu geliştirilmiş SVM algoritmasının, kumaş kusurlarının tespitinde daha iyi performans gösterdiğini belirtmektedirler. Ayrıca, bu yaklaşımın gerçek zamanlı uygulamalar için uygun olduğunu da vurgulamaktadırlar. Tekstil kusur tespiti için geliştirilmiş bir SVM algoritmasının, daha az eğitim verisi gerektiren bir yaklaşımla daha iyi performans gösterdiğini göstermektedir (Liu *et al.* 2017).

Gupta ve arkadaşları çalışmalarında, otomatik denetim sistemleri için kumaş kusurlarının analiz edilmesini ele almaktadır. Yazarlar, kumaş üretim sürecindeki kalite kontrolünün önemini vurgulamakta ve otomatik denetim sistemleri kullanarak kumaş kusurlarının tespit edilmesinin önemli bir adım olduğunu belirtmektedirler. Çalışmada, kumaş yüzeyindeki kusurların tespiti için farklı görüntü işleme ve özellik çıkarma teknikleri ele alınmaktadır. Bu teknikler arasında, morfolojik operasyonlar, Gabor filtreleri, renk tabanlı özellikler ve dalgacık dönüşümü bulunmaktadır. Yazarlar, bu teknikleri kullanarak kumaş yüzeyindeki kusurların tespit edilebileceğini ve sınıflandırılabilirliğini belirtmektedirler. Ayrıca, makalede ayrıca, kumaş kusurlarının tespiti için kullanılabilir donanım ve yazılım bileşenleri de ele alınmaktadır. Kumaş kusurlarının tespiti için farklı görüntü işleme ve özellik çıkarma tekniklerinin kullanılabilirliğini göstermektedir. Ayrıca, otomatik denetim sistemleri için gerekli donanım ve yazılım bileşenleri hakkında da bilgi vermektedir (Gupta and Mishra 2018).

Xie ve arkadaşları makalelerinde, derin evrişimli sinir ağlarının kullanımını ele alır ve tekstil endüstrisinde kumaş kusur tespiti için bir uygulama örneği sunar. Yazarlar, derin öğrenme yöntemlerinin kullanımının, insanların kumaş kusurlarını tespit etme sürecini otomatikleştirerek ve doğruluğu artırarak zaman ve maliyet tasarrufu sağlayabileceğini savunmaktadırlar. Çalışmada, kumaşların yüzey görüntülerinden özellik çıkarmak için bir derin evrişimli sinir ağı kullanılmıştır. Yazarlar, bu yaklaşımın geleneksel görüntü işleme tekniklerine kıyasla daha iyi sonuçlar verdiğini ve gerçek zamanlı uygulamalar için uygun olduğunu belirtmektedirler. Çalışma sonucunda, tekstil endüstrisinde kumaş kusur tespiti için derin öğrenme yöntemlerinin kullanımının etkinliğine vurgu yapıldığı görülmektedir (Xie *et al.* 2018).

Yao, Zhang ve Chen tarafından yayınlanan bu makalede, bir kumaş hata tespiti yöntemi sunulmaktadır. Yöntem, geliştirilmiş bir Evrimsel Sinir Ağı (ESA) olan bir Convolutional Neural Network (CNN) kullanır. Bu yöntemde, ESA'nın derin öğrenme özelliklerini kullanarak kumaş görüntülerindeki hataları tespit edebilen bir CNN modeli eğitilmiştir. Geliştirilen CNN modeli, özellik çıkarma, özellik eşleştirme ve sınıflandırma aşamalarından oluşan üç aşamalı bir süreçle çalışır. Yöntemin performansı, iki farklı veri seti kullanılarak test edilmiştir ve sonuçlar, yöntemin diğer yöntemlere göre daha yüksek doğruluk oranlarına sahip olduğunu göstermiştir (Yao *et al.* 2018).

El-Sonbaty ve arkadaşları tarafından yapılan çalışmada, ESA tabanlı bir kumaş hatalarının tespitinde kullanılan bir yöntem olan Convolutional Neural Network (CNN) kullanımını ele alınmaktadır. Çalışma, bir dizi adımı ve her adımda kullanılan teknikleri detaylı olarak açıklamaktadır. İlk olarak, veri ön işleme adımı, görüntü verilerinin ayıklanması, düzenlenmesi ve normalizasyonunu sağlamaktadır. Daha sonra, eğitim veri setinin hazırlanması için veri artırma yöntemleri kullanılmaktadır. CNN modeli eğitim veri setinde eğitilerek, ardından test veri setinde sağlanmaktadır. Çalışmada, ESA temelli CNN yönteminin diğer yöntemlere göre daha yüksek doğruluk oranı sağladığı ve kumaş hatalarının tespitinde etkili olduğu belirtilmektedir. Yöntemin kullanımı, kumaş üreticilerinin hata tespitini otomatikleştirmelerine ve üretim süreçlerinde verimliliği artırmalarına yardımcı olabileceği öne sürülmektedir (El-Sonbaty *et al.* 2018).

Işık ve Çakır çalışmalarında, kumaş kusur tespiti için bilgisayar görüşü tekniklerinin kullanımını ele almaktadır. Yazarlar, geleneksel yöntemlerin kumaş kusurlarını tespit etmek için yetersiz kaldığını, bu nedenle bilgisayar görüşü tekniklerinin daha doğru sonuçlar sağladığını savunmaktadırlar. Çalışmada, kumaşların yüzey görüntülerinden özellik çıkarmak için birkaç farklı görüntü işleme yöntemi kullanılmıştır. Bu yöntemler arasında renk uzayı dönüşümü, karşıtlık arttırma, histogram eşitleme, kenar tespiti ve morfolojik işlemler bulunmaktadır. Yazarlar, bu yöntemlerin bir araya getirilmesinin kumaş kusurlarının doğru bir şekilde tespit edilmesine olanak sağladığını belirtmektedirler. Bu yaklaşımın, üretim sürecinde zaman ve maliyet tasarrufu sağladığına dikkat çekilmektedir. Çalışmanın sonucunda bilgisayar görüşü tekniklerinin kumaş kusuru tespiti için kullanımının etkinliğini göstermektedir (Işık ve Çakır 2020).

Çıklaçandır tarafından yapılan çalışmada, özellik çıkarma adımımda ResNet18, ResNet50, GoogLeNet ve AlexNet olmak üzere dört CNN tabanlı modeli kullanan farklı yaklaşımlar kullanılmış, sınıflandırma adımımda ise EL, KNN ve SVM kullanılmıştır. Bu çalışmada, diğer çalışmalardan farklı olarak özellik çıkarımı için özellik birleştirme yöntemi kullanılmıştır (Çıklaçandır 2023).

Bu çalışmaların birçoğu, görüntü işleme, derin öğrenme ve yapay zekâ teknikleri gibi son teknolojileri kullanarak kumaş hatalarının otomatik olarak tespit edilmesini amaçlamaktadır. Bugüne kadar kumaş hatalarını tespit etmek için yapılan çalışmalarda mevcut bilgisayar donanımları düşünülerek yapılmıştır. Bundan dolayı sistemi yoran, uzun sürelerde sonuç çıkaran modelleri elemişlerdir. Ancak bilinmelidir ki günümüzde teknoloji çok hızlı gelişmekte ve donanımlar giderek çok daha güçlü hale gelmektedir. Özellikle kuantum teknoloji ile ilgili gelişmeler bu süreci çok daha kısaltacaktır. Diğer taraftan bu çalışmalar, otomatik kumaş kalite kontrolü ve hataların hızlı ve doğru bir şekilde tespit edilmesi için büyük önem taşımaktadır.

## 2. KUMAŞ HATALARI

### 2.1 Kumaşlarda Hata Çeşitleri

Kumaşların oluşumu, birbiriyle dik ve paralel pozisyonda yer alan ipliklerin belirli bir desene göre alttan ve üstten geçirilmesi suretiyle meydana gelmektedir. Bu iplikler, çeşitli malzemelerden üretilir ki bu malzemelerin arasında pamuk, yün, ipek ve keten gibi örnekler bulunmaktadır (Kısaoğlu 2006).

Dokuma sanatında, kumaşın oluşumunu sağlayan iki farklı iplik sistemi bulunmaktadır. Bu sistemlerden biri, atkılı ipliklerdir. Atkılı iplikleri, kumaşın enine yönünde konumlanmakta ve kumaşın kenarına dik bir şekilde yerleşmektedir. Diğer iplik sistemi ise çözgü iplikleridir ki bunlar, kumaşın kenarına paralel uzanmaktadır. Atkılı ve çözgü iplikleri dik açılar oluşturarak birlikte kumaşın dokusunu meydana getirmektedirler (Ala ve İkiz 2015).

Atkılı ve çözgü ipliklerinin kesişme noktaları belirli kurallara tabi bulunmaktadır. Bu kuralların belirlenmesi, kullanılan kumaşın dokuma desenine bağlı bulunmaktadır. Özellikle atkılı ipliğinin rengi, çözgü ipliğinden daha fazla etkide bulunarak kumaşın zemin rengini belirlemektedir (Ala ve İkiz 2015).

Kumaş üretim sürecinde, (Güvenoğlu ve Bağırhan 2019) tarafından belirtilen çözgü yönlü hatalar meydana gelmektedir. Bu hatalar çözgü kaçağı, çift çözgü, gevşek çözgü ve yüzen iplik olarak sınıflandırılmaktadır. Ala ve İkiz (2015) ise atkılı yönlü hatalara odaklanmış, bu hataları atkılı kaçağı, gevşek atkılı ve çift atkılı olarak tanımlamıştır. Kumaş üretimindeki diğer yaygın hata tipleri arasında, (Güler 2013)'ün işaret ettiği şantuk hatası, düğümlenme hatası, yabancı madde hatası, yağ lekesi ve delik gibi sorunlar da yer almaktadır.

Literatüre geçmiş 200 civarında kumaş hatası ve olası nedenleri belirtilmektedir. Hata çeşitlerinin çok fazla olması ve bu kusurların karmaşık olmasından dolayı bir tespit

sistemi ile tek seferde hatayı tespit etmek imkânsızdır (Çıklaçandır 2020). Diğer taraftan bunların yaklaşık 50 kadarı tekstilciler tarafından kalite kontrol kartlarına işlenmektedir (Ala ve İkiz, 2015). Ala yapmış olduğu çalışmasında bir fabrikadaki kumaş hatalarının istatistiksel verilerini kayıt altına almıştır. Öyle ki, toplam 3211 adet kusur tespit etmiş ve bu kusurları hata türüne göre sınıflandırmıştır. Çizelge 2.1’de yapılan bu çalışmadaki hata türlerinin ilk 5 tanesi görülmektedir. Bugüne kadar tespit edilen kusurların sayısal verilerine baktığımızda, en çok karşılaşılan ilk 5 hatanın toplam hatalar içindeki oranı yaklaşık olarak %85 civarlarındadır. Bundan dolayı çalışmamızda hatalı ürün klasörünü çoktan aza doğru sırasıyla; “çözümlü kaçığı”, “duruş izi”, “çözümlü yığması”, “atkı yığması”, “yarım atkı kaçığı” hatası olan ürünlerden oluşturduk.

**Çizelge 2.1** Kumaşlarda görülen hata ve miktarları (Ala ve İkiz 2015)

HATA ADI	HATA SAYISI	HATA YÜZDESİ
Çözümlü Kaçığı	1542	%48,0
Duruş İzi	492	%15,3
Çözümlü Yığması	279	%8,7
Atkı Yığması	221	%6,9
Yarım Atkı Kaçığı	191	%6,0
Diğer Hatalar	486	%15,1
Toplam	3211	%100

İmalat kalitesini arttırmak için üretim aşamasında kumaş hatalarının tespitini çok hızlı ve doğru bir biçimde yapmak gerekmektedir. Ancak hâlihazırda ülkemizde genellikle kumaşlardaki hata ve kusur tespitlerini insan gözüyle kontrol edilmektedir. Makineleşme sürecinden önce üretim daha az olduğundan hata tespitini yapmak çok daha kolaydı. Günümüzde hemen hemen her kumaş üretimi otomatik makinelerle yapıldığından ürünler bant üzerinden çok hızlı geçmektedir. Buda insan gözü ile kusurların tespitini zorlaştırmaktadır. Ayrıca bir kalite kontrol elemanının kumaş kalitesinin kontrolü esnasında işe odaklanma süresi en çok 30 dakika civarındadır (Güvenoğlu 2019). Kumaş hataları tekstil endüstrisindeki toplam hataların yaklaşık %85’ini oluşturmaktadır (Pınar 2020).


Bilgisayar programlarının gelişmesi ile kumaş hatalarını tespit etmek için birçok yazılım geliştirilmiştir. 2020’li yıllara kadar geliştirilen yazılımların birçoğu insan gözünün yakalayabildiği oranda (yaklaşık %60) hataları tespit etmekteydi. Ancak bilgisayar

destekli ekipmanlar, insan gözünden çok daha hızlı kusur tespit ettiği için başarılı olarak değerlendirilmiştir. Günümüze doğru gelindiğinde ise yapay zekâ alanında; makine öğrenmesi, görüntü işleme, derin öğrenme gibi önemli gelişmeler yaşanmıştır. Bu yazılımlarla beraber ortaya çıkan birçok algoritma yöntemi görüntü işleme üzerinde oldukça başarı elde ettiler. Görüntüleri alıp yorumlayan, hata ve kusurlarını tespit eden kütüphaneler ortaya çıkmaya başladı. Öyle ki bir görüntüdeki hatayı %90 üzerinde doğruluk payı ile kolaylıkla tespit edilebilir hale geldi.

## 2.2 Çözü Yöündeki Hatalar

### 2.2.1 Çözü kaçığı

Kumaş üretiminde en çok görülen hata türü olan çözü kaçığı, dokuma sırasında bir veya birden fazla çözü ipliğinin kopması sonucu ortaya çıkan bir hata türüdür. Bu kopma, çözü ipliklerinin eksikliği nedeniyle atkı ipliği ile olan bağlantının kaybına yol açmakta ve bu durum, kumaşın yüzeyinde çözü yönünde çizgilerin oluşmasına sebep olmaktadır. Çözü kaçığı, kumaşın estetik görünümünü ve dayanıklılığını olumsuz etkilemektedir. Otomatik tezgâhlarda, çözü ipliklerinin kopması ve çözü kontrol cihazının makineyi hemen durdurması durumunda, bu eksik iplikler kumaşa çizgiler oluşturmaktadır. Bu çizgiler, dokuma hatasının fark edilerek tezgâhın durdurulmasına kadar devam etmektedir. Dokuma hazırlığı aşamasındaki hatalar ve bobindeki ipliklerin tükenmesi gibi durumlar da dokumacının ihmalden kaynaklanan çizgilere yol açabilmektedir (Çıklaçandır 2020).



**Şekil 2.1** Çözü kaçığı

### 2.2.2 Çift çözü

Bu hata, dokuma sürecinde, bir çözü ipliği yerine yanlışlıkla iki çözü ipliğinin kullanılması durumunda meydana gelmektedir. Bu hata, her tür dokumada görülmekte ve özellikle gevşek dokuma ve sentetik ipliklerle yapılan düz kumaşlarda daha belirgin olmaktadır. Hatanın sonucunda, doku yüzeyinde iki çözü ipliği yan yana gelmekte veya bir kabarıklık oluşturarak daha kalın bir çözü oluşturmaktadır. Kumaşın üzerine ışıklı bir kontrol cihazı tutulduğunda, yan yana bulunan iki çözü ipliğinin atkılarla bağlandığı görülmektedir (Bağırğan 2019).



Şekil 2.2 Çift çözü

### 2.2.3 Gevşek çözü


Bu hata tipi, bir veya birden fazla çözü ipliğinin normalden daha gevşek olması durumunda meydana gelmektedir. Bu gevşeklik, kumaşın yüzeyinde düzensiz bir görünüm oluşturmakta ve kabarık bir duruma neden olmaktadır (Çıklaçandır, 2020).



Şekil 2.3 Gevşek çözü

#### **2.2.4 Yüzen iplik (atlama hatası)**

Çetin tarafından tanımlanan bir diğer hata tipi, çözgü ipliğinin dokuma sürecinde belirli bir süre boyunca kumaş yüzeyinde ilerlediği ve sonrasında örgüye yeniden dâhil olduğu durumlar olarak belirtilmektedir. Bu durum, ipliğin kumaş yüzeyi boyunca seyri esnasında ve sonrasında örgüye tekrar katılmasıyla ortaya çıkmaktadır (Çetin 2007).




**Şekil 2.4** Yüzen iplik

### **2.3 Atkı Yönündeki Hatalar**

#### **2.3.1 Atkı kaçığı**


Atkı Kaçağı, dokuma sürecinde atkı ipliğinin kopması sonucunda meydana gelmektedir. Bu kopma, kumaşın enine bölümünde belirli bir boşluk oluşmasına neden olmakta ve bu boşlukla kendini göstermektedir. Bu hata, farklı dokuma türlerinde görülebilmekte; ancak şardonlama işlemi görmüş kumaşlarda genellikle belirgin olmamaktadır. İnce dokumalarda bu hata daha çok dikkat çekmektedir. Küçük atkı kaçıkları, yüksek değerli kumaşlarda, ham kontrol işlemi sırasında örme yöntemiyle giderilebilmektedir. Ancak, hata büyükse ve dokumanın enine boyunca devam ediyorsa, maliyet nedeniyle genellikle düzeltme yapılamamaktadır (Acar 2005).



**Şekil 2.5** Atkı kaçığı

### **2.3.2 Gevşek atkı**

Gevşek Atkı hatası, atkı ipliğinin çözgü iplikleri arasına uygun gerginlikte yerleştirilememesi sonucu oluşmaktadır. Bu hata, gereken gerginlikte atılmayan bir veya daha fazla atkı ipliğinden kaynaklanmaktadır. Normal atkı ipliklerine göre daha az gerginlikte dokunan bir veya daha fazla atkı ipliğinin sonucunda meydana gelmekte ve dokumada gözle görülür bir farklılık yaratmaktadır (Acar 2005).



**Şekil 2.6** Gevşek atkı

### **2.3.3 Çift atkı**

Çift Atkı hatası, aynı ağızlık içine yanlışlıkla iki atkı ipliğinin konulması sonucu meydana gelmektedir. Bu durum, kumaş genişliğinde bir çizgi şeklinde kendini göstermektedir. Genellikle atkı ipliği ağızlıkta koptuğunda ve kalan iplik çıkarılmadan atkı taşıyıcısı yeniden kullanıldığında bu hata oluşmaktadır (Güler 2013).



**Şekil 2.7** Çift atkı

## **2.4 Diğer Kumaş Hataları**

### **2.4.1 Şantuk hatası**

İpliğin normal standartlara göre belirli bir bölümünde kalınlaşma olması durumu olarak tanımlanmaktadır. Dokuma sürecinde iplikte meydana gelen bu kalınlık farklılığı, hata oluşturabilir ve bu durum ‘şantuk hatası’ olarak adlandırılmaktadır.

### **2.4.2 Düğümlenme hatası**

İpliklerin birbirleriyle dolaşması ve sonucunda kumaş yüzeyinde hataya yol açması olarak belirtilmektedir. Genellikle, dokuma sırasında kopan ipliklerin birbirleriyle düğüm oluşturması durumunda bu tür bir hata meydana gelmektedir.

### **2.4.3 Yabancı madde hatası**

Dokuma sürecinde kumaş yapısına ekstra elyaf veya yabancı iplik gibi yabancı maddelerin karışması, belirli hatalara sebep olmaktadır. Örneğin, çözgü ipliği üzerinde elyaf topakları oluşumu, düğümlenmeye veya çözgü ipliği kopmalarına yol açabilmekte, hatta bazen bu iki hata aynı anda meydana gelebilmektedir. Atkı atma mekanizmasında biriken elyafın kumaşa karışması, ‘balık’ veya ‘palamut’ gibi çeşitli hataların oluşumuna neden olabilir veya atkı kopmasına sebebiyet verebilmektedir. Çözgü veya atkı ipliğine eklenen yabancı bir ipliğin sonucunda genellikle kumaş üzerinde bir çizgi şeklinde hata oluşmaktadır.


#### 2.4.4 Yağ lekesi ve delik hataları

Yağ lekesi hatası, dokuma sürecinde makine yağının kumaş ya da iplik yüzeyine damlaması ile meydana gelmektedir. Öte yandan, delik hatası genellikle kırılan bir iğne nedeniyle oluşmaktadır. Bu iki hata türü, dokuma işlemi sırasında kullanılan malzemelerin ve ekipmanın durumuna doğrudan bağlı olarak gerçekleşmektedir.



### 3. YAPAY ZEKÂ

Yapay zekâ, insan beyninin biyolojik yapısını ve öğrenme fonksiyonlarını model olarak geliştirilmiş, makine öğreniminin gelişmiş bir formu olarak kabul edilmektedir. Yapay sinir ağları, insan beynindeki biyolojik nöronları taklit eder. İnsan beynindeki nöronların biyolojik yapısı Şekil 3.1’de gösterilmiştir. Biyolojik bir nöronun dendritlerinin görevi, nöronun vücuduna gelen uyarı sinyallerini iletmektir, bunun sonucunda hücrenin kararlı durumu bozulur ve nöronda bir dizi kimyasal işlem başlar. Bir nörondaki bu kimyasal süreçte, tüm girdiler aksonlar aracılığıyla bir sonraki nörona iletilerek çalışmaktadır. Akson terminali ile nöronun bir sonraki dendriti arasındaki boşluk, sinaptik boşluk olarak tanımlanır. Yapay Sinir Ağları’nda (YSA) sinaptik boşluğun bu değişimi, öğrenim süreci olarak tanımlanmaktadır.

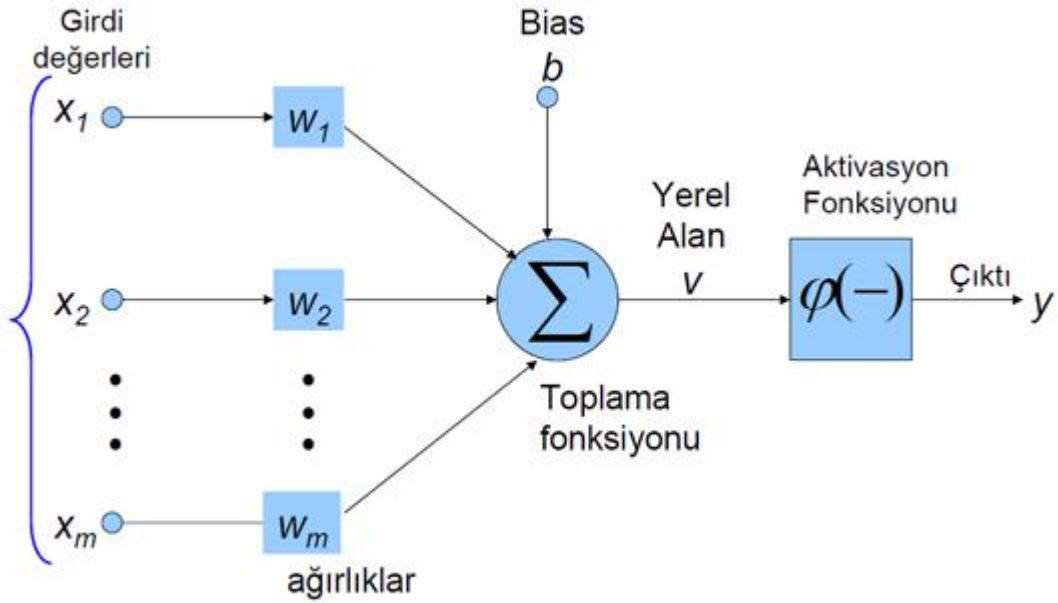


Şekil 3.1 Biyolojik beyin nöron yapısı

Yapay sinir ağları, matematiksel algoritmalar kullanılarak yapılandırılmış olup, temelde üç ana bölümden meydana gelmektedir. İlk bölüm olan girdi katmanı, sisteme giren verileri içermekte ve bu verileri işlemektedir; bu katman temelde bir giriş vektörü işlevi görmektedir. İkinci bölüm, gizli katman olarak adlandırılmakta ve YSA'nın çekirdeğini

oluşturan, nöron görevi gören sensörleri barındırmaktadır. Gizli katmanda yer alan algoritmalar, yapay sinir ağlarını kontrol etmekte beraber biyolojik nöronların fonksiyonlarını da taklit etmektedirler. Gizli katmandaki nöronlar, önceki katmandan aldıkları verileri işleyerek bir sonraki katmana aktarmakta ve bu süreçte anlamlı sonuçlar üretmeye çalışmaktadırlar.

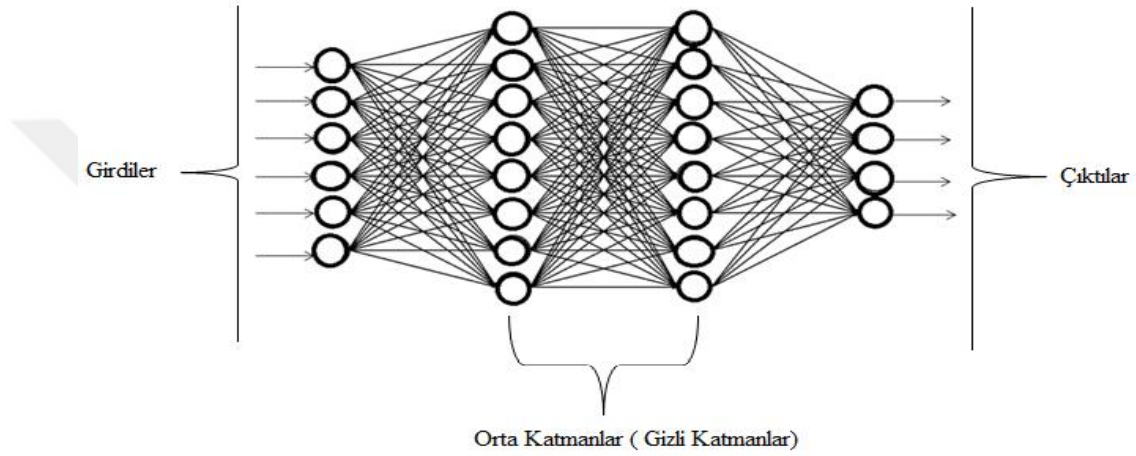
YSA girdi katmanında,  $X_1, X_2, \dots, X_i$  gibi girdi verileri bulunmaktadır. Bu veriler, YSA'nın nöronları tarafından  $W_1, W_2, \dots, W_i$  ağırlık vektörleriyle işlenmektedir. Giriş katmanındaki nöronlar, bu verileri bir aktivasyon fonksiyonundan geçirerek algoritmik bir çıktı üretmektedir. Bu süreçte,  $X_i$  giriş setinin toplamı,  $W_i$  ağırlıkları ile aktivasyon fonksiyonuna aktarılmakta ve sonuç olarak çıktı elde edilmektedir. Mekanik beyin nöronu yapısına ilişkin bir örnek Şekil 3.2'te gösterilmektedir.



**Şekil 3.2** Çok katmanlı ysa çalışma fonksiyonu

İnsan beynindeki nöronlara benzeyen şekildeki çizgiler ağırlık vektörleri olarak görev yapmaktadırlar. Ağırlık vektörünün dağılımı doğru belirlenmediği takdirde, bilgi ikinci katmana geçememekte veya eksik geçmektedir (Kızılboğa 2021).

YSA'nın giriş katmanında, her bir nörona giriş vektörü değerleri ayrı ayrı atanmaktadır. Bu değerler, JPEG formatında bir görüntünün RGB bandındaki piksel değerleri ya da ses aralığındaki titreşim değerleri gibi sayısallaştırılmış veriler olabilmektedir. Gizli katman nöronları,  $S = f(A)$  fonksiyonunu işlemekte ve her iterasyonda sapma değeri olarak bilinen bias ( $b$ ) eklemektedir. Oluşan her değer, sıradaki katmana aktarılmaktadır. Gizli katmanlardaki değerlerin bir sonraki katmana aktarılması süreci, bilginin sürekli ileri doğru taşınması nedeniyle, ileri beslemeli sinir ağı kavramını doğrulamaktadır.



**Şekil 3.3** İleri yönlü yapay sinir ağı katman yapısı


Hornik ve arkadaşları, evrensel bir yaklaşımla, standart bir çok katmanlı ileri beslemeli sinir ağının verileri yakınlığa göre sınıflandırabileceğini veya bir fonksiyonun sonucunu derecesine bakılmaksızın kabul edilebilir sonuçlarla tahmin edebileceğini savunmuşlardır. Tahmin sonucu başarısız olursa, sorun şudur: Bunun eksik girdi verileri, yetersiz gizli katmanlar, eğitim eksikliği veya girdi verileri ile ilgilenilen çıktı verileri arasındaki yetersiz korelasyondan kaynaklandığı vurgulanmaktadır (Hornik *et al.* 1989).

Sistemdeki her gizli katman aynı işlemi işleyerek ileri beslemeli ağ mantığı ile bir üst katmana ileterek, giriş katmanından başlamak üzere yayılımı sağlamaktadır. Sistem sayısallaşma sorunu ile sınıflandırma hatası verebilmektedir. Bunun bir sonucu olarak da zaman zaman sınıflandırma etiketlerinin çözülmemesi ile sorun yaşanabilmektedir. Aynı değerlerin birden çok kez yüklenmesi, ağırlık değeri özelliğinin ayarlandığı izlenimini vermektedir (Karaboğa 2020).

Bir YSA tarihine ilişkin bir öykü yazarken, 1980 öncesinin ve sonrasında farklılıkları, yazarlar için önemli bir noktadır. Yapay zeka tarihi üzerine yapılan kısaca bir değerlendirmede, 1980'ler sonrasında, doğrusal olmayan sigmoid fonksiyonları barındıran çok katmanlı algılayıcı modellerin popülerleşmesiyle YSA kullanımının artış gösterdiği görülmektedir. Sigmoid fonksiyonu,  $[0,1]$  aralığında bulanık mantık değerleri kullanan ve yapay sinir ağları oluştururken sıklıkla tercih edilen bir aktivasyon fonksiyonu olarak tanımlanmaktadır. Bu fonksiyon devamlı artış sergilemektedir (Balkışlı 2022). Denklem 3.1. de bu sorunun çözümüne ilişkin üretilen  $[0,1]$  değerine dair fonsiyonun sunumuna yer verilmektedir (Erkuş 2020).

$$y = s(x) = \frac{1}{1+e^{-x}} \quad , \quad 0 \leq s(x) \leq 1 \quad (3.1)$$

Bu fonksiyon, Sigmoid fonksiyonu olarak bilinmekte olup, fonksiyona ait grafiğe Şekil 3.4'de yer verilmektedir (Balkışlı, 2022).



**Şekil 3.4** Sigmoid fonksiyonunun gösterimi

Sigmoid fonksiyonu, nöral ağlarda genellikle ağırlıklı toplamların bir katmanı olarak ve daha sonra kısmi öğrenme ile desteklenen bir karar fonksiyonu olarak kullanılmaktadır. 1980'lerde bu fonksiyonun işlevselliği, güçlü bir bağlantılılık ile yeniden canlanmış ve önem kazanmıştır (Karaboğa 2020).

Bununla birlikte Sigmoid fonksiyonu, ileri beslemeli bir fonksiyon olarak, ađın geriye d6n6k bildirimlerinin iřlenemediđi g6r6lmektedir. Bu da sistem 6zerinde ileri beslemeli ađın, geri d6n6ř6 olmaksızın belli bir aıyla uzaklařmasını sađlamaktadır (Mira 1995). İki y6nl6 yani ileri ve geri yayılımlı yapay sinir ađlarına bu sebeple ihtiya duyulduđu ortaya ıkmıřtır.

Yapay sinir ađları sorununun 6z6lmesi, 21. yy. bařlarında gerekleřtiđi g6r6lmektedir. Paket programlara ait ikili basit makine 6đrenmesinde ise halen iki n6ronlu ileri beslemeli ađ yapısının kullanıldıđı g6r6lmektedir (Samatin and Zhao 2016).

Sigmoid fonksiyonunun kullanımı bađlamında, yapay zekâ ve YSA alanlarında, farklı aktivasyon kodları denemeleri yapılmıřtır. Bu abalar hem ileri beslemeli hem de geri beslemeli ađlar iin eřitli yaklařımların geliřtirilmesine odaklanmış ve bu s6rete yeni aktivasyon kodları oluřturulmaya alıřılmıřtır (Roodschild *et al.* 2020). Bunlar arasında en iyi bilinen ve sıklıkla kullanımına bařvurulan etkinleřtirme kodları, hiperbolik teđet iřlevi, ReLU ve Softmax iřlevleri olarak sıralanmaktadır (Erkuř 2020).

2000 yılı itibariyle, YSA algoritması, makine 6đrenmesiyle karřılařtırıldıđında birok avantaj sunmuř olmasına rađmen, maliyetli bulunmuřtur. Bu durum, probleme 6zg6 tasarlanmış destek vekt6r makinelerinin tercih edilmesine ve sonu olarak uzun eđitim s6relerine yol amıřtır. Uzun s6ren yapay zekâ eđitim s6releri, zaman iinde arařtırmacıları daha kısa s6rede eđitilebilir veya bazen hi eđitime ihtiya duymayan modellerin geliřtirilmesi fikrine y6nlendirmiřtir (Bramer 2016). Bu ihtiyacın bir sonucu olarak da, yapay sinir ađları artan hesaplama hızları, hesaplamalı grafik iřlem birimleri (GPU) kullanımını temel alan modellerin geliřimi dođurmuřtur (Balkıřlı 2022).

2000 yılı 6ncesinde, YSA algoritması makine 6đrenmesine kıyasla birok avantaj sunmasına rađmen, uzun eđitim s6releri ve y6ksek maliyetler nedeniyle tercih edilmemiřtir. Bunun yerine, 6zel olarak tasarlanmış destek vekt6r makineleri kullanılmıřtır. YSA'nın sonraki d6nemde tercih edilmesi, bilgisayarların artan iřlem hızları, grafik iřlem birimlerinin (GPU) hesaplamalarda kullanılması ve modellerin daha hızlı eđitilebilmesi gibi fakt6rlere bađlı bulunmaktadır (Bramer 2016).

### 3.1 Yapay Zekânın Gelişiminde Makine Öğrenmesi

1936'da Rudolf Carnap, "*Viyana Sözdizimsel Yapılarını*" yazmıştır. 1954'te Soğuk Savaş döneminde, ABD ordusu, Rusça belgeleri ve akademik makaleleri otomatik olarak çevirebilecek bir program talep etmiş, bu süreçte yapay zekâ önem kazanmış ama henüz istenen seviyede olmadığı görülmüştür. Ancak, sibernetik elektriksel kontrol bilimi 1951'den itibaren ilgi çekmeye devam etmiştir. Yapay zekâyâ olan ilgi, denklik reddiyle azalmıştır (Skansi 2018).

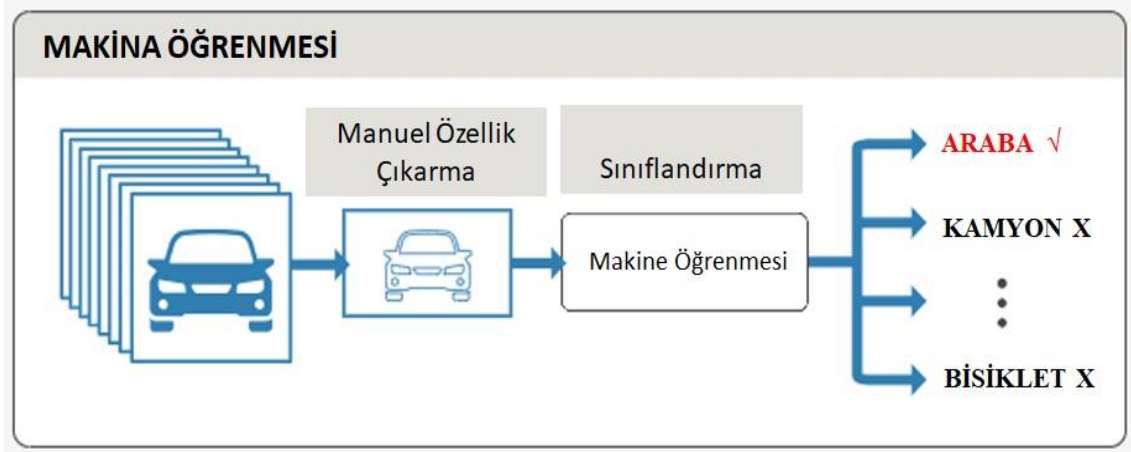
XOR problemi, modern sinir ağlarının karşılaştığı bir sorun olarak gösterilmekte, özellikle bu işlem eksik olduğunda grafiklerin doğrusal olarak temsil edilmesi gerektiğinde ortaya çıkmaktadır. İki boyutlu bir algılayıcı sistemde, bu sorun, çıktının doğrusal olmasından ve grafiğin eğriler içermemesinden kaynaklanmaktadır. XOR problemi, doğrusal olmayan ve türevlenebilir bir Sigmoid fonksiyonu kullanılarak çözülmüş ve bu çözüm, çok katmanlı algılayıcıların fikrini ortaya çıkarmıştır (Paluszek and Thomas 2017).

Support Vector Machines (SVM), ilk olarak 1963 yılında Vladimir Vapnik ve Aleksei Chervonenkis tarafından önerilmiş, istatistiksel öğrenmeye dayanan bir tür denetimli öğrenme algoritmasıdır. Ivahnenko ve Lapa tarafından 1965 yılında geliştirilen ileriye saçılan algılayıcı pek ilgi görmemiştir. Aynı yıl, Nilssons *Learning Machines* kitabını yayınladı. Yayımlanan eserde yapay zekâ ve makine öğrenimi üzerine yapılan tüm araştırmalar toplanmıştır (Vapnik 1963). 1969 yılında Amerikan yapay zekâ araştırma kuruluşu DARPA, XOR sorunu nedeniyle yapay zekâ ve makine öğrenimi üzerine araştırmaları desteklemeyeceğini açıklamıştır. Çok katmanlı perceptron, 1974 yılında Werbos tarafından geriye yayılım tekniği olarak geliştirilmiş ve yapay zekâ ile makine öğrenmesi alanlarında önemli bir yere sahip olmuştur. Bu yaklaşım, 1986 yılında Rumelhart'ın çalışmaları ile daha da ün kazanmış ve bu alanlarda temel bir yapı taşı haline gelmiştir (Lucci *et al.* 2022).

### 3.2 Makine Öğrenmesi

Makine öğrenmesi, otomasyon sağlayarak ve belirli bir sorunu çözmek için modelleri eğiterek sorun çözme sürecini hızlandıran bir dizi yazılım kodlama tekniklerini kapsamaktadır. Makine öğrenimi, performansı artırmak ve doğru tahminler yapmak amacıyla deneyimlerden yararlanan bilgisayar yöntemleri olarak en geniş anlamıyla tanımlanabilmektedir (Weeks 1996).

Makine öğrenimi, bir çözüm üretmek amacıyla belirlenmiş bir sorunu, tasarlanmış bir modelin oluşturularak, veriler üzerine eğitilerek, sorunun tanıtılmasını amaçlayan sistemler olarak bilinmektedir. Bu öğrenme biçimi, yapay zekânın bilgiyi temsil eden bir alt kümesi olarak kabul edilmektedir. Makine öğrenimi, bir veri kümesindeki örüntüleri tanıyan ve bütüne bağlı olarak istenilen nesneye göre eğitilen ve modellenen bir algoritmaya göre çözümü çıktı olarak sunan bir yöntem sunmaktadır. Yapay zekâ disiplinleri, rasyonel karar verme süreçlerinde istatistik, mantık ve hesaplama yöntemlerini bütünleştirerek sıklıkla makine öğrenimine başvurulmaktadır. Şekil 3.5’de bu öğrenme biçimine dair bir görsele yer verilmektedir.



Şekil 3.5 Klasik makine öğrenmesi (Kotsiantis *et al.* 2006)

### 3.2.1 Makine öğrenmesi çeşitleri

Büyük veri, geleneksel veri işleme yöntemleriyle tam ve etkin bir şekilde analiz edilemeyen, doğrulama işlemlerinin sınırlı bir biçimde gerçekleştirilebildiği durumlar için uygulanan geniş veri kümeleri olarak belirtilmektedir. Bu kapsamda, büyük veri imajları, imaj kavramı içinde yer almakta ve doğru sınıflandırmaların yapıldığı bir alan olarak tanımlanmaktadır.

Yapay sinir ağlarının daha geniş makine öğrenimi eğitiminde, yapay zekâ teknolojisinde ve derin öğrenme yöntemlerinin görüntü sınıflandırmasına ve oluşturulan veri kümelerindeki girdilerin ve çıktılarının uygun şekilde adlandırılmasına uygulanmasında önemli bir rol üstlenmektedir. Uygulamada oluşturulan ve amaca hizmet eden verilerin birleştirilmesi, aynı nesnenin veya canlının, farklı canlı türlerinin, farklı canlı ve cansız formlarının çekilmiş fotoğraflarının doğru sınıflandırılmasını ve anlamlandırılmasını sağlama işlevi bulunmaktadır. Veri kümeleri oluşturmak için çeşitli çerçeveler sürekli olarak üretilir, etiketlenir ve saklanır. Etiketlenen her veri, veri ambarında yerini aldığından, tekrarlanan model eğitimi olmadan sınıflandırmaya olanak tanınmasıyla öne çıkmaktadır. İncelenen her biçim için veri bolluğu, daha doğru makine öğrenimi ve YSA eğitimi sağlar. Bu nedenle verilerin doğru sınıflandırılması ve saklanması, büyük veri kaynaklarına açık erişime aktarılması, verilerle ilgili görsel kütüphanelerin oluşturulması, yapay zekâ araçlarının kullanımının artırılması ve doğru tanımlamaların yapılması önemli kabul edilmektedir. Bu nedenle tıbbi araştırmalarda hastalıkların teşhisinde yapay zekânın kullanımını kolaylaştırmak ve hastalıkları çok kısa sürede teşhis etmek, eğitim ve diğer alanlarda yapay zekânın kullanımını kolaylaştırmak ve birçok verinin sağlanmasına katkıda bulunmak için büyük veri setlerine sahip kütüphanelerinin oluşturulmasıyla, insanların birçok çevrimiçi hizmeti çok daha düşük bir fiyata alabilmesi sağlayacak sistemleri akla getirmektedir.

Günümüzde sıklıkla duyulan, büyük veri kümeleri oluşturmayı amaçlayan veri madenciliği de bu hizmetlerin daha çok sağlanması işlevine katkıda bulunmasının genel adı olarak kabul edilmektedir. Çünkü bilginin doğru kullanımı için bilgiyi elde etmek, onu depolamak, bilgiyi analiz etmek ve yönetmek için çeşitli kaynaklardan toplayan

bilimsel bir disiplin olarak tanımlanmaktadır. Veri madenciliği bilgi sistemleri, çeşitli kaynaklardan elde edilen verileri ve istatistiksel bilgileri toplamakta, saklamakta ve gerektiğinde bu bilgileri hızlı ve karmaşık analizler yaparak kullanıcıların ihtiyacına göre sunmaktadır. Makine öğrenimi, bilgiyi elde etmek için bilgi toplayan ve yöneten yapay zekâ algoritmalarının temelini oluşturmaktadır. Örneğin günümüzde arama motoru olarak hizmet veren Google çalışma mantığı da büyük ölçüde büyük veri madenciliği temeline, en çok ziyaret edilen siteler temeline yönlendirmek ve veri madenciliğine katkıda bulunmak üzere makine öğrenmesini temel almaktadır. Örnekteki Google arama motoru deneyimi, genellikle elektronik verilerle karıştırılan ve analiz için saklanan bilgidir. Makine öğrenimi, genellikle üç ana kategori altında incelenmektedir: Denetimli, denetimsiz ve yarı denetimli öğrenme olarak adlandırılan bu kategoriler, makine öğreniminin temel yöntemlerini oluşturmaktadır (Erkuş 2020).

### 3.2.1.1 Denetimli öğrenme

Denetimli öğrenme, her bir algoritmanın çıktılarının ve ilişkili girdi verilerinin bir araya getirildiği bir veri seti üzerinde çalışmaktadır. Bu veri seti, yüklenen algoritmalar ve sistem çıktıları arasındaki ilişkileri analiz ederek karar verme mekanizmasını öğrenmektedir (Sammur 2010).

$$y = f(x) \tag{3.2}$$

Denklem (3.2)'deki  $f(x)$  fonksiyonunun asıl amacı bir  $X$  girdisi geldiğinde  $Y$  çıktısını tahmin edebilmektir. Denetimli öğrenmeyi iki çeşit olarak ayırabiliriz. Biri regresyon diğeri ise sınıflama (Şahin 2018). Çıktı değeri ( $Y$ ) gerçek bir sayıdan ibaret olduğu durum regresyon, kategorik bir çıktı olduğu durum ise sınıflandırma olarak adlandırılır.

Örneğin bir öğrencinin sene boyunca aldığı notların ortalamasını puan olarak yansımaları regresyon, bu notun herhangi bir kriterle değerlendirilip sonuç olarak sadece “geçti” ya da “kaldı” olarak yansımaları sınıflandırmaya girer.

### **3.2.1.2 Denetimsiz öğrenme**

Bu, veri setinde etiketlerin olmadığı, sistemin çıktısını girdiye almayı nispeten zorlaştıran bir öğrenme şekli olarak kabul edilmektedir. Denetimsiz öğrenmede aynı danışmalı öğrenme gibi iki çeşide ayrılır. Bunlardan birincisi olan kümeleme faktörü, birbirinden değişik grupların bulunduğu yer, diğer denetimsiz öğrenme türü olan birliktelikse dataların büyükçe kısmını vasıflandıran problemdir (Şahin 2018).

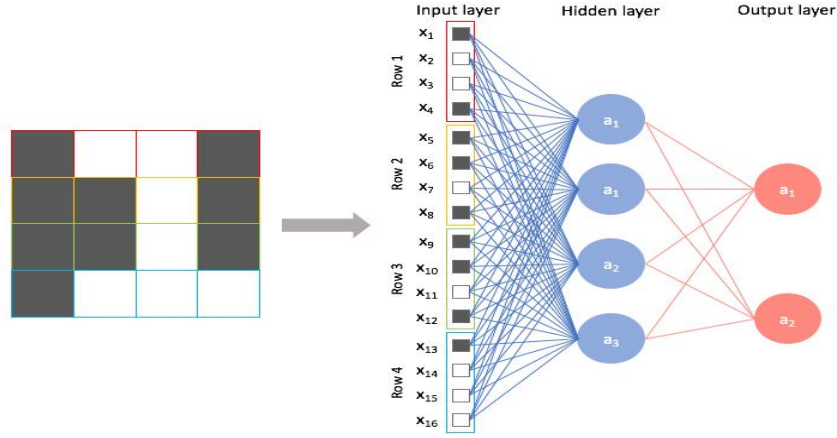
Kümelendirme denilen sınıflandırma içeren makine öğrenmesi, bu tür öğrenmeye bir örnek olarak kabul edilmektedir (Sağıroğlu *et al.* 2003).

### **3.2.1.3 Yarı denetimli öğrenme**

Makine öğreniminin, yarı denetimli öğrenme türü, insan öğrenimi ile oldukça benzeşmektedir. Bu öğrenme türü hem denetimli hem de denetimsiz olarak davranabilir. Etiketlenmemiş verilere göre etiketlenen verilerin daha az olduğu bu tür öğrenmede, etiketlenmemiş verileri, etiketlenen verilere göre ayırmaya çalışmaktadır. Bu tür öğrenmelerin örnekleri günümüz web arama motorları için tercih edilen öğrenme biçimi olarak da bilinmektedir (Sağıroğlu *et al.* 2003). Genellikle kalıtım sıralamalarında ve network sınıflandırmalarında kullanılmaktadır (Öztürk 2023).

## **3.3 Derin Öğrenme**

Derin öğrenme kavramı Geoffrey Hinton ve ekibi tarafından 2006 yılında yapılan bir yayınlara daha da popüler hale gelmiştir. Derin öğrenme ağları, katman sayısı arttıkça daha karmaşık hale gelmektedir. Ağın derinliği arttıkça artan hesaplama yükü ve geri besleme sinyalinin katmanlar arasında kaybolma riski, derin öğrenmenin karşılaştığı en büyük sorunlardan bazılarıdır. Ayrıca, eksik veriler fazla uyuma yol açabilmekte ve bu da derin öğrenme modellerinin etkinliğini azaltabilmektedir.



**Şekil 3.6** Derin sinir ağı (Mira 1995)

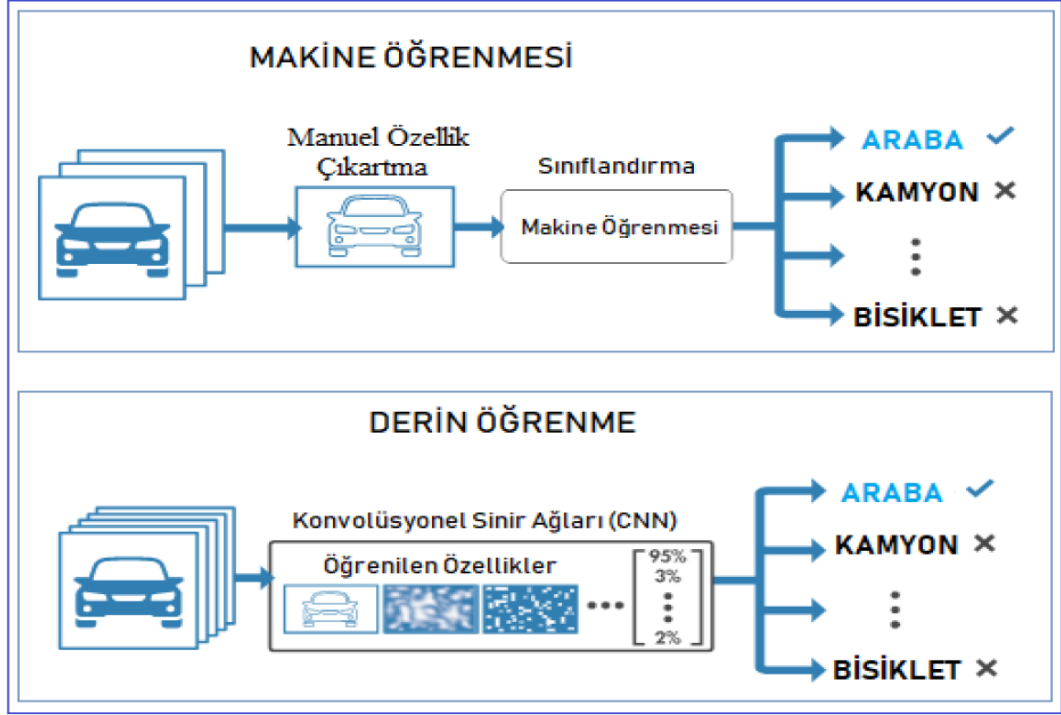
Denetimsiz öğrenme, veri setlerini etiketlemeden çalışan ve girdi verilerinden sistem çıktılarını elde etmenin daha zor olduğu bir öğrenme metodudur. Kümeleme, denetimsiz öğrenmenin tipik bir örneği olarak belirtilmektedir (Jaderberg *et al.* 2015).

2000 yılından itibaren bazı temel ancak önemli algoritmalar geliştirilmiştir. Bu algoritmalar, sinyallerin daha etkili bir şekilde geri gönderilmesine yardımcı olmuştur. Bunlar arasında; geliştirilmiş katman aktivasyon fonksiyonları (örneğin, ReLU, Softmax), daha iyi başlangıç ağırlık başlatma teknikleri, ileri düzey optimizasyon metodları (örneğin, RMSProp, Adam) bulunmaktadır.

Toplu normalleştirme, artık bağlantı ve derinlemesine ayrılabilir evrişim gibi teknikler, hata sinyalinin geri yayılımını iyileştirerek yüzlerce katmandan oluşan ağların oluşturulmasına imkân tanımaktadır. Bu teknikler, modelin başlangıçtan itibaren eğitilmesine olanak sağlamaktadır. Bu çalışmada, kumaş hatalarının belirlenmesinde derin öğrenme yöntemleri kullanılmıştır.

### 3.3.1 Derin öğrenmenin avantajları

Derin öğrenme, katmanların temsillerini ayrı ayrı değil, entegre bir şekilde öğrenmektedir. Bu sayede, düz modelleri birbirinin üstüne eklemek yerine, ara katmanlar aracılığıyla soyut temsillerin öğrenilmesi mümkün hale gelmektedir.



**Şekil 3.7** Makine öğrenmesi ile derin öğrenme karşılaştırılması

Derin öğrenmenin temel ayırt edici özelliklerinden biri, verileri model için anlamlı hale getirmek amacıyla yoğun ön işleme gereksinimi duymamasıdır. Geleneksel yöntemler, sorunların çözümüne katkıda bulunmak için veri girişlerinden özellikler çıkarmayı gerektirirken, derin öğrenme bu süreci tamamen otomatikleştirerek insan müdahalesini azaltmaktadır. Şekil 3.7, klasik makine öğrenimi modelleri ile derin öğrenme modellerinin, görüntülerdeki veri girişlerini nasıl işlediğini görsel olarak açıklamaktadır.

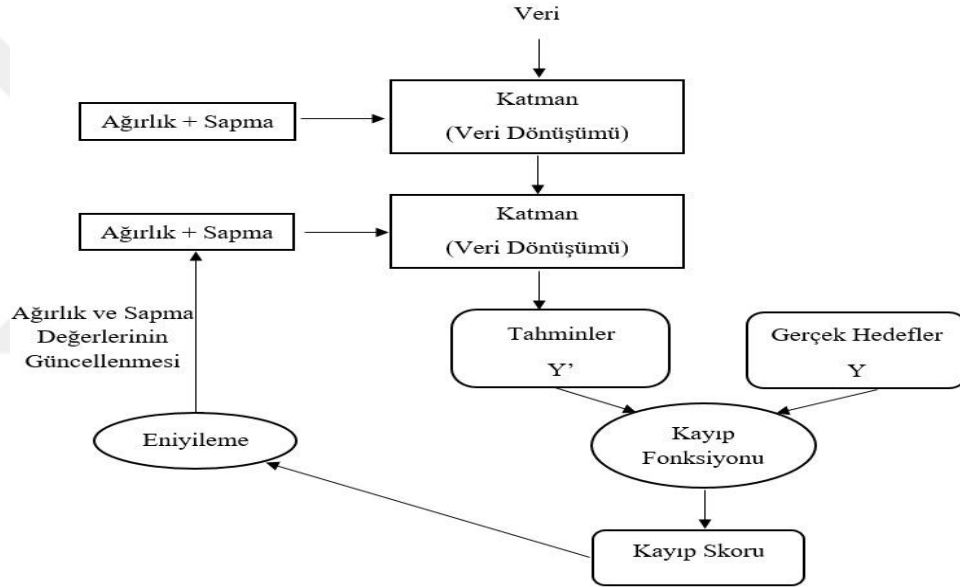
Derin öğrenme yöntemlerinde, eğitim verilerinin çeşitliliği ve miktarı arttıkça başarı oranları genellikle yükselmektedir. Derin öğrenme, geniş bir eğitim verisi seti gerektirirken, geleneksel makine öğrenimi yöntemleri daha az veri ile de iyi sonuçlar verebilmektedir.

Derin öğrenme ile çalışırken, çoğunlukla üç farklı yaklaşım benimsenmektedir. Birincisi, bir sorunu çözmek için uygun bir modeli tasarlamak ve eğitmektir. Ardından, bu önceden eğitilmiş ağ yeni verilerle tekrar eğitilmektedir. Son olarak, derin sinir ağlarından elde edilen özellikler, diğer makine öğrenimi modellerinde kullanılmak üzere çıkarılmaktadır.

Bu çalışmada, görüntü tanıma yöntemleri kullanılarak kumaş hatalarının tespiti yapılmış ve bu üç yöntem tümüyle uygulanmıştır.

### 3.3.2 Derin öğrenmede rol oynayan temel kavramlar

Derin öğrenme ağ yapısında, bağlantılı katmanlar kullanılarak girdi verileri tahminlere dönüştürülmektedir. Tahminlerin hedef değerlerle ne kadar uyumlu olduğunu değerlendirmek için, tahmin ve hedef arasındaki farkı belirleyen bir kayıp fonksiyonu kullanılmaktadır. Ağırlık ve sapma değerleri, bu kayıp değerine göre optimizasyon algoritması tarafından güncellenmektedir.



Şekil 3.8 Derin öğrenme algoritması

#### 3.3.2.1 Ağırlık

Sinir ağlarında eğitim sırasında kullanılan parametrelerden biri olan ağırlıklar, İngilizce’de ‘weight’ kelimesinden türetilerek genellikle ‘W’ harfi ile temsil edilmektedir. Sinir ağları, eğitim sürecinde, önemli bulunduğu girdilere daha yüksek ağırlık değerleri atmaktadır.

### 3.3.2.2 Sapma

Sinir ağılarında kullanılan eğitilmiş parametrelerden biri, İngilizce'deki 'bias' anlamına gelmekte ve genellikle 'b' harfi ile temsil edilmektedir. Ağırlıkların yanı sıra kullanılan bu ek doğrusal bileşen, sapma olarak adlandırılmaktadır. Bu değer, ağırlıklandırılmış girdilerin aralığını temelde değiştirmek amacıyla ağa eklenmektedir.


### 3.3.2.3 Aktivasyon fonksiyonu

Bu fonksiyonlar, tensörler üzerinde etkili olan doğrusal olmayan operasyonlardır ve amacı ağırlık ve sapma değerlerinin ayarlanması olmaktadır. Bu, nöronların aktivasyonu olarak da düşünülebilmektedir; yüksek bir değer alındığında nöron, daha güçlü bir sinyal üretmesi beklenmektedir. Yapay zekâ ve YSA'nda mükemmel bir yenilik meydana getiren Sigmoid Fonksiyonu ile ilişkin teferruatlı bilgiler verilmiştir. Ayrıca, Hiperbolik Tanjant Fonksiyonu, ReLU Fonksiyonu ve Softmax Fonksiyonları gibi diğer sık kullanılan fonksiyonlar hakkında da bilgiler verilmektedir.

Hiperbolik Tanjant Fonksiyonu (Tanh): Sigmoid Fonksiyonunun genişletilmiş bir versiyonu olarak  $[-1, 1]$  aralığında değerler almaktadır.

ReLU fonksiyonu: Sigmoid fonksiyonunun benzer bir sorunu yansıtmaktadır. Bu fonksiyonda 0'dan küçük değerler 0 olarak kabul edilmektedir. Pozitif değerler ise kendi değerlerini korurlar. ReLU fonksiyonunun dezavantajlarından biri, Sigmoid fonksiyonunda olduğu gibi, negatif değerlerin 0 olarak kabul edilmesidir. Bu, negatif ağırlık değerlerine sahip nöronların etkinliğini yitirmesi ve eğitim sürecinde tekrar aktif hale getirilememesi sorununa yol açmaktadır.

Softmax fonksiyonu: Girdiler için sınıflandırma olasılıklarına dayalı kayıp değerler üretmektedir. Sınıflandırıcı, girdilerin gerçek sınıflara ait olasılıkları ile olabilecek en yüksek olasılık fonksiyonunun normalizasyonunu yaparak, iki değer arasındaki çapraz entropiyi en aza indirmeye çalışmakta ve böylece çıktıları sunmaktadır.



**Şekil 3.9** Aktivasyon Fonksiyonları

Derin öğrenme alanında, farklı aktivasyon fonksiyonları bulunmaktadır ve bu çalışmada en yaygın kullanılan aktivasyon fonksiyonlarına odaklanılmıştır. Çalışmanın kapsamında, sınıflandırma amacıyla kullanılacak olan aktivasyon kodu, softargmax, argmax olarak da bilinirken, en yaygın tanınan adıyla softmax fonksiyonu olduğu belirtilmektedir.

### 3.3.2.4 Öğrenme katsayısı

Yapay Sinir Ağları'nda, öğrenme katsayıları, yani hata düzeltme katsayıları, taşıyıcı sinapslar gibi işlev görmekte ve gradyan iniş algoritmasında kullanılmaktadır. Öğrenme katsayısı, eğim inişi algoritmasının yakınsamasını etkileyen bir faktör olarak belirtilmektedir. Bu katsayının büyüklüğü arttıkça, sinapslar bilgiyi bir sonraki katmana etkin bir şekilde iletememektedir. Öğrenme katsayılarının ayarlanmasında çeşitli optimizasyon algoritmaları kullanılmaktadır. Bu algoritmaların temel amacı, öğrenme sürecinin ilerleyişini belirlemektir. Eğime dayalı olarak en sık tercih edilen algoritmalar arasında Adagrad, Adamax, Nadam, Adadelat, RMSprop ve Momentum algoritmaları bulunmaktadır.

### 3.3.2.5 Kayıp fonksiyonu

Bir kayıp fonksiyonu, ağın tahminlerinin doğruluk derecesini hesaplamak için kullanılmaktadır. Bu fonksiyon, ağın gerçek değerlerle uyumsuz tahminler yapması durumunda, ağa bir hata bedeli atmaktadır. Sınıflandırma problemlerinde, kategorik

çapraz entropi fonksiyonu yaygın olarak tercih edilmektedir. Çalışma kapsamında ele alınan problem bir sınıflandırma sorunu olduğundan, kullanılan modelde bu fonksiyon kullanılmıştır.

### **3.3.2.6 Geri yayılım**

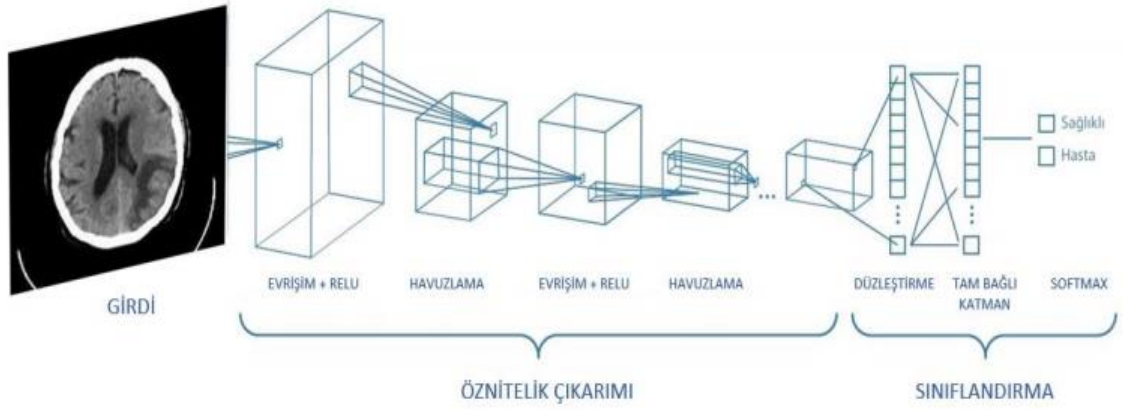
Her yineleme sırasında ağdaki hataları tespit ederek ağa geri beslenmekte ve bu bilgi, ağın ağırlıklarını güncellemek için kullanılmaktadır. Sonraki yinelemelerde, bu ağırlıklar, hatanın en aza indirilmesi amacıyla düzenlenmektedir. Ağırlıkların, kayıp fonksiyonunun eğimi ile güncellenmesi süreci ‘geri yayılım’ olarak adlandırılmaktadır.

### **3.3.2.7 Yiğın, epok ve tekrar sayısı**

Toplu işlem, bir modelin bir seferde işlediği veri miktarını ifade eder. Bütün girdileri tek seferde işlemek yerine, girdiler gelişigüzel seçilmiş ve eş değer büyüklükte bağımsız gruplara bölünmekte ve ardından ağ bu gruplar üzerinde eğitilmektedir. Tüm girdi gruplarının aynı anda işlendiği sürece ‘epok’ denmekte ve her bir grup sırasıyla işlenmektedir. Yapay sinir ağını eğitmek için kullanılacak örnek sayısına yiğın denir. Yapay sinir ağında veri setinin tam bir tur atmasına eğitim turu (epoch) denir.

### **3.3.3 Evrişimsel sinir ağı**

Evrişimli sinir ağlarının (ESA) adı, bu ağ yapısının temel ögesi olan evrişimli katmandan gelmektedir. İlk zamanlar Amerika Birleşik Devletleri Posta Servisi tarafından zarflar üzerindeki posta kodlarını okumak amacıyla kullanılmıştır (Sağıroğlu, et al., 2003). Evrişimli sinir ağları, özelleştirilmiş doğrusal işlemler içeren katmanlara sahiptir. Bu yapıda, belirlenen doğrusal fonksiyonlardan seçilen bir fonksiyon kullanılmakta ve sinir ağı, bir veya daha fazla katmanda yer alan matris çarpımlarının evrişim işlemleriyle değiştirilerek tanımlanmaktadır (Pratt, 1994).



**Şekil 3.10** ESA mimarisi katmanları

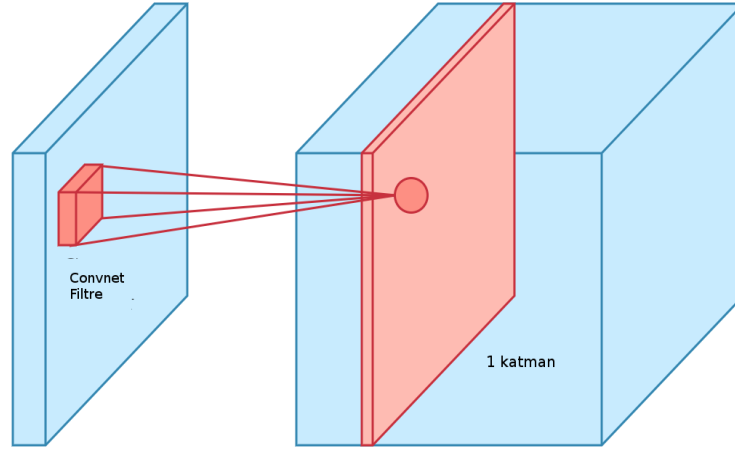
Evrışimli sinir ağlarının, özellikle 2 boyutlu verilerle, örneğin görüntülerle, etkili bir şekilde çalıştığı yaygın olarak kabul edilmektedir. Bu görüş, bir evrişim katmanındaki her bir filtresinin, girdiyi üç boyutlu nöron aktivasyonlarına dönüştürme kapasitesinden kaynaklanmaktadır. Bu ağ yapısı, görsel korteksin nörobiyolojik yapısından esinlenerek geliştirilmiştir ve görsel nesne tanıma alanında özellikle etkili olmaktadır. Şekil 3.10, bir evrişimli sinir ağının katmanlarını göstermektedir (Goodfellow, et al., 2016). Evrişimsel Sinir Ağları (ESA) mimarileri, temel olarak beş ana katmandan oluşan yapılar olarak modellenmektedir:

### 3.3.3.1 Giriş katmanı

Bu katman, ESA'nın ilk katmanını oluşturmaktadır. Girdi, herhangi bir işleme tabi tutulmadan doğrudan ağa verilmektedir.

### 3.3.3.2 Evrişim katmanı

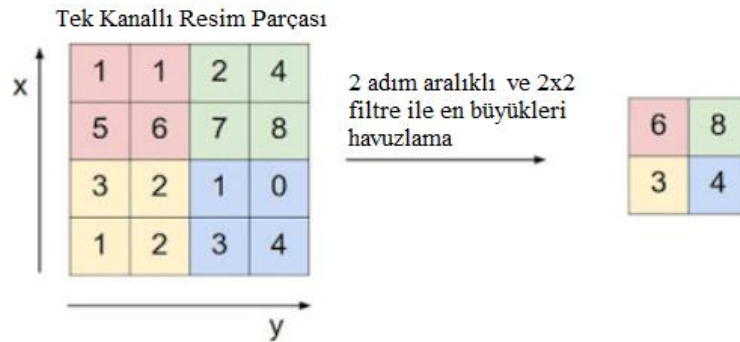
Doğrusal bir işlem olan evrişim sayesinde, girdilerin bölgesel örüntüleri öğrenilmektedir. Böylece, resmin bir bölgesinde öğrenilen bir örüntü, farklı bir konumda ortaya çıktığında yeniden eğitim gerektirmeksizin tanınabilmektedir.



**Şekil 3.11** Evrişim katmanı

### 3.3.3.3 Havuzlama katmanı

Bu katmanda, kanal sayısı değiştirilmeden boyut azaltma işlemi yapılmaktadır. Belirli bir filtrenin içindeki piksellerin maksimum değerleri veya ortalamaları alınarak, yükseklik ve genişlik boyutları küçültülmektedir. Bu işlem, belirli bir bilgi kaybına yol açsa da hesaplama yükünü azaltmakta ve evrişim katmanlarının daha geniş alanları kapsamalarını sağlamaktadır (Wang & Raj, 2017).



**Şekil 3.12** Filtreleme işlemi

### 3.3.3.4 Tam bağlı katman

Genellikle modelin son bölümlerinde yer almakta ve sınıf tahminlerini optimize etmek amacıyla kullanılmaktadır.

### 3.3.3.5 Çıktı katmanı

Sınıflandırmanın gerçekleştiği katmandır. Sınıflandırma işlemlerinde genellikle yüksek başarı gösteren softmax aktivasyon fonksiyonu kullanılmaktadır. Var olan sınıf sayısı kadar çıkış değeri bulunmaktadır.

### 3.3.4 Evrişimsel sinir ağları modellerinin tasarlanması

Evrişimsel Sinir Ağları için çeşitli modellerin tasarlanması mümkündür ve model seçimi, problemin çözümünde önemli bir rol oynamaktadır. Özellikle 2 boyutlu görüntü tanıma amaçlı pek çok başarılı model bulunmaktadır. Bu modeller, temel katmanların farklı düzenlemeleriyle, giriş ve çıktı katmanları dışında, çeşitli mimari yapılar oluşturulmasını mümkün kılmaktadır. İnternet üzerinden toplanan ve etiketlenen yaklaşık 1,5 milyon görüntüyü içeren ImageNet veri seti, ESA yapılarının görsel tanıma alanındaki başarısını kanıtlamıştır (Krizhevsky *et al.* 2012).

Kumaş hatalarının yüzey görünümelerini tespit etmek amacıyla, derin öğrenmenin üç yaygın yöntemi bu çalışmada uygulanmıştır. İlk olarak, özel olarak probleme yönelik bir model oluşturularak eğitilmiştir. İkinci olarak, önceden eğitilmiş bir model, aktarımlı öğrenme yöntemiyle yeni verilerle eğitilmiştir. Son olarak, derin öğrenme modeli, yalnızca özellik çıkarma amacıyla kullanılmış ve elde edilen öznitelikler geleneksel makine öğrenme yöntemleri ile sınıflandırılmıştır. Bırakma tekniği, sinir ağlarında ezberlemeyi önlemek için en etkili ve yaygın kullanılan yöntemlerden biridir. Bu teknik, eğitim sürecinde katmanın öğrendiği bilgilerin bir kısmını rastgele olarak sıfırlamaktadır. Amacı, nöronlara bağımsızlık kazandırarak ağırlıklarının daha etkin şekilde eğitilmesine yardımcı olmaktır.

### 3.3.5 Aktarımlı öğrenme

İnsanlar, bir alanda edindikleri deneyimleri benzer özelliklere sahip diğer alanlarda kullanabilirler. Örneğin, araba kullanmayı öğrenen bir kişi, bu deneyimi kamyon

kullanmada da deęerlendirebilmektedir. Yapay sinir aęları, bilgiyi veya deneyimi modelin aęırlık ve sapma deęerlerinde depolamaktadır.

Önceden eęitilmiş modeller, eęitim görmemiş modellere kıyasla daha hızlı öęrenebilmekte veya daha başarılı olabilmektedir. Bu yaklaşım, daha az veriyle farklı bir sorunu çözmede, görsel özelliklerin anlamlandırılmasında eęitilen sınıfların avantajını sunmaktadır. Bu çalışmada, hayvanlar ve günlük nesnelere içeren ImageNet veri seti, VGGNET, Inception ve ResNet gibi farklı ESA mimarileri kullanılarak başarılı bir şekilde sınıflandırılmıştır.



## 4. MATERYAL YÖNTEM

Gerçekleştirilen çalışma iki temel bölümden oluşmaktadır. İlk kısım veri setinin oluşturulması, ikinci olarak, sistemin seçilen kumaş hatalarını tanıyabilmesi için farklı modellerin geliştirilip eğitilmesi sınıflandırması ve başarısının değerlendirilmesidir. Son aşamada bunu bir program yazılarak, seçilen resimlerin bilgisayara bağlı webcam vasıtasıyla kameraya gösterilen görüntünün ekrana gerçek zamanlı metin olarak yazdırılması amaçlanmaktadır.

### 4.1 Veri Setleri

Tekstil sektörü çok geniş bir Pazar payına sahip olduğundan, kumaş iyileştirmeleri için birçok çalışmalar mevcuttur. Bununla birlikte birçok kumaş hataları ile ilgili veri setleri hazırlanmıştır. Çizelge 4.1’de en çok kullanılan 9 veri seti ve bilgileri yer almaktadır.

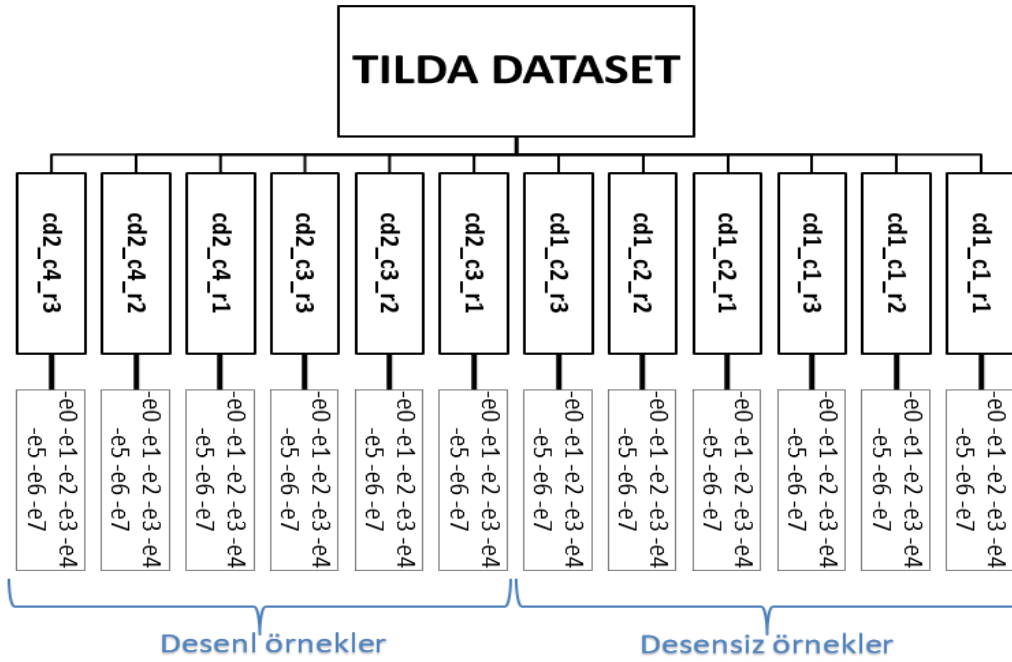
**Çizelge 4.1** Kumaşlar için oluşturulmuş halka açık veri setleri (Kahraman 2022)

VERİ SETİ	ÖRNEK SAYISI	HATA SAYISI	ÇÖZÜNÜR LÜK	KUMAŞ TİPİ	BAĞLANTI LİNKİ
TILDA	3200	8	768x512	8	<a href="https://lmb.informatik.uni-freiburg.de/data/TILDA/tilda_CD1+CD2.zip">https://lmb.informatik.uni-freiburg.de/data/TILDA/tilda_CD1+CD2.zip</a>
Kylberg Texture	4480	0	576x576	28	<a href="https://kylberg.org/kylberg-texture-dataset-v-1-0/">https://kylberg.org/kylberg-texture-dataset-v-1-0/</a>
Hong Kong Patterned	82	6	450x450	3	<a href="https://ytngan.wordpress.com/codes/">https://ytngan.wordpress.com/codes/</a>
Fabric Stain	466	2	1920x1080	2	<a href="https://www.kaggle.com/datasets/priemshpathirana/fabric-stain-dataset">https://www.kaggle.com/datasets/priemshpathirana/fabric-stain-dataset</a>
KTH - TIPS	810	-	1280x960, 200x200	10	<a href="https://www.csc.kth.se/cvap/databases/kth-tips/doc/kth_tips.html">https://www.csc.kth.se/cvap/databases/kth-tips/doc/kth_tips.html</a>
Fabrics	2000	2	1276x1215	2	<a href="https://ibug.doc.ic.ac.uk/resources/fabrics/">https://ibug.doc.ic.ac.uk/resources/fabrics/</a>
DAGM 2007	3450	2	512x512	10	<a href="https://conferences.mpi-inf.mpg.de/dagm/2007/prizes.html">https://conferences.mpi-inf.mpg.de/dagm/2007/prizes.html</a>
Tianchi	1500	10	224x224	-	<a href="https://tianchi.aliyun.com/competition/entrance/231666/information">https://tianchi.aliyun.com/competition/entrance/231666/information</a>
MV Tec	5354	2	2048x2048	-	<a href="https://www.mvtec.com/company/research/datasets/mvtec-ad">https://www.mvtec.com/company/research/datasets/mvtec-ad</a>


Bu veri setleri incelendiğinde hem örnek sayısı hem resim kalitesi hem de kumaşların sınıflandırılması dikkate alınmıştır. Bu bağlamda en kapsamlı veri seti olan Tilda veri seti seçilmiştir. Tilda veri seti ile birlikte kendi imkânlarımızla oluşturduğumuz veri setini de sistemde kullandık.

#### 4.1.1 Tilda veri seti


Kullandığımız birinci veri seti DFG'nin (Deutsche Forschungsgemeinschaft) bünyesinde bulunan "*Teknik Nesnelerin Otomatik Görsel Denetimi*" çalışma grubu tarafından geliştirilen, içinde 7 farklı kumaş hatası, 1 adet kusursuz olmak üzere 8 ayrı sınıflandırma bulunan bir veri setidir (Computer Vision Group, F., 1996). Tilda veri seti  $768 \times 512$  piksellik toplamda 3200 adet resimden oluşur. Veri seti 12 klasöre ayrılır. Bunlardan Cd1 ile başlayan klasörler desensiz kumaş (Şekil 4.2) örneklerinden Cd2 ile başlayan klasörler ise desenli (Şekil 4.3) kumaş örneklerinden oluşmaktadır. Her bir klasör 8 alt dizinden oluşur (e0, e1, e2, e3, e4, e5, e6, e7) ve her dizinin içinde 50 örnek vardır (Şekil 4.1). Kusursuz örnekler "e0" dizininde yer alır. Diğer dizinlerde kusurlu kumaş örnekleri bulunmaktadır.



Şekil 4.1 Tilda veri seti



**Şekil 4.2** Desensiz kumaş örnekleri




**Şekil 4.3** Desenli kumaş örnekleri

#### 4.1.2 Veri seti üretme

Bu tez çalışması için TILDA veri setinin yanı sıra Samsun ilinde bulunan Samteks fabrikalarında kendi imkânlarımızla oluşturduğumuz yaklaşık 1000 adet kusurlu, 1000 adet kusursuz toplamda 2000 adet örnekten oluşan kendi veri setimiz bulunmaktadır. Bu görüntüleri oluştururken kusurlu bir ürün örneğinin aynı cins kumaş ve deseninden bir tanede kusursuz örnek oluşturulmuştur. Görüntüler Nikon marka dijital fotoğraf makinesi ile 800 x 600 piksel formatında çekilmiştir. Daha sonra Microsoft Picture Manager programı ile tüm resimler 400 x 400 piksel boyutuna getirilmiştir. Bu işlem sürecinde boyutlarında oynama olmaması için görüntülere yatay kırpma işlemi uygulanmıştır. Oluşturduğumuz görüntüleri hatalı ve hatasız görüntüler olarak iki klasör olarak kaydedilmiştir. Hatasız klasörde örnekler Sam\_0\_(\*).jpg adıyla sıralanmış (Şekil 4.4), hatalı klasörde ise Sam\_1\_(\*).jpg adıyla sıralanmıştır (Şekil 4.5).



Şekil 4.4 Oluşturulan hatasız veri seti klasörü



Şekil 4.5 Oluşturulan hatalı veri seti klasörü

## 4.2 Algoritma

CNN daha çok görüntü işlemede kullanılan ve girdi olarak görsel nesnelere alan bir derin öğrenme algoritmasıdır (Türkoğlu, et al., 2021). Ayrıca CNN, bilgisayar ile görme uygulamaları için özel olarak geliştirilmiş çok katmanlı bir ANN (Artificial Neural Network) modelidir. Diğer sınıflandırma metodlarına göre daha yüksek başarımlar sağlayan bir yaklaşımdır. Diğer taraftan, CNN'nin dezavantajı, güçlü donanım kaynaklarına ihtiyaç duyulmasıdır (Çıklaçandır 2023).


Geleneksel CNN mimarisi beş ana katmandan meydana gelmektedir. Bunlar input, convolution, pooling, fully-connected ve output katmanlarıdır. Konvolüsyonel katmanı, input katmanından işlem yapılmadan gelen resmin özelliklerini algılar, filtreler ve yeni bir özellik haritası çıkarır. Pooling katmanı, aşırı öğrenmeyi önler ve modelin boyutunu düşürerek hesaplama maliyetini iyileştirir. Fully-connected katmanı ise sınıf puanlarını optimize eder ve CNN mimarisinin sonuna yakın bir yerde bulunur. Output katmanı sınıflandırmanın olduğu katmandır, sınıf sayısı kadar değeri vardır (Terzi 2021). Bu katmalardan, konvolüsyonel, havuzlama ve tam bağlı katmanların sayılarındaki yapılan değişiklikler ile birçok farklı CNN mimarileri oluşturabili (LeCun *et al.* 2015) r. CNN yapısına göre oluşturulabilecek çok sayıda değişik modellerden bahsedebiliriz. Modellerin seçim işlemi, mevcut problemi çözmek için oldukça önemli bir etken olarak kabul edilmektedir. İki boyutlu görüntülerin ayırt edilmesi amacıyla oluşturulmuş ve başarıları kanıtlanmış birçok model bulunmaktadır (Erkuş 2020). Önceden eğitilmiş modellerin eğitimsiz modellere göre daha hızlı öğrenmesi veya daha başarılı olması beklenir. Bu çalışmada farklı mimarilere sahip VGGNET16, InceptionV3 ve ResNet50 modellerini kullanıp sınıflandırılmalarını sağlamaktadırlar. Çizelge 4.2'de bu modellere ait ana parametreler gösterilmektedir.

**Çizelge 4.2** Modellerin parametreleri (Uçar 2021)

MODELİN ADI	GİRDİ BOYUTU	MİNİ TOPLULUK DEĞERİ	ÖĞRENİM ORANI
VggNet16	224x224x3	64	0.00005
InceptionV3	299x299x3	32	0.001
ResNet50	224x224x 3	32	0.001

## 4.2.1 VGGNet 16

VGG16, 2014 yılında ILSVR (Imagenet) yarışmasını kazanmak için kullanılan bir CNN mimarisidir. 16 katmandan oluşmaktadır. Genel yapı bakımından AlexNet'e benzetilmektedir. Şimdiye dek tasarlanmış derin öğrenme mimarileri içinde oldukça başarılı gösterim modeli mimarilerinden bir tanesi olarak kabul edilir. VGG16 ağı 138 milyon civarlarında parametreye sahiptir ve çok sayıda hiper parametre yerine tek adımda 3 x 3 filtrenin konveksiyon katmanlarından oluşur. VGG16 mimarisinde, evrişim ve maksimum havuz katmanları bütün mimari yapı boyunca tutarlı bir biçimde 2 x 2 filtreler de iki adımlı olmak aynı dolgu ve en büyükleri havuzlama katmanının kullanılmış olmasıdır. Son katmanda ise tamamen bağlı katmanlar olan iki tam bağlı katmanı ve ardından çıktı için bir softmax kullanılmaktadır. Şekil 4.6'de 224 x 224 x 64 boyutlarında bir görüntü tanıma ve sınıflandırma öğrenimi pixel bölümelemeyle sağlanır ve ağ eğitimi gösterilmektedir. Böylece ağ modelimiz sınıflandırmayı öğrenir ve görüntü çözümlemesinin de ağı öğrenmede doğruluk payı yükselmektedir.




Şekil 4.6 VGGNet16 mimarisi

## 4.2.2 InceptionV3

Google ekibinin geliştirdiği InceptionV3 mimarisi 2014 yılında ImageNet yarışmasını kazandı. Başlangıç mimarisi, paralel olarak bağlanmış katmanları kullanır. InceptionV3 modelinin yapısı; evrişim, ortalama havuzlama, maksimum havuzlama ve tam bağlantılı

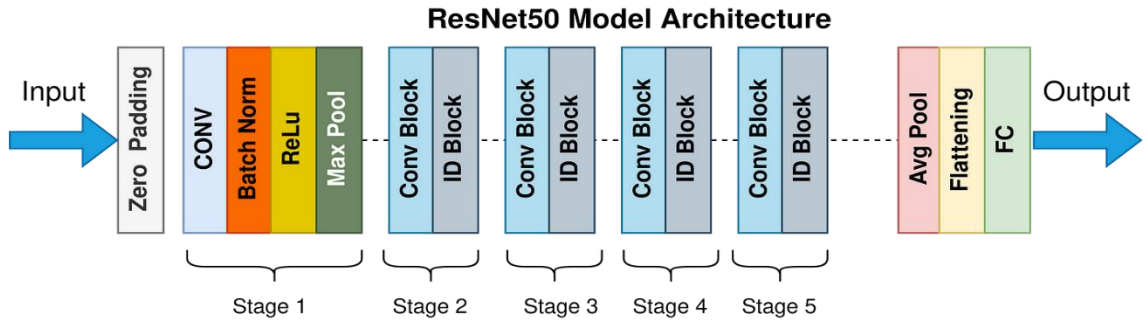
katman yapılarından meydana gelmektedir. Çıktı için softmax aktivasyon fonksiyonunu kullanan bu model toplam olarak 42 katman yapısından meydana gelir ve girdide 299 x 299 piksel ebatlarında imaj almaktadır.



Şekil 4.7 Inception mimarisi

#### 4.2.3 ResNet50

2015 ImageNet yarışmasını kazanan ResNet50 mimarisi, 152 katman ve 23 milyon civarı parametreden meydana gelmektedir. Görüntü algılama ve sınıflandırmada yaygın olarak kullanılmakta olan ResNet50 mimarisi, yapısında güncellenmiş bir sinir ağını andırıyor ve girdiyi bir sonraki iki katmanlı evrişimin çıktısına "artık" olarak besleme prensibiyle çalışıyor. Şekil 4.8'de, ResNET ve ResNET50 mimarileri için darboğazlar sağlayan "artık" işlevsel bloklar vardır. Artık değer fonksiyonlarını kullanan ImageNET yarışmalarında başarılı olduğu kanıtlanmıştır (Targ *et al.* 2016).

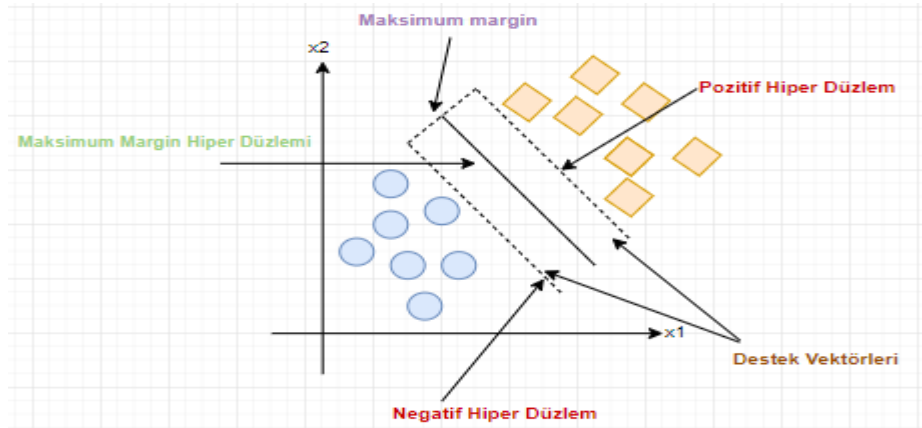


Şekil 4.8 ResNet mimarisi (Ala ve İkiz 2015)

### 4.3 Sınıflandırma

#### 4.3.1 Destek vektör makineleri (SVM)

Destek Vektör Makineleri (SVM), Vapnik tarafından 1963 yılında sunulan denetimli öğrenme algoritmalarındandır (Vapnik 1963). SVM algoritması, girdi örneklerine dayalı olarak çıktıları etiketleyerek çalışmaktadır. SVM'nin ana hedefi, veri setinin iki farklı sınıfa ayrılmasını sağlayan bir hiper düzlem veya karar yüzeyini belirlemektir. SVM sınıflandırma tespiti için kullanılan bir öğrenme algoritmasıdır (Shujun *et al.* 2018). Farklı sınıfları en üst seviyede ayıran yüksek boyutlu bir hiper düzlem bulma fikrine dayanır. SVM her sınıfın en yakın veri noktaları arasında maksimum marja veya mesafeye sahip olan hiper düzlemi bularak çalışır. Hiper düzleme en yakın olan veri noktaları destek vektörleri olarak adlandırılır ve hiper düzlemi tanımlamak için kullanılır (Osisanwo and Akinsola 2017). Farklı hiper düzlemler, veri noktalarını iki sınıfa ayırmakta, bu yüzden asıl hedef n-boyutlu bir alanda "maksimum pay" elde eden hiper düzlemi bulmaktır. Marj, hiper düzlemin boyutuna bağlı olarak iki sınıf arasındaki mesafeyi belirlemekte ve bu genellikle giriş özelliklerinin sayısı ile orantılı olmaktadır (Srivastava and Lekha 2010).




Şekil 4.9 SVM yapısı

SVM, özellikle doğrusal olmayan modellerde etkili bir yöntem olarak ön plana çıkmaktadır. Çekirdek seçiminin SVM modelinin performansı üzerinde önemli bir etkisi

bulunmaktadır. En uygun çekirdeği seçmek için, çeşitli çekirdek işlevlerinin veriler üzerinde uygulanıp denetlenmesi en etkili yöntemlerden biri olarak belirtilmektedir (Huang, et al., 2018). Doğrusal Destek Vektör Makineleri, +1 ve -1 düzlemine ayrılan sınıfları mükemmel bir şekilde ayıran bir karar düzlemi oluşturmaktadır (Srivastava & Lekha, 2010).

#### 4.3.2 K en yakın komşu (KNN)

K-NN (K En Yakın Komşu) algoritması ise tembel bir öğrenme algoritmasıdır. Eğitim verilerini öğrenmez, sadece ezberler. Bir tahmin yapmak istediğimiz de, bütün veri setinde en yakın komşulara bakar (Srivastava and Lekha 2010). Algoritma çalışma sisteminde önce bir “K” değeri belirlenmektedir. Bu “K” değerinin manası bakılacak eleman sayısıdır. Giren değer ile en yakın “K” elemanı arası uzaklık hesaplanır. Mesafe hesaplama işlemlerinde çoğunlukla Öklid fonksiyonu kullanılır. Öklid fonksiyonuna alternatif olarak yerine Manhattan, Minkowski ve Hamming fonksiyonları da kullanılabilir (Can 2021). Mesafeler hesaplandıktan sonra sıralanır ve gelen değer uygun olan sınıfa atanır (Chih Min *et al.* 2014). Bu algoritmanın öne çıkan özelliği, eğitim sürecinin olmaması ve bu nedenle ‘tembel’ bir öğrenme algoritması olarak kabul edilmesi, K-NN, eğitim verilerini öğrenmek yerine, bu veri setini hatırlamaktadır. Tahmin yapılırken, veri seti içinde en yakın komşuları aramaktadır. Bu algoritmanın dezavantajı, uzaklık hesaplamaları için tüm mesafelerin saklanması gerekliliği ve büyük veri kümeleri için yüksek bellek gereksinimi olması olarak belirtilmektedir (Huang *et al.* 2018).



Şekil 4.10 KNN yapısı

K-NN algoritmasının çalışma prensibinde, belirlenen bir K değeri önemlidir. Bu değer, bir noktanın kaç adet en yakın komşu ile değerlendirileceğini belirtmektedir. Yeni bir noktanın mevcut noktalara göre uzaklığı, uzaklık fonksiyonları kullanılarak hesaplanmakta ve bu nokta, en yakın K komşunun özelliklerine dayalı olarak bir sınıfa atanmaktadır. Uzaklık hesaplamalarında genellikle Euclidean (Öklid) fonksiyonu kullanılmakta, ancak Hamming, Manhattan ve Minkowski gibi alternatif fonksiyonlar da tercih edilebilmektedir (Huang *et al.* 2018).



## 5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

### 5.1 Sistem Özellikleri

Proje yazılımı için kullanılan bilgisayarın sistem bilgileri Çizelge 5.1’de gösterilmiştir. Oluşturulan sistemde, Python dili seçilmiş ve Jupyter Notebook ortamında keras kütüphanesi kullanılarak yazılım gerçekleştirilmiştir. Keras öğrenme hem kolay hemde model oluşturma kolaylığının yanında, geniş çapta benimsenme ve çok çeşitli export seçeneklerini de destekler (Karabay 2023). Ayrıca Modelleri CPU ve GPU’da sorunsuz bir şekilde çalıştırır.

**Çizelge 5.1** Çalışmada kullanılan bilgisayarın özellikleri

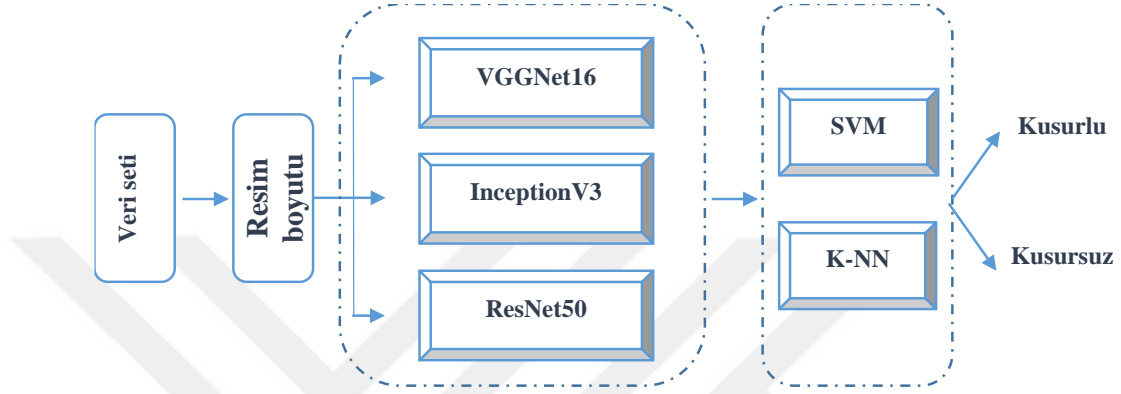
SİSTEM BİRİMİ	MODEL VE ÖZELLİĞİ
CPU	AMD Ryzen5 3400G 3,70 GHz.
RAM	16 GB.
GPU	AMD Radeon RX Vega 11 Graphics 2 GB + 7 GB
İşletim Sistemi	Microsoft Windows 10 Profesyonel x64 bit
Kamera Modeli	Front- Facing 720p kamera
Kamera Çözünürlüğü	1 MP

Bu çalışma kişisel bir masaüstü bilgisayarda yazılan kodlar ve bu bilgisayara bağlanmış olan bir kameradan meydana gelmektedir. Gerçekleştirilen çalışmada, yalnızca son kısımda ekran görüntülerinin alınması için indirilen veri setinden rasgele seçilen resimler kameraya gösterilmiştir. Resimler, kumaş olarak çözgü hataları, atkı hataları ve delik hataları ve lekeli lekesiz kumaş hataları için kullanılmıştır. Çalışma kapsamındaki amaç kumaş hatalarının karşılığını doğru olarak tanınip; daha sonra PC kamerası aracılığıyla ekrana gösterilen kumaşın tanımlanan hata sınıflarından hangisine benzediği yönünde eşleştirme yapmaktır.

### 5.2 Uygulanan Sistem

Kusurlu kumaşları tespit etmek için uyguladığımız sistem dört adımdan oluşmaktadır. Birincisi veri setinin yüklenmiş ve sonrasında kumaş örnekleri ön işlemde geçirilerek yeniden boyutlandırılmıştır. Daha sonra kumaş örnekleri önceden eğitilen modellere girdi

olarak verilmektedir. Önceden eğitilen derin öğrenme modellerinden; VGGNet16, InceptionV3 ve ResNet50 modelleri özellik çıkarıcı olarak kullanılmıştır. Sınıflandırıcı modeli olarak SVM ve KNN algoritmaları uygulanarak kumaş örnekleri kusurlu ya da kusursuz olarak ikili sınıflandırma uygulanmıştır. Önerilen yöntem Şekil 5.1’de verilmiştir.



Şekil 5.1 Uygulanan yöntem

### 5.3 Veri Setlerinin Hazırlanması

Bu çalışmada kullanmış olduğumuz ilk veri seti daha öncede tanıttığımız Tilda veri setidir. Bu veri seti 200 kusursuz, 1400 kusurlu toplam 1600 adet desensiz kumaş örneğinden ayrıca 200 kusursuz, 1400 kusurlu toplam 1600 adet desenli kumaş örneğinden oluşmaktadır. Toplam 2800 adet olan kusurlu örnekler 7 farklı klasörde (e1, e2, e3, e4, e5, e6 ve e7) kusurlarının türüne göre bölümlere ayrılmıştır. Çalışmamızın sonunda sadece kusurlu ve kusursuz olmak üzere ikili sınıflandırma kullanılacağı için e1, e2, e3, e4 e5, e6 ve e7 klasörlerindeki örnekler “e10” adında tek bir dizin altında toplanmıştır. Böylelikle kumaş görselleri kusurlu ya da kusursuz olarak iki temel kategori haline getirilmiştir. Ayrıca desenli ve desensiz kumaş örnekleri tek bir klasörde bir araya getirilmiştir.

İkinci veri seti olarak kendi oluşturduğumuz orijinal veri setini kullandık. Bu veri setinde Tilda veri setine göre daha az çeşit örneklem vardır. Toplamda 2000 adet örnek bir klasör

içinde 1000 adet hatalı 1000 adet hatasız olarak olduğu gibi kaydedilerek kendi veri setimizi hazırlamış olduk.

Üçüncü veri seti ise kendi veri setimize görüntü arttırımı uygulayarak oluşturulmuştur. Görüntü işleme uygulamalarında yeterli örnek olmadığı durumlarda modelde ezberlemeler görülmektedir. Bu durumu azaltmak için örneklerin arttırımı uygulanır. Resim veri setlerinin genişletilmesi için birçok teknik vardır.

Bu tez çalışmasında “ImageDataGenerator” komutuyla veri arttırımı yapılmıştır. ImageDataGenerator; Derin öğrenme kütüphanesi olan Keras kitaplığında bulunur. Veri arttırma işlemi sadece eğitim veri kümesine uygulanır, doğrulama ya da test veri kümesine uygulanmaz (İnaç 2023). Veri arttırımının görüntü kaydırma, görüntü çevirme, görüntü döndürme, parlaklık ayarı, görüntü yakınlaştırma gibi birçok tekniği vardır.

### 5.3.1 Görüntü kaydırma


Görüntünün boyutlarını sabit tutarak, görüntü içeriğini tek bir yönde belli bir mesafe kaydırma tekniğidir. width\_shift\_range ve height\_shift\_range parametreleri ile yatay ve dikey kaydırma miktarları belirlenir.



Şekil 5.2 Görüntüyü kaydırma tekniği

### 5.3.2 Görüntü çevirme


Görüntünün boyutlarını sabit tutarak, görüntünün tamamının dikey ya da yatay perspektifini alma tekniğidir. `horizontal_flip` ve `vertical_flip` parametreleri ile yatay ve dikey çevirmeler belirlenir.



Şekil 5.3 Görüntüyü dikey çevirme tekniği

### 5.3.3 Görüntü rastgele çevirme


Görüntünün boyutlarını sabit tutarak, görüntü içeriğini farklı açılarda bir yönde belli bir mesafe çevirme tekniğidir. `rotation_range` parametresi ile  $0-90^\circ$  arasında çevirme miktarları belirlenir.



Şekil 5.4 Görüntü rastgele çevirme tekniği

### 5.3.4 Görüntü rastgele parlaklık tekniği

Görüntünün boyutlarını sabit tutarak, görüntü içeriğini rastgele aydınlatma ya da karartma tekniğidir. `brightness_range` parametresi ile aydınlatma ya da karartma miktarları belirlenir.



Şekil 5.5 Görüntüyü rastgele parlatma tekniği

### 5.3.5 Görüntü rastgele yakınlaştırma

Görüntünün boyutlarını sabit tutarak, görüntü içeriğini yakınlaştırıp uzaklaştırma tekniğidir. `zoom_range` parametresi ile yakınlaştırma ya da uzaklaştırma yüzdeleri belirlenir.




Şekil 5.6 Görüntüyü rastgele yakınlaştırma tekniği

### 5.3.6 Görüntü renk ayarları

Görüntünün boyutlarını sabit tutarak, görüntü renk özelliklerini değiştirme tekniğidir. Renkli resmi siyah beyaza çevirme ya da gri tonlamaya çevirme gibi parametreler ile resmin renk ayarlarında değişiklikler yapılabilir (Çizelge 5.2).



Şekil 5.7 Görüntüyü gri tonlamaya çevirme tekniği



Şekil 5.8 Görüntüyü daha canlı renklere çevirme tekniği

Çizelge 5.2 Veri setleri

VERİ SETİ	RESİM BOYUTU	TOPLAM ÖRNEK SAYISI	KUSURLU ÖRNEK SAYISI	KUSURSUZ ÖRNEK SAYISI
Tilda	768 × 512	3200	2800	400
Kendi veri setimiz	400 x 400	2000	1000	1000
Arttırılmış kendi veri setimiz	400 x 400	3200	2800	400

## 5.4 Programlama Aşaması

### 5.4.1 Yeniden boyutlandırma

Farklı modellerin görüntü girişleri birbirinden ayrı olmasından dolayı, kumaş örneklerinin ebatları değiştirilmiştir. InceptionV3 modeli için görüntü boyutları 299 x 299 piksele, VGGNet16 modeli için görüntü boyutları 224 x 224 piksele ve son olarak ResNet50 modeli içinse görüntü boyutları 224 x 224 piksele ayarlanarak tekrar kaydedilmiştir (Er, 2021).

### 5.4.2 Eğitim ve test dosyalarının oluşturulması

Hangi resimlerin eğitim için, hangilerinin test için kullanılacağı önemlidir. Daha önceden oluşturduğumuz 3 farklı veri setini eğitim ve test olarak hepsini ayrı ayrı ikiye bölünmüştür. Bu bölünme aşamasında eğitim için tüm resimlerin %80'i, test için ise %20'sini rastgele olacak şekilde belirledik. Veri setlerinin son durumu Çizelge 5.3'de gösterilmektedir.

**Çizelge 5.3** Eğitim seti ve test seti

VERİ SETİ	TOPLAM ÖRNEK SAYISI	EĞİTİM İÇİN AYRILAN (%80)	TEST İÇİN AYRILAN (%20)
Tilda	3200	2560	640
Kendi veri setimiz	2000	1600	400
Arttırılmış kendi veri setimiz	3200	2560	640

### 5.4.3 Önceden eğitilmiş modellerden özellik çıkarma

Bu çalışmada, daha önce görüntü işlemede iyi sonuçlar almış üç adet önceden eğitilen derin öğrenme modelleri kumaş hatalarının tespiti için uygulanmıştır. Bu modeller; VGGNet, Inception ve ResNet modelleridir. Bu üç modelini seçmemizin temel nedeni, geçmiş literatürler incelendiğinde hata kusur tespiti ve sınıflandırmalarında bu modellerin oldukça yüksek oranda doğruluk derecelerine ulaşmasıdır. Özellikle büyük veri setlerinde oldukça iyi performans sağlamaktadırlar.

#### **5.4.4 Sınıflandırma işlemi**

Bu çalışmada sınıflandırmada en çok tercih edilen iki algoritma olan SVM (Destek vektör makineleri) ve K-NN (K En Yakın Komşu) kullanıldı. Geçmiş çalışmalara bakıldığında metin ağırlıklı veri setlerinde SVM algoritması, resim ağırlıklı veri setlerinde KNN algoritmasının kullanılması neticesinde çalışmamızda SVM ve KNN algoritmaları seçilmiştir.

#### **5.5 Modellerin Birbirleriyle Karşılaştırılması**

Bu çalışma kapsamında daha önce kumaş hataları tespiti üzerinde yapılan çalışmalar incelendiğinde en çok kullanılan modellerden olan VGG16, InceptionV3 ve Resnet50 mimarisi ile modeller oluşturulmuştur. Bu çalışmamız da veri setlerinde bulunan hata çeşitleri tek bir klasörde toplanmış ve ardından kusurlu ve kusursuz olmak üzere ikili sınıflandırma uygulamıştır. Sonuç olarak uyguladığımız modellerin performanslarını Doğruluk, Kesinlik ve F Skoru gibi farklı metrikler kullanılarak değerlendirilmiştir. Bu metriklerin hesaplanması aşağıda gösterilmektedir.

Yanlış pozitifler (YP): Veri değerlendirmeleri sonucunda aslında negatif değere sahip olan ancak sanki pozitif değere sahipmiş gibi tahmin edilen örneklerdir. Yani gerçekte negatif, tahminde pozitif değerler.

Yanlış negatifler (YN): Veri değerlendirmeleri sonucunda aslında pozitif değere sahip olan ancak sanki negatif değere sahipmiş gibi tahmin edilen örneklerdir. Yani gerçekte pozitif, tahminde negatif değerler.

Doğru pozitifler (DP): Veri değerlendirmeleri sonucunda pozitif değere sahip olan ve doğru tahmin edilen örneklerdir. Yani hem gerçekte pozitif, hem de tahminde pozitif değerler.

Doğru negatifler (DN): Veri değerlendirmeleri sonucunda negatif değere sahip olan ve doğru tahmin edilen örneklerdir. Yani hem gerçekte negatif, hem de tahminde negatif değerler.

Doğruluk, bir modelin başarısını ölçmek için en fazla kullanılmakta olan fakat karar verme sürecinde tek başına yeterli olamayan bir metrik çeşididir. Yapılan tahminlerin sonucunda doğru tahminlerin tüm tahmin sonuçlarına oranıyla hesaplanmaktadır. Doğruluk ölçümü Denklem 3’de verilmiştir.

$$\text{Doğruluk} = \frac{|DP| + |DN|}{|DP| + |DN| + |YP| + |YN|} \quad (5.1)$$

Kesinlik, yapılan tahminlerin sonucunda pozitif bir tahminin doğru olup olmadığını tahmin eden bir metrik çeşididir. Doğru tahmin edilen pozitif değerlerin hem doğru hem de yanlış tahmin edilen pozitif değerlere bölümüyle hesaplanmaktadır. Kesinlik ölçümü Denklem 4’de verilmiştir.

$$\text{Kesinlik} = \frac{|DP|}{|YP| + |DP|} \quad (5.2)$$

F skor, değeri bize Kesinlik (Precision) ve Duyarlılık (Recall) değerlerinin harmonik ortalamasını göstermektedir. Hem Precision hem de Recall değerinin etkisini tutmaktadır. Denklem 5’de gösterildiği gibi hesaplanır.

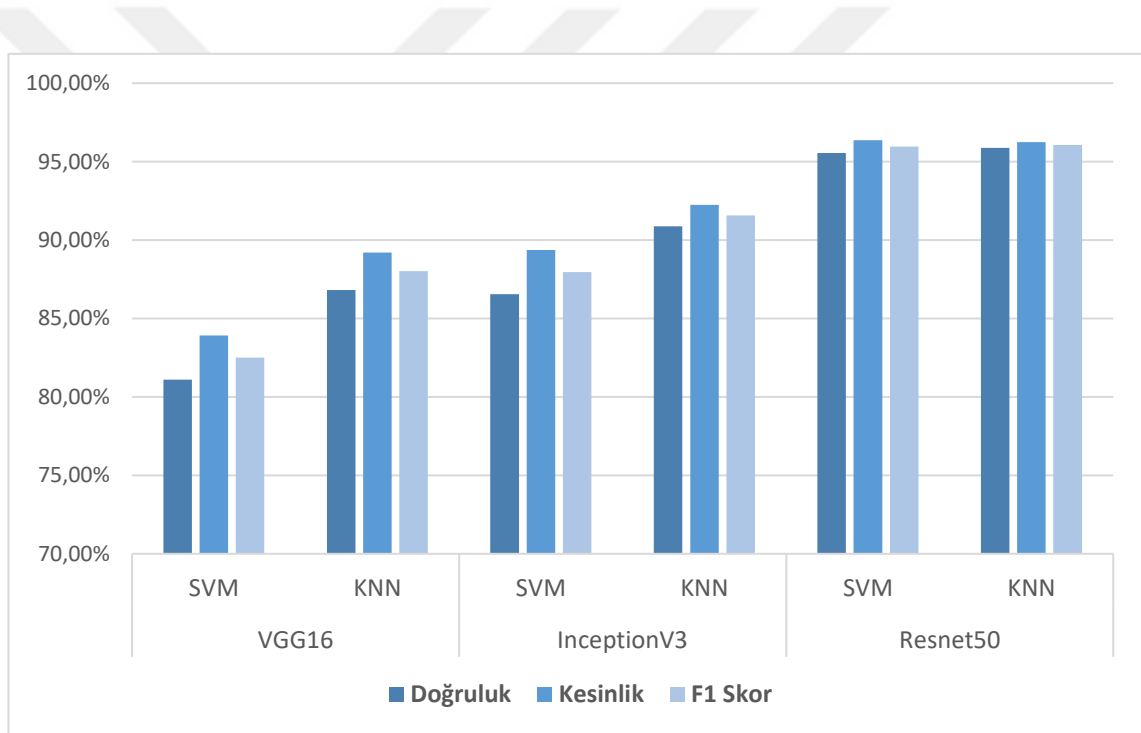
$$\text{F skor} = \frac{2 \times |DP|}{2 \times |DP| + |YP| + |YN|} \quad (5.3)$$

Tilda veri setinden gelişigüzel belirlenen verilerden %80’i eğitim için %20’si de test için kullanılmaktadır. Her model için ayrı ayrı SVM ve KNN sınıflandırıcı uygulanmış olup çıkan değerleri doğruluk, kesinlik ve F skoru formülleri uygulanmıştır. Metrik değerlerinden elde edilen sonuçlar Çizelge 5.4’de gösterilmektedir. En yüksek doğruluk %95,88 değeri ile Resnet50 modeli ve KNN sınıflandırıcı ile elde edilmiştir; en düşük doğruluk değerini ise %81,11 ile VGG16 modeli ve SVM sınıflandırıcı ile elde edilmiştir.

Tabloya genel baktığımızda modellerden Resnet50 modeli, sınıflandırma algoritmalarından KNN algoritması daha başarılı olduğu görülmektedir. Bu bağlamda elde ettiğimiz sonuçlar Şekil 5.9’de grafik olarak gösterilmiştir.

**Çizelge 5.4** Tilda veri seti kullanılarak elde edilen sonuçlar

MODEL	RESİM BOYUTU	SINIFLANDIRICI	DOĞRULUK	KESİNLİK	F SKORU
VGG16	224x224	SVM	81,11%	83,91%	82,51%
		KNN	86,82%	89,20%	88,01%
InceptionV3	299x299	SVM	86,55%	89,36%	87,95%
		KNN	90,18%	92,25%	91,56%
Resnet50	224x224	SVM	95,54%	96,36%	95,95%
		KNN	95,88%	96,25%	96,06%



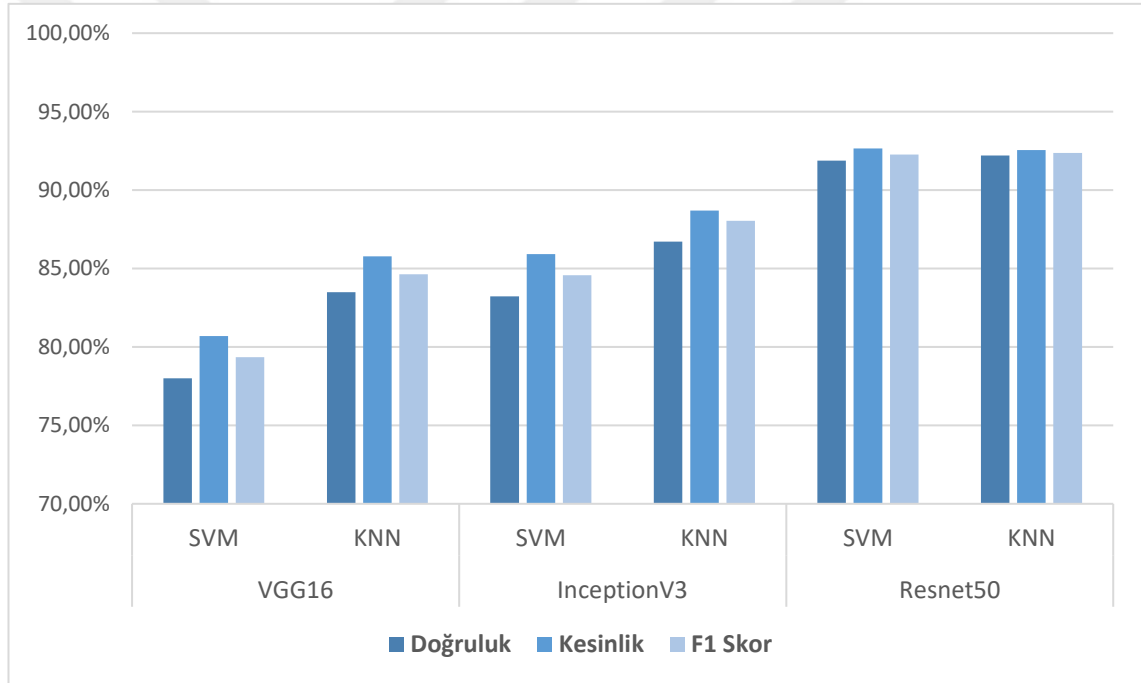
**Şekil 5.9** Performans karşılaştırılması

İkinci olarak kendi veri setimizden gelişigüzel belirlenen verilerden %80’i eğitim için %20’si de test için kullanılmaktadır. Her model için ayrı ayrı SVM ve KNN sınıflandırıcı uygulanmış olup çıkan değerleri doğruluk, kesinlik ve F skoru formülleri uygulanmıştır. Metrik değerlerinden elde edilen sonuçlar Çizelge 5.5’de gösterilmektedir. En yüksek doğruluk %92,19 değeri ile Resnet50 modeli ve KNN sınıflandırıcı ile elde edilmiştir; en düşük doğruluk değerini ise %77,99 ile VGG16 modeli ve SVM sınıflandırıcı ile elde

edilmiştir. Tabloya genel baktığımızda modellerden Resnet50 modeli, sınıflandırma algoritmalarından KNN algoritması daha başarılı olduğu görülmektedir. Bu bağlamda elde ettiğimiz sonuçlar Şekil 5.10’de grafik olarak gösterilmiştir.

**Çizelge 5.5** Kendi veri setimizi kullanarak elde edilen sonuçlar

MODEL	RESİM BOYUTU	SINIFLANDIRICI	DOĞRULUK	KESİNLİK	F SKORU
VGG16	224x224	SVM	77,99%	80,68%	79,34%
		KNN	83,48%	85,77%	84,63%
InceptionV3	299x299	SVM	83,22%	85,92%	84,57%
		KNN	86,71%	88,70%	88,04%
Resnet50	224x224	SVM	91,87%	92,65%	92,26%
		KNN	92,19%	92,55%	92,37%




**Şekil 5.10** Performans karşılaştırılması

Üçüncü olarak kendi veri setimizden veri artırımı uygulayarak oluşturduğumuz yeni veri setinden gelişigüzel belirlenen verilerden %80’i eğitim için %20’si de test için kullanılmaktadır. Her model için ayrı ayrı SVM ve KNN sınıflandırıcı uygulanmış olup çıkan değerleri doğruluk, kesinlik ve F skoru formülleri uygulanmıştır. Metrik değerlerinden elde edilen sonuçlar Çizelge 5.6’de gösterilmektedir. En yüksek doğruluk %94,09 değeri ile Resnet50 modeli ve KNN sınıflandırıcı ile elde edilmiştir; en düşük

doğruluk değerini ise %79,60 ile VGG16 modeli ve SVM sınıflandırıcı ile elde edilmiştir. Tabloya genel baktığımızda modellerden Resnet50 modeli, sınıflandırma algoritmalarından KNN algoritması daha başarılı olduğu görülmektedir. Bu bağlamda elde ettiğimiz sonuçlar Şekil 5.11’de grafik olarak gösterilmiştir.

**Çizelge 5.6** Arttırılmış kendi veri setimizi kullanılarak elde edilen sonuçlar

MODEL	RESİM BOYUTU	SINIFLANDIRICI	DOĞRULUK	KESİNLİK	F SKORU
VGG16	224x224	SVM	79,60%	82,35%	80,97%
		KNN	85,20%	87,54%	86,37%
InceptionV3	299x299	SVM	84,94%	87,69%	86,31%
		KNN	88,50%	90,53%	89,85%
Resnet50	224x224	SVM	93,76%	94,56%	94,16%
		KNN	94,09%	94,46%	94,27%



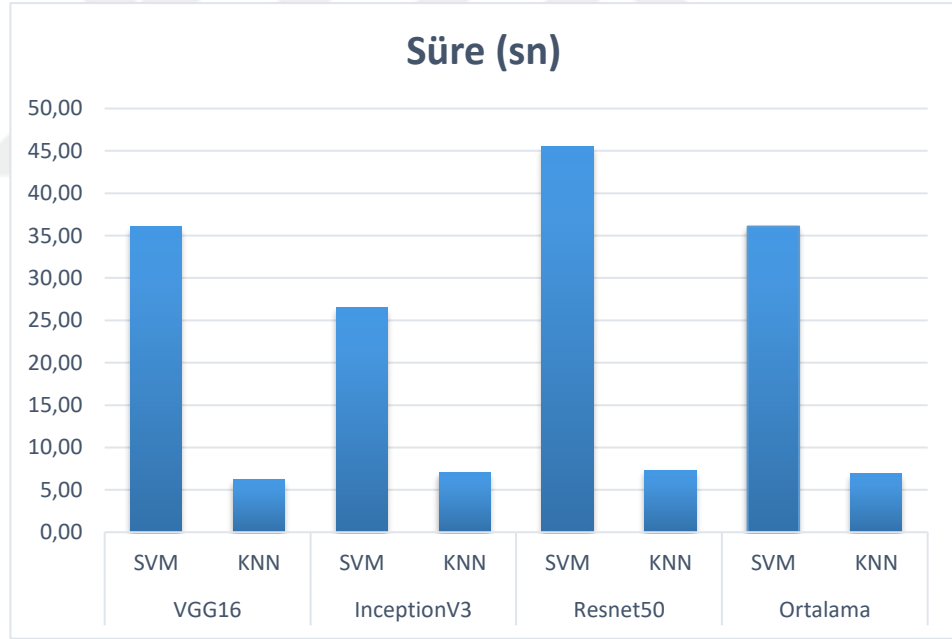
**Şekil 5.11** Performans karşılaştırılması

SVM sınıflandırıcı daha düşük doğruluk bulması veri setinin büyüklüğü ile ilgilidir. Tilda ve yeni oluşturulan kendi veri setimiz boyut ve sayı bakımından büyük olduğundan SVM için uygun olmadığı görülmüştür. KNN algoritmasının sonuçlarına baktığımızda ise resim boyutunun çok etkilenmediği görülmekle beraber doğruluk değerlerinde SVM’ye göre daha uygun olduğu görülmüştür. Bununla birlikte sınıflandırıcıların süre bakımından performanslarına bakmak için rastgele seçilmiş 100 örnek kullanarak yapılan öznelik

seçimi sonucunda çıkan değerler çizelge 4’te gösterilmektedir. Bu sonuçlara bakıldığında SVM sınıflandırıcının KNN’e göre çok daha uzun sürdüğü görülmüştür. SVM sınıflandırıcının ortalama süresi 36,07 saniye, KNN’in ise 6,87 saniyedir. SVM’nin 100 örnekte bu kadar uzun sürmesi, büyük veri setlerinde kullanımın en büyük dezavantajlarından biridir.

**Çizelge 5.7** Sınıflandırma süreleri

MODEL	SINIFLANDIRICI	SÜRE (SN)
VGG16	SVM	36,12
	KNN	6,21
InceptionV3	SVM	26,55
	KNN	7,08
Resnet50	SVM	45,54
	KNN	7,34
Ortalama	SVM	36,07
	KNN	6,87



**Şekil 5.12** Sınıflandırma süreleri

## 5.6 Sonuçların Değerlendirilmesi

Yapılan işlemlerin sonunda en iyi sonucu aldığımız Resnet50 modeli sonuçları kıyaslandığında; Tilda veri seti ile %95,88 doğruluk değerine, kendi veri setimizle

%92,19 doğruluk değerine, arttırılmış veri setimiz ile %94,09 doğruluk değerine ulaştığımız görülmektedir.

**Çizelge 5.8** Sonuçların değerlendirilmesi

VERİ SETİ	VGGNET16 DOĞRULUK DEĞERİ	INCEPTIONV3 DOĞRULUK DEĞERİ	RESNET50 DOĞRULUK DEĞERİ	ORTALAMA DOĞRULUK DEĞERİ
Tilda	86,82%	90,18%	95,88%	90,96%
Kendi veri setimiz	83,48%	86,71%	92,19%	87,46%
Arttırılmış kendi veri setimiz	85,20%	88,50%	94,09%	89,26%

## 5.7 Tartışma

Genel olarak, tüm sonuçları değerlendirdikten sonra, oluşturduğumuz modellerimiz verilerde hem zaman hem de performans açısından klasik makine öğrenimi yöntemlerinden daha iyi performans göstermiştir. Derin öğrenmenin, veri miktarı arttığında ve gürültü arttığında SVM ve K-NN'den daha iyi performans göstereceği tahmin edilmektedir. Ayrıca bu tezde, her probleme özgü derin bir ağ modeli oluşturmanın daha hızlı ve daha başarılı sonuçlara yol açtığı belirtilmiştir.

Bu araştırmada, 30 epok süresince eğitim gören ve öğrenme aktarımı yöntemiyle hassas ayarlamalar yapılan ESA modelleri arasında hem başarı oranı hem de işlem süresi açısından Resnet50 mimarisine sahip modelin diğerlerine göre daha üstün olduğu gözlemlenmiştir. Bu ağın, çok sayıda ve küçük boyutlu evrişim katmanları kullanımı sayesinde parametre miktarını önemli ölçüde azaltmayı başardığı belirtilmiştir. VGGnet16 modelinin yaklaşık 60 milyon parametreye sahip olduğu düşünüldüğünde, InceptionV3 modelinin parametre sayısını 4 milyona indirmesi dikkate değer bir başarı olmuştur. Buna ek olarak, ResNet50 modelinin 23 milyon parametreye sahip olduğu bilgisine de vurgu yapılmıştır. Bu rakamlar ışığında, Resnet50'nin diğer modellere kıyasla daha hızlı çalışmasının beklenen bir sonuç olduğu ifade edilmiştir.

Bu araştırmada, derin öğrenme ve klasik makine öğrenmesi teknikleri hibrit bir yaklaşımla entegre edilerek kullanılmıştır. İncelemede, özellik çıkarımı amacıyla başarılı olduğu kanıtlanan Resnet50 modeli tercih edilmiştir. Bu modelin çıkarımlarından

yararlanarak, klasik makine öğrenmesi metotlarından olan SVM ve KNN algoritmalarıyla sınıflandırma işlemleri gerçekleştirilmiştir. Sonuçlar, Resnet50 mimarisinin bu problemdeki özellikleri etkin bir şekilde belirleyebildiğini göstermektedir. Bu yöntemin, doğrudan Resnet50 mimarisi kullanmak yerine, klasik makine öğrenmesi teknikleri ile birleştirilerek sınıflandırma sürecini hızlandığı anlaşılmıştır.

Çalışmada, VGGnet, Inception ve ResNet mimarilerinin karşılaştırmalı performans analizini sunmaktadır. Bu mimarilerden en yüksek performansı gösteren Resnet50 ve düşük performans sergileyen VGG16 ile InceptionV3 için karışıklık matrisleri incelenmiştir. Karışıklık matrisleri, modellerin tahminlerini gerçek değerlerle karşılaştırarak, modelin güçlü ve zayıf yönlerini belirlemek için kullanılmaktadır. Bu matrisler, modelin performansını derinlemesine anlamak ve potansiyel iyileştirmeler için fikirler geliştirmek amacıyla ele alınmıştır.

## 6. SONUÇ VE ÖNERİLER

### 6.1 Sonuç

Çalışmamızın asıl amacı kumaş kalitesini arttırmak için en yeni teknolojileri kullanarak kumaşta oluşabilecek kusurları en hızlı ve en doğru bir biçimde tespit etmektir. Son yıllarda görüntü işleme tekniklerinde büyük gelişmeler yaşanmıştır. Bununla birlikte CNN tabanlı modellerin kullanımı bu alanda epeyce yaygın hale gelmiştir. Bu çalışmada halka açık yayınlanan toplam 3200 kumaş örneğinden oluşan Tilda veri seti yöntemleri test etmek için kullanılmıştır. Öncelikle tüm görüntüler modelin özelliklerine göre boyutlandırılmıştır. Daha sonra önceden eğitilmiş modeller tarafından öznelik çıkarma işleminde elde edilen özellikler, akabinde sınıflandırmaya geçilmiştir. Özellik çıkarma adımında VGGNet16, InceptionV3 ve ResNet50 olmak üzere üç farklı model kullanılırken, sınıflandırma adımında SVM ve KNN algoritmaları kullanılmıştır. Gerçekleştirilen deneysel çalışmaların sonucunda, en iyi sonuçları ResNet50 modeli ve KNN sınıflandırıcı vermiştir. Doğruluk, keskinlik ve F skoru sonuçlarına bakıldığında KNN sınıflandırıcı daha iyi sonuç vermesine karşın birbirlerine yakın değerler vermiştir. Ancak süre testi yapıldığında SVM algoritması oldukça kötü performans vermiştir. Buda SVM algoritmasının büyük veri setlerinde kullanımının uygun olmadığı sonucuna varılabilir.

Bu çalışmada, modeller arası kıyaslamalar yapılmış, çalışma süreleri hesaplanmış fakat model seçiminde çalışma süreleri göz ardı edilmiştir. Bu kıyaslama neticesinde Resnet50 modelinin diğer modellere göre daha yüksek oranda doğruluk verdiği görülmektedir. Bununla birlikte VGG16 ve InceptionV3 algoritmaları süre bakımından Resnet50'ye göre daha iyi performans sergilediler. Resnet50 mimarisi daha geç doyum noktasına ulaşsa da %95 civarlarında bir doğruluk elde etmesi tercih sebebidir. Günümüz teknolojisiyle tasarlanan bu modellerin en büyük dezavantajı hatayı bulma sürelerinin uzun olmasıdır. Mevcut çalışmalar genellikle bu süreyi kısaltmak için veri tabanı içinden alınan resimleri filtreleyip belli bir oranda küçültmek zorunda kalmaktadır. Süre açısından bazı modeller daha verimli olsalar bile teknolojinin hızla geliştiği bu devirde ben doğruluğun en yüksek

olduđu modeli tercih ediyorum. Çünkü çok yakın zamanda yaygınlařacak olan kuantum bilgisayar teknolojileri ile bu süresinin mili saniyelerde olacađına řüphesizdir.

Sonuç olarak ResNet50 modeli diđer önceden eđitilmiş modellere göre daha iyi performans sergileyerek kumař hatası teřhisinde etkili kullanılabileceđi ortaya konulmuřtur. Bu bulgular bilgisayar destekli teřhis sistemlerinin tekstil alanında önemli bir rol oynayabileceđine ve literatüre deđerli bir katkı sađlayabileceđine dair umut vaat etmektedir.

Bugüne kadar kumař hatalarını tespit etmek için yapılan çalıřmalarda mevcut bilgisayar donanımları düşünülerek yapılmıřtır. Bundan dolayı sistemi yoran, çok uzun sürelerde sonuç çikaran modeller tercih edilmemiřlerdir. Ancak bilinmelidir ki günümüzde teknoloji çok hızlı geliřmekte ve donanımlar giderek çok daha güçlü hale gelmektedir. Özellikle kuantum teknoloji ile ilgili geliřmeler bu süreci çok daha kısaltacaktır. Bu sayede derin öğrenme ile ilgili bir model geliřtirirken artık bilgisayar performansı ve yazılımın derleme süresinin hesaplanması tarihe karıřacaktır.

Türkiye'de kumař hatalarının tespiti konusunda sınırlı sayıda çalıřma bulunmaktadır. Bu sistem, herhangi bir ek ekipman gerektirmediđi için maliyet açısından avantajlıdır. Ultrason gibi cihazlar kullanmadan tespit iřlemine gerçekteřtirebilmesi ve veri çeřitliliđinin yüksek olması, kullanıcılar için kolaylık sađlamaktadır. Bu çalıřma kapsamında elde edilen sonuçlar, kumař hatalarının gerçekte zamanlı olarak metne dönüřtürülerek başarıyla tespit edildiđini göstermektedir.

Sonuç olarak, bu çalıřmada ulařılan kıyaslamalar neticesinde ülkemizin en büyük Pazar payına sahip olan kumař sektöründe yapılacak olan düşük bir yatırımla, bu sistem kurulabilir ve kumař kalitesini çok daha yukarılara çıkarılabilir. Sistemi kurmak gerekli olan yazılım hazırlanıp test edilmiřtir. İlerleyen çalıřmalarda bu yazılımı bir donanımla birleřtirip sektöre kazandırabiliriz. Donanım olarak en önemli malzeme ise kayıt çözünürlüğü ve tepkime süresi yüksek bir kameradır. Bu kamerayı ram ve ekran kartı güçlü bir anakart ile entegre ederek gayet düşük bütçeli bir sistem kurulabilecektir.

## 6.2 Öneri

Bu çalışma, modelin başarısını ince ayar yoluyla geliştirilen ve daha önceden eğitilmiş diğer modellerle kıyaslayarak değerlendirmektedir. Üretim hatları ve kontrol sistemlerinde hareketli mekanizmaların kullanıldığı ortamlarda, video tabanlı bir kumaş hata tespit sistemi geliştirmenin mümkün olduğu öngörülmektedir. Ayrıca, bu çalışmada geliştirilen sistem, kumaş hatalarının çeşitli türlerinin tanınması için daha da iyileştirilebilmektedir. Günlük kullanımda herkes tarafından kullanılabilir bir kumaş hata tespit uygulamasının geliştirilmesi ve bu uygulamanın akıllı telefonlarda etkin bir şekilde çalışıp çalışmadığının, dokunmatik etkileşim gerektirmeden kullanılabilir olup olmadığının araştırılması planlanmaktadır. Bu tür araştırmalar, kumaş hatalarının azaltılmasına ve üretimden son kullanıcıya kadar ekonomik kayıpların önlenmesine büyük katkı sağlayacaktır.

Ayrıca kumaş hatalarını tespit için en çok zorlanılan durum hiç şüphesiz veri seti oluşturmaktır. Hâlihazırda kumaş sektöründe birçok veri seti bulunmaktadır. Fakat kumaş çeşitlerinin bolluğu, kumaş renkleri ve desenlerinin aşırı çeşitli olması nedeniyle veri setlerinde istenen verimlere ulaşmak zor görünmektedir. Bunun için veri seti olmadan bir sistem geliştirilebilir. Şöyle ki; kumaş üzerinde bulunan kameradan alınan görüntüler sisteme aktarılır. Sistem bu görüntüleri kullanarak kumaşın tüm bölümlerini küçük parçalara ayırıp kendi veri setini oluşturur. Daha sonra bu parçaları birbirleriyle kıyaslar. Farklılık bulduğu yerleri uyarır. Bir sonraki çalışmam bu konu üzerinde olacaktır.

## KAYNAKLAR

- Acar, A., 2005. Denim kumaş hatalarının optimizasyonuna yönelik çözüm önerileri, Yüksek Lisans Tezi, Marmara Üniversitesi, 113 sayfa, İstanbul.
- Akyol, A., 2001. Tekstil ve hazır giyim sektörüne pazar oryantasyonu açısından genel bir bakış, Pazarlama Dünyası Dergisi, Ankara, 48: 521-532.
- Ala, D. M. & İkiz, Y., 2015. A Statistical Investigation For Determining Fabric Defects That Occur During Weaving Production.. Pamukkale Üniversitesi Muhendislik Bilimleri Dergisi, Denizli, 21(7): 282-287.
- Bağırhan, M., 2019. Shearlet dönüşümü kullanılarak gerçek zamanlı kumaş hatası tespiti, Yüksek Lisans Tezi, Maltepe Üniversitesi, 88 sayfa, İstanbul.
- Balkışlı, S., 2022. Covid 19 Süreci İçin Yapay Sinir Ağları İle Amortisör Satış Tahmini, Yüksek Lisans Tezi, Sakarya Üniversitesi, 92 sayfa, Sakarya.
- Bramer, M., 2016. Principles Of Data Mining. 812 sayfa, London.
- CAN, U. S., 2021. Web sitesi: <https://www.medium.com> Erişim Tarihi: 30.10.2023.
- Chih Min, M., Wei Shui, Y. & Bor Wen, C. 2014. How the parameters of knearest neighbor algorithm impact on the best classification accuracy: In case of parkinson dataset, Journal of Applied Sciences, 171–176.
- COMPUTER VISION GROUP, F. 1996. Web sitesi: <https://lmb.informatik.uni-freiburg.de/resources/datasets/tilda.en.html>. Erişim Tarihi: 30.10.2023.
- Çedikçi, T. 2008. Türkiye ekonomisinde markalaşmanın yeri ve önemi; tekstil sektöründe bir uygulama. Yüksek Lisans Tezi, Kültür Üniversitesi, 113 sayfa, İstanbul.
- Çetin, C., 2007. Dokuma Kumaş Özelliklerinin ve Görmüş Olduğu Mekanik Bitim İşlemlerinin Dokuma Kumaş Mukavemetine Etkisi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, 115 sayfa, İstanbul.
- Çıklaçandır, F. G. Y., 2023. The effects of fusion-based feature extraction for fabric defect classification.. Textile Research Journal ; 93(23-24): 5448-5460.
- Çıklaçandır, F. G. Y. 2020. Kumaşlarda hatayı yerel olarak arayan denetimsiz bir sistem, Tekstil ve Mühendis, 27(120): 252-259.
- DPT, 2001. Tekstil ve hazır giyim sanayii özel ihtisas komisyonu raporu, Devlet Planlama Teşkilatı, Ankara.

- Dtm, 2001. Tekstil ve Hazır Giyim Ticareti, ekonomik arařtırmalar ve deęerlendirme, Ankara: Dıř Ticaret Müsteřarlıęı.
- El-Sonbaty, Y., El-Fattah, A. & Attia, M. 2018. Automatic fabric defect detection using convolutional neural network. International Journal of Advanced Computer Science and Applications, 9(6): 542-548.
- Erkuř, M. 2020. Türk İřaret dilinde kelime tabanlı derin öęrenme uygulaması, Yüksek Lisans Tezi, Bařkent Üniversitesi, 73 sayfa, Ankara.
- Er, M. B. 2021. Önceden eęitilmiş derin aęlar ile göęüs röntgeni görüntüleri kullanarak pnömoni sınıflandırılması. Konya Mühendislik Bilimleri Dergisi, 9(1): 193-204.
- Goodfellow, I., Bengio, Y. & Courville, A., 2016. Deep Learning (Adaptive Computation And Machine Learning). 777 sayfa, Cambridge, Massachusetts.
- Gupta, M. & Mishra, A. 2018. Analysis of fabric defects for automated inspection system. International Journal of Engineering & Technology, 7(30): 115-119.
- Güler, H. 2013. GPU ile kumař hata tespiti ve sınıflandırması, Yüksek Lisans Tezi, Sütçü İmam Üniversitesi, 63 sayfa, Kahramanmarař.
- Güvenoęlu, E. 2019. Shearlet dönüşümü ve görüntü işleme teknikleri kullanılarak kot kumařlar üzerinde gerçek zamanlı hata tespiti. El-Cezerî Fen ve Mühendislik Dergisi, 491-502.
- Hornik, K., Stinchcombe, M. & White, H. 1989. Multilayer Feedforward Networks Are Universal Approximators, Neural Networks, 2(5): 359-366.
- Huang, S. ve dięerleri, 2018. Applications Of Support Vector Machine (SVM) Learning İn Cancer Genomics.. Cancer Genomics & Proteomics, 15(1): 41-51.
- İNAÇ, E. 2023. Web sitesi: <https://yazilimkaravani.net/makine-ogrenimi-icin-veri-artirimi-data-augmentation/>. Eriřim Tarihi: 12.08.2023
- Iřık, M. & Çakır, M. 2020. Detection of fabric defects using computer vision techniques. Measurement, 153(2): 380-393.
- Jaderberg, M., Simonyan, K., Zisserman, A. & Kavukcuoglu, K. 2015. Spatial transformer networks, Neural Information Processing Systems (NIPS), 1-9.
- Kahraman, Y. 2022. Deep learning based fabric defect detection: A review, Gaziantep: Gaziantep University. 93: 5-6.
- KARABAY, A. 2023. Web sitesi: <https://www.karabayyazilim.com/blog/keras-nedir-2020-02-08-225241>. Eriřim Tarihi: 11.11.2023.

- Karaboğa, D. 2020. Yapay zeka optimizasyon algoritmaları. Nobel Akademik Yayıncılık. 244 sayfa, Kayseri.
- Kısaoglu, Ö. 2006. Kumaş kalite kontrol sistemleri. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 12(2): 233-241.
- Kızılboğa, A. Y. 2021. Yapay sinir ağları ve derin öğrenme teknikleri kullanılarak meyve ve sebze çeşitli hastalıkların tespit edilmesi, Yüksek Lisans Tezi, Kırıkkale Üniversitesi, 91 sayfa, Kırıkkale.
- Kotsiantis, S. B., Zaharakis, I. D. & Pintelas, P. E. 2006. Machine learning: A review of classification and combining techniques. Artificial Intelligence Review, 26(3): 159-190.
- Krizhevsky, A., Sutskever, I. & Hinton, G. E. 2012. Imagenet classification with deep convolutional neural networks, Advances in Neural Information Processing Systems, 1097-1105.
- LeCun, Y., Bengio, Y. & Hinton, G. 2015. Deep learning. Nature, 521: 436-446.
- Liu, L., Wang, Y., Zhang, X. & Li, G. 2017. An improved SVM algorithm for textile defect detection, Journal of Intelligent Manufacturing, 28(6): 1329-1338.
- Lucci, S., Kopec, D. & Musa, S. 2018. Artificial intelligence in the 21st century. Mercury Learning and Information, 99: 2169-3536.
- Mira, J. 1995. Neural computation lecture notes in computer, International Workshop on Artificial Neural Networks, 4-15.
- Osisanwo, F. & Akinsola, J., 2017. Supervised machine learning algorithms: classification and comparison. International Journal of Computer Trends and Technology, 48(3): 128-138.
- ÖZTÜRK, E. E. 2023. Web sitesi: <https://www.veribilimiokulu.com/makineler-nasil-ogrenir/>. Erişim Tarihi: 21.08.2023
- Paluszek, M. & Thomas, S., 2017. The history of autonomous learning in MATLAB machine learning, Berkeley, CA.,17-23.
- Pınar, Z. 2020. Denim Kumaşlarda Görüntü İşleme İle Hata Tespiti. BEÜ Fen Bilimleri Dergisi,1609-1620.
- Pratt, L. Y. 1994. Experiments on the transfer of knowledge between neural networks, Computational Learning Theory And Natural Learning Systems, Constraints and Prospects, 1(9): 22-32

- Rejeb, A., Ayadi, M. & Jemai, H. 2018. Fabric defect detection using computer vision techniques: A review. *Journal of Manufacturing Systems*, 49: 245-259.
- Roodschild, M., Gotay Sardiñas, J. & Will, A. 2020. A new approach for the vanishing gradient problem on sigmoid activation, *Progress in Artificial Intelligence*, 9(4): 351-360.
- Sağıroğlu, Ş., Beşdok, E. & Erler, M. 2003. Mühendislikte yapay zeka uygulamaları-1, *Yapay Sinir Ağları*, 24-47.
- Samatin, N. A. N. & Zhao, H. 2016. A novel activation function for multilayer feed-forward neural networks, *Applied Intelligence*, 45(1): 75-82.
- Sammut, C. G. I. 2010. *Encyclopedia of machine learning*, Springer Science Business Media, LLC, 8: 947–948.
- Huang S, Cai N, Pacheco PP, Narrandes S, Wang Y, Xu W. 2018. Applications of support vector machine (SVM) learning in cancer genomics. *Cancer Genomics & Proteomics*, 15: 41-51.
- Skansi, S. 2018. *Introduction to deep learning: from logical calculus to artificial intelligence*. Springer International Publishing, 196 page, Zagreb.
- Srivastava, D. & Lekha, B. 2010. Data classification using support vector machine. *Journal of Theoretical and Applied Information Technology*, 12(1): 1-7.
- Şahin, E. 2018. Makine öğrenme yöntemleri ve kelime kümesi tekniği ile istenmeyen e-posta / e-posta sınıflaması, Yüksek Lisans Tezi, Hacettepe Üniversitesi, 113 sayfa, Ankara.
- Targ, S., Almeida, D. & Lyman, K. 2016. Resnet in ResNet: generalizing residual architectures, *Workshop Track-ICLR 2016*, 1-7.
- Taşçioğlu, Y. 2017. *Quality control in textile industry quality control and assurance*. IntechOpen, 201-212.
- Terzi, M. S. 2021. Derin öğrenme ile göğüs röntgenlerinden hastalık teşhisi, Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi, 63 sayfa, Konya.
- Türkoğlu, M., Hanbay, K. & Sivrikaya, S. 2021. Kayısı hastalıklarının derin evrişimli sinir ağı kullanılarak sınıflandırılması. *Bitlis Eren Üniversitesi*, 9: 334–345.
- Uçar, M., 2021. Glokom hastalığının evrişimli sinir ağı mimarileri ile tespiti, *DEÜFMD*, 23(68): 521-529.

- Vapnik, V. 1963. Pattern recognition using generalized portrait method, *Automation And Remote Control*, 24: 774–780.
- Wang, H. & Raj, B. 2017. *The origin of deep learning*, Language Technologies Institute School of Computer Science, 70 page, Carnegie Mellon University.
- Weeks, A. R. 1996. *Fundamentals of electronic image processing*, SPIC Press, 32: 37-40.
- Xie, H., Jiang, X., Wang, D. & Zhou, J. 2018. Intelligent fabric defect detection using deep convolutional neural network. *IEEE Transactions on Instrumentation and Measurement*, 67(12): 2957-2965.
- Yao, Z., Zhang, X. & Chen, C. 2018. Automatic fabric defect detection method based on improved convolutional neural network. *Applied Sciences*, 8(9): 1522-1532.
- Zhang, B., Wenqian H., Jiangbo L., Chunjiang Z., Shuxiang F., Jitao W. & Chengliang L. 2014. Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. *Food Research International* 62: 326–43.
- Zhang, Y., Lu, J., Chen, H. & Li, J. 2014. Fabric defect detection based on Gabor filters and PCA algorithm. *Journal of Textile Engineering & Fashion Technology*, 1: 1-7.

## ÖZGEÇMİŞ

### Kişisel Bilgiler

Adı ve Soyadı : Recep Ali GEZE

### Eğitim

Yüksek Lisans Çankırı Karatekin Üniversitesi 2021-2024  
Fen Bilimleri Enstitüsü  
Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı

Lisans 19 Mayıs Üniversitesi 2012-2015  
Mühendislik Fakültesi  
Bilgisayar Mühendisliği Bölümü

### İş Deneyimi

Yıl	Kurum	Görev
2022-Halen	Samsun Atakum Belediyesi	Bilgisayar Mühendisi
2019-2022	Samteks Tekstil Fabrikası	Bilgisayar Mühendisi
2017-2019	Osmanlı Yapı	Bilgisayar Mühendisi
2008-2016	Delta Koleji	Müdür Yardımcısı

### Akademik Aktiviteler

1. Siber Güvenlik Terim Karşılıkları Kitabı, Baskı: Bilgisayar Mühendisleri Odası, Yayın: 2023