

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI**

**KALİTE KONTROL SİSTEMİ İÇİN DERİN ÖĞRENME TABANLI
BİR MODEL ÖNERİSİ**

HAZIRLAYAN

YAREN ÇELİK

YÜKSEK LİSANS TEZİ

ANKARA - 2022

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI**

**KALİTE KONTROL SİSTEMİ İÇİN DERİN ÖĞRENME TABANLI
BİR MODEL ÖNERİSİ**

HAZIRLAYAN

YAREN ÇELİK

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

PROF. DR. BERNA DENGİZ

ANKARA – 2022

FEN BİLİMLERİ ENSTİTÜSÜ

Endüstri Mühendisliği Anabilim Dalı Endüstri Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Yaren Çelik tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 16 / 08 /2022

Tez Adı: Kalite Kontrol Sistemi İçin Derin Öğrenme Tabanlı Bir Model Önerisi

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)

İmza

Prof. Dr. Berna Dengiz

Başkent Üniversitesi

.....

Doç Dr. Erman Çakıt

Gazi Üniversitesi

.....

Dr. Öğr. Üyesi Selda Güney

Başkent Üniversitesi

.....

ONAY

Prof. Dr. Ömer Faruk Elaldı

Fen Bilimleri Enstitüsü Müdürü

Tarih : ... / ... /

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: ... / ... /

Öğrencinin Adı, Soyadı: Yaren Çelik

Öğrencinin Numarası: 21910502

Anabilim Dalı: Endüstri Mühendisliği Ana Bilim Dalı

Programı: Endüstri Mühendisliği Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı: Prof. Dr. Berna Dengiz

Tez Başlığı: Kalite Kontrol Sistemi İçin Derin Öğrenme Tabanlı Bir Model Önerisi

Yukarıda başlığı belirtilen Yüksek Lisans/Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 82 sayfalık kısmına ilişkin, 22 / 08 / 2022 tarihinde şahsım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 9'dır. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: ... / ... /

Prof. Dr. Berna Dengiz

TEŞEKKÜR

Yaptığım tüm çalışmalarda beni destekleyen, akademik bilgi ve tecrübeleriyle bana ışık tutan, akademik hayatımı bir kılavuz gibi yönlendiren ve kariyerime yön veren çok değerli tez danışmanım Prof. Dr. Berna Dengiz'e en derin sevgi, saygı ve teşekkürlerimi sunarım.

Tez çalışmamı destekleyerek bu süreçte akademik bilgi birikimiyle bana yol gösteren ve çalışmam için tüm desteğini veren ve en yoğun olduğu zamanlarda bile bıkmadan bana zaman ayıran sevgili hocam Dr. Öğr. Üyesi Selda Güney'e sevgi, saygı ve teşekkürlerimi sunarım.

Tüm üniversite hayatım boyunca sevgisini ve desteğini bir an esirgemeyen, yaptığım her çalışmada bana güvenen, her sorumda kapısını sonuna kadar açan, bıkmadan usanmadan cevaplayan ve varlığıyla beni mutlu eden canım hocam Prof. Dr. Kumru Didem Atalay'a sevgi, saygı ve teşekkürlerimi sunarım.

Akademik bilgi ve tecrübeleri ile yol gösterici olduğu, bana güvendiği ve desteklerini hiç esirgemediği için enstitü müdürümüz Prof. Dr. Ömer Faruk Elaldı, bölüm başkanımız Prof. Dr. Yusuf Tansel İç ve Doç. Dr. Gülin Feryal Can hocalarıma sevgi, saygı ve teşekkürlerimi sunarım.

Tez konum belirlendiği andan itibaren yardımlarını ve desteklerini esirgemeyen, her soruma her zaman cevap veren, bilgi, tecrübe ve deneyimleriyle hem tez sürecime hem çalışma hayatıma katkı sağlayan sevgili iş arkadaşlarım Araş. Gör. Burcu Oltu'ya ve Araş. Gör. Kübra Büşra Karaca'ya en içten sevgi ve teşekkürlerimi sunarım.

Tez sürecimde hep yanımda olan, her soruma bıkmadan usanmadan cevap veren, ellerinden gelen hiçbir yardımı esirgemeyen ve çalışma hayatını zevkli kılan ikinci evimiz olan B403 numaralı odanın kıdemli üyeleri, sevgili oda arkadaşlarım Araş. Gör. Ayşenur Yurtsever hocama ve Araş. Gör. İpek Damla Akpınar'a en içten sevgi ve teşekkürlerimi sunarım.

Adını sayamadığım yardımlarını esirgemeyen tüm öğretim üyesi hocalarıma ve Başkent Üniversitesi ailesine en içten saygı ve teşekkürlerimi sunarım.

Beni her zaman sevgiyle büyüten ve bugünlere getiren, bana asla pes etmemeyi öğreten, verdiğim her karara saygı duyan, maddi ve manevi desteklerini asla esirgemeyen, benimle sonsuz gurur duyan, tüm eğitim hayatım boyunca benim tüm kahrımı çeken, bana benden çok güvenen inan biricik çekirdek aile üyelerimin ve hayatımın en önemli parçası olan annem Nilgün Çelik ve babam Murtaza Çelik'e sevgi ve teşekkürlerimi sunarım.

Çok sevgili anneannem Melek Orhan, büyükbabam Mustafa Orhan, dayım Prof. Dr. Ayhan Orhan'a ve tüm aile üyelerime attığım her adımda beni izledikleri ve destekledikleri, bu süreçte de hayatımın her döneminde olduğu gibi yanımda oldukları ve bana güvendikleri için en derin sevgi, saygı ve teşekkürlerimi sunarım.



ÖZET

Yaren ÇELİK

KALİTE KONTROL SİSTEMİ İÇİN DERİN ÖĞRENME TABANLI BİR MODEL ÖNERİSİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Endüstri Mühendisliği Ana Bilim Dalı

2022

Ahşap hammaddeler günümüzde birçok endüstride yaygın olarak kullanılmaktadır. Ahşap hammadde üzerinde olan ve gözden kaçan istenmeyen görüntüler elde edilen ürünü görsel ve dayanıklılık açısından negatif etkilemekte, satışını engellemektedir. Bu nedenle bu tür hammaddelerin üretim sürecine girmeden belirlenmesi veya üretim hattına kurulacak bir otomasyon sistemi ile hatalı hammaddelerin belirlenerek üretim dışında bırakılması istenir. Kusurlu hammaddenin elle ve gözle kontrolü zor ve yanıltıcıdır. Sürekli gelişen dijital teknoloji ve sistemler sayesinde bu tür kontroller için otomasyon sistemleri geliştirilmektedir. Son yıllarda araştırmacılar görüntü işleme tabanlı denetim sistemlerini kullanarak kalite kontrol uygulamaları geliştirmektedirler. Bu teknolojiler sayesinde hammadde üzerinde olan kusurlar üretimin erken aşamalarında fark edilerek oluşacak son ürünün kusurlu veya hatalı olması engellenebilir. Böylece işgücü ve malzeme kayıpları nedeniyle oluşacak maliyetler ve harcanan zaman azaltılabilmektedir.

Bu çalışmada, üretim hattı üzerinde kurulacak özel bir kamera sistemi ile elde edilen görüntüler üzerindeki kusurları belirleyecek model derin öğrenme yöntemleri ile elde edilmiş ve kusurlu kusursuz ayrımı yapan sistem önerisi geliştirilmiştir. Kusurların tespiti için görüntü işlemede ayrım tabanlı bir yöntem olan Evrişimsel Sinir Ağı (ESA), en uygun yöntemlerden biri olması nedeniyle tercih edilmiştir. Ayrıca ShuffleNet, AlexNet, GoogleNet gibi farklı ESA mimarileri ve parametreleri denenerek probleme en uygun olan mimari belirlenmeye çalışılmıştır. Ahşap ürünlerinde kusurlu ve kusursuz ayrımı yapan kalite kontrol sistemleri için çalışmada dikkate alınan ESA yönteminde, MobileNet, DenseNet ve Inception mimarileri umut verici sonuçlar vermektedir. Ayrıca ESA yöntemi denemelerine görüntü çoğaltma ve görüntü iyileştirme yöntemleri hem ayrı ayrı hem de bir arada eklenerek bu yöntemlerin performans metriklerini nasıl etkilediği incelenmiştir. Yapılan her denemede parametreler değiştirilmiş performans metrikleri üzerindeki etkileri

incelenmiştir. Böylece en iyi performansı veren parametre seti ile ESA mimarisine karar verilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Görüntü İşleme, Evrimsel Sinir Ağları, Ahşap Kusur Tespiti, Ahşap Endüstri, Kalite Kontrol, Sınıflandırma



ABSTRACT

Yaren ÇELİK

A DEEP LEARNING - BASED MODEL PROPOSAL FOR A QUALITY CONTROL SYSTEM

Başkent University Institute of Science

Department of Industrial Engineering

2022

Wood as a raw material is currently used in many industries. Unsightly texture and other defects on the wood make it less visually appealing and impact its durability as a material. Blemishes on the wood reduce its value, and defective material should be identified and removed from production. Since it's difficult to spot defects through visual or manual inspection, an automated system integrated into the production system is a viable option. With the help of advanced digital technology, automated systems for such controls are being developed. In recent years, researchers have been developing quality control applications using image processing-based inspection systems. By means of these technologies, defects in the raw material can be spotted in the early stages of production. Early identification of defects will prevent the production of faulty end products and will reduce labor and material losses in production.

In this study, an integrated system is proposed to identify defective material. The proposed system acquires images of the raw material through a special camera installed on the production line. Digital images will be analyzed by deploying deep learning methods, and defective materials will be set apart. Convolutional Neural Network (CNN), a distinction-based method in image processing for detecting defects, was preferred because of its suitability. In addition, different CNN architectures such as ShuffleNet, AlexNet, GoogleNet, and parameters associated with these architectures were tested to identify the most suitable architecture for this problem. In the CNN method, considered in the study for quality control systems to separate out defective wood products, MobileNet, DenseNet, and Inception architectures gave promising results. In addition, image augmentation and image enhancement methods were added to the CNN method experiments, both separately and together, and their effect on performance metrics was examined. In each trial, parameters were modified, and the impact of parameters on the performance metrics was examined.

Consequently, CNN architecture was selected with the parameter set giving the best performance.

Keywords: Deep Learning, Image Processing, Convolutional Neural Networks, Wood Anomaly Detection, Wood Industry, Quality Control, Classification



İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	iii
ABSTRACT	v
İÇİNDEKİLER.....	vii
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ	x
SİMGELER VE KISALTMALAR LİSTESİ	xiii
1. GİRİŞ.....	1
2. ALANYAZIN TARAMASI	3
3. PROBLEM TANIMI.....	16
4. MATERYAL VE METOT	18
4.1. Ahşap Güve Kovucu Veri Seti	18
4.2. Sınıflandırma Yöntemleri.....	21
4.3. Yapay Zeka ve Yapay Zeka Teknolojileri	21
4.3.1. Makine öğrenmesi ve yapay sinir ağları.....	22
4.3.1.1. Destek vektör makineleri	23
4.3.1.2. K en yakın komşu algoritması.....	26
4.3.1.3. Karar ağaçları	27
4.3.1.4. Yapay sinir ağları.....	28
4.3.1.5. Evrişimsel sinir ağları	32
4.3.1.6. Derin öğrenme modelleri	41
4.4. Görüntü Çoğaltma Yöntemleri	46
4.5. Görüntü İyileştirme Yöntemleri	47
4.6. Sınıflandırıcı Performansının Değerlendirilmesi	49
4.6.1. Sınıflandırıcı modeli doğrulama yöntemleri	49

4.6.1.1. Sınama seti (holdout) yöntemi.....	49
4.6.1.2. K-Katlı çapraz doğrulama (k-fold cross validation) yöntemi ..	50
4.6.1.3. Tek-Çıkışlı çapraz doğrulama (leave one out cross validaion) yöntemi.....	50
4.6.1.4. Yeniden örnekleme (bootstrap) yöntemi.....	50
4.6.2. Sınıflandırıcı modelin başarısının hesaplanması	50
5. UYGULAMA	54
5.1. Çalışmada Kullanılan Ahşap Güve Kovucu Görüntülerinin Düzenlenmesi	54
5.2. Ahşap Güve Kovucu Yüzeyindeki Hataların Belirlenmesi	55
5.3. Sınıflandırma Modelleri: Senaryolar	56
5.4. Performans Metriklerine Göre Model Seçimi	59
5.5. Sonuçların Karşılaştırılması.....	69
6. KALİTE KONTROL SİSTEM TASARIM ÖNERİSİ	72
7. SONUÇLAR VE ÖNERİLER.....	80
KAYNAKLAR.....	82

TABLÖLER LİSTESİ

Tablo 2.1. Alanyazın taraması özeti	8
Tablo 4.1. Bazı Renkleri RGB Değerleri	18
Tablo 4.2. Beyin görsel korteks ile evrimsel sinir ağı işlev karşılaştırması	33
Tablo 4.3. İki sınıflı karışıklık matrisi	51
Tablo 5.1. Derin ağı mimarileri girdi boyutları	55
Tablo 5.2. Model geliştirme adımları	56
Tablo 5.3. Derin ağı mimarileri parametreleri ve sonuçları – I	59
Tablo 5.4. Derin ağı mimarileri parametreleri ve sonuçları – II	60
Tablo 5.5. Derin ağı mimarisi MobileNet-V2 parametreleri ve sonuçları	61
Tablo 5.6. MobileNet-V2 mimarisi ile öznetelik çıkarımı - I	63
Tablo 5.7. MobileNet-V2 mimarisi ile öznetelik çıkarımı - II	64
Tablo 5.8. Derin ağı mimarileri parametreleri ve sonuçları – III	65
Tablo 5.9. Tasarlanan evrimsel sinir ağı parametreleri ve sonuçları – I	66
Tablo 5.10. Tasarlanan evrimsel sinir ağı parametreleri ve sonuçları - II	67
Tablo 5.11. Tasarlanan evrimsel sinir ağı parametreleri ve sonuçları - III	67
Tablo 5.12. Görüntü çoğaltma uygulanan evrimsel sinir ağı parametreleri ve sonuçları	68
Tablo 5.13. Görüntü iyileştirme uygulanan evrimsel sinir ağı parametreleri ve sonuçları	68
Tablo 5.14. Görüntü çoğaltma ve iyileştirme uygulanan evrimsel sinir ağı parametreleri ve sonuçları	69
Tablo 5.15. Görüntü çoğaltma ve nöron eksiltme işlemi uygulanan evrimsel sinir ağı parametreleri ve sonuçları	69

ŞEKİLLER LİSTESİ

Şekil 3.1. İki lineer robotik kol kullanılarak ZG3D cihazındaki giriş ve çıkış sisteminin bir görüntüsü	17
Şekil 4.1. Kusursuz görüntü örnekleri	19
Şekil 4.2. Kusurlu görüntü örnekleri	19
Şekil 4.3. Çalışmada izlenen iş akışı	20
Şekil 4.4. Makine öğrenme algoritmaları	22
Şekil 4.5. DVM için 2 sınıflı doğrusal ayrılabilen problem örneği	24
Şekil 4.6. DVM için 2 sınıflı tam olarak doğrusal ayrılamama problem örneği	25
Şekil 4.7. DVM için 2 sınıflı doğrusal ayrılamama problem örneği	25
Şekil 4.8. K en yakın komşu algoritması	27
Şekil 4.9. Basit karar ağacı yapısı	28
Şekil 4.10. Biyolojik sinir hücresi ve yapay sinir ağı	28
Şekil 4.11. Biyolojik sinir sistemi elemanı ve yapay sinir sistemi işlem elemanı karşılıkları	29
Şekil 4.12. Çok katmanlı yapay sinir ağı yapısı	30
Şekil 4.13. Aktivasyon fonksiyonları	31
Şekil 4.14. İnsan görsel korteks ile evrimsel sinir ağı karşılaştırması	33
Şekil 4.15. Basit evrimsel sinir ağı mimarisi	34
Şekil 4.16. Evrim katmanında evrim işlemi	36
Şekil 4.17. Düzleştirilmiş doğrusal birim fonksiyonunun çıkış verisine etkisi	37
Şekil 4.18. Aktivasyon fonksiyonları	38
Şekil 4.19. Evrimsel sinir ağına dropout katmanı uygulanması	40

Şekil 4.20. AlexNet mimarisi	41
Şekil 4.21. MATLAB AlexNet mimarisi	42
Şekil 4.22. GoogleNet mimarisi	42
Şekil 4.23. MATLAB GoogleNet mimarisi	43
Şekil 4.24. MATLAB MobileNet-V2 mimarisi	43
Şekil 4.25. MATLAB ShuffleNet mimarisi	44
Şekil 4.26. MATLAB SqueezeNet mimarisi.....	45
Şekil 4.27. MATLAB DenseNet-201 mimarisi.....	45
Şekil 4.28. MATLAB Inception-V3 mimarisi.....	46
Şekil 4.29. Kusursuz bir ürüne görüntü çoğaltma teknikleri uygulaması	47
Şekil 4.30. Kusurlu bir ürüne görüntü çoğaltma teknikleri uygulaması.....	47
Şekil 4.31. Kusursuz bir ürüne görüntü iyileştirme teknikleri uygulaması	48
Şekil 4.32. Kusurlu bir ürüne görüntü iyileştirme teknikleri uygulaması	49
Şekil 4.33. İşlem karakteristik eğrisi (ROC)	53
Şekil 5.1. Veri setinden örnek görüntüler.....	54
Şekil 5.2. Algoritma geliştirmede adım 1 detayı.....	57
Şekil 5.3. Derin ağ mimarileri sonuçları – I	60
Şekil 5.4. Derin ağ mimarileri sonuçları – II	61
Şekil 5.5. Derin ağ mimarisi MobileNet-V2 sonuçları.....	62
Şekil 5.6. Derin ağ mimarileri sonuçları – III.....	65
Şekil 5.7. MobileNet-V2 derin ağ mimarisi karışıklık matrisi	70
Şekil 5.8. Inception-V3 derin ağ mimarisi karışıklık matrisi	70

Şekil 6.1. Kalite kontrol sistem tasarımı	72
Şekil 6.2. Kalite kontrol sistem tasarım bileşenleri	73
Şekil 6.3. ZeroGravity3D cihazı.....	74
Şekil 6.4. Kalite kontrol sistemi arayüz tasarım akışı	74
Şekil 6.5. Akıllı kalite kontrol sistemi arayüzü – I.....	75
Şekil 6.6. Akıllı kalite kontrol sistemi arayüzü – II.....	76
Şekil 6.7. Akıllı kalite kontrol sistemi arayüzü – III	77
Şekil 6.8. Akıllı kalite kontrol sistemi arayüzü – IV	78
Şekil 6.9. Akıllı kalite kontrol sistemi arayüzü – V	79

SİMGELER VE KISALTMALAR LİSTESİ

ADALINE	Uyarlamalı Lineer Nöron veya sonraki Uyarlamalı Lineer Eleman
AUC	İşlem Karakteristik Eğri Değeri
CIFAR	Kanada İleri Araştırmalar Enstitüsü
ÇESA	Çağdaş Evrişimsel Sinir Ağların
ÇKA	Çok Katmanlı Algılayıcılar
DA	Derin Ağ
DN	Doğru Negatif
DP	Doğru Pozitif
DSA	Derin Sinir Ağları
DTCWT	Çift Ağaçlı Karmaşık Dalgacık Dönüşümü
DVM	Destek Vektör Makineleri
ESA	Evrişimsel Sinir Ağı
Epok	Eğitim Tur Sayısı
FMMIS	Bulanık Enk-Enb Sinir Ağları
k-NN	K En Yakın Komşu Algoritması
LBP	Yerel İkili Desen
LSTM	Uzun Ömürlü Kısa-Dönem Belleği
NCAP	Sinirsel Hesaplama ve Adaptif Algı
R-CNN	Bölgeye Dayalı Evrişimsel Sinir Ağları
ReLU	Düzleştirilmiş Doğrusal Birim Katmanı
ROC	İşlem Karakteristik Eğrisi
S-LVQ	Spiking Öğrenme Vektör Kuantajı
SOM	Kendi Kendini Organize Eden Haritalar
UAD	Denetimsiz Anomali Algılama
YN	Yanlış Negatif
YP	Yanlış Pozitif
YSA	Yapay Sinir Ağları
YZ	Yapay Zeka

1. GİRİŞ

İnsanlar her zaman üretim, sanat, ticaret, mimari gibi birçok alanda kalite arayışı içinde olmuşlardır. Kalite anlayışı, 1960'lı yıllardan itibaren kendini yenileyerek insan odaklı iken rekabetin artması ve küreselleşme sonucunda 20.yüzyılın son çeyreğinde bir yönetim yaklaşımı haline gelmiştir. Bu anlayış ile firmalar arasındaki rekabetin, ne kadar çok ürün üretildiği ile değil üretilen ürünün ne kadar kaliteli olduğu ile ilgili olması gerektiği ön plana çıkmıştır.

Genel olarak kalite, bir ürün veya hizmetin belirlenen ya da olabilecek ihtiyaçları karşılayan ve tüketicinin isteklerine cevap veren özelliklerinin toplamıdır. Kalite kontrolü ise bir sürecin etkinliğini azaltacak durumlara karşı önlem olarak kaliteyi koruma anlamına gelir. Temel amacı müşterilerin beklentilerinin ve firmaların amaçlarının en uygun seviyede karşılanabileceği ürünün üretimi için planların oluşturulup uygulanarak etkin bir sürekliliğin sağlanmasıdır. Kalite kontrolü, üretimin her aşamasında olduğu kadar, önceki ve sonraki faaliyetlerde de etkili olan geniş bir fonksiyondur. Modern yönetimin gelişmiş matematiksel araçlarından biridir ve üretilen ürünün şartlarına uygun kalitesini sağlamak için yapılan işlemlerin tümüdür [1].

Üretim sürecinde hatalar varsa, bu hataların önceden gözlenmesini ve düzeltici önlemler alınarak üretilen ürünlerin hatalı olması önlenir. Bu sayede işgücü, hammadde veya yarı mamul ve zaman israfı da engellenmiş olur. Kalite kontrol ile piyasaya sunulan ürünün belli bir standarda sahip olması ve ürünün üretiminin her aşamasının da yine standartlaştırılması sağlanmaktadır. Böylece üretilen her ürüne ve üreticisine olan güven artar, çabuk ve etkili muayenelerle daha az masraf ve zararla üretim süreçleri korunabilir. Geçmişte gözle yapılan kontroller günümüz teknolojisi ile otomatik hale gelmektedir. Gıdadan tekstile, otomotive kadar birçok sektörde üreticiler üretimin her aşamasında otomasyona geçmeyi istemektedir [1].

Sürekli gelişen teknoloji ve sistemler sayesinde üretimin her aşaması kontrol altında tutulabilmektedir. Sektör ne olursa olsun üretim süreçlerini kontrol altında tutabilmek için hammadde ve yapısı, üretim süreci, kalite kriterleri, kalite kontrol faaliyetleri gibi kriterler göz önüne alınmalıdır. Son yıllarda teknolojik gelişmelerle birlikte rekabetin arttığı üretim sektörlerinde kalite kontrol faaliyetleri daha çok önem taşımaya başlamıştır [1].

Yüzey veya Dokuya Dayalı Anormallik algılama, endüstriyel kalite denetimi kapsamında, örneğin lekeler, renk uyumsuzluğu, çatlaklar vb. gibi nesnelerin dokusuyla

ilgili hataları tespit etmeye odaklanan bir alandır. Bu anormallikler hatalı sonuçlara yol açtığı için nihai ürün kalite kontrolünü gerekli kılar. Bu genellikle, nesnenin dokusunun modellerini algılayabilen kameralar veya diğer sensörler kullanılarak gerçekleştirilir. El ile muayenenin veya incelemenin birçok endüstri için sıkıcı, yavaş ve hatalı olabildiği durumlar nedeniyle süreci otomatikleştirebilmek çok önemlidir.

Ahşap malzemelerin yapılarında ve renklerindeki çeşitlilik nedeniyle anormallikleri tespit etmek zordur. Bu nedenle “sadece doğru ahşap dokuları öğrenmek” zorlaşır. Bununla birlikte, endüstri kullanıcıları, üretim sırasında meydana gelebilecek olası tüm anormallikleri ve bunların görünümelerini genellikle derleyemezler. Diğer yandan, el ile etiketleme işlemi oldukça öznel ve zaman alıcı bir iştir. Bu zorluklar nedeniyle, problem karmaşık bir probleme dönüşür. Ahşap anormalliklerinin tespit edilmesinde bu zorluklar önemli bir rol oynamaktadır.

Tez çalışması yedi ana başlıktan oluşturmaktadır. İlk bölümde çalışmanın konusuna, amacına ve önemine yer verilmiştir. İkinci bölümde ahşap hataları sınıflandırma çalışmaları üzerine yapılmış araştırmalar ve alanyazın özeti verilmiştir. Tezin üçüncü bölümünde ele alınan probleme yer verilirken dördüncü bölümünde kullanılan veri seti tanıtılmış, uygulanan yöntemler matematiksel temelleri ile açıklanmıştır. Beşinci bölümünde tez çalışmasında izlenen yol haritasına yer verilerek adım adım anlatılmış, dördüncü bölümde matematiksel temelleri ile açıklanan yöntemlerin yine aynı bölümde tanıtılan veri setine uygulanarak elde edilen araştırma bulgularına yer verilmiştir. Altıncı bölümde çevrimiçi kalite kontrol sistem tasarımı tanıtılmaktadır. Tezin yedinci ve son bölümünde ise elde edilen tüm sonuçların değerlendirilmeleri, alanyazındaki çalışmalar ile karşılaştırılmaları ve öneriler yer almaktadır.

Sonuçta yapılan bu tez çalışmasında, ahşap kusurlarını içeren veri setinin yüksek doğrulukla sınıflandırılmasını sağlayan bir model ve bu modelin kullanılacağı bir sistem önerilmiştir.

2. ALANYAZIN TARAMASI

Yapay Sinir Ağları (YSA) 1940'lı yıllardan beri var olan bir alandır. İlk defa 1943 yılında Nöroloji hekimi McCulloch ve matematikçi Pitts insan beynindeki hücrelerin çalışma şeklinden esinlenerek beyninin fonksiyonlarına dayalı bir matematiksel model önermişlerdir. Bu doğrusal model pozitif ya da negatif olduğuna bakarak iki farklı sınıfı birbirinden ayırabilmektedir. Burada temel amaç insan beyninin öğrenme yeteneğini kullanmak olmuştur. Bunun için modelin ağırlıklarının ayarlanmış olması (en iyi değerlerinin bulunması) gerekmektedir [2].

1949 yılına gelindiğinde ise Donald Hebb, soyadını verdiği Hebb kuralı ile sinir ağı bağlantı sayısını değiştirerek daha iyi bir öğrenmenin sağlanacağını belirtmiştir [3].

1958 yılında Frank Rosenblatt tarafından tek katmanlı algılayıcılar geliştirilmiştir. Bu çalışmada her sınıftan verilen örnekleri kullanarak ağırlıkları öğrenen ilk model olan perceptron kullanılmıştır [4]. Ardından 1960 yılında Widrow ve Hoff adaptif $f(x)$ fonksiyonunun değerlerini kullanarak reel sayı tahmini yapan doğrusal eleman Uyarlamalı Lineer Nöron veya sonraki Uyarlamalı Lineer Eleman (Adaptive Linear Neuron or later Adaptive Linear Element ADALINE) modelini geliştirmiştir [5].

1975 yılında Fukushima beyin fonksiyonları hakkındaki bilgilerden esinlenerek ilk karmaşık sinir hücresini kullanmıştır. 1980 yılında ise Fukushima görüntü işlemede memeli beyninin görsel sisteminden esinlenerek elde ettiği çok güçlü bir model mimarisini ortaya koymuştur. Böylece Derin Ağ (DA)'ların da temelini oluşturulmuştur ve bu tarihten sonra da YSA ile ilgili gelişmeler hızlanmıştır [6].

İlk olarak Rumelhart 1986 yılında tek ve iki katmanlı sinir ağlarında geri yayılım algoritması kullanmıştır. Bu algoritma ile YSA modellerinin kullanımında büyük bir artış görülmüştür [7].

1997 Hochreiter ve Schmidhuber doğal dil işleme problemi gibi birçok dizilim modelleme probleminde kullanılacak Uzun Ömürlü Kısa-Dönem Belleği (Long-Short Term Memory, LSTM) modelini geliştirdiler [8]. 1998 yılına gelindiğinde ise LeCun ve arkadaşları Çağdaş Evrimsel Sinir Ağların (ÇESA) temelini oluşturan modeller geliştirmişlerdir [9].

2000'li yıllara gelindiğinde Kanada İleri Araştırmalar Enstitüsü (CIFAR), Sinirsel Hesaplama ve Adaptif Algı (NCAP) programıyla sinir ağı araştırmalarını canlı tutmaya devam etmiştir. Bu sayede birçok makine öğrenmesi araştırma grubu birlikte çalışmıştır [10].

Sinir ağı araştırmalarının 3. dalgası 2006 yılında Geoffrey Hinton tarafından Derin Sinir Ağları (DSA) olarak bilinen bir tür sinir ağını gösterdiği çalışma ile başlamıştır. Bu çalışmada DA katmanları denetimsiz öğrenme metodu kullanılarak eğitilmiştir [11]. 2007 yılında aynı metodu kullanarak Bengio, Ranzato ve arkadaşları farklı birçok ağı eğitilebileceğini gösterdiler. Sinir ağlarının bu gelişmesinden sonra makine öğrenmesi teknolojilerine dayalı Yapay Zeka (YZ) sistemleri de yaygınlaşmıştır.

Yapay zeka teknolojilerinde yaşanan gelişmeler YZ'nin sağıktan savunmaya, üretimden hizmete birçok sektörde kullanımını artırmıştır. Son yıllarda üretim sektöründe özellikle kalite kontrol gibi insan gözlemine bağlı işlemlerin yeni teknolojilerle dönüşümü, dolayısıyla otomasyon sistemlerinin tasarımı önem taşımaktadır. Özellikle bu alandaki çalışmaların sayısı gün geçtikçe artmaktadır. Tablo 2.1'de ahşap endüstrisinde yapılan çalışmalara kısaca değinilmiştir. Yapılan çalışmalar incelendiğinde özellikle derin öğrenme yöntemlerinin uygulandığı görülmektedir.

Ruz ve ark. (2005), Şili üniversitesi veri tabanından elde ettikleri 900 renkli görüntü için Bulanık Enk-Enb Sinir Ağları (Fuzzy Min-Max Neural Networks for Image Segmentation) FMMIS) yöntemi kullanmışlardır. FMMIS yöntemi ile test setinde yüzde 95'lik bir kusur tespit oranı elde edildi. Sonuçlar, önceki çalışmalara kıyasla önemli gelişmeler olduğunu ve FMMIS yönteminin hesaplama yükünün gerçek zamanlı bölütleme görevleri için uygun olduğunu göstermektedir [12].

Aynı yıl França ve ark. (2005), yayınladıkları çalışmada 199 plaka için Görüntü işleme ve öznitelik çıkarımı gibi ön işlem adımları uygulayarak ileri beslemeli sinir ağlarını kullanmışlardır. Çalışmalarında önerdikleri iki sınıflandırıcı diğerlerinden daha iyi sonuçlar vermiştir. Her ağ için yalnızca bir özellik kullanan ve çıktıları doğrudan bulanık kurallara bağlı olan ilk sınıflandırıcının en yüksek doğruluk değeri %66,33, her ağın çıktılarına bulanıklaştırma katmanı uygulayan ikinci sınıflandırıcının en yüksek doğruluk değeri ise %67,33 olarak elde edilmiştir [13].

Shahnorbanun ve ark (2010), 12 farklı kusurlu ve kusursuz görüntülerden oluşan veri setini kullanarak 17 öznitelik için 232 öznitelik vektörü elde etmişlerdir. Spiking Öğrenme Vektör Kuantajı (Spiking Learning Vector Quantization, S-LVQ) mimarisi ile bu öznitelikleri sınıflandırmışlardır. S-LVQ ağları ile yapılan deneyler, çeşitli kusur türleri arasında daha iyi ayırım yapma yeteneğine sahip olduklarını göstermiştir. Ayrıca sınıflandırma süresi açısından da hata sınıflandırmasını daha iyi yapmışlardır [14].

Kamal ve ark. (2017), Oulu Üniversitesi'nin erişime açık 5 farklı ahşap düğüm kusurlarına sahip toplam 395 görüntüden oluşan veri setini kullanmışlardır. Önerilen

yöntem, ilk olarak, farklı ahşap kusurlarına ait 395 örnekten gri seviyeli birlikte oluşum matrisine dayalı öznetelikleri çıkartır ve ardından farklı ahşap kusurlarına ait 395 örnekten yasaların doku enerjisi ölçümlerine dayalı öznetelikleri çıkarır. İleri beslemeli geri yayılım sinir ağı, ilk olarak gri seviyeli birlikte oluşum tabanlı öznetelikler ve ikinci olarak yasalara göre doku enerji ölçüleri tabanlı öznetelikler kullanılarak kusurları sınıflandırmak için kullanılır. Önerilen teknik, ahşap kusurları sınıflandırması için umut verici sonuçlar vermiştir [15].

Ren ve ark. (2018), erişime açık 4 farklı veri setini ESA ile sınıflandırmışlardır. Çalışmada öznetelik çıkarımı ile sınıflandırma ve hata bölütleme yapılmıştır. Sınıflandırma işlemlerinde önerilen yöntem, doğruluk değerini artırmıştır. Bölütleme işlemlerinde ise önerilen yöntem üç kusur türünde hata kaçış oranlarını azaltırken yedi kusur türünün tümünde doğruluk değerlerini artırmıştır [16].

He ve ark. (2019) 6 sınıfa sahip 1200 görüntüyü VGG16 ve Tam Evrişimsel Sinir Ağından oluşan Karma Tam Evrişimsel Sinir Ağı modelini kullanarak sınıflandırmışlardır. Orijinal veri setine çeşitli görüntü işleme yöntemleri uygulanmıştır. Ayrıca yeni veri setindeki kusurlar incelenerek etiketlenmiştir. Altı tür ahşap kusurunun tanımlanması Karma Tam Evrişimsel Sinir Ağı ile yüksek bir doğrulukla sağlamıştır [17].

Urbonas ve ark. (2019) yaptıkları çalışmada 4 farklı kusuru içeren kusurlu kusursuz toplam 4729 görüntüyü kullanarak sinir ağı eğitmişlerdir. Bu veri setindeki görüntüler çoğaltmış ve 800×600 piksel çözünürlüğe düşürmüşlerdir. Çalışmada ahşap kaplama yüzey kalitesinin otomatik analizi için daha hızlı Bölgeye Dayalı Evrişimsel Sinir Ağları (Region Based Convolutional Neural Networks, R-CNN) modelini kullanmışlardır. Sonuçlar, dört sınıf ahşap kaplama yüzey kusurunun tanımlanması için, veri artırma ve transfer öğrenme tekniklerinin uygulanabilirliğini göstermiştir. En iyi ortalama doğruluk, önceden eğitilmiş ResNet152 sinir ağı modeli kullanılarak elde edilirken, tüm kusur sınıflarını tek tipte birleştirerek, yüzey kusurlarını bulmada %96,1 doğruluk elde edilmiştir [18].

Ding ve ark. (2020), Akagi ve Pinus sylvestris ağaçlarından elde edilen iki tür ahşap için 3 farklı sınıf kusuru (tahta düğümler, ölü düğümler ve kontrol) içeren 200×200 piksel boyutunda toplam 500 görüntü elde etmişlerdir. Bu kusurları tespit etmek için transfer öğrenme yöntemine dayalı bir hedef tespit algoritması kullanılmıştır. Algoritmayı geliştirmek için DenseNet ağı seçilmiştir. Üç tür kusuru için ortalama hassasiyet %96,1'dir [19].

Yapılan bir başka çalışmada Gao ve ark. (2021), Oulu Üniversitesi tarafından sağlanan ve 448 ladin düğümü için görüntü içeren bir veri setini kullanmışlardır. Ahşap düğümler veri

seti, sırasıyla 268 eğitim, 90 doğrulama ve 90 test görüntüsü dahil olmak üzere 6:2:2 oranında eğitim seti, doğrulama seti ve test seti olarak ayrılan 448 görüntüden oluşan yedi sınıf içerir. Veri çoğaltma ile yeni veriler eklemiş ve çeşitli görüntü işleme işlemleri uygulamıştır. Son olarak eğitim, doğrulama ve test veri kümeleri için sırasıyla 1885, 636 ve 615 görüntü elde etmişlerdir. Bu veri setindeki ahşap düğüm kusurlarını hızlı ve doğru bir şekilde belirlemek için TL-ResNet-34 transfer artık sinir ağını önermişlerdir. Önerilen bu yöntem, diğer uygulamalara göre daha doğru ve daha hızlı ahşap kusurlarını tanımlanmaktadır [20].

Qayyum ve ark. (2021), Oulu Üniversitesi erişime açık olan ahşap düğüm kusurlarına ait veri seti kullanmışlardır. Önerilen sinir ağı yöntemi, 90 farklı ahşap kusur örneğinden gri seviyeli birlikte oluşum matrisine dayalı öznetelikleri çıkarır. Bu öznetelikleri kullanarak kusurları sınıflandırmak için bir Parçacık Sürü Optimizasyonu ile belirlenen parametreler eğitilen ileri beslemeli sinir ağını kullanmışlardır [21].

Ahşap kusurlarının tespiti için yapılan çalışmalarda derin öğrenme yöntemlerinin yanısıra geleneksel makine öğrenmesi yöntemleri de kullanılmıştır.

Silven ve ark. (2001), çalışmalarında VTT Building Technology tarafından hazırlanan veri setine 2 aşamalı bir muayene işlemi uygulamışlardır. İlk aşamada, olası kusurlu bölgeler tespit edilirken ikinci aşamada, bu bölgelerdeki bireysel kusurlar incelenmiştir. Her iki aşamadaki sınıflandırmalar, Kendi Kendini Organize Eden Haritalar (Self-Organizing Map (SOM)) kullanılarak uygulanan denetimsiz kümelemeye dayanmaktadır. Burada sunulan sonuçlar, diğer yaklaşımlarla aynı test materyali için daha önce elde edilen sonuçlardan önemli ölçüde daha iyidir [22].

Cavalin ve ark. (2006), çalışmalarında eğitim verileri için Pinus kerestesinden ve test verileri için diğer 100 keresteden elde edilen toplam 400 görüntüden oluşan bir veri setini kullanmışlardır. Burada, gri tonlamalı görüntülerden çıkarılan öznetelikler kullanılarak ahşaptaki kusurlar tespit edilmeye çalışılmıştır. Öznetelik setinin performansını değerlendirmek için Sinir Ağları, Destek Vektör Makineleri ve çok amaçlı genetik algoritmalara dayalı bir özellik seçim algoritması kullanmışlardır. Deneysel sonuçlar, öznetelik seçiminden sonra, gri tonlamalı görüntü tabanlı öznetelik kümesinin, renkli görüntü tabanlı özneteliklere göre ahşap kusur tespiti için daha iyi bir performans elde edildiğini göstermektedir [23].

Wu ve ark. (2009), yılında VTT Building Technology tarafından sağlanan görüntü veri tabanından hatasız 1229 pozitif örnek ve kusurlu 879 negatif örnek olmak üzere toplam 2106 örneği eğitim seti olarak seçip WOOD_T adlı bir veri seti oluşturmuşlardır.

Yerel İkili Desen (Local Binary Pattern, LBP) ve Çift Ağaçlı Karmaşık Dalgacık Dönüşümü (Dual-Tree Complex Wavelet Transform, DTCWT) yöntemleri, sınıflandırma işlemlerinde sıklıkla kullanılan Destek Vektör Makineleri (DVM) birleştirilerek yeni bir ahşap kusurlarını tanıma yöntemi sunmuşlardır. Kullanılan yöntemlerin başarısının, örüntü tanımada LBP ve DTCWT'nin yaygın olarak kullanılmasından ve bunların etkili bir şekilde birleştirilmesinden kaynaklandığı anlaşılmaktadır [24].

Mahram ve ark. (2012), Oulu Üniversitesi tarafından hazırlanmış olan ahşap ve düğüm veri tabanını kullanarak 5 kusur türü için sınıflandırma algoritması geliştirmişlerdir. Bu sınıflandırma algoritmasında Destek Vektör Makineleri (DVM) ve k-En Yakın Komşu (k-Nearest Neighbour, k-NN) sınıflandırıcıları kullanılmıştır. Çalışmada hem SVM hem de k-NN sınıflandırıcıları için hibrit özniteliklerin, önceki önerilen yöntemlere kıyasla daha iyi performansa sahip olduğu açık bir şekilde gösterilmiştir [25].

Mohan ve ark. (2012) yaptıkları çalışmayı 4 farklı budak türü içeren toplam 400 adet ahşap budak görüntüsü kullanılarak gerçekleştirmişlerdir. Bu çalışmada ahşap levhalardaki budakların tespiti ve sınıflandırılması önerilmiştir. Düğümlerin görüntüsüne Hilbert dönüşümü ve Gabor filtreleri kullanılarak önceden işlenmiş ve öznitelikleri çıkarılmıştır. Çıkarılan öznitelikler Naive Bayes, Radyal Temel fonksiyonu ve Torbalama Teknikleri kullanılarak sınıflandırılmıştır. Radyal Temel fonksiyonu ile elde edilen sonuçlar yüksek sınıflandırma doğruluğu vermiştir[26].

Faura ve ark. (2021), yaptıkları çalışmada Window ve Facade adıyla erişime açık iki veri setini kullanmışlardır. Bu veri setleri farklı ağaç örneklerinden kaydedilen Nem İçeriği (MC) sinyallerinden oluşmaktadır. Denetimsiz Anomali Algılama (Unsupervised Anomaly Detection, UAD) tekniklerini uygulayarak kusur tespiti yapmışlardır. Deneysel sonuçlar UAD'nin her iki durumda da anomalileri başarılı bir şekilde tespit etmek için uygulanabileceğini göstermektedir. Elde edilen anormallik skorunu, en büyük $F_{0.5}$ skoru 0.9581 olarak, daha düşük bir eşik değeri kullanıldığında ise 1 olarak elde etmişlerdir [27].

Tablo 2.1. Alanyazın taraması özeti

No	Yıl	Yazar	Çalışma	Veri Seti	Sınıflandırma Yöntemi	Kullanılan Diğer Yöntemler
1	2001	O. Silven, M. Niskanen, H. Kauppinen	Wood Inspection with Non-Supervised Clustering	Veri seti VTT Building Technology tarafından hazırlanmıştır. Her kusur için temel doğruluk sınıflandırmalarına sahip çok sayıda çam ahşaptan oluşur. Toplamda yaklaşık 900 mb veri ve 1000'den fazla etiketli kusur içeren bir dizi 42 pano görüntüsüne dayanmaktadır.	Ahşap muayene iki aşamaya ayrılır. İlkinde, olası kusurlu bölgeleri tespit edilirken ikincisinde, bunlar bireysel kusurlar olarak incelenir. Her iki aşamadaki sınıflandırmalar, kendi kendini organize eden haritalar (Self-Organizing Map (SOM)) kullanılarak uygulanan denetimsiz kümelemeye dayanmaktadır.	Yerel ikili özellik (Local Binary Patterns) özelliklerini çıkarılmıştır.
2	2005	G.A. Ruz, P.A. Estévez	Image Segmentation Using Fuzzy Min-Max Neural Networks for Wood Defect Detection	Şili Üniversitesi veri tabanından ahşap panoların 900 renkli görüntüsünden (320×240 piksel) bir örnek alınmıştır. Her görüntü, 10 kusur kategorisinden (kuş gözü ve çil, kabuk ve zift cepleri, solma, ayrılma, leke, mavi leke, öz, ölü düğüm, canlı düğüm ve delik.) birine göre manuel olarak etiketlenmiştir. Kategori başına 90 görüntüye karşılık gelen veri seti, eğitim seti için 600 görüntü ve test seti için 300 görüntü olmak üzere iki gruba ayrılmıştır.	Bulanık Enk-Enb Sinir Ağları (Fuzzy min-max neural network (FMMIS)) kullanılmıştır.	Görüntü bölütleme işlemi uygulanarak kusurlu bölgeler belirlenmiştir.

Tablo 2.1. devam ediyor.

3	2005	Celso A. Franca, A. Gonzaga	Classification of Wood Plates by Neural Networks and Fuzzy Logic	Test seti (199 plaka) üç endüstri müfettişi tarafından sınıflandırıldı. Bunlar arasında sadece 116 plakanın aynı sınıflandırmaya ulaştığı doğrulandı.	İleri beslemeli Sinir Ağları	Görüntü işleme ve Öznelik çkarımı gibi ön işlem adımları uygulanmıştır.
4	2006	P. Cavalin, L. S. Oliveira, A. L. Koerich, A. S. Britto Jr	Wood Defect Detection Using Grayscale Images and An Optimized Feature Set	Kusur tespiti durumunda, iki sınıfla ilgilendirilmiştir: iyi ahşap ve kusurlular. Eğitim setini oluşturmak için grafiksel bir arayüz geliştirilmiştir. Bu arayüz görüntüyü 32×32 dikkdörtgen bölgelere ayırır ve bir çeşit kusur içerirler sınıf 1 (kusurlu) olarak işaretlenir. İşaretlenmemiş olanlar sınıf -1 (iyi ahşap) olarak etiketlenir. Bu çalışmada ele alınan veri tabanı, eğitim için Pinus kerestesinden ve test için diğer 100'den keresteden elde edilen 400 görüntüden oluşmaktadır.	Gri tonlama tabanlı özellik setinin performansını değerlendirmek için iki farklı makine öğrenimi yöntemi seçilmiştir: Sinir Ağları ve Destek Vektör Makineleri. Ağların parametreleri ampirik olarak belirlenmiştir. Deneylerde LIBSVM paketini kullanılmıştır. SVM'nin parametreleri, LIBSVM'de bulunan bir ızgara arama aracı aracılığıyla ayarlanmıştır.	Gri tonlamalı tabanlı özellik ve Renk tabanlı özellikler çıkarılarak sınıflandırma çalışmalarında kullanılmıştır.

Tablo 2.1. devam ediyor.

5	2009	Si-Y. Wu, Z. Zhang, L. Feng	Statistical Feature Representations for Automatic Wood Defects Recognition Research and Applications	VTT Building Technology tarafından sağlanan görüntü veritabanından hatasız 1229 pozitif örnek (1 etiketli) ve kusurlu 879 negatif örnek (-1 etiketli) dahil olmak üzere 2106 örneği eğitim seti olarak seçilmiştir. Test örnekleri olarak 30 temsili örnek seçilmiş ve kusurların renklerini, dokularını, arka plana yakın olanlar ve daha farklı olanların bulunabileceği WOOD_T adlı bir veri seti oluşturulmuştur.	VTT Building Technology tarafından sağlanan görüntü veritabanından hatasız 1229 pozitif örnek (1 etiketli) ve kusurlu 879 negatif örnek (-1 etiketli) dahil olmak üzere 2106 örneği eğitim seti olarak seçilmiştir. Test örnekleri olarak 30 temsili örnek seçilmiş ve kusurların renklerini, dokularını, arka plana yakın olanlar ve daha farklı olanların bulunabileceği WOOD_T adlı bir veri seti oluşturulmuştur.	LBP+SVM ve DTCWT+SVM olmak üzere iki hibrit algoritma kullanılmıştır.	Yerel ikili desen (LBP), kıvrımlı kenarlar gibi orijinal uzamsal yerel yapı özelliklerini çıkarmak ve daha iyi parlaklık uyarlayabilmek için kullanılmıştır. Eşzamanlı olarak, farklı yönlerden ve frekanslardan enerji tabanlı istatistiksel özellikleri çıkarmak için çift ağaçlı karmaşık dalgacık dönüşümü (DTCWT) kullanılmıştır.
6	2010	S. Shahnorbanun, S.A. Siti Nurul Huda, A. Haslina, O. Nazlia, H. Rosilah	A Computational Biological Network for Wood Defect Classification	Veri seti ahşap kaplama yüzeylerindeki on iki yaygın kusur türünü göstermektedir. Bu çalışmada gerçekleştirilen sınıflandırma deneyleri, temiz ahşabı ve kusurlu ahşap görüntülerini temsil eden aynı 232 öznetelik vektörü kullanılmıştır. Kusur içeren veya içermeyen farklı ahşap görüntülerden on yedi öznetelik çıkarılmış ve S-LVQ sınıflandırıcısı eğitmek için kullanılmıştır.	Ahşap sınıflandırmasında Spiking Öğrenme Vektör Kuantajı (S-LVQ) mimarisi		

Tablo 2.1. devam ediyor.

7	2012	A. Mahram, Mahrokh G. Shayesteh, S. Jafarpour	Classification Of Wood Surface Defects with Hybrid Usage of Statistical and Textural Features	Bu çalışmada Oulu ahşap ve düğüm veri tabanı kullanılmıştır. Bu veritabanında beş tür ahşap düğümün renkli görüntüleri sunulmaktadır. Tüm renkli görseller 64×64 piksel boyutunda gri seviyeye dönüştürülmüştür.	Sınıflandırma için Destek Vektör Makineleri ve K-En Yakın Komşu sınıflandırıcıları kullanılmıştır.	Ahşap yüzey öznetelik çıkarımı için önerilen algoritmalar şunlardır: GLCM, LBP ve istatistiksel momentler. Daha sonra öznetelik vektör boyutunu küçültmek ve en iyi öznetelikleri seçmek için PCA+LDA kullanılarak öznetelik indirgeme işlemi gerçekleştirilir.
8	2012	S. Mohan, K. Venkatachalapathy	Wood Knot Classification Using Bagging	Değerlendirme, 400 adet ahşap budak görüntüsü kullanılarak gerçekleştirilmiştir. Seçilen düğüm türleri kuru düğüm, sağlam düğüm, boynuz düğüm ve kenar düğümüdür. Veri seti, her düğüm sınıfının 100 görüntüsünden oluşur.	Naïve Bayes, Radial Basis Function gibi çeşitli sınıflandırıcılar kullanılarak deneyler yapılmıştır. Torbalama, Naïve Bayes, K En Yakın Komşu (k-NN), REP ağaçları ve Rastgele orman ile kullanılmıştır. Orijinal eğitim veri setinin 1/4'ü kullanılarak oluşturulan her bir bireysel sınıflandırıcı ile bir sınıflandırıcılar komitesi oluşturmak için dört yaklaşım seçilmiştir.	Görüntülere, özellik çıkarma için Hilbert dönüşümü ve özellik azaltma için Gabor filtresi kullanılarak ön işleme işlemleri uygulanmıştır.

Tablo 2.1. devam ediyor.

9	2017	K. Kamal, R. Qayyum, S. Mathavan, T. Zafar	Wood Defects Classification Using Laws Texture Energy Measures and Supervised Learning Approach	Oulu University, Finland erişime açık olan ahşap düğüm kusurlarına ait veri seti kullanılmıştır. Veri setinden (dry knot, second, horn knot, leaf knot, sound knot and edge knot) olmak üzere 5 farklı sınıf oluşturulmuştur. Toplamda 395 görüntü bulunmaktadır.	Enerji, kontrast, korelasyon, ve homojenlik olmak üzere 4 öz nitelik ile İleri beslemeli sinir ağı kullanılmıştır.	GLCM ve LTEM'den elde edilen özelliklerle 2 farklı sınıflandırma performansı gözlemlenmiştir. Ayrıca gizli katmandaki nöron sayıları değiştirilerek sonuçlar incelenmiştir.
10	2018	R. Ren, T. Hung, K. C. Tan	A Generic Deep-Learning-Based Approach for Automated Surface Inspection	NEU surface defect, Weld defect, Wood defect ve Micro-structure defect veri setleri olmak üzere 4 farklı veri seti kullanılmıştır.	Evrişimsel Sinir Ağları	Deneyler 2 bölümden oluşmaktadır. İlk bölümde öz nitelik çıkarımı (multiresolution local binary patterns (MLBP) and gray level co-occurrence matrix (GLCM)) ile sınıflandırma, ikinci bölümde ise hata bölütleme yapılmaktadır.

Tablo 2.1. devam ediyor.

11	2019	T. He, Y. Lu, C. Xu, X. Zhou, Z. Hu, J. Fan	A Fully Convolutional Neural Network for Wood Defect Location And Identification	Dead knot, live knot, blue stain, crack, brown stain, and pitch streak olmak üzere 6 sınıfa sahip 1200 orijinal görüntü elde edilmiştir.	Karma Tam Evrişimsel Sinir Ağı modelini, VGG16 ve Tam Evrişimsel Sinir Ağı kullanılmıştır.	Orijinal veri setine çeşitli görüntü işleme yöntemleri uygulanmıştır. Görüntüler 90,180 ve 270 döndürülmüş, her görüntü iki köşegen boyunca yansıtılmış, her görüntünün yatay ve dikey olarak yansıtılması, görüntünün parlaklığının, kontrastının, doygunluğunun veya tonunun değiştirilmiş, görüntülere Gauss gürültüsü, tuz ve biber gürültüsü eklenerek ya da kutupsal koordinatları dönüştürülerek yeni görüntüler elde edilmiştir. Yeni veri setindeki araçtaki kusurlara bakılarak etiketleri elde edilmiştir.
12	2019	A. Urbonas, V.Raudonis, R. Maskeliunas, R.Damaševicius	Automated Identification of Wood Veneer Surface Defects Using Faster Region-Based Convolutional Neural Network With Data Augmentation And Transfer Learning	1525 × 1525 mm boyutundaki 250 kaplama, eğitim ve test için 300 × 300 mm'lik gruplar halinde taranmıştır. Toplam kullanılabilir görüntü sayısı 4729'du. Bu sayıdan, 982 dal, 288 çekirdek, 398 yarık ve 253 leke kusuru içeren ahşap kusurlu 353 kaplama görüntüsü elde edilmiştir. Toplamda 285 görüntüde en az bir kusur vardı ve altı görüntüde hiç kusur yoktur. Geri kalanlar (kusursuz görüntüler) arka plan olarak kategorize edilmiştir.	Evrişimsel Sinir Ağları. Eğitim için 291 görüntü ve test için en kusurlu tek kaplama yapıklarını temsil eden 62 görüntü kullanılmıştır.	Görüntü işleme ve Öznetelik çıkarımı gibi ön işlem adımları uygulanmıştır. Sinir ağı eğitimini iyileştirmek için orijinal veri seti genişletil ve görüntüler 800 × 600 piksel çözünürlüğe düşürülmüştür.

Tablo 2.1. devam ediyor.

13	2020	F. Ding, Z. Zhuang, Y. Liu, D. Jiang, X. Yan, Z. Wang	Detecting Defects on Solid Wood Panels Based on An Improved SSD Algorithm	2 tip ahşap için 200'er görüntü olmak üzere toplamda 400 görüntü elde edilmiştir. Ön işleme aşamasından sonra 200X200 boyutlarında 3 farklı sınıfa ait toplam 500 görüntü oluşturulmuştur.	ResNet152, Faster-RCNN, YOLO-tiny, SSD, DenseNet-SSD gibi farklı Evrişimsel Sinir Ağı yöntemleri kullanılmıştır.	Optimizasyon yöntemi olarak SGD ve ADAM yöntemleri tercih edilmiştir.
14	2021	R. Qayyum, K. Kamal, T. Zafar, S. Mathavan	Wood Defects Classification Using Glim Based Features and PSO Trained Neural Network	Oulu Üniversitesi erişime açık olan ahşap düğüm kusurlarına ait veri seti kullanılmıştır. Dry, Horn ve Sound olmak üzere 3 farklı düğüm kusur tipini içermektedir	Enerji, kontrast, korelasyon ve homojenlik olmak üzere 4 öznetellik ile ileri beslemeli sinir ağıları kullanılmıştır.	Parçacık Sürü optimizasyon yöntemi ile parametreleri belirlemede kullanılmıştır.

Tablo 2.1. devam ediyor.

15	2021	Á. García Faura, D. Štepec, M. Cankar, M. Humar	Application Of Unsupervised Anomaly Detection Techniques to Moisture Content Data from Wood Constructions	Window ve Facade dataset olmak üzere 2 farklı veri seti üzerinde çalışılmıştır.	Farklı gözetimsiz kusur tespiti yöntemleri kullanılmıştır. (Küme tabanlı Yerel Aykırı Değer Faktörü (CBLOF), PCA yeniden oluşturma hatası (PCA uygulandıktan sonra geri dönüştürülürken yeniden yapılandırma hatası anormallik puanı olarak kullanılır), tek sınıf Destek Vektör Makinesi (SVM), Uzun Kısa Süreli Bellek (LSTM) ve LSTM kodlayıcı-kod çözücü)	Orijinal görüntülere veri çoğaltma işlemleri uygulanmıştır. (A) orijinal görüntü, (B) 180° döndürülmüş dikey ayna (C), (D) yatay ayna, (E) görüntüye Gauss gürültüsü eklenmiş, (F) tuz -biber gürültüsü eklenmiş ve (G) tonu 10'a artırdı. Orijinal görüntüler farklı yöntemlerle işlenmiş ve veri çoğaltma işlemleri uygulanmıştır. Son olarak eğitim, doğrulama ve test veri kümeleri için sırasıyla 1885, 636 ve 615 görüntü elde edilmiştir.
16	2021	M. Gao, D. Qi, H. Mu, J. Chen	A Transfer Residual Neural Network Based on Resnet-34 For Detection of Wood Knot Defects	Deneyisel veri seti, Oulu Üniversitesi Elektrik Mühendisliği Bölümü Bilgisayar Laboratuvarı tarafından sağlanmıştır ve 448 ladin düğümü için görüntü bilgilerini içermektedir. Deneyisel örnek olarak toplam 448 ahşap budak görüntüsü hazırlanmış, böylece 450 orijinal görüntü elde edilmiştir. Ahşap düğümler veri seti, sırasıyla 268 eğitim, 90 doğrulama ve 90 test görüntüsü dahil olmak üzere 6:2:2 oranında eğitim seti, doğrulama seti ve test seti olarak ayrılan 448 görüntüden oluşan yedi sınıf içerir.	AlexNet, VGGNet-16, GoogLeNet, and TL-ResNet34 olmak üzere 4 farklı Evrişimsel Sinir Ağı yöntemleri kullanılmıştır.	

3. PROBLEM TANIMI


Değişen ve gelişen dünya koşullarında üretim sektöründeki firmalar en yüksek seviyede kazanç sağlayabilecek şekilde süreçlerini iyileştirmek için farklı yöntemler kullanmaktadır. 1950’li yıllardan beri gelişmekte olan YZ teknolojileri, bu yöntemlerden biri olarak alanyazında sıklıkla karşımıza çıkmaktadır. Bu tezde, bir üretim hattında üretilen nihai ahşap ürünün görsel kalite kontrol faaliyetinin operatör yerine yapay zekâ yöntemlerinden ESA veya DSA ile oluşturulacak bir modelin kullanıldığı bir sistem tarafından yapılması hedeflenmektedir. Ahşap ürünlerdeki görsel hatalar üretici firmalar için hem maliyette hem de müşteri memnuniyetsizliğinde artışa neden olmaktadır. Ayrıca nihai ürünlerde ortaya çıkabilen hataların anlaşılması çoğu zaman öznellik içeren bir karar mekanizması olduğu için kontrolleri yapacak ve değerlendirecek bir sistemin olması sürecin doğru işlemesine yardımcı olacaktır. Bu tez kapsamında önerilecek tasarım ile ahşap ürün üreten firmalarda insana dayalı kalite kontrol faaliyetlerinin yapay zekâ yöntemleriyle otomatikleştirilmesi ve maliyet, zaman, müşteri memnuniyeti gibi birçok açıdan iyileşme sağlaması beklenmektedir [1].

Bu çalışmada kullanılan görüntüler (veri seti) 16 kameradan oluşan sıfır yer çekimli bir 3-Boyutlu (3 Dimension, 3D) cihaz olan “ZG3D” ile Instituto Tecnológico de Informática (ITI) araştırma enstitüsünde elde edilmiştir. Bu cihaz, birden fazla kamerası ile havadaki bir nesnenin görüntüsünü alır. Alınan görüntüler kırıldıktan sonra ilgili alanda depolanmıştır. Ahşap endüstrisinde kalite kontrol faaliyetlerinde kullanılabilecek bu cihazın daha işlevsel olabilmesi için çevrimiçi sınıflandırma yapması hedeflenmektedir. Bu cihaz bir üretim hattına serbest düşüş veya robotik kol beslemeli olmak üzere iki farklı şekilde kurulabilmektedir. Serbest düşme durumunda incelenecek parçalar bir konveyör içinde hareket eder ve ZG3D cihazının içine düşer, nesne kürenin merkezindeyken tüm kameralar nesnenin görüntüsünü alır, böylece nesnenin hiçbir gizli yüzeyi kalmaz. Daha sonra nesne başka bir konveyöre düşer. Robotik kol beslemesinin görevi ise nesnelerin cihazın altından yukarıya fırlatılmasıdır. Böylece nesne cihazın içinde yer çekimsiz merkezde yakalanabilmektedir.

ZG3D cihazı içerisine ürünler robotik kol beslemesi ile fırlatılmıştır. Şekil 3.1’de bir bant üzerinde ilerleyen ahşap ürünün iki robotik kol ile fırlatıldığında görüntüsü alındıktan sonra, sınıflandırma sonucuna göre, kırmızı (hatalı) ya da yeşil (hatasız) kararın verildiği

süreç gösterilmektedir. Kontrol edilecek ahşap parça giriş konveyör bandından iki lineer robotik koldan biri kullanılarak alınmakta ve cihazın merkezine doğru fırlatılmaktadır. Ahşap parça havada asılıyken eşzamanlı olarak aydınlatma ve 16 kamera tetiklenerek parçanın birden fazla görüntüsü alınmaktadır. Ardından diğer kol parçayı nazikçe alarak çıkış kayışına bırakmaktadır. Bundan sonraki aşamada ise görüntü tanıma işlemi için bu tezde geliştirilen model (yazılan yazılımı) ile ahşap parçanın hatalı olup olmadığına karar verilir ve farklı kutulara konur.

Tezde dikkate alınan bu kalite kontrol sistem tasarımı alanyazında [28] tarafından geliştirilmiş olup henüz bu alanda bilimsel bir yayın yapılmamıştır. Bu kalite kontrol sistem tasarımı içinde kullanılabilecek sınıflandırma modelinin geliştirilmesi hedeflenmiştir. Araştırma grubu ile yapılan işbirliği kapsamında veri setine uygun doğru tahmin etme oranı yüksek olan bir sınıflandırma modelinin geliştirilmesi bu tezin problemini oluşturmaktadır.



Şekil 3.1. İki lineer robotik kol kullanılarak ZG3D cihazındaki giriş ve çıkış sisteminin bir görüntüsü

4. MATERYAL VE METOT

4.1. Ahşap Güve Kovucu Veri Seti

Bu veri setini elde etmenin temel amacı, bir üretim hattında üretilen ahşap güve kovucu üzerinde anormal görüntülü olanı tespit ederek atmaktır. Veri setindeki görüntüler, sıfır yerçekimi olan 3D cihazı kullanılarak elde edilmiştir. Bu cihaz, birden fazla kameranın görüntülediği bir nesneyi havada konumlandırır ve aynı anda görüntüsünü alır [28].

Bu veri seti, aynı sınıftan ahşap dokulu nesnelerden birkaç görünüm yakalayarak anormallik algılama problemi için elde edilmiştir. Bu görüntülerin anormal bölgeleri el ile etiketlenmiştir. Ayrıca, güvenilirliği artırmak için her görüntü iki farklı ekip tarafından etiketlenmiştir. Nesneler çatlak, leke, gözeneklilik ve düğüm olmak üzere dört olası anormallik içermektedir. Bu dört anormallik türü tek bir etiketle işaretlenmiştir ve anormal durum olarak tanımlanmıştır [29].

Veri seti içinde bulunan görüntüler Kırmızı Yeşil ve Mavi (Red Green and Blue, RGB) formatında olup farklı piksel seviyelerine sahiptirler. Bunun sebebi her görüntünün renk tonlarının farklı olmasıdır. Tablo 4.1’de renk bazı temel renklerin RGB türünden değerleri verilmiştir.

Tablo 4.1. Bazı Renkleri RGB Değerleri

Renk	R	G	B
Kırmızı	255	0	0
Yeşil	0	255	0
Mavi	0	0	255
Beyaz	255	255	255
Siyah	0	0	0
Açık Gri	200	200	200
Koyu Gri	100	100	100
Sarı	255	255	0
Turkuaz	0	255	255
Eflatun	255	0	255

Veri setini paylaşan araştırma grubunu bir istatistiksel analiz yapıp yapmadığı eğer yapıldıysa hangi durumda verileri istatistiksel olarak uygun olup olmadıkları

bilinmemektedir. Bu nedenle verilerin istatistiksel olarak uygun olduđu varsayılmış ve herhangi bir analiz yapılmamıştır. Kusursuz ve kusurlu görüntü örnekleri Şekil 4.1 ve Şekil 4.2’de verilmiştir.



Şekil 4.1. Kusursuz görüntü örnekleri [29]




Şekil 4.2. Kusurlu görüntü örnekleri [29]

Açık erişimli veri setinin yapısı dört ana bölümden oluşmaktadır: “Eğitim”, “Doğrulama”, “Test” ve “Tamamı Test”. Eğitim ve doğrulama dizinlerinde bulunan tüm görüntüler kusurlu olmayan yani normal görüntülerdir. Ancak, test dizini iki klasör içerir: “Görüntüler” ve “Maskeler”. Görüntüler dizini içindeki görüntülerin maskeler dizini içerisinde eğer adı (maskesi) varsa bu görüntü kusurlu yani anormal görüntüdür. Sonuç olarak yalnızca anormal görüntülerin maskeleri maske dizini içinde bulunmaktadır. Son olarak, tamamı test dizini içindeki görüntüler test aşaması için daha fazla sayıda görüntü içerir. Bu dizin içinde de bu görüntüler için ayrıca iki maske dizini bulunmaktadır. Bu dizinler, iki ekip tarafından oybirliğiyle etiketlenen (Ve) ve yalnızca bir ekip tarafından etiketlenen (Veya) görüntülerin bölgelerini böler. Bu ayırım ile algoritmaların daha doğru bir şekilde değerlendirilmesine olanak sağlanması hedeflenmiştir. Çünkü alanında uzman insanların bile anlaşılamadığı bölgeler içinde algoritma herhangi bir anormal piksel tespit etse

de bu algoritmanın başarısızlığını göstermez. Bu nedenle anormalliklerde fikir birliği olmayan bölgeler değerlendirme metriklerinden çıkarılmalıdır. Sonuçta yalnızca bir ekip tarafından etiketlenen bölgelerinin yok sayılmasına ve değerlendirme metriklerinde yalnızca iki ekip tarafından oybirliğiyle etiketlenen anormal bölgelerin kullanılmasına karar verilmiştir [29].

Eğitim dizini içerisinde 619 görüntü, doğrulama dizini içerisinde 183 görüntü, test dizini içerisinde 478 görüntü ve tamamı test dizini içerisinde 2398 görüntü bulunmaktadır. Tüm veri 3678 görüntüden oluşmaktadır.

Çalışmada izlenen yol Şekil 4.3'te gösterilmiştir.



Şekil 4.3. Çalışmada izlenen iş akışı

4.2. Sınıflandırma Yöntemleri

Sınıflandırma, bir veri seti üzerinde tanımlı olan çeşitli sınıflara veriyi dağıtma işlemidir. Sınıflandırma algoritmaları, verilen eğitim setinden dağılım şeklini öğrenir ve ardından sınıfı belli olmayan test setindeki verileri öğrendiği bilgiler doğrultusunda doğru sınıflara dağıtmaya çalışır. Veri setinde tanımlı bu sınıfların değerlerine etiket adı verilir ve hem eğitim hem de test verilerinin sınıflarının belirlenmesinde kullanılabilir. Alanyazında farklı birçok sınıflandırıcı bulunmaktadır, ancak bu yöntemlerden hangisinin en doğru en başarılı olduğu kesin olarak söylenemez. Burada önemli nokta veri setinin özellikleri ve verilerin sahip olduğu özniteliklerin dağılımlarının nasıl olduğudur. Bunu belirleyen en önemli nokta problem tanımıdır.

Bu çalışmada farklı yöntemler gerek tek tek gerek bir arada uygulanmış ve sonuçlar incelenmiştir. En iyi sonucu veren yöntem veya yöntemler sınıflandırıcı olarak önerilmiştir.

4.3. Yapay Zeka ve Yapay Zeka Teknolojileri

İlk sanayi devrimi ile başlayan teknolojik gelişmeler günümüze kadar hızla artarak gelmektedir. Özellikle Endüstri 4.0'ın ortaya çıkması nesnelerin interneti, akıllı sistemler gibi kavramları hayatımıza katmıştır. Öyle ki otomotivden havacılığa, tıptan savunma sanayine birçok sektörde internete bağlı nesnelerin, robotların kullanıldığı, kullanılan bu sistemlerin insanlar gibi birbiriyle haberleştiği görülmüştür. Bu gelişmelerle daha çok önem kazanan yapay zeka ilk defa 1950'li yıllarda ortaya çıkmış ve hayatın vazgeçilmez parçaları olan yeni sistemlerin doğmasına yol açmıştır.

Yapay zeka insan zekasına özgü olan, algılama, öğrenme, düşünme, fikir üretme, sorun çözme, iletişim kurma ve karar verme gibi birçok bilişsel fonksiyonları ve otonom davranışları sergilemesi beklenen bir işletim sistemi olarak tanımlanabilir.


Gündelik yaşantıda karşılaşılan olaylar ve problemlerin değişmesi bilgisayarların insanların karar verme ve problem çözme yeteneklerini taklit etmelerinin sağlanmasının değişiklik göstermesine neden olmaktadır. Bu nedenle yapılan yapay zeka çalışmaları yeni teknolojilerin ortaya çıkmasına neden olmuştur:

- a) Uzman sistemler: Bir uzmanın problemleri çözdüğü şekilde problemlere çözümler üreten sistemlerdir.
- b) Makine öğrenmesi ve yapay sinir ağları: Örneklerden aralarındaki ilişkileri öğrenerek hiç görmediği yeni örnekler hakkında karar veren sistemlerdir.

- c) Genetik algoritmalar: Geleneksel eniyileme teknolojisi ile çözülemeyen NP-Zor problemleri çözmek için geliştirilen algoritmalarlardır.
- d) Bulanık önermeler mantığı: Kesin olarak ifade edilemeyen durumlara karar vermeyi sağlayan ve belirsiz bilgileri işleyebilen teknolojilerdir.
- e) Zeki etmenler: Bağımsız çalışabilen ve farklı yapay zeka tekniklerini kullanabilen sistemlerdir.

4.3.1. Makine öğrenmesi ve yapay sinir ağları

İlk olarak Amerikan bilgisayar bilimcisi Arthur Samuel tarafından 1959'da kullanılan makine öğrenmesi terimi, bilgisayarların direkt programlanmadan, insan gözlemlerinin bilgi ve veri formunda kendilerine verilmesiyle insan davranışı göstererek öğrenmesi olarak tanımlanmaktadır. Şekil 4.4'te görüldüğü üzere dört tür makine öğrenme algoritması vardır:



Şekil 4.4. Makine öğrenme algoritmaları

Makine Öğrenmesi problemleri, çözülecek problemin özelliklerine göre Eğitimli Öğrenme, Eğitimli Öğrenme, Yarı Eğitimli Öğrenme ve Pekiştirmeli Öğrenme olarak 4 ana başlık altında toplanabilir [30], [31].

Eğitimli Öğrenme, veri seti içerisindeki örneklerin ne olduğu bilinen problemlerdir. Veri setinde bulunan her örneğin bir sınıfı yani etiketi vardır. Eğitimli Öğrenme Yöntemleri genel olarak sınıflandırma, regresyon ve tahmin olmak üzere üç alt kategoriden oluşur.

Sınıflandırma problemlerinde veri setindeki örnekler farklı etiketler alırlar. Problemlerin çözümü için oluşturulan algoritmalarından elde edilen çıktı test edilecek çıktının ait olduğu sınıfı bulabilmektir. Veri seti içerisinde birbirlerinden farklı sınıflarla etiketlenen örneklerin olması durumunda, yani elde sürekli-sayısal veri varsa bu tip problemler Regresyon problemleri olarak adlandırılır. İki problem arasındaki fark, regresyon problemlerinin veri setlerinde sürekli değerleri kullanılırken sınıflandırma problemlerinin veri setlerinde ayrık sınıf etiketleri kullanılır. Tahmin problemleri ise geçmiş ve şimdiki verilere dayanarak gelecekle ilgili tahminler yaparak genel eğilimlerini analiz etmek için kullanılır [30], [31].

Eğitimsiz Öğrenme, veri seti içerisindeki örneklerin ne olduğu bilinmeyen problemlerdir. Bu problemlerde, veri seti içerisindeki örneklerin benzerliklerine göre bir araya getirilmesi, kümelenmesi sıklıkla kullanılır. Bu problemlerde sınıf bilgisi aranmaz. Veri setindeki örnekler, sahip oldukları özellik değerlerine göre karşılaştırılır ve birbirlerine benzer olan örnekler bir araya getirilir. Eğitimsiz Öğrenme Yöntemleri genel olarak kümeleme ve boyut azaltma olmak üzere iki alt kategoriden oluşur. Kümeleme problemleri, veri setinde benzerlik gösterenlerin gruplanması olarak tanımlanır. Boyut küçültme problemleri ise kesin bilgiye ulaşmak için gerekli olduğu düşünülen değişken sayısını azaltmak olarak tanımlanabilir [30], [31].

Eğitilmiş ve Eğitimsiz Öğrenme Yöntemleri arasında en önemli fark sınıf bilgisinin kullanılıp kullanılmamasıdır. Eğitim aşamasında kullanılan veri setinin kalitesi, yüksek doğruluk metriği için en önemli etkenlerdendir.

Yarı Eğitilmiş Öğrenme Yöntemleri, denetimli öğrenmeye benzemekle birlikte veri setinde bulunan hem etiketli hem etiketsiz verileri kullanmaktadır. Etiketli veriler anlamlı etiketlere sahiptir, bu sayede makine öğrenme algoritmaları etiketsiz verileri anlar ve etiketler.

Pekiştirmeli Öğrenme Yöntemleri ise bir makine öğrenme algoritmasını düzenli olarak öğrenmeye odaklanmaktadır. Burada algoritmalar geçmiş deneyimlerinden öğrenmeye başlar ve elde edilebilecek en iyi sonucu cevap yaklaşımı olarak uyarlar [30], [31].


Bu yöntemlerden hangisinin daha doğru olduğu veri boyutu, elde edilecek çıktı, eğitim süresi, öznitelikler arasındaki ilişkiler gibi birçok faktöre bağlıdır [30], [31].

4.3.1.1. Destek vektör makineleri

Oldukça etkili ve basit bir yöntem olan Destek Vektör Makineleri (DVM), sınıflandırma ve regresyon analizi problemlerin çözümü amacıyla Vapnik tarafından önerilen istatistiksel öğrenme teorisine dayanan bir makine öğrenme algoritmasıdır [32].


DVM'ler etiketli eğitim verilerini kullanarak modeli eğitirler. Ardında eğitilmiş model ile etiketi olmayan verilerin etiketini yani sınıfını belirlerler. DVM'lerin asıl prensibi, veri setindeki verileri yine veri setine ait iki sınıfa göre en doğru şekilde ayıran hiper düzlemi bulmaktır. DVM, doğrusal ayrılma, tam olarak doğrusal ayrılamama ve doğrusal ayrılamama olarak 3 ana grupta toplanabilir [33], [34].

Şekil 4.5'te görüldüğü gibi doğrusal olarak ayrılabilen verileri sınıflandırırken birçok hiper düzlem elde edilebilir. Ancak DVM'ler ile sınıflandırmadaki esas amaç, her sınıfın kendisine ait en yakın destek vektörleri arasındaki uzaklıkları maksimize eden hiper düzlemi bulmaktır.




Şekil 4.5. DVM için 2 sınıflı doğrusal ayrılabilen problem örneği

Veri setinin tam olarak doğrusal ayrılamama durumu, veri setinde gürültülü veri bulunması, çok boyutlu ya da karmaşık yapıda olması gibi nedenlerden olabilir. Bu nedenler veri setindeki verilerin %100 ayrılamamasına yol açabilir. Örneğin; Şekil 4.6'da içi dolu kare gibi veriler sınır içerisine düşebilir (ayrılamama) veya içi dolu dairedeki gibi ayrılma çizgisinin karşısına düşebilirler (yanlış ayrılma). Bu gibi durumlarda istenen doğruların en az hatayla verilerin ayrımını yapabilmesidir [35].



Şekil 4.6. DVM için 2 sınıflı tam olarak doğrusal ayrılamama problem örneği

Gerçek hayat problemlerinde elde edilen veriler doğrusal bir fonksiyonla tam ya da en az hata ile ayrılması çoğunlukla mümkün olmaz. Bu durumda Şekil 4.7’de görüldüğü gibi doğrusal ayrılamama durumu oluşur, burada DVM’ler ayırma işlemini, ayırma eğrisini tahmin ederek yapabilmektedir. Bu tahmin işlemini girdi uzayını kendisinden daha yüksek boyutlu bir özellik uzayına taşıyarak yaparlar [36].



Şekil 4.7. DVM için 2 sınıflı doğrusal ayrılamama problem örneği

4.3.1.2.K en yakın komşu algoritması


İlk olarak Thomas M. Cover ve Peter E. Hart tarafından önerilen K en yakın komşu algoritması, sınıfları belli olan bir veri setine yeni katılacak bir veri noktasının mevcut verilere göre k sayıda en yakın komşuluğuna bakılarak sınıfının belirlenmesi işlemidir.

K en yakın komşu algoritmasının adımları şu şekildedir:

- 1) K komşu sayısı belirlenir. Bu parametre veri setindeki bir noktaya en yakın komşuların sayısıdır.
- 2) Veri setine yeni katılacak olan veri noktasının mevcut verilere göre seçilen uzaklık fonksiyonuna göre uzaklığı tek tek hesaplanır.
- 3) Hesaplanan bu uzaklık değerlerinden belirlenen k en yakın komşusu dikkate alınır. Öznitelik değerlerine ve uzaklıklarına bakılarak k komşu veya komşularının sınıfına atanır. Bu atama ile yeni verinin sınıfı yani etiketi belli olur.

K en yakın komşu algoritmasında probleme özgü seçilebilecek birçok uzaklık fonksiyonu vardır. Bu uzaklık fonksiyonlarından Öklid uzaklığı en çok kullanılan fonksiyondur. Veri setinin sürekli ya da ayrık olması veya aynı tür verilere sahip olup olmaması gibi birçok faktör uzaklık fonksiyonunun seçiminde önemlidir. Ancak her zaman her analize uygun yöntemler bulunamayabilir ve bu durumlar en iyi parametrelerle yapılan analizlerde seçilen metrikler için deneme yanılma yoluyla da belirlenebilir.

Şekil 4.8’de k tane komşu için k en yakın komşu algoritması gösterilmektedir. Veri setine yeni gelen veri noktasının (yıldız) k tane en yakın komşusuna bakılarak bu noktanın sınıfına karar verilmektedir. Ancak karar mekanizması her zaman bu kararı kolay verememektedir. Veri setinin az sayıda veri içermesi veya veri setinin sınıf bazında dengesiz olması gibi birçok sorun çıkabilir. Bu sorunları engellemek ve yapılan analizleri güçlendirmek için girdi uzaylarının rastgele alt uzaylarında eğitilmesi veya yakın komşulara yüksek ağırlıklar verilmesi gibi yöntemler geliştirilmiştir [37].




Şekil 4.8. K en yakın komşu algoritması

4.3.1.3. Karar ağaçları

Ağaç tabanlı öğrenme algoritmalarından biri olan karar ağaçları denetimli sınıflandırma çalışmalarında yaygın olarak tercih edilmektedir. Bu algoritmalar hedef değişkeni bünyelerinde tutarak en tepeden en aşağıya inen bir strateji ile sınıflandırma yapmaktadır. Bir karar ağacı çok sayıda etiketli veri seti içerisinde çeşitli karar kuralları uygulayarak daha küçük setlere bölmek için kullanılan bir yapıdır. Karar ağaçlarının genel adımları şu şekildedir:

- 1) En etkili öznitelik belirlenir ve bu öznitelik ağacın kök düğümüne yerleştirilir. Bundan sonra veriler bu özneliğin değerlerine göre ayrılır.
- 2) Ardından ikinci en etkili öznitelik seçilir ve buna göre veriler tekrar ayrılır.
- 3) Kalan öznitelikler arasından en etkilileri belirlenerek bu süreç tekrar ederek devam eder.


Basit bir karar ağacı yapısı Şekil 4.9'da gösterilmektedir. Çok sayıda özneliğin olduğu durumlarda ağaç yapısı karmaşık bir hale gelebilir. Bu durum kurulan ağacın veri setindeki verileri ezberlemesine ve sadece eğitim için kullanılan verilerde geçerli olmasına yol açar. Genellikle daha basit yapılarda karar ağaçları daha sağlam olduğu için karmaşık yapıli ağaçlar budama yöntemiyle yani ağaçta bulunan en az yararlı dallar kesilmesiyle veya bölme kriterleri ve düğüm büyüklükleri gibi kısıtlamalar getirilerek daha basit yapılara dönüştürülür [35], [38].



Şekil 4.9. Basit karar ağacı yapısı


4.3.1.4.Yapay sinir ağları

Yapay sinir ağları, insan beynini öğrenme mekanizmasını taklit ederek temel işlevlerini gerçekleştirdiği yapılardır. İnsan beyni sinir hücresi ve yapay sinir ağı benzetimleri Şekil 4.10'da verilmiştir.




Şekil 4.10. Biyolojik sinir hücresi ve yapay sinir ağı [39]

Biyolojik sinir sistemi elemanı ve yapay sinir ağı sistemi işlem elemanı karşılıkları Şekil 4.11’de verilmiştir.



Şekil 4.11. Biyolojik sinir sistemi elemanı ve yapay sinir sistemi işlem elemanı karşılıkları

Sinir hücresi (nöron), beynin temel birimidir. Her sinir hücresi, girdi yolları (dendrit) ile diğer sinir hücrelerinden sinyalleri alır ve birleştirir. Ardından aksonlarla diğer sinir hücrelerine iletir. Bu yapıdan esinlenerek oluşturulan yapay sinir ağının en temel birimi olan işlem elemanı sahip olduğu birçok girdi yolundan x_1, x_2 gibi verileri toplar. Transfer fonksiyonu ile çıktı sinyalini üretilir. Transfer fonksiyonu, toplanan veri belirli bir düzeye ulaştığında bilgi geçişine izin veren bir eşik (threshold) fonksiyonu veya sürekli bir fonksiyondur. Elde edilen çıktı değeri, bu işlem elemanının çıktısını oluşturur. Bir işlem elemanının çıktı yolu, bağlantı ağırlıkları ile diğer işlem elemanlarının girdi yollarına bağlanır. Her bağlantının bilgiyi depolayan bir ağırlığı vardır, bir işlem elemanına gelen sinyallerin ağırlıklı toplamaları alınır.



Şekil 4.12. Çok katmanlı yapay sinir ağı yapısı


Şekil 4.12’de birden fazla işlem elemanın birleşiminden oluşan YSA’da, girdi, çıktı ve gizli katman olmak üzere üç farklı katman vardır ve işlem elemanları bu katmanlar içerisinde bulunur. Girdi katmanı YSA’ya veri girişini sağlar, çıktı katmanı YSA’nın ürettiği cevabın alınmasını sağlar. Gizli katman, girdi ve çıktı katmanı arasında veri işlemeyi gerçekleştirir. Bir YSA’da birden fazla gizli katman bulunabilir. Gizli katman üzerindeki nöronların sayısı ve gizli katman sayısı belirlenmesi gereken parametrelerdir. Her bir problem için kaç gizli katman olacağı, bu gizli katmanlarda kaç nöron olacağı bir eniyileme problemidir. Ve bunlar belirlendiğinde modelin mimari yapısı ortaya çıkmaktadır.

Bu yapıda öğrenme ise girdideki değişiklikleri değerlendirerek olmaktadır. Öğrenme, YSA’daki ağırlıkların değişimi ile gerçekleşir. Denetimli (supervised), denetimsiz (unsupervised) ve pekiştirmeli (reinforcement) olmak üzere üç farklı öğrenme şekli vardır. Denetimli öğrenmede, öğrenme çifti veya öğrenme seti olarak adlandırılan iki eleman vardır. Bunlar, girdi ve bu girdi için önceden elde edilmiş (istenilen) çıktıdır. Denetimli öğrenme işlemi için en çok kullanılan öğrenme yöntemi ise geri yayılma (back propagation) algoritmasıdır. Geri yayılım algoritması, öğretilen veri ile öğrenilenin arasındaki farkı en küçükleyecek şekilde geriye dönüp belli bir sistematik içinde ağırlıkları değiştirerek kabul edilir fark düzeyi için ağırlık setinin hesaplanmasıdır.

Yapay Sinir Ağları’nda nöron sayısı, gizli katman sayısı gibi parametrelerin dışında belirlenmesi gereken ağın yapısında kullanılan çeşitli fonksiyonlar vardır.

a) Aktivasyon fonksiyonları

YSA’da gerçekleşen işlemler sonucunda ağ ve elemanları doğrusal yapıda olmaktadır. Doğrusal yapılar veya doğrusal fonksiyonlar tek dereceli polinomlardır. Aktivasyon fonksiyonu kullanılmayan bir sinir ağında öğrenme gücü sınırlı olup doğrusal davranacaktır. Gerçek dünya da çalışılan problemler ise genellikle doğrusallıktan uzaktır. Aktivasyon fonksiyonları bu noktada bu doğrusal yapıları doğrusal olmayan yapılara dönüştürür. Bu sayede ağın elemanları daha kolay türevlenebilir. Bu da ağın hesaplama hızını artırmaya yardımcı olur. Sıklıkla kullanılan aktivasyon fonksiyonları Şekil 4.13’te gösterilmiştir:



Şekil 4.13. Aktivasyon fonksiyonları

Hangi aktivasyon fonksiyonun kullanılacağı problemin yapısına göre değişmektedir. Aktivasyon fonksiyonunun seçimindeki ilk kriter ağın kolay ve hızlı yakınsamasını sağlamasıdır. Düzleştirilmiş Doğrusal Birim Katmanı (Rectified Linear Unit, ReLU) hız bakımından avantajlı olmasına rağmen gradyanların ölmesi göze alınmalıdır. Gradyanların ölmesi problemine ilk çözüm Leaky ReLU olabilir. ReLU genellikle çıkış değil ara katmanlarda kullanılır. Çıkış katmanlarında genellikle Softmax kullanılır.

b) Hata hesaplama yöntemleri


YSA'dan elde edilen çıktıların, istenilen çıktılarla farkını belirlemek önemlidir. Elde edilen ve istenilen değerler arasındaki fark ağın doğru sınıflandırmalar yapmaya ne kadar yakın ya da uzak olduğunu belirler. YSA'da hata hesabından önce çıktı katmanından elde edilen sonuçların normalizasyonu yapılır. Normalize edilen bu değerler daha sonra hata fonksiyonuna verilir. Genellikle ikili sınıflandırmalarda Sigmoid fonksiyonu, çoklu sınıflandırmalarda ise Softmax fonksiyonu tercih edilmektedir. Hata hesaplama fonksiyonu olarak Ortalama Kareli Hata, Ortalama Mutlak Hata ve Çapraz Entropi yöntemlerinden biri kullanılabilir.

c) Optimizasyon yöntemleri

YSA'nda ağırlıkların güncellenmesi öğrenme işleminin doğru şekilde yapılması için çok önemlidir. Hata hesapları yapıldıktan sonra hatalara göre ağırlıklar güncellenir. Genellikle Geri Yayılım Algoritması ağırlıkların güncellenmesinde tercih edilir. YSA'daki her bir ağırlığın, hesaplanan hata üzerindeki etkisini hesaplamak için gradyan tabanlı Stokastik Gradyan Azalma, RMS-Prop, Adam ve Adadelata gibi metotlar kullanılır.

4.3.1.5. Evrişimsel sinir ağları

Beynin nesneleri öğrenme yapısından esinlenerek benzer katmanlarla yapay sinir ağları Derin Ağ (DA)'lara dönüştürülmüştür. Evrişimsel Sinir Ağları (ESA)'da DA modellerinden biridir. ESA, birincil görsel korteksteki basit ve karmaşık hücreleri anımsatan, evrişim ve alt örnekleme olmak üzere iki temel işlemi değiştiren hiyerarşik modellerdir. ESA, ağırlıkları paylaştığı için, standart çok katmanlı ağlarda olduğu gibi, serbest parametre sayısı giriş boyutlarıyla orantılı olarak artmaz. Bu nedenle ESA, gerçek boyutlu görüntülere iyi ölçeklenir ve birçok nesne tanıma, görüntü işleme vb çalışmaların karşılaştırmasında üstündür [40]. Görüntü işleme, nesne tanıma problemlerinde başarılar elde eden ESA Şekil 4.14'te gösterilen insan görsel korteks yapısından esinlenerek gerçekleştirilmiştir.



Şekil 4.14. İnsan görsel korteks ile evrişimsel sinir ağı karşılaştırması

Her görsel alan, girdi aldığı alandan biraz daha karmaşık bir özelliği hesaplar. Bu hesaplamalar beynin karar verme alanlarına ulaştığında, yeterince soyut olan nesne tanıma nispeten basit bir şekilde yapılabilir. Bu yapıdan esinlenen ESA ve beyin görsel korteks bölgeleri ise Tablo 4.2’de verilmiştir.


Tablo 4.2. Beyin görsel korteks ile evrişimsel sinir ağı işlev karşılaştırması

Beyin Görsel Korteks Bölgeleri	İşlevi	Evrişimsel Sinir Ağındaki Karşılığı
Retina ve Lateral Genikülat Çekirdeği (LGN)	Görsel bilgilerin işlenmesinde birincil merkez olarak görev yapar. LGN, darbeleri görsel korteksin V1'ine iletmeden önce, nesnelerin aralığını ölçer ve her ana nesneyi bir hız etiketi ile etiketler. Bu etiketler, nesne hareketini tahmin eder.	Girdi Katmanı
V1	Görsel bilginin uzamsal konumunu, yani kenarların ve çizgilerin oryantasyonunu algılar.	Evrişim Havuzlama Katmanları
V2	Nesnenin uzamsal frekansını, boyutunu, rengini ve şeklini toplamaktır.	
V3	Nesnelerin "küresel hareketini" (yön ve hız) işlemeye yardımcı olur. V3 alanında renge ve harekete duyarlı daha karmaşık özelliklere sahip bazı hücreler bulunur.	
V4	Basit geometrik şekilleri tanır ve ayrıca nesnenin tanınmasını sağlar.	

Tablo 4.2. devam ediyor.

V5	Hareket eden görsel nesnenin hızını ve yönünü yani hareket algısını tespit etmek için kullanılır. Ayrıca karmaşık görsel özelliklerin hareketini de algılar.	
Yanal (Lateral) Oksipital Korteks (LOC)	Görsel nesne işlemenin ana alanlarından biri olan LOC ise nesne tanıma için anahtar konumdur.	Tam Bağlantılı Yapay Sinir Ağı

Bu çalışmada, ahşap anomalilerini sınıflandırmak için ESA yöntemi kullanılarak çeşitli uygulamalar yapılmıştır. Şekil 4.15'te gösterildiği gibi bir ESA, burada kısaca açıklanan birkaç temel yapı taşından oluşur:



Şekil 4.15. Basit evrişimsel sinir ağı mimarisi

Bir ESA, bir görüntüyü girdi olarak alabilen, bu görüntüdeki çeşitli özelliklere önem atayabilen ve bu özelliklerin birini diğerinden ayırt edebilen en çok tercih edilen derin öğrenme algoritmasıdır. Gerekli olan ön işlem sayısı, klasik sınıflandırma algoritmaları ile karşılaştırıldığında çok daha düşüktür. Klasik yöntemlerde öznitelikler, yeterli eğitimle elle üretilirken, ESA yapısı gereği bu öznitelikleri öğrenme yeteneğine sahiptir [41].

Genel olarak bir ESA yapısı özellik çıkarma katmanı (evrişim bloğu), evrişim katmanı, Düzleştirilmiş Doğrusal Birim (ReLU) ve biriktirme katmanını içerir ve yüksek boyutlu verilerden düşük boyutlu özelliklerin çıkarılmasını sağlar. Evrişim katmanı, çekirdek (filtre) ve girdi (görüntü) arasındaki evrişim sürecini gerçekleştirerek özellik haritaları oluşturur. Evrişim katmanının çıktısı, filtre boyutu, filtre sayısı, adım ve dolgu gibi parametrelere

dayanır. Her evrişim katmanından sonra ReLU katmanı uygulanır ve bu katman ağı doğrusal olmayan bir yapıya dönüştürür ve öğrenmeyi hızlandırır. Biriktirme diğer bir adıyla havuzlama, her bir özellik haritasının boyutunun küçültülmesi anlamına gelen bir alt örnekleme tekniğidir. Biriktirme katmanı, sonraki ağ katmanları için hesaplama yükünü azaltır. Son aşamada ağı sonunda tam bağlantılı katmanlar kullanılır ve bu katmanlar geleneksel sinir ağı mimarisinden oluşur. Tam bağlantılı katmanı, önceki katmanlarda çıkarılan öznitelikleri kullanarak sınıflandırma sonucunu vermeyi amaçlar [42].

a) Giriş katmanı

ESA'nın ilk katmanını oluşturur. Bu katman ile veri ham halde ağı girdi olarak verilir. Tasarlanan ağı başarısında girdinin boyutu önemlidir. Girdi görüntü boyutunun yüksek olması ağı başarısını artıracak gibi bellek ihtiyacını ve görüntü başına düşen test süresini de artırabilir. Bu durumu ortadan kaldırmak için girdi görüntü boyutunun düşük seçilmesi ise bellek ihtiyacını ve test süresini azaltmasıyla birlikte ağı derinliğinin azalmasına ve performansının düşmesine neden olabilir. Bu nedenle ESA tasarlanırken uygun ağı derinliği, düşük donanımsal hesaplama maliyeti ve yüksek ağı başarısı için ağı uygun girdi (görüntü) boyutu seçmek önemlidir.

b) Evrişim (konvolüsyon) katmanı

Konvolüsyon diğer bir adıyla evrişim katmanı dönüşüm işleminin gerçekleştiği ESA'nın temel katmanıdır. Dönüşüm işlemi belirlenen fitrenin tüm görüntü üzerinde dolaştırılmasıyla gerçekleşir. Buradaki en önemli yapıtaşları filtrelerdir. Filtreler birçok farklı boyutta olabilir. Hangi filtre boyutunun daha iyi olacağı önemli bir karardır. Görüntüler bu filtreleme işleminden geçtikten sonra aktivasyon haritası (öznitelik haritası) oluşur. Bu harita her filtreye ait özelliklerin bulunduğu yapılardır. Eğitim aşamasında tüm filtrelerin değerleri, eğitim verilerindeki her öğrenme işlemiyle değişir. Böylece oluşturulan sinir ağı, özniteliklerini belirlemek için verilerin önem taşıdığı yerler belirler.

Matematikte evrişim, bir sinyalin şeklinin diğeri tarafından nasıl değiştirildiğini ifade eden üçüncü bir fonksiyon üreten iki fonksiyon (f ve g) üzerinde matematiksel bir işlemdir. Sinyal yapıları sürekli özellikler gösterdiği için evrişim işlemi f(t) ve g(t) iki sinyal fonksiyonu için eşitlik (4.1)'deki gibidir.


$$f(t) * g(t) = \int_{-\infty}^{\infty} f(\tau)g(t - \tau)d\tau \quad (4.1)$$

Bu evrişim formülü sayısallaştırılmış dizi şeklinde saklanan $f[t]$ ve $g[t]$ sinyal fonksiyonları için eşitlik (4.2)'de verildiği şekilde kullanılır.

$$f[n] * g[n] = \sum_{k=-\infty}^{\infty} f[k]g[n - k] \quad (4.2)$$

Görüntülerde kullanılan evrişim işleminin matematiksel ifadesi eşitlik (4.3) şeklinde gösterilebilir. Bu evrişim işlemi ise 2 boyutludur.

$$S(i,j) = (I \times K)_{(i,j)} = \sum_{m=1}^m \sum_{n=1}^n I(m,n) K(i - m, j - n) \quad (4.3)$$




Şekil 4.16. Evrişim katmanında evrişim işlemi

Şekil 4.16'da K filtre, I giriş görüntüsü ise, 2 görüntünün evrişim işlemi şekilde görüldüğü gibi görüntü üzerinden filtrenin sırayla kaydırılması ve her kaydırmada piksel değeri çarpımlarının toplanmasından oluşur. Dolayısıyla evrişim işlemi sonucunda filtre ile görüntü arasında benzerlik ne kadar fazla ise S çıkış görüntüsünde o piksel değeri yüksek, ne kadar az ise piksel değeri o kadar düşük olacaktır. Buradaki şekilde filtre göz olduğu için görüntüdeki göz ile filtre kesiştiği esnada en yüksek değeri alırken boş alanlarda ise en düşük değeri alacaktır.

Evriřim iřleminin amacı, giriř g r nt s nden probleme  zg  ayırt edilebilir  zelliklerin filtreler aracılıęıyla ortaya  ıkarılmasını saęlamaktır.  rneęin; insan y z n  ayırt etmek istiyorsak, insan y z n n ayırt edici  zellikleri olan kař g z burun gibi  zellikleri ortaya  ıkarmamız gerekir. Bu katmanda bu  zniteliklerin ortaya  ıkarılmasını saęlamaktadır. ESA'ların bir evriřim katmanı ile sınırlı olması gerekmez. Geleneksel olarak, ilk katman, kenarlar, renk, gradyan y n  vb. gibi d ř k seviye  zelliklerini yakalarken, eklenen katmanlarla mimari, y ksek seviye  zelliklere de uyum saęlayarak daha ayırt edilebilir  zellik uzayına tařır. Bu katmanda belirlenecek en  nemli parametreler filtre boyutu, filtre sayısı ve transfer- aktivasyon fonksiyonudur.

c) D zleřtirilmiř doęrusal birim katmanı (ReLU)

D zleřtirilmiř Doęrusal Birim Katmanı dięer bir adıyla aktivasyon katmanı doęrusal yapıdaki  ıktıları doęrusal olmayan bir yapıya d n řt r r. B ylece daha hızlı  ęrenme ger ekleřir. ESA  ıktıları i in en  ok tercih edilen aktivasyon fonksiyonu d zleřtirilmiř doęrusal birim fonksiyonudur.




řekil 4.17. D zleřtirilmiř doęrusal birim fonksiyonunun  ıkıř verisine etkisi

řekil 4.17'de g sterilen bu fonksiyonun matematiksel eřitlik eřitlik (4.4)'te verilmiřtir. Bu fonksiyon ile negatif deęerlerin etkisi sıfıra  ekilirken pozitif deęerlerin etkisi deęiřmez.

$$\text{Düzleştirilmiş Doğrusal Birim fonksiyonu } f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (4.4)$$

Alanyazında birçok aktivasyon fonksiyonu bulunmaktadır. Problemin yapısına göre kullanılacak fonksiyon değişmektedir. Şekil 4.18’de alanyazında sıklıkla kullanılan aktivasyon fonksiyonlarının yapıları gösterilmiştir.



Şekil 4.18. Aktivasyon fonksiyonları

d) Biriktirme (havuzlama) katmanı

Bu katman veri içindeki, önemsiz, çalışmaya değer katmayan verilerin ayıklanmasını ve giriş boyutunun sonraki katmanlar için azalmasını sağlamaktadır. Böylece hedef için gerekli olan bilgilerin dışındaki veriler elenir ve piksel sayısı azalır. Bu durum sonraki katmanlarda meydana gelecek işlemlerin daha küçük görüntülerle yapılmasını sağlayacağından işlem yükü de azalacaktır. Azalan bu işlem yüküyle birlikte ağız ezberlemesi de önlenmektedir. Bir önceki evrişim katmanında kaç filtre kullanılmışsa, evrişim katmanı çıkışında o kadar çıktı görüntüsü olacaktır. Biriktirme katmanı çıktı sayısı da aynı sayıda görüntüye sahip olacak, ancak her biri daha az piksele sahip olacaktır.

Evrişim katmanında olduğu gibi biriktirme katmanında da filtreler kullanılmaktadır. Filtreler girdi görüntüsü üzerinde belirlenen adım değerlerine göre gezdirilerek piksellerin değerleri hesaplanır. Piksel değerleri hesaplanırken maksimum değer veya ortalama değer gibi çeşitli biriktirme işlemleri yapılabilir. ESA’larda biriktirme katmanını yapmak zorunlu

değildir. Tamamen mimariye ve problemin yapısına bağlıdır. Biriktirme katmanında gerçekleşen işlemin matematiksel gösterimi eşitlik (4.5)'te verilmektedir.

$$\text{Üretilen görüntünün boyutu} = G_2 \times Y_2 \times D_2 \quad (4.5)$$

$$G_2 = (G_1 - F) / A + 1 \quad (4.6)$$

$$Y_2 = (Y_1 - F) / A + 1 \quad (4.7)$$

$$D_2 = D_1 \quad (4.8)$$

G_1 = Giriş görüntü boyutunun genişlik değeri

Y_1 = Giriş görüntü boyutunun yükseklik değeri

D_1 = Giriş görüntü boyutunun derinlik değeri

F = Filtre boyutu ve A = Adım sayısı

Biriktirme işleminde çoğunlukla $F = 2$ ve $A = 2$ olarak seçilir.

Bu çalışmada tasarlanan ESA mimarisinde $F = 2$ ve $A = 2$ alınarak en büyük biriktirme (max pooling) işlemi uygulanmıştır. Bir görüntünün boyutları $G_1 = 360$, $Y_1 = 360$ ve $D_1 = 3$ iken biriktirme işlemi uygulandığında yeni çıktının boyutları şu şekilde hesaplanır;

$$G_2 = (G_1 - F) / A + 1 = (360 - 2) / 2 + 1 = 180$$

$$Y_2 = (Y_1 - F) / A + 1 = (360 - 2) / 2 + 1 = 180$$

$$D_2 = D_1 = 3$$

Bu katmanda seçilecek en önemli iki parametre vardır. Biri seçilecek pencere boyutu, diğeri biriktirme işleminin hangi fonksiyona göre yapılacağıdır. Farklı problemlerde farklı fonksiyonlar ya da pencere boyutları daha iyi sonuçlar verebilmektedir. Alanyazın araştırmalarıyla ya da ön çalışmalarla bu parametrelere karar verilebilir. Genellikle alanyazındaki görüntü işleme çalışmalarına bakıldığında 2x2 pencere boyutu ve en büyüğü olarak biriktirme işleminin kullanımı iyi sonuçlar verdiği görülmektedir.


e) Tam bağlantılı yapay sinir ağı

Ard arda gelen evrişim, ReLU ve biriktirme katmanlarından sonra genelde tam bağlı katman gelir. Son katman olan tam bağlı katman sayısı farklı ağlarda değişkenlik gösterebilir ancak bu katmanda her giriş tüm nöronlara bağlıdır. Düzleştirilmiş çıktı, ileri beslemeli bir sinir ağını besler. Eğitimin her yinelemesine geri yayılım algoritması uygulanır. Model, bir girdi seti boyunca, görüntülerdeki belirlenen baskın ve düşük seviyeli özellikler arasında ayırım yapabilir ve bunları sınıflandırabilir.

Yapay sinir ağlarında gizli katman, her gizli katmandaki nöron sayısı ve her bir işlem biriminin aktivasyon fonksiyonu bu katmandaki seçilecek parametrelerdir.

f) Nöron eksiltme işlem (dropout) katmanı

Büyük girdi görüntüleri ile ESA'ların eğitimi yapıldığında bazen ağ ezberler. Bunu engellemek için bu katman ağa eklenir. Şekil 4.19'da verilen bu işlemdeki temel amaç sinir ağındaki bazı nöronların kaldırılmasına dayanmaktadır.



Şekil 4.19. Evrişimsel sinir ağına dropout katmanı uygulanması

g) Sınıflandırma katmanı

Bu katmanın amacı sınıflandırma yapmaktır. Bu katman tam bağlantılı katmandan sonra gelmektedir. Bu katmanın çıktı nöron sayısı sınıflandırma sayısına eşittir. Burada farklı sınıflandırıcılar kullanılmaktadır. Genellikle alanyazındaki başarıları nedeniyle


softmax sınıflandırıcısı tercih edilir. Burada 0 ile 1 aralığında her sınıf için bir çıktı değeri üretilir. Olasılığı en yüksek çıkan işlem birimine göre o girdiye ait çıktı belirlenmiş olur. Belirlenen tüm parametrelerle model oluşturulur ve denetimli öğrenme için modeli eğitim verisine göre probleme özgü ağırlıkları öğrenmeye ve modelin hatasını tolere edilebilir bir hata düzeyine çekmeye çalışır.

4.3.1.6. Derin öğrenme modelleri


Büyük veri ve işlemci kapasitelerinin gelişmesiyle farklı derin öğrenme mimarileri tasarlanmaya başlanmıştır. Bu mimariler girdi verisinden farklı katmanlarda farklı özelliklerin keşfedildiği öğrenme işlemini kendisi yapmaktadır. En temel derin öğrenme mimarisi ESA'dır. ESA'lar görüntü sınıflandırma, segmentasyon, video işleme, nesne tanımlama vb. birçok problemde başarılı sonuçlar elde edilecek şekilde uygulandığı için derin öğrenme mimarileri de bu problemlere uygulanarak başarılı sonuçlar elde edilmiştir [43], [44].

4.3.1.6.1. AlexNet

Derin öğrenmenin ilk kez 1998 yılında Yann LeCun'nun yaptığı çalışma ile ortaya çıkmıştır. Yayılması 2012 yılında ImageNet yarışmasını AlexNet modelinin kazanması ile olmuştur. Şekil 4.20'de verilen AlexNet mimarisi 1000 nesneyi sınıflandıracak şekilde tasarlanmış ve nesne tanımlanmadaki hata oranı %15,4'e indirilmiştir. Bu mimarinin ilk beş katmanı evrişim katmanından ve son üç katmanı ise tam bağlantılı katmandan oluşmaktadır. Bu katmanlar arasında biriktirme ve aktivasyon katmanları bulunmaktadır. Ayrıca bu mimari giriş ve çıkış katmanlarını da içermektedir. Girdi görüntü boyutu 224x224x3, kullanılan filtrelerin boyutu 11x11, filtre sayısı 96 ve adım uzunluğu 4 olarak belirlenmiştir [45], [46]. Şekil 4.21'de MATLAB AlexNet mimarisi verilmektedir [47].




Şekil 4.20. AlexNet mimarisi [46]




Şekil 4.21. MATLAB AlexNet mimarisi [47]

4.3.1.6.2. GoogleNet

GoogleNet ardışık olarak evrişim ve biriktirme katmanlarını istifleyen yapılardan uzaklaşan ilk ESA mimarilerinden biridir. Şekil 4.22’de verilen 22 katmanlı yapısı birbirine paralel bağlı Inception modüllerini içermektedir. Bu ağ mimarisinde diğer mimarilerden farklı olarak ağın derinliği ve genişliği artarken hesaplama ve bellek maliyeti ile ağın ezberleme olasılığı azaltılmıştır. GoogleNet 2014 yılında yapılan ImageNet yarışmasını nesne tanımadaki %6,67 top-5 hata oranı ile kazanmıştır [48], [49]. Şekil 4.23’te MATLAB GoogleNet mimarisi verilmektedir [50].




Şekil 4.22. GoogleNet mimarisi [49]



Şekil 4.23. MATLAB GoogleNet mimarisi [50]

4.3.1.6.3. MobileNet-V2


Mobil cihazlarda iyi performans göstermeyi hedefleyen ESA mimarisidir. Darboğaz katmanları (bottleneck structure) arasında artık bağlantıların (residual connection) olduğu ters çevrilmiş yapıdadır. 32 filtreli evrişim katmanı ve 19 artık darboğaz katmanından oluşan MobileNet-V2, 53 katman derinliğine sahiptir. ImageNet veritabanı ile önceden eğitilmiş bu ağ mimarisi çok çeşitli görüntüler için öznitelikleri öğrenebilir ve çok sayıda nesneyi sınıflandırabilir. Bu mimari $224 \times 224 \times 3$ girdi görüntü boyutuna sahiptir [48], [51]. Şekil 4.24'te MATLAB MobileNet-V2 mimarisi verilmektedir [52].



Şekil 4.24. MATLAB MobileNet-V2 mimarisi [52]

4.3.1.6.4. ShuffleNet


ImageNet veritabanı üzerindeki görüntülerde eğitilmiş bir başka ESA ise 224x224x3 girdi görüntü boyutuna sahip olan ShuffleNet mimarisidir. Hesaplama maliyetini azaltmak için geliştirilen bu mimari, ilk olarak belirli bir gruptan gelen çıktılardaki bilgi bloke edilirken ikinci durumda kanal karıştırma işlemi kullanılır. Evrişim katmanında bilgi farklı gruplara aktarılır [48], [53]. Şekil 4.25'te MATLAB ShuffleNet mimarisi verilmektedir [54].



Şekil 4.25. MATLAB ShuffleNet mimarisi [54]

4.3.1.6.5. SqueezeNet


ImageNet veritabanından bir milyondan fazla görüntü üzerinde eğitilmiş bir başka ESA SqueezeNet mimarisidir. Önceden eğitilmiş bu ağ mimarisi diğer mimarilerde olduğu gibi çok çeşitli görüntüler için zengin öznetelik temsillerini öğrenerek sınıflandırma yapabilir. SqueezeNet, 18 katman derinliğine ve 227x227x3 girdi görüntü boyutuna sahiptir [48], [55]. Şekil 4.26'da MATLAB SqueezeNet mimarisi verilmektedir [56].



Şekil 4.26. MATLAB SqueezeNet mimarisi [56]

4.3.1.6.6. DenseNet-201


DenseNet-201 mimarisi 201 katman derinliğine sahip olup, ImageNet veritabanındaki görüntüler üzerinde eğitilmiş bir başka ESA'dır. 224x224x3 girdi görüntü boyutuna sahip olan DenseNet-201, önceden eğitilmiş diğer ağlarda olduğu gibi çok çeşitli görüntüler için zengin öznitelikleri öğrenerek sınıflandırır [48], [57]. Şekil 4.27'de MATLAB DenseNet-201 mimarisi görülmektedir [58].



Şekil 4.27. MATLAB DenseNet-201 mimarisi [58]

4.3.1.6.7. Inception-V3

Inception-V3 48 katman derinliğine sahip olan bir ESA'dır. ImageNet veritabanından önceden eğitilmiş bir başka ağ mimarisidir. Çok çeşitli görüntüler için zengin öznitelikleri öğrenerek sınıflandıran ağ, 299x299x3 bir görüntü girdi boyutuna sahiptir [48], [59]. Şekil 4.28'te MATLAB Inception-V3 mimarisi görülmektedir [60].




Şekil 4.28. MATLAB Inception-V3 mimarisi [60]

4.4. Görüntü Çoğaltma Yöntemleri

DA modellerinin ve ESA'ların çok sayıda veri seti ile eğitimi modellerin sınıflandırma performanslarını arttırmaktadır. Görüntü işleme uygulamalarında veri çoğaltma işleminin yapılmasındaki temel amaç modelleri yeteri kadar veri ile destekleyerek daha doğru kararlar veren modeller elde etmektir. Ağlar yapıları itibariyle verilen bir veri setindeki verilerin özelliklerini çıkarmak için tasarlanmıştır. Ancak küçük veri setlerinde modellerin veriyi ezberlemesine neden olduğu için modelin doğruluk değeri düşük olmaktadır.

Çoğaltma veya dönüşüm olarak tanımlanan teknikler, görüntüler üzerinde: yansıma, dönme, ölçekleme ve kırpma gibi işlemlerinin gerçekleştirilmesidir. Bu çoğaltma işlemleri görüntülerin miktarını artırarak genelde DA'ları ve sınıflandırma modellerini eğitmek amacıyla kullanılır. Daha önce geliştirilen DA yapıları çok sayıda veri içeren veri setleri ile eğitildikleri için daha başarılı sonuçlar vermiştir. Bu nedenle ağ yapılarında ve sınıflandırma modellerinin başarısında veri sayısı çok önemlidir.

Bu nedenle bu tez çalışmasında elde edilecek modellerin performansını artırmak ve bu değişimi gözlemlemek için sıkça kullanılan çoğaltma teknikleri ile mevcut görüntülerden yeni görüntüler üretilmektedir. Kullanılan çoğaltma teknikleri gerçek hayatta karşılaşılabilecek durumlar düşünülerek “rand rotation”, “rand x translation”, “rand y translation” olarak seçilmiştir. Böylece gerçek zamanlı hata tespitlerinde daha yüksek başarı elde edilmesi hedeflenmektedir. Çoğaltma teknikleri kullanılarak eğitim veri setindeki görüntülerin sayısı artırılmıştır. Şekil 4.29 (a) seçeneğinde kusursuz bir ürün için orijinal görüntü gösterilmektedir, (b), (c) ve (d), seçeneklerinde ise çoğaltma teknikleri ile elde edilen yeni görüntüler sırasıyla gösterilmektedir.



Şekil 4.29. Kusursuz bir ürüne görüntü çoğaltma teknikleri uygulaması

Şekil 4.30 (a) seçeneğinde kusurlu bir ürün için orijinal görüntü gösterilmektedir, (b), (c) ve (d), seçeneklerinde ise çoğaltma tekniklerinden sonra elde edilen yeni görüntüler sırasıyla gösterilmektedir.



Şekil 4.30. Kusurlu bir ürüne görüntü çoğaltma teknikleri uygulaması

4.5. Görüntü İyileştirme Yöntemleri

Görüntü iyileştirme teknikleri, elde edilen görüntülerin kalitesinin yükseltilmesi için kullanılır. Kontrast ve parlaklık düzenlemeleri, histogram eşitleme, gürültü ve medyan


filtreleri, kenar zenginleştirme gibi uygulamalar kişinin görsel algısını etkileyen en temel görüntü iyileştirme yöntemleridir. Gürültü barındıran, kalitesi kayıpları gibi bozulmalara sahip görüntülere uygulanan bu yöntemlerle önerilen modellerin başarıları artırılmaktadır.

Alanyazında birçok görüntü iyileştirme ve onarma yöntemleri önerilmiştir. Yaygın uygulamalar arasında filtreleme, histogram eşitleme, kontrast geliştirme, gürültü ekleme, gibi yöntemler sıralanabilir. Şekil 4.31 (a) seçeneğinde kusursuz bir ürün için orijinal görüntü gösterilmektedir, (b), (c) ve (d), seçeneklerinde ise “Gürültülü resim”, “Medyan filtresi”, “Histeg” yöntemleri ile iyileştirme teknikleri ile elde edilen yeni görüntüler sırasıyla gösterilmektedir.



Şekil 4.31. Kusursuz bir ürüne görüntü iyileştirme teknikleri uygulaması

Şekil 4.32 (a) seçeneğinde kusurlu bir ürün için orijinal görüntü gösterilmektedir, (b), (c) ve (d), seçeneklerinde ise iyileştirme tekniklerinden sonra elde edilen yeni görüntüler sırasıyla gösterilmektedir.



Şekil 4.32. Kusurlu bir ürüne görüntü iyileştirme teknikleri uygulaması

4.6. Sınıflandırıcı Performansının Değerlendirilmesi

4.6.1. Sınıflandırıcı modeli doğrulama yöntemleri

Geliştirilen modellerin hangisinin daha iyi olanı belirlemek ve ileride bu öğrenme modelinin ne kadar iyi sınıflandıracağını anlamak için modelleri değerlendirmeye ihtiyaç duyulmaktadır. Modelleri değerlendirirken sadece eğitim verilerini kullanmak doğru değildir. Çünkü geliştirilen modeller aşırı uyum (overfitting) durumunda olabilirler. Bu durumdan kaçınmak ve daha doğru bir şekilde model performansını ölçmek için bir test kümesi oluşturulur ve farklı yaklaşımlarla model değerlendirilir.

4.6.1.1. Sınama seti (holdout) yöntemi

Veri seti, eğitim ve test olmak üzere iki sete ayrılır. Eğitim veri seti, modelin eğitildiği verilerden, test veri seti ise modelin eğitiminde kullanılmayan verilerden oluşur ve model performansının ne kadar iyi olduğunu göstermek için kullanılır. Yaygın olarak kullanılan bu yöntem en basit model doğrulama yöntemidir. Genellikle eğitim için verilerin %70-80'i ve test için kalan %20-30'u kullanılmaktadır. Bu oran veri setinin büyüklüğüne göre değişmektedir.

4.6.1.2. K-Katlı apraz doęrulama (k-fold cross validation) yntemi

Başlangıta sına ma seti ynteminde olduęu gibi veri seti eęitim ve test olmak zere ikiye ayrılır. Bu doęrulama ynteminde eęitim veri seti k adet kmeye ayrılır. Ardından belirlenen alt kmelerden birisi dıřarı da bırakılır. Belirlenen biri dıřında kalan dięer kmelerle model oluřturulur ve dıřarı da bırakılan kme ile model test edilir. Bu iřlem tm kmeler iin sırasıyla tekrar edilir. Daha sonra elde edilen hataların ortalaması alınır. Bu ortalama deęer doęrulama hatası olur. Son olarak en başta ayırdıęımız test veri seti ile model test edilir.

4.6.1.3. Tek-ıkıřlı apraz doęrulama (leave one out cross validaion) yntemi

Bu yntemde k kme sayısı veri setindeki n rnek sayısına eřittir. n tane kme sırasıyla her biri bir kere dıřarı da bırakılarak test edilen edilir. K-katlı apraz doęrulama ynteminin zel bir hali olan bu yntemi uygulamak veri seti bydke zorlařmaktadır.

4.6.1.4. Yeniden rnekleme (bootstrap) yntemi

Bu doęrulama yntemi dięer yntemlere benzer olarak veri setini ikiye bler ve bir kısmıyla modeli eęitirken bir kısmıyla modeli test eder. Ancak buradaki nemli nokta veri seti ierisinde veri setindeki gzlem sayısından daha az olacak řekilde yeniden rnekleme rneklerinin oluřturulmasıdır. Oluřturulan her rnek zerinden model kurulur. Kurulmuř modeller test veri seti ile test edilip, eęitim ve testlerin ortalaması alınarak sonular deęerlendirilir. zetle; yerine koymalı bir řekilde veri seti ierisinden veri tretmek olarak kullanılır ve oluřan yeni verilerin her birisi zerinden model kurulur, bu modeller test edilir ve buna gre sonular deęerlendirilir.

4.6.2. Sınıflandırıcı modelin bařarısının hesaplanması

Makine ęrenim yntemlerinin ve DA'ların sınıflandırma problemlerindeki performanslarının deęerlendirilmesinde birok lt kullanılmaktadır. Kullanılan ltlerle hangi modelin daha doęru sonular rettięine karar verilir. Alanyazında sıklıkla kullanılan ltler karıřıklık matrisi adı verilen tabloya dayandırılarak hesaplanmaktadır. Sınıflandırma problemlerinde bir sınıflandırıcı modelin performansını grsel olarak sunan tablo dzenine karıřıklık matrisi adı verilir. Bu matriste her stn tahmin deęerlerini, her

satır ise gerçek değerleri ifade etmektedir. İki sınıflı bir sınıflandırma problemi için oluşturulan karışıklık matrisi Tablo 4.3'teki gibidir.

Tablo 4.3. İki sınıflı karışıklık matrisi

		TAHMİN EDİLEN SINIF	
		POZİTİF	NEGATİF
GERÇEK SINIF	POZİTİF	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	NEGATİF	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Doğru Pozitif (DP), sınıflandırıcı model tarafından pozitif sınıfa ait verilerden doğru sınıflanan sayısını verirken; Yanlış Pozitif (YP), gerçekte negatif sınıfa ait verilerin sınıflandırıcı model tarafından sınıflandırılması sonucunda pozitif olarak etiketlenenlerinin sayısını verir.

Doğru Negatif (DN), sınıflandırıcı model tarafından negatif sınıfa ait verilerden doğru sınıflanan sayısını verirken; Yanlış Negatif (YN), gerçekte pozitif sınıfa ait verilerin sınıflandırıcı model tarafından sınıflandırılması sonucunda negatif olarak etiketlenenlerinin sayısını verir.

Karışıklık matrisindeki bu değerler kullanılarak hesaplanan ölçütler ile sınıflandırıcı modelin performansı değerlendirilir. Performansı değerlendirmede tek bir ölçüt yeterli olmamaktadır. Bu nedenle dikkate alınacak ölçütler eşitlik (4.9), eşitlik (4.10), eşitlik (4.11), eşitlik (4.12) ve eşitlik (4.13)'te verilmiştir.

Eğitim veri setiyle eğitilen modelin test veri setindeki verileri sınıflandırırken doğru sınıflandırdıklarının oranıdır:

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (4.9)$$

Eğitilen modelin gerçekte pozitif sınıfa ait verilerden doğru sınıflandırdıklarının tahmin ettikleri içindeki oranıdır:

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (4.10)$$

Eğitilen modelin gerçekte negatif sınıfa ait verilerden doğru sınıflandırdıklarının tahmin ettikleri içindeki oranıdır:

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (4.11)$$

Modelin pozitif olarak sınıflandırdıklarının ne oranda doğru sınıfa ait olarak sınıflandırıldığını gösteren orandır:

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (4.12)$$

Genellikle kesinlik ve duyarlılık tek başına anlamlı karşılaştırma için yeterli olmamaktadır. Bu iki ölçüt bir araya getirilip harmonik ortalaması alınarak daha anlamlı F skor değeri bulunur. Bu değer 0 ile 1 arasında olur, ancak 1'e yakın olması beklenmektedir.


$$F_{\beta} \text{ skor} = \frac{(1 + \beta^2) \times (\text{kesinlik} \times \text{duyarlılık})}{\beta^2 + (\text{kesinlik} \times \text{duyarlılık})}; \quad (4.13)$$

β değeri genellikle 1,0.5 ve 2 değerlerini alır.

%100 doğruluğa, duyarlılığa ve özgüllüğe sahip sınıflandırıcı mükemmel sınıflandırıcı olarak adlandırılır; fakat bu çok sık karşılaşılan bir durum değildir. Duyarlılık ile özgüllük arasında biri artarken diğerrinin azaldığı ters ilişkili bir denge vardır. Bu nedenle en başarılı sınıflandırıcı model seçilirken yüksek doğruluk değerrinin yanında duyarlılık ve özgüllük bir denge durumu elde edilmeye çalışılmalıdır.

İşlem Karakteristik Eğrisi (ROC), sınıflandırma, tanı koyma gibi problemlerde performans metriği olarak yalnızca duyarlılık ve özgüllük değerrlerini kullanmanın önüne geçmek için geliştirilmiş istatistiksel değerrlendirme yöntemidir. İşlem Karakteristik Eğrisi üzerindeki her nokta, farklı değerrlere karşılık gelen doğru pozitif (duyarlılık) ve yanlış

pozitif (1-özgüllük) değerlerini gösterir. Genellikle düşük yanlış pozitif oranı düşük doğru pozitif oranına karşılık gelir ve yanlış pozitif oranı arttıkça doğru pozitif oranı da artmaktadır. Bir işlem karakteristik eğrisi altında kalan alan (AUC), testin performansını tek bir değer ile ifadesini sağlayan pratik bir yöntemdir. Bu değer ne kadar büyükse test sonucu o kadar iyi olmaktadır. İşlem karakteristik eğrisi altında kalan alan 0.5'ten 1'e kadar değişim göstermektedir. Şekil 4.33'te işlem karakteristik eğrisine gösterilmiştir.




Şekil 4. 33 İşlem karakteristik eğrisi (ROC)

5. UYGULAMA

5.1. Çalışmada Kullanılan Ahşap Güve Kovucu Görüntülerinin Düzenlenmesi

Bu çalışma da yalnızca iki ekip tarafından oybirliğiyle etiketlenen etiketlere sahip görüntüler anormal olarak kabul edilmiş ve sınıflandırma uygulamaları için veri seti yeniden düzenlenmiştir. İlk olarak, tüm normal ve anormal görüntülerin etiketleri maskelerine göre etiketlenmiştir. Ardından normal ve anormal dizinleri olarak bir araya toplanmıştır. Veri setinde 1855'i anormal, 1823'ü normal olmak üzere toplam 3678 görüntü bulunmaktadır. İkinci olarak, veri setinin %70 eğitim için ve %30 test için ayrılmıştır. Bu sayede eğitim ve test veri kümeleri hem normal hem de anormal ahşap dokuları içermiştir. Son olarak, eğitim verilerini eğitmek için %70 ve doğrulama için %30 rasgele olarak bölünmüştür. Verilerden anormal ve normal sınıfın görüntüleri Şekil 5.1'de verilmiştir.



Şekil 5.1. Veri setinden örnek görüntüler [29]

Özetlemek gerekirse, amaç “normal” bir ahşap dokudan “normal”in ne olduğunu öğrenen ve incelenen bir ahşap dokusunun anormal olup olmadığını çıkaran bir yöntem geliştirmektir. Bu nedenle, geliştirilen yöntemden bir görüntüden anormalliği öğrenerek veri setindeki görüntüleri normal ve anormal olarak sınıflandırması beklenir. Bu sorunu pratik bir endüstriyel perspektiften ele almak için izlenecek en uygun yaklaşım ESA’dır. Bu yaklaşım göz önüne alındığında, yeni bir anormallik algılama süreci oluşturmak, sınıflandırılacak bir dizi nesnenin toplanmasını gerektirir ve bunlar kullanılarak bir ağ eğitilir. Ardından, inceleme altındaki diğer tüm nesneler ilk kümeyle karşılaştırılır.

Normallikten önemli bir sapma olduğunda, nesne otomatik olarak anormal olarak sınıflandırılır.

Düzenlenen görüntüler girdi olarak verilen DA mimarilerinde farklı girdi boyutları kullanılmıştır. Bu görüntüler renkli formatta olduğu için girdi boyutları 3 parametreden oluşmak zorundadır. Tablo 5.1’de her mimari için uygulanan girdi boyutları verilmiştir.

Tablo 5.1. Derin ağ mimarileri girdi boyutları

Derin Ağ Mimarileri	Girdi Boyutları
ESA	(360 x 360 x 3) ve (224 x 224 x 3)
AlexNet	227 x 227 x 3
GoogleNet	224 x 224 x 3
SqueezeNet	227 x 227 x 3
Inception – V3	299 x 299 x 3
ShuffleNet	224 x 224 x 3
DenseNet-201	224 x 224 x 3
MobileNet – V2	224 x 224 x 3

5.2. Ahşap Güve Kovucu Yüzeyindeki Hataların Belirlenmesi

Tez kapsamında yapılan ön çalışmalarda sıfırdan bir ESA oluşturulmuştur. Bununla birlikte alanyazında kullanılan DA’larda eğitim ve test veri setinde uygulanmış ve sonuçları incelenmiştir. Ön çalışmalar sonucunda elde edilen doğruluk değerini artırmak için yeni metodolojiler belirlenmiş ve Tablo 5.2’de gösterilmiştir. Tabloda gösterilen adımlar izlenerek basit model yapısında yola çıkılarak daha karmaşıklaşan model yapıları incelenecektir.

- Adım 1: Ham görüntüden öznetelik çıkartmak için ESA kullanılacak, çıkartılan öznetelikler ÇKA, DVM gibi klasik makine öğrenme algoritmalarıyla ve derin öğrenme mimarileriyle sınıflandırılacaktır.
- Adım 2: 2a ve 2b alt başlıklarıyla iki farklı yaklaşımdan oluşmaktadır:
 - a) Bunlardan ilki görüntülerin çoğaltılması sonucu elde edilen daha fazla görüntüden oluşan veri setine birinci adımdaki öznetelik çıkarım ve sınıflandırma yöntemlerinin uygulanmasıdır.


- b) İkincisi ise görüntülere görüntü iyileştirme yöntemlerinin uygulanması sonucunda elde edilen iyileştirilmiş görüntülerden oluşan veri setine yine birinci adımdaki öznitelik çıkarım ve sınıflandırma yöntemlerinin uygulanmasıdır.
- Adım 3: Bu adımda ise sırasıyla görüntü iyileştirme yöntemlerinin uygulanması, iyileştirilmiş görüntülere görüntü çoğaltma işlemleri uygulanarak veri setinin genişletilmesi ardından birinci adımdaki öznitelik çıkarım yöntemlerinin uygulanması ve elde edilen özniteliklerin sınıflandırılmasını içermektedir.

Tablo 5.2. Model geliştirme adımları

ADIM	METODOLOJİ			
1	CNN ile öznitelik çıkarımı		Sınıflandırma	
2	Görüntü çoğaltma	CNN ile öznitelik çıkarımı		Sınıflandırma
	Görüntü iyileştirme	CNN ile öznitelik çıkarımı		Sınıflandırma
3	Görüntü iyileştirme	Görüntü çoğaltma	CNN ile öznitelik çıkarımı	Sınıflandırma

5.3. Sınıflandırma Modelleri: Senaryolar

Adım 1 'de öznitelik çıkarım yöntemi olarak tasarlanacak bir ESA mimarisi veya transfer öğrenmesi ile kurulan ESA mimarisi kullanılacaktır [61]. Daha sonra çıkartılan öznitelikler hem derin öğrenme yöntemleri ile hem de makine öğrenimi yöntemleri ile sınıflandırılacaktır. Şekil 5.2'de görüldüğü gibi öznitelik çıkarımı amacıyla kurulacak ESA yapılarının model hiperparametreleri (evrişim katmanların sayısı, sıralaması ve filtre sayısı) ve eğitim hiperparametreleri (parti büyüklüğü (batch size), öğrenme oranı ve epok sayısı) optimize edilerek en yüksek ayrışım yapabilen öznitelikler çıkartılacaktır [62]. Daha sonra sınıflandırma yöntemi olarak hangilerinin tercih edileceği kararı denemeler sonucunda verilerek sınıflandırma yapılacaktır. Sınıflandırıcı algoritmalarının başarısı özniteliklerin dağılımına göre farklılık göstermektedir. Bu nedenle bu çalışma kapsamında ESA çıkışında elde edilen özniteliklerin yüksek başarıyla sınıflandırılması için denenebilecek tüm yöntemler denenecek ve en yüksek performansı (yüksek doğruluk) veren sınıflandırıcı seçilecektir [63], [64].



Şekil 5.2. Algoritma geliştirme adımları

Alanyazında ESA yapılarının özelleştirilmiş ya da transfer öğrenmesi yaklaşımlarıyla kullanıldığı gözlenmektedir. ESA, büyük veri setlerinde daha iyi performans gösterir. Ancak, ESA eğitimi için büyük veri setleri oluşturmak önemli ölçüde zaman ve maliyet gerektirir. Veri seti yeterince büyük olmadığında ESA uygulamalarında bu sorunu aşmak için transfer öğrenmesi yaklaşımı veya sıfırdan kurulan sıkı ağlar önerilmektedir.

Adım 2’de görüntülere aşağıda açıklandığı gibi Adım 1’e ek olarak ilk olarak görüntü çoğaltma teknikleri ve sonra görüntü iyileştirme yöntemlerinin uygulanmasından sonra öznetelik çıkarımı için her ikisinde de ESA kullanılarak çıkartılan öznetelikler sınıflandırılacaktır.

- a) Bu tez çalışmasında, görüntüler farklı görüntü çoğaltma işlemleri ile çoğaltıldıktan sonra, çoğaltılmış görüntüler eklenerek elde edilen tüm görüntülere adım 1’deki gibi öznetelik çıkarımı algoritmaları uygulanacak, çıkartılan öznetelikler sınıflandırılacaktır.
- b) Tez çalışması kapsamında görüntü iyileştirme tekniklerinin sınıflandırma performansına etkilerini araştırmak için iyileştirilen görüntülere adım 1’de açıklanan öznetelik çıkarımı ve sınıflandırma yöntemleri uygulanacaktır.

Görüntü iyileştirme genel olarak düşük kontrastlı, düşük yoğunluklu, gürültülü, bulanık elde edilen veya pek çok belirsizlik içeren durumlarda ihtiyaç duyulan en yaygın işlemlerden biridir. Görüntü iyileştirme teknikleri, bir görüntünün doğal bilgi içeriğini değiştirmeden içerdiği bilgileri iyileştirir ve görüntünün istenen bölgenin tanımlanmasını sağlar. Derin öğrenme algoritmaları, iyi bir performans elde etmek için çok sayıda yüksek kaliteli eğitim örneği gerektirir. Gerçek hayatta elde edilen görüntülerin çoğu bulanık, gürültülü ya da belirsizlikler içermektedir. Genellikle düşük kalitede olabilmektedir. Bu sorunu çözmek için görüntü iyileştirme tekniklerinin derin öğrenme modellerinin performansına etkisi araştırılmaktadır.

Adım 3’te ise yukarıda da açıklandığı gibi Adım 2’de sınıflandırma performansını artırması için görüntülere sırasıyla görüntü çoğaltma ve görüntü iyileştirme yöntemleri uygulanacaktır. Adım 3’te ise amaç bu iki yöntemin ardışık olarak birlikte uygulanması sonucunda (Önce görüntü iyileştirme yöntemleri uygulandıktan sonra iyileştirilen görüntülerin çoğaltılması), çoğaltılan görüntülerden Adım 1’de belirtildiği gibi öznetelik

çıkartılması ve çıkartılan özneliliklerin sınıflandırılmasının sonucunda performansın artırıp artırmadığı incelenecektir.

5.4. Performans Metriklerine Göre Model Seçimi


Alanyazında yapılan çalışmalar incelendiğinde model seçimi için çeşitli performans metriklerinin dikkate alındığı görülmüştür. Burada önemli olan nokta problem yapısıdır. Eğer incelenen problem sonucunda hassas bir sonuç elde edilecek ise (örneğin; bir hastalığı belirleme) bu durumda birden fazla metrik ile modeller karşılaştırılırken çok hassas bir sonuç elde edilmeyecek ise tek bir metrik ile modeller karşılaştırılır. Sınıflandırma çalışmalarında çoğunlukla tercih edilen ilk metrik doğruluk değeri (Accuracy) olmaktadır.

Bu çalışmada öncelikle modeller doğruluk değeri bazı alınarak karşılaştırılmıştır. Ardından her senaryoda elde edilen en yüksek doğruluk değerlerine sahip sonuçlar bir araya getirilerek eğrinin altında kalan alan değerine (AUC) göre karşılaştırılmıştır. Burada istenilen yüksek doğruluk değerine sahip modelin aynı zamanda yüksek eğrinin altında kalan alan değerine de sahip olmasıdır.

Çalışmada ilk olarak DA mimarileri kullanılmıştır. Alanyazında da sıklıkla kullanılan derinlik ve genişlik açılarından farklı mimariler olan bu 7 mimari 5 farklı parametre değerlerine bakılarak uygulanmıştır. Sonuçlar doğrulama ve test doğruluk metrikleri için karşılaştırılmıştır. Toplam 3678 görüntünün %70'i eğitim için, %30'u test için kullanılmıştır. Eğitim için kullanılacak veriler, kullanılan paket program aracılığı ile %70'i eğitim ve %30'u doğrulama olmak üzere rasgele ayrılmıştır.

Tablo 5.3. Derin ağ mimarileri parametreleri ve sonuçları – I

Derin Ağlar	Öğrenme Oranı	Doğrulama Sıklığı	Maksimum Epok	Minimum Parti Boyutu	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
GOOGLNET	0,01	50	30	64	50,39%	50,50%	SGDM
INCEPTION-V3	0,01	50	30	64	80,44%	83,51%	SGDM
SQUEEZENET	0,01	50	30	128	50,39%	50,50%	SGDM
SHUFFLENET	0,01	50	30	128	76,42%	80,43%	SGDM
MOBILENET-V2	0,01	50	30	128	81,87%	85,60%	SGDM
DENSENET-201	0,01	50	30	128	78,37%	83,61%	SGDM
ALEXNET	0,01	50	30	128	50,39%	50,50%	SGDM




Şekil 5.3. Derin ağ mimarleri sonuçları – I

Aynı mimariler öğrenme oranı düşürülerek tekrar uygulanmış ve sonuçlar kaydedilmiştir. Sonuçlar doğrulama ve test doğruluk metrikleri için karşılaştırılmıştır. Öğrenme oranı düşürüldüğünde GoogleNet, SqueezeNet ve AlexNet ağlarının performans metrik değerleri artarken, Inception, ShuffleNet, MobileNet-V2 ve DenseNet-201 ağlarını performans metrik değerleri azalmıştır.

Tablo 5.4. Derin ağ mimarleri parametreleri ve sonuçları – II

Derin Ağlar	Öğrenme Oranı	Doğrulama Sıklığı	Maksimum Epok	Minimum Parti Boyutu	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
GOOGLENET	0,001	50	30	64	78,89%	81,79%	SGDM
INCEPTION-V3	0,001	50	30	64	77,72%	82,97%	SGDM
SQUEEZENET	0,001	50	30	128	79,27%	82,16%	SGDM
SHUFFLENET	0,001	50	30	128	76,04%	80,34%	SGDM
MOBILENET-V2	0,001	50	30	128	75,65%	80,25%	SGDM
DENSENET-201	0,001	50	30	128	76,68%	81,34%	SGDM
ALEXNET	0,001	50	30	128	75,26%	79,08%	SGDM




Şekil 5.4. Derin ağ mimarleri sonuçları – II

İki tablo incelendiğinde en iyi sonucu veren MobileNet-V2 mimarisi, öğrenme oranı ve maksimum epok sayısı parametrelerinin farklı değerleri için uygulanmıştır. Elde edilen sonuçlar doğrulama ve test doğruluk metrikleri için karşılaştırılmıştır.

Tablo 5.5. Derin ağ mimarisi MobileNet-V2 parametreleri ve sonuçları

Derin Ağ	Öğrenme Oranı	Doğrulama Sıklığı	Maksimum Epok	Minimum Parti Boyutu	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
MOBILENET-V2	0,01	50	30	128	81,87%	85,60%	SGDM
MOBILENET-V2	0,01	50	30	128	80,31%	81,61%	ADAM
MOBILENET-V2	0,001	50	30	128	75,65%	80,25%	SGDM
MOBILENET-V2	0,01	50	50	128	79,79%	83,79%	SGDM
MOBILENET-V2	0,01	50	50	128	79,66%	81,07%	ADAM
MOBILENET-V2	0,001	50	50	128	76,55%	79,71%	SGDM
MOBILENET-V2	0,001	50	50	128	80,44%	83,61%	ADAM



Şekil 5.5. Derin ağ mimarisi MobileNet-V2 sonuçları

Yapılan ön denemelerdeki DA mimarileri içerisinde en iyi sonucu veren MobileNet-V2 mimarisinin öznelilik çıkarım yöntemi olarak performansı da ayrıca incelenmiştir. Farklı iki katmandan öznelilikler alınarak farklı sınıflandırma yöntemlerine girdi olarak verilerek performans metriği incelenmiştir.

İlk olarak tüm eğitim verileri kullanılarak öznelilik çıkarımı yapıldı. Genellikle özneliliklerin düzleştirme katmanından çıkarılması istenir. MobileNet-V2 için düzleştirme katmanı 'Logicts' olarak adlandırılmıştır. Elde edilen öznelilikler sınıflandırma yöntemlerine girdi olarak verilmiştir. Burada $k=5$ için çapraz doğrulama uygulanmıştır. En iyi sonuçlar Mediun Gaussian Svm yöntemi ile elde edilmiştir. Bu sonuç MobileNet-V2 mimarisi ile yapılan sınıflandırma sonucundan daha düşüktür.

Tablo 5.6. MobileNet-V2 mimarisi ile öznitelik çıkarımı - I

MobileNet-V2 "Logicts Layer" İle Öznitelik Çıkarımı	Doğrulama Doğruluğu
Fine Tree	67,4
Medium Tree	67,4
Coarse Tree	67,4
Linear Discriminant	66,7
Logistic Regression	66,6
Gaussian Naive Bayes	68,4
Kernel Naive Regression	68,8
Linear Svm	75,6
Quadratic Svm	76,3
Cubic Svm	74,9
Fine Gaussian Svm	56,7
Medium Gaussian Svm	76,4
Coarse Gaussian Svm	72,3
Fine Knn	69,6
Medium Knn	71,5
Coarse Knn	70,2
Cosine Knn	72,7
Cubic Knn	71,4
Weighted Knn	73,2
Boosted Tree	74,4
Bagged Tree	74,1
Subspace Discriminant	74,1
Subspace Knn	69,9
Rusboosted Tree	68,7
Narrow Neural Network	73,2
Medium Neural Network	73,2
Wide Neural Network	72,7
Bilayered Neural Network	71,7
Trilayered Neural Network	71,9

DA mimarileri ile öznitelik çıkarımında düzleştirme katmanından iyi sonuç elde edilmediği durumlarda daha erken katmanlardan öznitelik çıkarımı yapılabilir. Veri setinin durumuna göre bazı durumlarda iyi sonuçlar elde edilebilmektedir. Bu nedenle erken katmanlardan iyi sonuç elde edilip edilemeyeceğini görmek için tüm eğitim verileri MobileNet-V2 mimarisine verilerek 'block_15_expand' olarak adlandırılan katmandan öznitelikleri elde edilmiştir. Elde edilen öznitelikler sınıflandırma yöntemlerine girdi olarak verilmiş ve k=5 için çapraz doğrulama uygulanmıştır. En iyi sonuçlar Quadratic Svm

yöntemi ile elde edilmiştir. Ancak bu sonuçta MobileNet-V2 mimarisi ile yapılan sınıflandırma sonucundan daha düşüktür.


Tablo 5.7. MobileNet-V2 mimarisi ile öz nitelik çıkarımı - II

Mobilenet-V2 "Block15expand Layer" İle Öz nitelik Çıkarımı	Doğrulama Doğruluğu
Fine Tree	66,2
Medium Tree	66,7
Coarse Tree	66,3
Gaussian Naive Bayes	67,4
Kernel Naive Regression	67,7
Linear Svm	75,7
Quadratic Svm	77,4
Cubic Svm	76,7
Fine Gaussian Svm	57,0
Medium Gaussian Svm	75,8
Coarse Gaussian Svm	70,6
Fine Knn	65,3
Medium Knn	67,8
Coarse Knn	68,5
Cosine Knn	69,1
Cubic Knn	68,3
Weighted Knn	69,7
Boosted Tree	75,1
Bagged Tree	73,2
Subspace Discriminant	73,6
Subspace Knn	65,7
Rusboosted Tree	69,9
Narrow Neural Network	74,7
Medium Neural Network	74,6
Wide Neural Network	75,3
Bilayered Neural Network	73,7
Trilayered Neural Network	74,3

DA mimarileri için yapılan son çalışma, en yüksek 3 sonuca sahip mimariler dikkate alınarak yapılmıştır. Bu mimariler DenseNet-201, Inception-V3 ve MobileNet-V2 için doğrulama sıklığı ve maksimum Epok parametreleri sırasıyla 50 ve 30 olarak ayarlanmış ve 4 farklı parametre değeri değiştirilmiştir. Doğrulama ve test doğruluk metriklerine bakılarak sonuçlar karşılaştırılmıştır.

Tablo 5.8. Derin ağ mimarileri parametreleri ve sonuçları – III

Derin Ağ	Eğitim ve Doğrulama Ayrımı	Öğrenme Oranı	Minimum Parti Boyutu	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
DENSENET-201	30%	0,01	128	78,37%	83,61%	SGDM
INCEPTION-V3	30%	0,01	64	80,44%	83,51%	SGDM
MOBILENET-V2	30%	0,01	128	81,87%	85,60%	SGDM
DENSENET-201	30%	0,001	128	76,68%	81,34%	SGDM
INCEPTION-V3	30%	0,001	64	77,72%	82,97%	SGDM
MOBILENET-V2	30%	0,001	128	75,65%	80,25%	SGDM
DENSENET-201	20%	0,01	128	83,50%	84,78%	SGDM
INCEPTION-V3	20%	0,01	64	82,91%	88,41%	SGDM
MOBILENET-V2	20%	0,01	128	82,52%	0,8578	SGDM



Şekil 5.6. Derin ağ mimarileri sonuçları – III

DA mimarileri incelendikten sonra bu mimarilerin eğitiminde kullanılan veri sayısından daha az sayıda veri ile çalışıldığı için derinliği daha az olan bir ESA tasarlamasına karar verilmiştir. Bunun için kullanılacak veriler DA mimarilerinde kullanılan ile aynıdır. Yine verilerin %70'i eğitim, %30'u test için kullanılmıştır. Eğitim için kullanılacak veriler, kullanılan paket program aracılığı ile %70'i eğitim ve %30'u doğrulama olmak üzere rasgele ayrılmıştır. Buradaki tek fark girdi görüntüsünün boyutlarıdır. DA mimarilerinin yapılarına özel girdi boyutları olduğu için değiştirilemez. Ancak burada girdi boyutlarını tasarımı yapan belirleyebilmektedir. Çok veri kaybı olmaması için 360 x 360 boyutlarına karar verilmiştir. Tasarlanan ESA katman sayısına karar verirken kademe kademe artırılarak sonuçlar incelenmiştir. Katman sayısına karar verdikten sonra öğrenme oranı, eğitim tur sayısı (epok) ve optimizasyon yöntemi parametreleri farklı değerler için değiştirilmiştir.

Tablo 5.9. Tasarlanan evrimsel sinir ağı parametreleri ve sonuçları – I

	Deneme	Öğrenme Oranı	Katman Sayısı	Maksimum Epok	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
TASARLANAN EVRİŞİMSEL SİNİR AĞI	1	0,01	3	4	53,37%	49,73%	SGDM
	2	0,01	6	4	55,18%	61,14%	SGDM
	3	0,001	6	4	66,06%	64,76%	SGDM
	4	0,001	9	4	69,3%	72,64%	SGDM
	5	0,0001	9	4	68,78%	70,92%	SGDM
	6	0,0001	9	10	73,58%	74,73%	SGDM
	7	0,0001	9	10	69,17%	78,44%	ADAM
	8	0,0001	9	10	71,63%	75,27%	RMSPROP
	9	0,0001	9	20	72,02%	77,45%	RMSPROP
	10	0,0001	9	20	69,3%	74,37%	ADAM
	11	0,0001	9	20	71,11%	77,17%	SGDM
	12	0,0001	9	100	72,67%	76,54%	SGDM

En iyi sonucu veren mimarinin maksimum epok sayısı artırılarak denemeler yapılmıştır. Epok sayısının artırılmasıyla öğrenme işlemi çok kez tekrarlanır. Bu sayede mimarilerin farklı olasılıkları öğrenmesi ve yeni gelen görüntü için daha doğru sınıflandırma yapması beklenir. Ancak burada önemli olan nokta tasarlanan ağın ezberlemesinin önüne geçmektir. Bu deneme sonuçları doğrulama ve test doğruluk metrikleri için karşılaştırılmıştır.

Tablo 5.10. Tasarlanan evrişimsel sinir ağı parametreleri ve sonuçları - II

	Deneme	Öğrenme Oranı	Katman Sayısı	Maksimum Epok	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
TASARLANAN EVRİŞİMSEL SİNİR AĞI	1	0,0001	9	10	69,17%	78,44%	ADAM
	2	0,0001	9	20	69,3%	74,37%	ADAM
	3	0,0001	9	30	68,01%	77,81%	ADAM
	4	0,0001	9	40	71,63%	76,54%	ADAM
	5	0,0001	9	50	71,11%	76,09%	ADAM
	6	0,0001	9	60	70,47%	75,27%	ADAM
	7	0,0001	9	70	72,67%	77,54%	ADAM
	8	0,0001	9	100	74,22%	78,17%	ADAM
	9	0,0001	9	150	71,76%	78,17%	ADAM
	10	0,0001	9	200	71,76%	79,08%	ADAM
	11	0,0001	9	250	71,37%	77,26%	ADAM
	12	0,0001	9	300	71,24%	78,53%	ADAM
	13	0,0001	9	400	71,37%	76,54%	ADAM

Daha sonra DA mimarilerinde sıklıkla kullanılan girdi boyutu olan 224 x 224 için denemeler yapılmıştır. Ancak sonuçlar incelendiğinde önceki denemelerden daha iyi sonuç elde edilememiştir. Bunun sebebi veri setindeki görüntülerin küçültülmesi ile özellikle kusurlu bölgeleri içeren veri kaybının çok olmasıdır.

Tablo 5.11. Tasarlanan evrişimsel sinir ağı parametreleri ve sonuçları - III

	Deneme	Öğrenme Oranı	Katman Sayısı	Maksimum Epok	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
TASARLANAN EVRİŞİMSEL SİNİR AĞI	1	0,0001	9	30	68,78%	76,9%	ADAM
	2	0,0001	9	50	67,36%	76,99%	ADAM
	3	0,0001	9	70	71,63%	75,27%	ADAM
	4	0,0001	9	100	74,09%	74,55%	ADAM
	5	0,0001	9	150	70,73%	76,09%	ADAM
	6	0,0001	9	200	69,56%	74,64%	ADAM

Tasarlanan ESA'na görüntü çoğaltma ve görüntü iyileştirme yöntemleri hem ayrı ayrı hem de birlikte uygulanmış, sonuçlar doğrulama ve test doğruluk metrikleri için karşılaştırılmıştır. Görüntü çoğaltma yöntemlerinin seçiminde gerçek hayatta karşılaşılabilecek durumlar göz önünde bulundurulmuştur. Görüntü iyileştirme yöntemlerinin seçiminde ise sıklıkla kullanılan yöntemlere öncelik verilmiştir. Görüntü

çoğaltma ve görüntü iyileştirme yöntemlerini birleştirirken daha önceki denemelerde en yüksek performans metriklerine sahip olan yöntemler kullanılmıştır.

Tablo 5.12. Görüntü çoğaltma uygulanan evrimsel sinir ağı parametreleri ve sonuçları

Görüntü Çoğaltma	Deneme	Öğrenme Oranı	Katman Sayısı	Maksimum Epok	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
'InputSize', [360 360 3] 'RandRotation', [-20,20], 'RandXTranslation', [-3,3], 'RandYTranslation', [-3,3]	1	0,01	8	30	74,09%	77,17%	SGDM
	2	0,01	8	100	78,11%	79,17%	SGDM
	3	0,01	8	100	79,15%	81,97%	ADAM
	4	0,001	8	100	79,02%	77,99%	ADAM
	5	0,01	8	200	79,92%	82,61%	ADAM
	6	0,01	8	300	79,15%	81,16%	ADAM

Görüntü iyileştirme yöntemlerinde öğrenme oranı, katman sayısı, maksimum Epok parametreleri sırasıyla 0,01, 8 ve 200 olarak ayarlanmıştır. 3 farklı parametre değeri değiştirilerek doğrulama ve test doğruluk performans ölçütleri karşılaştırılmıştır.

Tablo 5.13. Görüntü iyileştirme uygulanan evrimsel sinir ağı parametreleri ve sonuçları

Görüntü İyileştirme	Deneme	Eğitim ve Doğrulama Ayrımı	İterasyon sayısı	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
GÜRÜLTÜ EKLEME	1	30%	14	66,58%	65,58%	ADAM
	2	20%	16	66,80%	70,92%	ADAM
MEDYAN FİLTRESİ	3	30%	14	66,45%	73,37%	ADAM
	4	20%	16	67,96%	70,20%	ADAM
HİSTOGRAM FİLTRESİ	5	30%	14	74,48%	78,35%	ADAM
	6	20%	16	75,34%	77,90%	ADAM
	7	30%	14	72,41%	80,34%	SGDM

Görüntü çoğaltma ve iyileştirme yöntemleri birlikte uygulandığında öğrenme oranı ve maksimum Epok parametreleri sırasıyla 0,01 ve 200 olarak ayarlanmıştır. 4 farklı parametre değeri değiştirilerek doğrulama ve test doğruluk performans ölçütleri karşılaştırılmıştır.

Tablo 5.14. Görüntü çoğaltma ve iyileştirme uygulanan evrimsel sinir ağı parametreleri ve sonuçları

Görüntü Çoğaltma ve Görüntü İyileştirme Birlikte	Deneme	Eğitim ve Doğrulama Ayırımı	Katman Sayısı	İterasyon sayısı	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
HİSTOGRAM FİLTRESİ	1	30%	8	14	78,76%	77,45%	ADAM
	2	30%	8	14	76,30%	79,80%	SGDM
	3	30%	9	14	74,74%	76,72%	SGDM
	4	20%	9	16	69,13%	73,28%	SGDM
MEDYAN FİLTRESİ	5	30%	8	14	67,62%	70,38%	ADAM

Tüm sonuçlar incelendiğinde tasarlanan ağın belli bir noktada ezberlediği görülmüştür. Bunun için nöron eksiltme işlemi uygulanmıştır. Öğrenme oranı, maksimum Epok ve iterasyon sayısı parametreleri sırasıyla 0,01, 200 ve 14 olarak ayarlanmış, 3 farklı parametre değeri değiştirilmiştir. Sonuçlar doğrulama ve test doğruluk metrikleri için karşılaştırılmıştır.

Tablo 5.15. Görüntü çoğaltma ve nöron eksiltme işlemi uygulanan evrimsel sinir ağı parametreleri ve sonuçları


Görüntü Çoğaltma	Deneme	Katman Sayısı	Nöron Eksiltme Katmanı	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
'InputSize', [360 360 3] 'RandRotation', [-20,20], 'RandXTranslation', [-3,3], 'RandYTranslation', [-3,3]	1	8	0,5	75,78%	79,17%	ADAM
	2	8	0,5	79,02%	81,43%	SGDM
	3	8	0,2	79,02%	82,43%	ADAM
	4	8	0,2	76,3%	80,43%	SGDM
	5	9	0,2	78,63%	82,52%	ADAM

5.5. Sonuçların Karşılaştırılması


Alanyazında yapılan derin öğrenme çalışmalarında genellikle başarılı sonuçlar elde edilmektedir. Her ne kadar bu mimariler ve tasarlanacak yeni mimarilerin iyi sonuçlar vermesi beklense de bu durum veri setlerinin yapılarına bağlı olarak değişiklik göstermektedir. Bu çalışmada derin öğrenme mimarilerinin uygulanmasının sebebi bu

mimarilerin başarılı sonuçlar vermesinin yanında farklı veri setlerine uyum sağlayabilen mimariler olmasıdır.

Tüm sonuçlar incelendiğinde bu çalışmada kullanılan veri setine en uygun derin öğrenme mimarisi Inception-V3 mimarisidir. Çalışma kapsamında incelenen 8 mimari içerisinde en iyi sonucu vermiştir. Hem doğrulama doğruluğu hem de test doğruluğu ölçütlerinde %80'nin üstünde bir başarıya sahiptir.



Şekil 5.7. MobileNet-V2 derin ağ mimarisi karışıklık matrisi



Şekil 5.8. Inception-V3 derin ağ mimarisi karışıklık matrisi


Şekil 5.7’de MobileNet-V2 mimarisinin ve Şekil 5.8’de Inception-V3 mimarisinin karışıklık matrisleri verilmiştir. Şekil 5.7’deki matriste MobileNet-V2 mimarisinin test görüntüleri içerisindeki normal görüntülerin 63’ünü anormal ve anormal görüntülerin 96’sını normal olarak görülmektedir. Şekil 5.8’deki matriste ise Inception-V3 mimarisinin test görüntüleri içerisindeki normal görüntülerin 49’unu anormal ve anormal görüntülerin 79 normal olarak görülmektedir. Bu durumda mimarilerin anormal görüntüleri sınıflandırırken zorlandığı anlaşılmaktadır.



6. KALİTE KONTROL SİSTEM TASARIM ÖNERİSİ


Kalite kontrol işlemleri, üretim hatlarında her an kontrol edilmesi zor işlemlerdir. Bu nedenle belli noktalarda kalite kontrol yapılarak üretilcek ürünlerde en az firenin verilmesi hedeflenir. Ayrıca seri üretim hatlarında çok sayıda ürünün nesnel bir şekilde hızlıca kontrol edilmesi mümkün olmamaktadır. Önerilen bu tasarım ise üretim hattında gerek ham madde girişinde gerekse son ürünün çıkışında istenilen noktalara kurularak hızlı bir şekilde gerçek zamanlı kalite kontrol yapılabilir. Bu sayede hatalı ürünler ayrılarak yapılabiliriyorsa tekrar işlenmeye gönderilebilir. Erkenden verilen bu karar ile müşteri memnuniyeti sağlanmış zaman ve maliyet açılarından kazanç sağlanmış olur.

Önerilen sistem tasarımı Şekil 6.1’de verilmiştir. Bu sistem tasarımında Instituto Tecnológico de Informática tarafından geliştirilen ZeroGravity3D cihazı kullanılmıştır. Üretim hattında kontrol edilmesi gereken noktaya bu cihaz yerleştirilir. Hareket eden hat üzerinden ürünler iki lineer robotik kola (mekanizmayı kontrol eden veya hareket ettiren bir tür motorlu kol) gelir. Biri parçayı cihaza fırlatırken diğeri düşen parçayı alır ve hat üzerine bırakır. Bu sırada incelenen ürünü kusurlu ve kusursuz olarak ayırt etmek için sınıflandırma çalışması yapılır. Kusurlu (kırmızı renkli) kararı verilen ürün kusurlu yani kırmızı renkli kutuya, kusursuz (yeşil renkli) kararı verilen ürün kusursuz yani yeşil renkli kutuya ayrıştırılır. Bu ayrımı yapmak için hat üzerinde hareketli bir kol bulunmalıdır. Bu kol sayesinde ürünler hat üzerinde ilgili kutulara yönlendirilebilir.




Şekil 6.1. Kalite kontrol sistem tasarımı [65]

Önerilen sistem tasarımı ve bileşenleri Şekil 6.2’de verilmiştir.




Şekil 6.2. Kalite kontrol sistem tasarım bileşenleri [65]

ZeroGravity3D cihazı, endüstriyel görüş sistemlerinde uzmanlaşmış bir Araştırma-Geliştirme ekibi tarafından, karşılaştıkları gerçek sorunları çözmek amacıyla endüstri ile iş birliği içinde geliştirilmiştir. Makine görüşüne dayanan bu sistem, her bir parçanın anında 3D yeniden yapılandırılmasını sağlayarak 800 adet/s'de algılamaya ve birden fazla referansla %100 hat içi incelemeye olanak tanımaktadır. Üzerinde bulunan 16 kamera ile bir ürünün yerçekimsiz ortamda 16 farklı açıdan görüntüsü alınabilmektedir. Bu sayede tek bir açıdan kontrol yerine birden fazla açıdan kontrol sağlanmış olur. Bu cihazın görüntü Şekil 6.3’te görülmektedir [28].




Şekil 6.3. ZeroGravity3D cihazı [28]

Bu sistem tasarımı ile entegre edilmesi planlanan gerçek zamanlı kalite kontrol sistemi arayüz tasarım akışı Şekil 6.4'te, kalite kontrol sistemi arayüzleri Şekil 6.5, Şekil 6.6, Şekil 6.7, Şekil 6.8 ve Şekil 6.9'da verilmiştir.



Şekil 6.4. Kalite kontrol sistemi arayüz tasarım akışı

Şekil 6.5'te verilen ilk arayüz kullanıcının karşılaşacağı ilk ekrandır. Burada kullanıcıyı uyarmak için bir uyarı kutusu, senaryo seçimleri için bir listbox ve devam etmek için bir Devam butonu bulunmaktadır.



Şekil 6.5. Akıllı kalite kontrol sistemi arayüzü – I

Eğer Senaryo 1 seçilirse Şekil 6.6'da verilen arayüz ekranı kullanıcının karşısına çıkar. Burada kullanıcı sınıflandırma işlemi için kullanmak istediği mimariyi seçebilir ve seçtiği mimari için eğitim parametrelerinin değerlerini belirleyebilmektedir. Tüm işlemlerden sonra Başlat butonu ile eğitim işlemi başlatılır.

SINIFLANDIRICI SEÇİMİ

INCEPTION
SQUEEZENET
SHUFFLENET
MOBILENET-V2
DENSENET-201
ALEXNET

EĞİTİM PARAMETRE DEĞERLERİ

Eğitim ve Doğrulama Ayrımı 0

Öğrenme Oranı 0

Maksimum Epok Sayısı 0

Doğrulama Sıklığı 0

Minimum Parti Boyutu 0

Optimizasyon Yöntemi 0

BAŞLAT

Şekil 6.6. Akıllı kalite kontrol sistemi arayüzü – II

Eğer Senaryo 2.1 seçilirse kullanıcı Şekil 6.7’de verilen arayüz ekranı ile karşılaşır. Burada kullanıcı sınıflandırma işlemi için kullanmak istediği mimariyi seçmenin ve seçtiği mimari için eğitim parametrelerinin değerlerini belirlemenin yanı sıra görüntü çoğaltma işlemi için gerekli olan parametre değerlerini de belirlemektedir. Gerekli tüm seçimler yapıldıktan sonra Başlat butonu ile eğitim işlemi başlatılır.

SINIFLANDIRICI SEÇİMİ

INCEPTION

SQUEEZENET

SHUFFLENET

MOBILENET-V2

DENSENET-201

ALEXNET

GÖRÜNTÜ ÇOĞALTMA YÖNTEMİ PARAMETRE DEĞERLERİ

Girdi Boyutu

0

Rastgele Döndürme

0

Rastgele X Ekseninde Çevirme

0

Rastgele Y Ekseninde Çevirme

0

EĞİTİM PARAMETRE DEĞERLERİ

Eğitim ve Doğrulama Ayrımı

0

Öğrenme Oranı

0

Maksimum Epok Sayısı

0

Doğrulama Sıklığı

0

Minimum Parti Boyutu

0

Optimizasyon Yöntemi

0

BAŞLAT

Şekil 6.7. Akıllı kalite kontrol sistemi arayüzü – III

Eğer Senaryo 2.2 seçilirse kullanıcı Şekil 6.8’de verilen arayüz ekranı ile karşılaşır. Burada kullanıcı sınıflandırma işlemi için kullanmak istediği mimariyi seçmenin ve seçtiği mimari için eğitim parametrelerinin değerlerini belirlemenin yanı sıra görüntü iyileştirme işlemi için istediği yöntemi de belirlemektedir. Gerekli tüm seçimler yapıldıktan sonra Başlat butonu ile eğitim işlemi başlatılır.

The interface is divided into three main sections:

- SINIFLANDIRICI SEÇİMİ** (Classifier Selection): A dropdown menu with the following options: INCEPTION, SQUEEZENET, SHUFFLENET, MOBILENET-V2, DENSENET-201, and ALEXNET. 'INCEPTION' is currently selected.
- GÖRÜNTÜ İYİLEŞTİRME YÖNTEMİ SEÇİMİ** (Image Enhancement Method Selection): Three checkboxes are present, all of which are unchecked:
 - ☐ Görüntü Ekleme
 - ☐ Medyan Filtresi
 - ☐ Histogram Filtresi
- EĞİTİM PARAMETRE DEĞERLERİ** (Training Parameter Values): Six input fields, each with a '0' value:
 - Eğitim ve Doğrulama Ayrımı: 0
 - Öğrenme Oranı: 0
 - Maksimum Epok Sayısı: 0
 - Doğrulama Sıklığı: 0
 - Minimum Parti Boyutu: 0
 - Optimizasyon Yöntemi: 0

A **BAŞLAT** (Start) button is located at the bottom right of the interface.

Şekil 6.8. Akıllı kalite kontrol sistemi arayüzü – IV

Son olarak eğer Senaryo 3 seçilirse Şekil 6.9’da verilen arayüz ekranı kullanıcının karşısına çıkar. Burada kullanıcı sınıflandırma işlemi ile birlikte görüntü çoğaltma ve görüntü iyileştirme yöntemlerini birlikte kullanmayı seçmiştir. Bu nedenle sınıflandırma işlemi için kullanmak istediği mimariyi seçmenin ve seçtiği mimari için eğitim parametrelerinin değerlerini belirlemenin yanı sıra hem görüntü çoğaltma işlemi için gerekli olan parametre değerlerini hem de görüntü iyileştirme işlemi için istediği yöntemi de belirlemesi gerekmektedir. Gerekli tüm seçimler yapıldıktan sonra Başlat butonu ile eğitim işlemi başlatılır.

The interface is titled 'Akıllı kalite kontrol sistemi arayüzü - V'. It is divided into several sections for configuring a deep learning model for image classification.

- SINIFLANDIRICI SEÇİMİ (Classifier Selection):** A dropdown menu with options: INCEPTION, SQUEEZENET, SHUFFLENET, MOBILENET-V2, DENSENET-201, and ALEXNET. 'INCEPTION' is currently selected.
- GÖRÜNTÜ ÇOĞALTMA YÖNTEMİ PARAMETRE DEĞERLERİ (Image Augmentation Method Parameter Values):**
 - Girdi Boyutu (Input Size): 0
 - Rastgele Döndürme (Random Rotation): 0
 - Rastgele X Ekseninde Çevirme (Random X-axis Flip): 0
 - Rastgele Y Ekseninde Çevirme (Random Y-axis Flip): 0
- GÖRÜNTÜ İYİLEŞTİRME YÖNTEMİ SEÇİMİ (Image Enhancement Method Selection):**
 - ☐ Görüntü Ekleme (Add Image)
 - ☐ Medyan Filtresi (Median Filter)
 - ☐ Histogram Filtresi (Histogram Filter)
- EĞİTİM PARAMETRE DEĞERLERİ (Training Parameter Values):**
 - Eğitim ve Doğrulama Ayrımı (Training and Validation Split): 0
 - Öğrenme Oranı (Learning Rate): 0
 - Maksimum Epok Sayısı (Maximum Epoch Count): 0
 - Doğrulama Sıklığı (Validation Frequency): 0
 - Minimum Parti Boyutu (Minimum Batch Size): 0
 - Optimizasyon Yöntemi (Optimization Method): 0
- BAŞLAT (Start):** A button to initiate the training process.

Şekil 6.9. Akıllı kalite kontrol sistemi arayüzü – V

Eğitim başlatıldıktan sonra mimari etiketli görüntüler eğitilir. Eğitilmiş mimari yeni eklenen görüntüleri sınıflandırır ve elde edilen sonuçlar çıktı ekranı aracılığı ile kullanıcı ile paylaşılır.

7. SONUÇLAR VE ÖNERİLER

Son yıllarda teknolojik gelişmelerle birlikte rekabetin arttığı üretim sektörlerinde kalite kontrol faaliyetleri daha çok önem taşımaya başlamıştır. Kalite kontrol faaliyetleri ile hem piyasaya sunulan ürünün hem de üretiminin her aşamasının standartlaştırılması sağlanmaktadır. Üretim süreçlerinde hatalar varsa, bu hataların önceden gözlenmesi ve düzeltici önlemler alınarak üretilen ürünlerin hatalı olmasının önlenmesi tüm üretim süreçleri için önemlidir. Bu sayede işgücü, hammadde veya yarı mamul ve zaman israfları engellenmiş olur. Daha önce gözle ya da elle yapılan kontroller günümüz teknolojisi ile daha otomatik hale gelmektedir. Bununla birlikte, endüstri kullanıcıları, üretim sırasında meydana gelebilecek olası tüm anormallikleri ve bunların görünümelerini genellikle bilemezler. Bu durum ahşap anormalliklerinin tespit edilmesinde önemli bir rol oynamaktadır. Ayrıca çalışmanın bazı kısıtları bulunmaktadır. Kullanılan veri setindeki görüntülerin farklı piksel boyutlarında olması, başka gruplar tarafından etiketlendiği için etiketsiz gelen verilerin etiketlenememesi ve istatistiksel analizlerde kullanılacak ölçütlerin bilinmemesi, iki grubun ortak karar veremediği etiketlerin olması, derin ağ mimarilerinin farklı girdi boyutlarına sahip olması, derin ağ mimarilerin farklı parametre değerlerinde performans ölçütlerinin farklılık göstermesi, eğitim, test ve doğrulama verilerinin paylaşımının kesin bir ölçütünün olmaması, bu veri seti ile yapılan benzer bir yayın olmaması bu kısıtlardan bazılarıdır.

Bu çalışmada öncelikle veri seti düzenlenmiştir. Bu düzenleme ile veri setlerini etiketleri belirlenerek eğitim ve test olmak üzere iki gruba ayırımı gerçekleştirilmiştir. Bu ayırım yapılırken mümkün olan en homojen dağılım olmasına dikkat edilmiştir. Veri seti hazır hale geldikten sonra DA mimarileri ile ön çalışmalar yapılarak performansları incelenmiştir. Ayrıca umut verici sonuçlar veren MobileNet-V2 mimarisi öznetelik çıkarım yöntemi olarak da kullanılmış ve klasik sınıflandırma yöntemlerinin performansları incelenmiştir. Son olarak bir ESA tasarlanmış ve değişik parametrelerde aldığı sonuçlar incelenmiştir. Bir ESA'nın tasarlanmasının sebebi veri setinde bulunan görüntü sayısının DA mimarilerinin eğitiminde kullanılan görüntü sayılarına göre daha az olmasıdır. Veri setinde görüntü sayısının az olduğu durumlarda derinliği nispeten daha az olan ağların daha başarılı sonuçlar verip vermediği incelenmiştir. Tasarlanan ESA'da görüntü iyileştirme ve görüntü çoğaltma yöntemleri ayrı ayrı ve birlikte uygulanarak performans metriklerinde artış olup olmadığı araştırılmıştır. Sonuçta yapılan çalışmalarda en iyi sonuçları Inception-V3 mimarisi vermiştir. Bu mimari ile doğrulama doğruluğu %82,91 ve test doğruluğu %88,41

olarak bulunmuştur. Bununla birlikte MobileNet-V2 ve DenseNet-201 mimarileri de umut verici sonuçlar vermiştir.

Alanyazında ahşap görüntüleri üzerinde yapılan diğer çalışmalarla kıyaslandığında bazı çalışmalardan düşük olmasına rağmen umut verici sonuçlar sağladığı görülmektedir. Alanyazında bu çalışmada yapılan analizlerde kullanılan ahşap görüntülerini içeren veri setiyle yapılan bir çalışma bulunmamaktadır. Bu tezde sunulan sonuçlar her ne kadar umut verici olsa da diğer çalışmalarda kullanılan verilerle sayı ve özellik olarak aynı olmadığı için başarı değerlerinin birebir karşılaştırılması yapılamaz.

Tüm çalışmalar bir araya toplanarak üretime entegre edilmesi hedeflenen bir kalite kontrol sistemi ile bu sistemde kullanılacak bilgisayar destekli kalite kontrol uygulaması tasarlanmıştır.

Yapay zeka çalışmalarına duyulan ilgi gün geçtikçe artmaktadır. Artan bu ilgi ile yapay zekanın çalışma alanları genişlemekte ve yüksek başarılarla sahip mimariler geliştirilmektedir. Bu nedenle bu tez kapsamında yapılan çalışma daha da derinleştirilebilir. İleride yapılacak çalışmalarda farklı mimariler ve farklı parametreler dikkate alınarak performans üzerindeki etkileri incelenebilir. Ayrıca görüntü iyileştirme ve çoğaltma tekniklerinin DA üzerindeki etkileri gözlemlenebilir. Son olarak bir ürün için alınan farklı görüntüler bir araya getirilerek DA mimarilerine girdi olarak verildiğinde sonuçların nasıl değiştiği gözlemlenebilir.

KAYNAKLAR

- [1] B. Kesici and M. S. Yildiz, “Kalite kontrol faaliyetlerinde yapay zekâ kullanımı ve bir otomotiv yan sanayisinde uygulanması,” *Yalova Sosyal Bilimler Dergisi*, vol. 6, no. 12, pp. 307–323, Dec. 2016, Accessed: Aug. 21, 2022. [Online]. Available: dergipark.org.tr/tr/pub/yalovasosbil/issue/27392/289024
- [2] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *The bulletin of mathematical biophysics* 1943 5:4, vol. 5, no. 4, pp. 115–133, Dec. 1943, doi: 10.1007/BF02478259.
- [3] D. O. Hebb, *The Organization of Behavior: A Neuropsychological Theory*. Psychology Press, 2005. doi: 10.4324/9781410612403.
- [4] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in the brain,” *Psychological Review*, vol. 65, no. 6, pp. 386–408, Nov. 1958, doi: 10.1037/H0042519.
- [5] B. Widrow and M. E. Hoff, “Adaptive switching circuits,” *Computer Science*, Jun. 1960, doi: 10.21236/AD0241531.
- [6] K. Fukushima, “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,” *Biological Cybernetics* 1980 36:4, vol. 36, no. 4, pp. 193–202, Apr. 1980, doi: 10.1007/BF00344251.
- [7] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature* 1986 323:6088, vol. 323, no. 6088, pp. 533–536, 1986, doi: 10.1038/323533a0.
- [8] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/NECO.1997.9.8.1735.

- [9] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2323, 1998, doi: 10.1109/5.726791.
- [10] "CIFAR – Convening extraordinary minds to address the most important questions facing science and humanity." cifar.ca/ (accessed Aug. 05, 2022).
- [11] G. E. Hinton, S. Osindero, and Y. W. Teh, "A Fast Learning Algorithm for Deep Belief Nets," *Neural Computation*, vol. 18, no. 7, pp. 1527–1554, Jul. 2006, doi: 10.1162/NECO.2006.18.7.1527.
- [12] G. A. Ruz and P. A. Estévez, "Image segmentation using fuzzy min-max neural networks for wood defect detection," in *Intelligent Production Machines and Systems-First I* PROMS Virtual Conference: Proceedings and CD-ROM set*, 2005, pp. 183–189. Accessed: Aug. 05, 2022. [Online]. Available: researchgate.net/publication/236586295
- [13] C. Aparecido De França and A. Gonzaga, "Classification of wood plates by neural networks and fuzzy logic image and video processing view project detection of architectural distortion in mammograms view project," *Computer Science*, 2005, Accessed: Aug. 05, 2022. [Online]. Available: researchgate.net/publication/266290506
- [14] S. Shahnorbanun, S.A.Siti Nurul Huda, A. Haslina, O. Nazlia, and H. Rosilah, "A computational biological network for wood defect classification," *Proceedings of the World Congress on Engineering and Computer Science*, pp. 559–563, Oct. 2010, Accessed: Aug. 07, 2022. [Online]. Available: iaeng.org/publication/WCECS2010/WCECS2010_pp559-563.pdf
- [15] K. Kamal, R. Qayyum, S. Mathavan, and T. Zafar, "Wood defects classification using laws texture energy measures and supervised learning approach," *Advanced Engineering Informatics*, vol. 34, pp. 125–135, Oct. 2017, doi: 10.1016/J.AEI.2017.09.007.

- [16] R. Ren, T. Hung, and K. C. Tan, "A generic deep-learning-based approach for automated surface inspection," *IEEE Trans Cybern*, vol. 48, no. 3, pp. 929–940, Mar. 2018, doi: 10.1109/TCYB.2017.2668395.
- [17] T. He, Y. Liu, C. Xu, X. Zhou, Z. Hu, and J. Fan, "A fully convolutional neural network for wood defect location and identification," *IEEE Access*, vol. 7, pp. 123453–123462, 2019, doi: 10.1109/ACCESS.2019.2937461.
- [18] A. Urbonas, V. Raudonis, R. Maskeliunas, and R. Damaševičius, "Automated identification of wood veneer surface defects using faster region-based convolutional neural network with data augmentation and transfer learning," *Applied Sciences 2019, Vol. 9, Page 4898*, vol. 9, no. 22, p. 4918, Nov. 2019, doi: 10.3390/APP9224898.
- [19] F. Ding, Z. Zhuang, Y. Liu, D. Jiang, X. Yan, and Z. Wang, "Detecting defects on solid wood panels based on an improved SSD algorithm," *Sensors (Switzerland)*, vol. 20, no. 18, pp. 1–17, Sep. 2020, doi: 10.3390/S20185315.
- [20] M. Gao, J. Chen, H. Mu, and D. Qi, "A transfer residual neural network based on resnet-34 for detection of wood knot defects," *Forests 2021, Vol. 12, Page 212*, vol. 12, no. 2, p. 227, Feb. 2021, doi: 10.3390/F12020212.
- [21] R. Qayyum, K. Kamal, T. Zafar, and S. Mathavan, "Wood defects classification using GLCM based features and PSO trained neural network," in *2016 22nd International Conference on Automation and Computing, ICAC 2016: Tackling the New Challenges in Automation and Computing*, Oct. 2016, pp. 273–277. doi: 10.1109/ICONAC.2016.7604931.
- [22] O. Silvén, M. Niskanen, and H. Kauppinen, "Wood inspection with non-supervised clustering," *Machine Vision and Applications 2003 13:5*, vol. 13, no. 5, pp. 275–285, Mar. 2003, doi: 10.1007/S00138-002-0084-Z.
- [23] P. Cavalin, L. S. Oliveira, A. L. Koerich, and A. S. Britto, "Wood defect detection using grayscale images and an optimized feature set," in *IECON Proceedings*

- (*Industrial Electronics Conference*), 2006, pp. 3408–3412. doi: 10.1109/IECON.2006.347618.
- [24] S. Y. Wu, Z. Zhang, and L. Feng, “Statistical feature representations for automatic wood defects recognition research and applications,” in *PACIIA 2009 - 2009 2nd Asia-Pacific Conference on Computational Intelligence and Industrial Applications*, 2009, vol. 1, pp. 19–22. doi: 10.1109/PACIIA.2009.5406462.
- [25] A. Mahram, M. G. Shayesteh, and S. Jafarpour, “Classification of wood surface defects with hybrid usage of statistical and textural features,” in *2012 35th International Conference on Telecommunications and Signal Processing, TSP 2012 - Proceedings*, 2012, pp. 749–752. doi: 10.1109/TSP.2012.6256397.
- [26] S. Mohan and K. Venkatachalapathy, “Wood knot classification using bagging,” *International Journal of Computer Applications*, vol. 51, no. 18, pp. 50–53, Aug. 2012, doi: 10.5120/8146-1937.
- [27] Á. G. Faura, D. Štepec, M. Cankar, and M. Humar, “Application of unsupervised anomaly detection techniques to moisture content data from wood constructions,” *Forests*, vol. 12, no. 2, pp. 1–19, Feb. 2021, doi: 10.3390/F12020194.
- [28] J. C. Perez-Cortes, A. J. Perez, S. Saez-Barona, J. L. Guardiola, and I. Salvador, “A system for in-line 3d inspection without hidden surfaces,” *Sensors 2018, Vol. 18, Page 2993*, vol. 18, no. 9, p. 2993, Sep. 2018, doi: 10.3390/S18092993.
- [29] “Wood Anomaly Detection One Class Classification | Kaggle.” kaggle.com/datasets/itiresearch/wood-anomaly-detection-one-class-classification (accessed Jul. 26, 2022).
- [30] T. M. Mitchell, *Machine Learning*, 1997th ed., vol. 1st Edition. New York, USA: McGraw-Hill Education, 1997.
- [31] C. M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*, 2007th ed. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006.

- [32] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning* 1995 20:3, vol. 20, no. 3, pp. 273–297, Sep. 1995, doi: 10.1007/BF00994018.
- [33] E.U. Küçüksille and N. Ateş, "Destek vektör makineleri ile yaramaz elektronik postaların filtrelenmesi," *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, vol. 6, no. 1, Jun. 2016, Accessed: Aug. 09, 2022. [Online]. Available: dergipark.org.tr/tr/pub/tbbmd/issue/22246/238807
- [34] S. Ayhan and Ş. Erdoğan, "Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi," *Eskişehir Osmangazi Üniversitesi İibf Dergisi*, vol. 9, no. 1, pp. 175–198, Apr. 2014, Accessed: Aug. 09, 2022. [Online]. Available: dergipark.org.tr/tr/pub/oguiibf/issue/5712/76473
- [35] Z.-H. (Computer scientist) Zhou, *Ensemble methods : foundations and algorithms*, 1st edition. Florida: CRC Press Taylor & Francis Group, 2012.
- [36] T. Kavzoglu and I. Colkesen, "Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi," *Harita Dergisi*, vol. 144, no. 7, pp. 73–82, Jul. 2010, Accessed: Aug. 07, 2022. [Online]. researchgate.net/publication/275037555
- [37] T. K. Ho, "Nearest neighbors in random subspaces," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1998, vol. 1451, pp. 640–648. doi: 10.1007/BFB0033288/COVER.
- [38] M. Alan, "Karar ağaçlarıyla öğrenci verilerinin sınıflandırılması," *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, vol. 28, no. 4, pp. 101–112, Nov. 2014, doi: 10.16951/IIBD.11519.
- [39] V. G. Maltarollo, K. M. Honório, and A. B. F. da Silva, "Applications of artificial neural networks in chemical problems," in *Artificial Neural Networks - Architectures and Applications*, IntechOpen, 2013. doi: 10.5772/51275.

- [40] J. Masci, U. Meier, D. Ciresan, J. Schmidhuber, and G. Fricout, "Steel defect classification with Max-Pooling Convolutional Neural Networks," 2012. doi: 10.1109/IJCNN.2012.6252468.
- [41] M. Toğaçar, B. Ergen, and F. Özyurt, "Evrişimsel sinir ağı modellerinde özellik seçim yöntemlerini kullanarak çiçek görüntülerinin sınıflandırılması," *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 32, no. 1, pp. 47–56, Mar. 2020, doi: 10.35234/FUMBD.573630.
- [42] B. K. Karaca, S. Guney, B. Dengiz, and M. Agildere, "Comparative study for tuberculosis detection by using deep learning," in *2021 44th International Conference on Telecommunications and Signal Processing, TSP 2021*, Jul. 2021, pp. 88–91. doi: 10.1109/TSP52935.2021.9522634.
- [43] Ö. İnik and E. Ülker, "Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri," *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, vol. 6, no. 3, pp. 85–104, Dec. 2017, Accessed: Aug. 10, 2022. [Online]. Available: dergipark.org.tr/tr/pub/gbad/issue/31228/330663
- [44] G. Ser and C. T. Bati, "Derin sinir ağları ile en iyi modelin belirlenmesi: mantar verileri üzerine keras uygulaması," *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, vol. 29, no. 3, pp. 406–417, Sep. 2019, doi: 10.29133/YYUTBD.505086.
- [45] O. Russakovsky *et al.*, "ImageNet large scale visual recognition challenge," *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211–252, Dec. 2015, doi: 10.1007/S11263-015-0816-Y/FIGURES/16.
- [46] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Commun ACM*, vol. 60, no. 6, pp. 84–90, May 2017, doi: 10.1145/3065386.
- [47] "AlexNet convolutional neural network - MATLAB alexnet." mathworks.com/help/deeplearning/ref/alexnet.html?searchHighlight=alexnet&s_tid=srchtitle_alexnet_1 (accessed Jul. 26, 2022).

- [48] J. Deng, W. Dong, R. Socher, L.-J. Li, Kai Li, and Li Fei-Fei, “ImageNet: A large-scale hierarchical image database,” in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Mar. 2009, pp. 248–255. doi: 10.1109/CVPR.2009.5206848.
- [49] C. Szegedy *et al.*, “Going deeper with convolutions,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Oct. 2015, vol. 07-12-June-2015, pp. 1–9. doi: 10.1109/CVPR.2015.7298594.
- [50] “GoogLeNet convolutional neural network - MATLAB googlenet.” mathworks.com/help/deeplearning/ref/googlenet.html (accessed Jul. 26, 2022).
- [51] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: inverted residuals and linear bottlenecks,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Dec. 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.
- [52] “MobileNet-v2 convolutional neural network - MATLAB mobilenetv2.” mathworks.com/help/deeplearning/ref/mobilenetv2.html?searchHighlight=mobilenetv2&s_tid=srchtitle_mobilenetv2_1 (accessed Jul. 26, 2022).
- [53] X. Zhang, X. Zhou, M. Lin, and J. Sun, “ShuffleNet: an extremely efficient convolutional neural network for mobile devices,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Dec. 2018, pp. 6848–6856. doi: 10.1109/CVPR.2018.00716.
- [54] “Pretrained ShuffleNet convolutional neural network - MATLAB shufflenet.” mathworks.com/help/deeplearning/ref/shufflenet.html?searchHighlight=shufflenet&s_tid=srchtitle_shufflenet_1 (accessed Jul. 26, 2022).
- [55] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, “SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size,” Feb. 2016. doi: 10.48550/arxiv.1602.07360.

- [56] “SqueezeNet convolutional neural network - MATLAB squeezenet.” mathworks.com/help/deeplearning/ref/squeezenet.html (accessed Jul. 26, 2022).
- [57] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, Nov. 2017, vol. 2017-January, pp. 2261–2269. doi: 10.1109/CVPR.2017.243.
- [58] “DenseNet-201 convolutional neural network - MATLAB densenet201.” mathworks.com/help/deeplearning/ref/densenet201.html (accessed Jul. 26, 2022).
- [59] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Dec. 2016, vol. 2016-December, pp. 2818–2826. doi: 10.1109/CVPR.2016.308.
- [60] “Inception-v3 convolutional neural network - MATLAB inceptionv3.” mathworks.com/help/deeplearning/ref/inceptionv3.html (accessed Jul. 26, 2022).
- [61] K. Fırıldak and M. F. Talu, “Evrişimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi,” *Anatolian Journal of Computer Science - Anatolian Science*, vol. 4, no. 2, pp. 88–95, Dec. 2019, Accessed: Aug. 10, 2022. [Online]. Available: dergipark.org.tr/tr/pub/bbd/issue/49546/527863
- [62] S. Altun and M. F. Talu, “Derin sinir ağları için hiperparametre metodlarının ve kitlerinin incelenmesi,” *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, vol. 12, no. 2, pp. 187–199, Mar. 2021, doi: 10.24012/DUMF.767700.
- [63] E. Tanyildizi and F. Demirtas, “Hiper parametre optimizasyonu - Hyper parameter optimization,” Nov. 2019. doi: 10.1109/UBMYK48245.2019.8965609.
- [64] A. Gülcü and Z. Kuş, “A survey of hyper-parameter optimization methods in convolutional neural networks,” *J Sci, Part C*, vol. 7, no. 2, pp. 503–522, Jun. 2019, doi: 10.29109/gujsc.514483.

- [65] “Sistema avanzado de Inspección Industrial en 3D.” zerogravity3d.com/ (accessed Jul. 26, 2022).

