

BURSA TEKNİK ÜNİVERSİTESİ ❖ FEN BİLİMLERİ ENSTİTÜSÜ

**LAZER KESİM MAKİNELERİ İÇİN ÖZEL ŞEKLİ
BORU VE PROFİLLERİN GÖRÜNTÜ İŞLEME İLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Ahmet Muhammed YAHŞİ

Mekatronik Mühendisliği Anabilim Dalı

Ağustos 2021

BURSA TEKNİK ÜNİVERSİTESİ ❖ FEN BİLİMLERİ ENSTİTÜSÜ

**LAZER KESİM MAKİNELERİ İÇİN ÖZEL ŞEKLİ
BORU VE PROFİLLERİN GÖRÜNTÜ İŞLEME İLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

**Ahmet Muhammed YAHŞİ
(181241782006)**

Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Celalettin YÜCE

Ağustos 2021

BTÜ, Fen Bilimleri Enstitüsü'nün 181241782006 numaralı Yüksek Lisans Öğrencisi Ahmet Muhammed YAHŞI, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “LAZER KESİM MAKİNELERİ İÇİN ÖZEL ŞEKİLLİ BORU ve PROFİLLERİN GÖRÜNTÜ İŞLEME İLE SINIFLANDIRILMASI” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Celalettin YÜCE**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Fatih KARPAT**
Bursa Uludağ Üniversitesi

Doç. Dr. Gökhan GELEN
Bursa Teknik Üniversitesi

Teslim Tarihi : **01 Ağustos 2021**
Savunma Tarihi : **16 Ağustos 2021**



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Ahmet Muhammed YAHŞİ

İmzası :

X X X X



Sevgili Aileme,

ÖNSÖZ

Tez çalışmam süresince bana her türlü desteğini esirgemeyen Dr. Öğr. Üyesi Celalettin Yüce'ye en içten teşekkürlerimi sunarım. Çalışmamı gerçekleştirirken yanımda olan maddi, manevi desteklerini hissettiğim değerli aileme ve arkadaşlarıma minnettarım. Yeni nesil teknolojiler ile tanışmama vesile olan ve bilgi dağarcığımı genişleten Ermaksan firmasına, mühendislik alanında gelişimime liderlik eden saygıdeğer Bekir Koca'ya ve Ürün Geliştirme bölümü ekip arkadaşlarıma teşekkürlerimi sunarım.

Ağustos 2021

Ahmet Muhammed YAHŞİ

İÇİNDEKİLER

Sayfa

ÖNSÖZ	v
İÇİNDEKİLER	vi
KISALTMALAR	viii
SEMBOLLER	ix
ÇİZELGE LİSTESİ	x
ŞEKİL LİSTESİ	xi
ÖZET	xiii
SUMMARY	xiv
1. GİRİŞ	15
1.1 Tezin Amacı	17
2. LİTERATÜR ARAŞTIRMASI	18
2.1 Lazer Teknolojisi	18
2.2 Görüntü İşleme	19
2.2.1 Gri resim dönüşümü	20
2.2.2 Histogram eşitleme	20
2.2.3 Eşikleme	20
2.2.4 Genişletme ve aşındırma	21
2.2.5 Bulanıklaştırma	21
2.2.6 Keskinleştirme	22
2.2.7 Kenar bulma yöntemleri	22
2.2.7.1 Sobel algoritması	22
2.2.7.2 Canny kenar bulma algoritması	24
2.2.7.3 Hough dönüşümü	25
2.2.8 Köşe bulma yöntemleri	26
2.2.8.1 Moravec yöntemi	26
2.2.8.2 Harris yöntemi	27
2.2.9 Lazer teknolojisine yönelik yapılan çalışmalar	28
2.3 Öznitelik Çıkarım Yöntemleri	30
2.3.1 Yerel ikili örüntüler (LBP)	30
2.3.2 Gri seviye eş oluşum matrisi (GLCM)	31
2.3.3 Gabor filtresi ile öznitelik çıkarımı	32
2.3.4 SIFT algoritması	33
2.3.5 SURF algoritması	34
2.4 Sınıflandırma Algoritmaları	35
2.4.1 K-En yakın komşu algoritması	35
2.4.2 Naïve bayes algoritması	35
2.4.3 Karar ağaçları	36
2.4.4 Rassal orman algoritması	37
2.4.5 Destek vektör makineleri	38
2.4.6 Lineer diskriminant analizi	39

2.4.7 AdaBoost algoritması.....	39
2.4.8 Yapay sinir ağıları	39
2.4.8.1 Çok katmanlı ileri beslemeli yapay sinir ağıları.....	41
2.4.8.2 Geri yayılım algoritması	42
2.4.9 CNN-Evrişimli sinir ağıları.....	42
2.4.9.1 AlexNet	45
2.4.9.2 GoogleNet	45
2.4.9.3 ResNet.....	47
2.5 Benzer Sınıflandırma Çalışmaları	48
3. MATERYAL ve YÖNTEM.....	54
3.1 Test Düzenegi ve Kullanılan Donanımlar	54
3.1.1 Kamera	54
3.1.2 Aydınlatma.....	55
3.1.3 Üç boyutlu örnek şekillerin tasarımı ve imalatı	55
3.1.4 Derin öğrenme veri setinin oluşturulması.....	56
3.1.4.1 Kullanılan veri artırma yöntemleri.....	58
3.2 Veri Seti Görüntü Ön İşleme Algoritması.....	63
3.3 Derin Öğrenme Algoritmaları	66
3.4 Uygulama Yazılımının Geliştirilmesi	68
4. BULGULAR VE TARTIŞMA.....	69
5. SONUÇ VE ÖNERİLER.....	80
6. KAYNAKÇA	82
EKLER	87
ÖZGEÇMİŞ.....	90

KISALTMALAR

Nd:YAG	: Neodymium Doped Yttrium Aluminum Garnet
GLCM	: Gray Level Co-occurrence Matrix
KNN	: K Nearest Neighbors
NB	: Naive Bayes
LBP	: Local Binary pattern
SURF	: Speeded Up Robust Features
SIFT	: Scale Invariant Feature Transform
LDA	: Linear Discriminant Analysis
RESNET	: Deep Residual Network
CNN	: Cellular Neural Network
HSV	: Hue, Saturation, Value
RGB	: Red, Green, Blue
LASER	: Light Amplification by Stimulated Emission of Radiation
YSA	: Yapay Sinir Ağları
DVM	: Destek Vektör Makineleri
ReLu	: Rectified Linear Units
HOG	: Histogram of Oriented Gradients
KOÖ	: Köşe Olma Ölçüsü
FPS	: Frame Per Second
MS	: Milisaniye

SEMBOLLER

$^{\circ}$	: Derece
G_x	: Dikey operatör matrisi
G_y	: Yatay operatör matrisi
T	: Eşik değeri
θ	: Açık değeri
I	: Parlaklık değeri
G_p	: Komşu piksel
G_c	: Merkez piksel
R	: Yarıçap
d	: Uzaklık
λ	: Dalga boyu
σ	: Standart sapma
w	: Ağırlık değeri
μ	: Ortalama değeri vektörü
O_k	: Aktivasyon fonksiyon çıkışı

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Sobel Konvolüsyon Matrisi G_x , G_y	23
Çizelge 2.2 : G_x Dikey Operatör, G_y Yatay Operatör	24
Çizelge 3.1 : Şekil Ad Listesi.....	57
Çizelge 4.1 : Ham veri seti eğitimi test sonuçları.	70
Çizelge 4.2 : Ham veri seti 32 tam döngü sonuçları.	71
Çizelge 4.3 : Arttırılmış veri seti eğitimi test sonuçları.	71
Çizelge 4.4 : Arttırılmış veri seti 32 tam döngü eğitim test sonuçları.	71
Çizelge 4.5 : İşlenmiş resim veri seti eğitim ve test sonuçları.....	72
Çizelge 4.6 : İşlenmiş resim veri seti 32 tam döngü eğitim ve test sonuçları.	72
Çizelge 4.7 : Eğitim oranı düşürülmüş veri seti ile eğitim ve test sonuçları.....	73
Çizelge 4.8 : Eğitilmiş GoogleNet modeli gerçek zamanlı uygulama test sonuçları.	75
Çizelge 4.9 : İşlenmiş ve İşlenmemiş resimlerin oluşturduğu veri seti ile GoogleNet eğitimi sonuçları.....	77
Çizelge 4.10 : Yeni oluşturulan veri seti ile elde edilen GoogleNet test sonuçları....	77
Çizelge 4.11 : GoogleNet modelleri gerçek zamanlı test sonuçları	78
Çizelge 4.12 : İşlenmemiş veri seti ile eğitilen ResNet modeli gerçek zamanlı test sonuçları.....	79

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Özel boru-profil şekilleri (Small Tube Products, 2020).	16
Şekil 2.1 : (a) Orijinal (b) Otsu eşikleme uygulanmış hali (Perihanoğlu, 2015).	20
Şekil 2.2 : (a) Genişletme (b) Aşındırma (Atalı ve diğ, 2016).....	21
Şekil 2.3 : (a) Orijinal (b) Laplace maskesi uygulanmış (c) Birleştirilmiş son hali (Perihanoğlu, 2015).....	22
Şekil 2.4 : (a) Orjinal Görüntü (b) Eşiklenmiş hali (c) Sobel filtresi uygulanmış hali (Hatipoğlu, 2018).	23
Şekil 2.5 : (a) Orijinal (b) Canny uygulanmış resim (Canny Edge Detector, 2021)..	25
Şekil 2.6 : Dairesel Hough dönüşümü (Değirmenci ve diğ, 2019).	26
Şekil 2.7 : Moravec pencere kaydırma yöntemi (Aydoğdu, 2010).	26
Şekil 2.8 : Harris kenar ve köşe bulma yöntemi (Varol, 2014).	28
Şekil 2.9 : Örnek LBP sonucu (Toptaş, 2018).	30
Şekil 2.10 : GLCM yön ve komşuluk Bilgisi (Toptaş, 2018).	31
Şekil 2.11 : SIFT algoritması aşamaları.	33
Şekil 2.12 : SURF ile öznelilik noktalarının çıkarımı (Boyras ve diğ, 2019).	34
Şekil 2.13 : Düşüm ve karar yapıları (Er, 2016).	37
Şekil 2.14 : Rassal Orman algoritması çoklu karar ağacı gösterimi (Fidan, 2020). ..	38
Şekil 2.15 : DVM ile sınıflandırma (Destek vektör makinesi, 2021).	38
Şekil 2.16 : Yapay nöron modeli (Erkınay, 2012).	40
Şekil 2.17 : YSA aktivasyon fonksiyonları (a) Doğrusal (b) Rampa (c) Basamak (d) Sigmoid (Erkınay, 2012).	41
Şekil 2.18 : YSA aktivasyon fonksiyonları denklemleri.	41
Şekil 2.19 : İleri beslemeli YSA modeli (Erkınay, 2012).	42
Şekil 2.20 : Geri beslemeli YSA.	42
Şekil 2.21 : CNN yapısı (Ergin, 2021).	43
Şekil 2.22 : ReLu katmanı ile doğrultma işlemi (Kın, 2019).	44
Şekil 2.23 : ReLu katmanının görüntüye etkisi (İnik ve Ülker, 2017).	44
Şekil 2.24 : AlexNet katman yapısı (Doğan ve Türkoğlu, 2018).	45
Şekil 2.25 : GoogleNet mimarisi katmanları ve parametreleri (Szegedy ve diğ, 2019).	46
Şekil 2.26 : GoogleNet mimari şeması (Szegedy ve diğ, 2019).	46
Şekil 2.27 : Resnet artık blok (Aksoy ve diğ, 2021).	47
Şekil 2.28 : ResNet mimarisinin gösterimi.	47
Şekil 2.29 : Kabuk zincir kodunun üretilmesi (Tuna, 2019).	50
Şekil 2.30 : Şekil iskeleti ve kritik noktaların bulunması (Bölük, 2016).	50
Şekil 2.31 : Profil ölçüm sistemi (Şeker, 2018).	51
Şekil 2.32 : Geometrik şekiller (Gómez ve diğ, 2015).	52
Şekil 2.33 : Test edilen şekiller (Çapkan, 2018).	53
Şekil 2.34 : Kenar tespit algoritmalarının karşılaştırılması (Alper Baştürk, 2009) ...	53
Şekil 3.1 : Logitech C270 kamera (Logitech, 2021).	54

Şekil 3.2 : Üç boyutlu yazıcı ile üretilen parçalar.	56
Şekil 3.3 : Sınıf isimleri ile şekillerin gösterimi.	57
Şekil 3.4 : Orjinal resim.	58
Şekil 3.5 : Döndürülmüş resim.....	58
Şekil 3.6 : Yansıtılmış resim.	59
Şekil 3.7 : Kırpılarak döndürülmüş resim.	59
Şekil 3.8 : Parlaklığı bozulan resim.	60
Şekil 3.9 : Kontrastı bozulan resim.	60
Şekil 3.10 : Yapay gürültülü resim.	61
Şekil 3.11 : Bulanıklaştırılmış resim.....	61
Şekil 3.12 : Renk saflığı değiştirilmiş resim.	62
Şekil 3.13 : Renk tonu değiştirilmiş resim	62
Şekil 3.14 : Veri tabanından alınan resim.	63
Şekil 3.15 : Gri resme dönüştürülmüş resim.	63
Şekil 3.16 : Gaussian filtresi ile yumuşatılmış resim.....	64
Şekil 3.17 : İkili dönüşüm uygulanmış resim.	64
Şekil 3.18 : Morfolojik açma işlemi uygulanmış resim.	64
Şekil 3.19 : Morfolojik kapama işlemi uygulanmış resim.	65
Şekil 3.20 : Canny kenar algılama metodu uygulanmış resim.....	65
Şekil 3.21 : Derin ağ son üç katmanı.	66
Şekil 3.22 : Matlab Deep Network Designer görüntüsü	66
Şekil 3.23 : Deep Network Designer veri seçimi.	67
Şekil 3.24 : Deep Network Designer parametre sayfası.	67
Şekil 4.1 : Farklı ortam ışığında görüntü ön işleme uygulanmış resim.	74
Şekil 4.2 : Gerçek zamanlı test uygulaması sınıflandırma sonuçlarının görüntüleri.	76
Şekil A.1 : İşlenmiş Veri Seti GoogleNet Eğitim Sonuçları.....	87
Şekil B.1 : İşlenmiş Veri Seti ResNet Eğitim Sonuçları.....	88

LAZER KESİM MAKİNELERİ İÇİN ÖZEL ŞEKLİ BORU ve PROFİLLERİN GÖRÜNTÜ İŞLEME İLE SINIFLANDIRILMASI

ÖZET

Teknolojinin gelişmesiyle bilgisayar tabanlı sistemler sayesinde birçok problem çözümünde üretime hız kazandıran, yüksek performanslı yöntemler geliştirilmektedir. Gelişen endüstride seri üretim, kalite kontrol, otomasyon vb. konularda insan gücünün yetersiz ya da yavaş kaldığı durumlarda görüntü işleme yöntemleri hızlı, verimli ve optimize çözümler üretilmesine aracı olmaktadır. Gözle kontrolün mümkün olmadığı, sensörler ile algılama yeteneğinin yetersiz kalması durumlarında, insan gücü ile rutin olarak yapılan işlerde görüntü işleme yöntemlerinin kullanılması iş güvenliği, zaman ve maliyet açısından etkinliğin artırılmasında fayda sağlanmaktadır. Bilgisayar tabanlı sistemlerde düşük maliyet, yüksek kalite ve minimum iş gücü sağlanarak verim artırılabilir. Bu tez çalışmasında metal işleme sektöründe yaygın olarak kullanılan lazer boru-profil kesim makineleri için özel şekilli boru-profillerin sınıflandırılma işlemini gerçekleştirebilen bir uygulama çözümü sunulmuştur. Boru-profil kesim makinelerinde tam otomatik boru-profil yükleme sistemleri kullanılmaktadır. Bu sistemlerde yüklenen boru-profilin otomatik olarak algılanması geleneksel yöntemlerle mümkün değildir. Mevcut makinelerde bulunan otomatik yükleme sistemleri bu yetersizlikten dolayı aynı anda yalnızca tek tip boru-profilin yüklenmesine izin vermektedir. Bu durum zaman kaybına yol açmaktadır. Diğer yandan boru-profillerin otomatik algılanamaması mekanik olarak tasarımda birçok kompleks yapının kullanılmasını gerektirmektedir. Bu tez çalışmasında endüstri koşulları dikkate alınarak geliştirilen uygulama ile özel şekilli boru-profillerin sınıflandırma işlemi gerçekleştirilmektedir. Otuz farklı boru-profil şekli için veri tabanı oluşturularak, geniş yelpazede sınıflandırma işlemi yapılması amaçlanmıştır. Oluşturulan veri tabanlarındaki veriler görüntü işleme yöntemleriyle çoğaltılmıştır. Veri tabanındaki görüntülere geliştirilen görüntü ön işleme algoritması uygulanarak derin ağ eğitimlerinde başarı oranı artışı sağlanması amaçlanmıştır. Oluşturulan veri tabanları ile GoogleNet ve ResNet derin ağları kullanılarak farklı veri tabanı kombinasyonları için eğitim ve testler gerçekleştirilmiştir. Derin ağ eğitim sonuçları ve gerçek zamanlı uygulamada yapılan testlere göre daha kısa eğitim süresine sahip daha yüksek doğruluk sağlayan, işlenmiş ve işlenmemiş görüntülerin bulunduğu veri tabanı ile eğitilen GoogleNet modeli uygun bulunmuştur. Model doğruluk ortalaması %99,73 olarak ölçülmüş, sınıflandırma tahmin süresi ise ortalama 89 milisaniye olarak gözlemlenmiştir. Model gerçek zamanlı testlerde 30 sınıf için yapılan tahminlerin tümünde doğru sınıf tahmininde bulunmuştur. ResNet ile eğitilen modeller eğitim süresinin fazla olması, sınıflandırma tahminlerinde yüksek hata oranı ve yaklaşık 2 kat daha yavaş sınıflandırma süresi ile tercih edilmemiştir.

Anahtar kelimeler: Görüntü İşleme, Derin Öğrenme, Sınıflandırma, Lazer Kesim, Profil Kesim.

CLASSIFICATION OF SHAPED TUBES AND PROFILES FOR LASER CUTTING MACHINES

SUMMARY

New technologies provide high-performance and high accuracy on computer-based systems. Image processing and machine learning are developed to solve complex problems. Image processing methods are highly effective in cases where manpower is insufficient or slow in mass production, quality control, automation area. Image processing is capable to increase productivity and efficiency. In cases where visual control is not possible and the ability to detect with sensors is impossible, the use of image processing methods may serve low cost, well-optimized and safe processes. In this thesis, a solution that is classifying shaped tubes-profiles that are used in the metal fabricating industry is presented. Fully automatic pipe-profile loading systems are used in laser cutting machines. Automatic detection of the loaded tube and profile in these systems is not possible with traditional methods. Due to this inadequacy, the automatic loading systems in the existing machines allow only one type of tube-profile to be loaded at the same time. This problem leads to a waste of time. On the other hand, the inability to detect tubes-profiles automatically requires the use of many complex structures in mechanical design. In this thesis, the classification process of special-shaped tube-profiles is carried out with the application developed by taking into account the industrial conditions. It is aimed to perform a wide range of classification processes by creating a database for thirty different tube-profile shapes. The data in the created databases were reproduced via image processing methods. It is aimed to increase the accuracy rate in deep network training by applying the developed image preprocessing algorithm to the images in the database. Training and tests were carried out for different database combinations using the created databases and GoogleNet and ResNet deep networks. The GoogleNet model, which is trained with a database of processed and unprocessed images, is successful, providing higher accuracy with a shorter training time compared to the deep network training results and the tests made in the real-time application. The model accuracy average was measured as 99.73%, and the classification prediction time was observed as 89 milliseconds on average. The model predicted the correct class in all of the predictions made for 30 classes in real-time tests. Models trained with ResNet are not preferred due to the high training time, the high error rate in classification predictions, and approximately 2 times slower classification time.

Keywords: Image Processing, Deep Learning, Classification, Laser Cutting, Tube Cutting.

1. GİRİŞ

Teknolojinin gelişmesiyle birlikte bilgisayar tabanlı sistemler sayesinde birçok problem çözümünde üretime hız kazandıran, yüksek performanslı yöntemler geliştirilmektedir. Gelişen endüstride seri üretim, kalite kontrol, otomasyon vb. konularda insan gücünün yetersiz ya da yavaş kaldığı durumlarda görüntü işleme yöntemleri hızlı, verimli ve optimize çözümler üretilmesine aracı olmaktadır. Gözle kontrolün mümkün olmadığı, sensörler ile algılama yeteneğinin yetersiz kalması durumlarında, insan gücü ile rutin olarak yapılan işlerde görüntü işleme yöntemlerinin kullanılması iş güvenliği, zaman ve maliyet açısından etkinliğin artırılmasında fayda sağlanmaktadır. Bilgisayar tabanlı sistemlerde düşük maliyet, yüksek kalite ve minimum iş gücü sağlanarak verim artırılabilir.

Lazer kesim teknolojisinin gelişmesiyle birlikte metal işleme makinelerinde kullanılan üretim tekniklerinin hızı ve verimliliği artış göstermiştir. Üretimi kolaylaştıran lazer kesim tekniği, zamanla birçok alanda etkin olarak kullanılmaya başlanmıştır. Günlük hayatımızda ve endüstriyel alanlarda kullanılan boru ve profillerin işlenmeleri lazer kesim makinelerinde gerçekleştirebilmektedir. Yüksek ivme ve hızlarda çalışabilen bu makinelerdeki seri üretimin durdurulmadan devam edebilmesi için boru-profil yükleme işlemini gerçekleştiren otomasyon sistemleri geliştirilmektedir. Günümüzde tasarlanmış ve kullanılmakta olan otomatik yükleme sistemleri standart olarak yuvarlak boru, kare profil, dikdörtgen profil şekillerinin sisteme istiflenmesine ve tutucu aynalara yüklenmesine izin vermektedir. Ancak endüstride kullanılan boru-profil çeşitliliği daha fazladır. Kullanılmakta olan bazı boru-profil şekilleri Şekil 1.1’de gösterilmektedir.

SHAPE TUBE PROFILES				
				
Square	Rectangle	Square Solid	Rectangle Solid	Round Solid
				
Round/Square	D-Shape	Round/D-Shape	Hex	Hex/Round
				
Square/Round	Octagon	Round/Hex	Pentagon	Hex Solid
				
Trapezoid	Octagon/Round	Oval	Oval/Round	Flat Oval
				
Triangle	Fluted/Rectangle	Skull	Fluted/Oval	Hourglass
				
B-Shape	Mailbox	Fluted/Round	Round/Fluted	Duplex
				
Triplex	Doghouse	Brushholder	Keyhole	I-Shape
Others Available Upon Request				

Şekil 1.1 : Özel boru-profil şekilleri (Small Tube Products, 2020).

Gösterilmiş olan bazı özel boru-profillerin otomatik yükleme sistemleri ile kesim yapan tezgahların aynalarına yüklenebilmesi ve işleme yapılabilmesi için şekillerin operatörden bağımsız olarak sistem tarafından tanınması ve uygun açıda aynalara tutturulması gerekmektedir. Bu nedenle sistemin akıllı olması ve problem çözebilme yeteneğine sahip olması ihtiyacı doğmaktadır.

Bu tez çalışmasının konusu görüntü işleme ve sınıflandırma algoritmaları kullanılarak, boru-profillerin tanımlanması, sınıflandırılmasıdır. Özel şekilli profillerin herhangi bir sensör ile algılanıp şekil tespitin yapılabilmesi mümkün değildir. Bu probleme görüntü işleme ve sınıflandırma algoritmalarını kullanarak çözüm üretilebilir. Bu yöntemler sayesinde operatör yardımıyla işlenebilen birçok boru-profilin otomatik olarak tutucu aynalara yüklenip, işlenmesi imkânı sunulmuş olacaktır.

1.1 Tezin Amacı

Bu tez çalışmasının amacı, boru-profil kesim makinelerinin otomatik yükleme sistemlerinde karşılaşılan boru-profil tanıma problemine görüntü işleme ve derin öğrenme yöntemleri kullanılarak çözüm üretmektir. Geleneksel yöntemler ve donanımsal algılayıcılar ile özel şekilli boru-profillerin tanınması mümkün değildir. Boru-profil şeklinin algılanamaması birçok tasarımsal problemi de beraberinde getirmektedir. Mevcut boru-profil yükleme sistemleri tek seferde demet halinde tek tip boru-profil yükleyecek şekilde tasarlanmaktadır. Farklı bir tipte boru yüklemek için diğer tipteki boruların demetten çıkarılması gerekmektedir. Aynı zamanda profillerin kesici aynalara doğru açıda tutturulabilmesi için birçok mekanizma bulunmaktadır. Profil şekillerinin tanınması problemi çözüldüğü takdirde sistemdeki mekanik tasarım yükü de azalacaktır. Mevcut sistemlerde bu kısıtlardan dolayı standart kabul edilen boru-profiller yüklenebilmekte ancak özel şekilli profiller yüklenememektedir. Lazer kesim makineleri özel şekilli boru-profilleri işleme kabiliyetine sahiptir. Bu problemin çözümü sayesinde özel şekilli profillerin aynalara otomatik yüklenmeleri ve farklı tipte boru-profillerin aynı anda yüklenmesi mümkün olacaktır. Bu sayede hem makine kabiliyetleri artmış hem de üretim süreleri kısaltılmış olacaktır. Bu çalışmada görüntü işleme yöntemleri kullanılarak özel-şekilli profillerin sınıflandırılması problemine hızlı ve yüksek doğrulukla çalışan, endüstri uygulamalarına entegrasyonu kolay bir çözüm üretilmesi amaçlanmaktadır.

2. LİTERATÜR ARAŞTIRMASI

Görüntü işleme, Nesne tespiti ve Sınıflandırma konuları birçok alanda zor problemlerin çözümüne yönelik efektif olarak kullanılmakta ve sürekli olarak geliştirilmektedir. Bu bölümde literatürde yer alan, metal işleme sektöründe lazer teknolojisi kullanılan makineler için geliştirilen yöntemler, diğer endüstrilere yönelik geliştirilen nesne tespiti, sınıflandırma yöntemleri ve algoritmalarından bahsedilmiştir. Boru-Profil şekillerine benzerlik gösteren iki boyutlu geometrik şekillerin sınıflandırılması ve nispeten benzerlik gösteren metin sınıflandırma yöntemleri de sunulmuştur.

2.1 Lazer Teknolojisi

İngilizcesi “Laser” olan kısaltılmış kelime “Light Amplification by Stimulated Emission of Radiation” tamlamasının baş harflerinden türetilmiştir. Uyarılmış radyasyon emisyonu ile ışık amplifikasyonu olarak Türkçe ’ye çevrilmektedir. Lazerin ana çalışma prensibi 1917 yılında ilk olarak Albert Einstein tarafından öne sürülmüştür. Temel olarak atom ve molekül enerji düzeyleri arasındaki elektron geçişleri ile oluşan ışık fotonlarına dayanır. Yüksek enerji düzeyine çıkarılan atom ve moleküller minimum enerji ilkesine göre kendiliğinden düşük enerji düzeyine geçiş eğilimindedir (Lazer, 2021). Lazerler yüksek güçlü ve düşük güçlü olarak iki gruba ayrılmaktadır. Birçok alanda lazer teknolojisinden faydalanılmaktadır. Metal işleme tezgahlarında, kaynak uygulamalarında, eklemeli imalat makinelerinde, barkod okuyucularda, yazıcılarda, ölçüm sensörlerinde, iletişim araçlarında, sağlık alanında birçok cihazda etkin olarak lazer teknolojisi kullanılmaktadır.

Metal işleme makinelerinde Nd:YAG, Karbondioksit ve Fiber lazerler yaygın olarak kullanılmaktadır. Kalın malzemelerde karbondioksit lazer, hassas kesimlerde Nd:YAG lazerler yaygın olarak kullanılmakta iken Fiber lazerler yüksek güç, ışın kalitesi, verimlilik ve bakım kolaylığı gibi avantajları sayesinde sektörün en çok kullandığı lazer tipi olmuştur (Yüce, 2019).

Lazer teknolojisi sürekli geliştirilmeye ve optimizasyona ihtiyaç duyulan, yeni konuların keşfedilmesine olanak tanıyabilen bir özelliğe sahiptir. Sac işleme sektöründe lazer teknolojisi ile geometrik şekiller kolaylıkla işlenmekte olup hız, verim, yüksek hassasiyet beklentileri karşılanmaktadır. Makinelerdeki hız, verimlilik

artışı otomasyon sistemlerinin geliştirilmesine önayak olmuştur. İnsan gücüyle yapılan işler makinelerin duruş süresini arttırdığı için otomatik mekanizmalar ve akıllı sistemler geliştirilerek birçok konuda optimizasyon sağlanabilmektedir. Örnek bir çalışmada iki boyutlu lazer kesim makinesinde işlenecek materyallerin makineye yerleştirilmesi problemine yönelik bir otomasyon sistemi tasarımı gerçekleştirilmiştir. Operatör aracılığıyla sac makine yerleştirilmesinin zaman alması, ağır malzemelerde sac yükleme işleminin zorluğu ve sürekliliğin sağlanması için operatörün takibinin zorunlu olması vb. problemlere çözüm üretilmiştir. Sistemde bulunan raflara istiflenmiş olan materyaller, lazer makinesinden gelen sac talebine göre kesim tablalarına yüklenmektedir (Onderova, 2018). Bu sistemde yüklenen materyallerin doğrulanması, referans köşe noktasının tespiti, kalınlıklarının ölçümü, uzunluk ve genişliğinin doğrulanması gibi birçok gereksinim bulunmaktadır. Geliştirilen otomasyon sistemlerinde optimizasyon gereksinimleri de dikkate alındığında teknolojik yöntemlerin sistemlere entegrasyonu gerekmektedir. Lazer kesim makinelerinde sac, boru ve profil işlenebildiği düşünülürse birden fazla değişken durum söz konusudur. İşleme yapılacak malzeme tipi, boyutu, şekli vb. birçok özelliğin geliştirilecek olan otomasyon sistemi tarafından algılanması gerekmektedir. Boru kesim makinelerinde birçok üç boyutlu şeklin işlenmesi mümkündür. Makineler için geliştirilen otomatik yükleme sistemlerinde işlenecek şeklin tanınması, istenen açıda kesici aynalara tutturulması, kaynak noktasının tespiti gibi daha kompleks problemler bulunmaktadır. Örneğin; simetrik şekillerde malzemenin istenen açıya getirilmesi mekanik yapılarla sağlanabilirken, asimetrik şekillerde bunu sağlamak mümkün değildir. Bu gibi problemlerin çözümünde görüntü işleme yöntemleri ile çözüm üretmek, daha düşük maliyet, yüksek performans ve tasarım kolaylığı sağlayabilmektedir.

2.2 Görüntü İşleme

Görüntü işleme, dijital ortama aktarılan görüntülerin işlem görmesi, içerdiği bilginin analizi veya değiştirilmesi amacıyla kullanılmaktadır. Genellikle kameralar ile elde edilen görüntüler, bilgisayar ortamında sayısal olarak ifade edilerek, yazılım araçları ile işlenebilmektedir. Elde edilen görüntülerdeki bozukluklar, gürültüler matematiksel işlemler içeren filtreleme teknikleri ile temizlenmektedir. Görüntüdeki bilgilerin

anlamlandırılması adına kenar, köşe, daire algılayan sayısal algoritmalar mevcuttur. Bu bölümde literatürde bulunan görüntü işleme yöntemlerine değinilmiştir.

2.2.1 Gri resim dönüşümü


Renkli olarak elde edilen görüntülerin bazı algoritmalarla birlikte kullanılabilmesi için gri seviyeli görüntüye dönüştürülmesi gerekmektedir. Gri seviyeli görüntüler 8 bit formatında saklanır. Bu görüntülerde ışık yoğunluğu bilgisi yer alır. Pikselin 0 değeri siyah rengi, 255 değeri beyaz rengi ifade eder. Renkli görüntüdeki piksellerin RGB(Red,Green,Blue) değerlerinin toplamının 3'e bölünmesiyle gri seviyeli resim elde edilir (Çelik ve Tekin, 2020).

2.2.2 Histogram eşitleme

Histogram, görüntülerdeki piksellerin ağırlığını belirten grafiksel gösterimdir. Histogram eşitleme ile gri seviyelerdeki dağılımın homojen olması amaçlanır. Bu yöntem görüntüdeki detayların daha iyi algılanabilmesi için gerekli dönüşümü sağlamaktadır. Gri seviyedeki piksel sayısının, toplam piksel sayısına bölünmesiyle ifade edilir (Perihanoğlu, 2015).

2.2.3 Eşikleme


Eşikleme, görüntüdeki nesnelerin arka plandan ayrıştırılması için kullanılan bir yöntemdir. Belirlenen eşik değerine göre, görüntüdeki piksellerin siyah veya beyaz olarak değiştirilmesi işlemidir. Gri seviyeli bir resmin ikili görüntüye dönüşümünü sağlar. Şekil 2.1'de örnek eşikleme işleminin uygulaması gösterilmektedir.



Şekil 2.1 : (a) Orijinal (b) Otsu eşikleme uygulanmış hali (Perihanoğlu, 2015).

2.2.4 Geniřletme ve ařındırma

İkili resme d n řt r len g r nt lerde sıfır ve birlerden oluřan 3x3 bir matris resim  zerinde gezdirilerek iřlem yapılır. Geniřletme iřlemi ile sınır b lgelerde kalınlařtırma, ařındırma iřlemi ile inceltme yapılmaktadır. Eęer  nce geniřletme sonra ařındırma yapılırsa g r nt ye a ma iřlemi,  nce ařındırma sonra geniřletme iřlemi uygulandıęında ise kapama yapılmıř olur (G nen  ve  ner, 2021). Bu iřlemler kare, dikd rtgen ve daire řeklindeki yapısal operat rler ile yapılabilmekte ve uygulamaya g re keskin ya da yumuřak sınırlar elde etmek m mk nd r (Atalı ve dię, 2016). Bu y ntemler ile resimde bulunan g r lt n n temizlenmesi saęlanmaktadır. řekil 2.2’de g r ld ę   zere geniřletme iřlemi ile dıř kontur hatları kalınlařmıř, ařındırma iřlemi ile inceltilmiřtir.



řekil 2.2 : (a) Geniřletme (b) Ařındırma (Atalı ve dię, 2016).


2.2.5 Bulanıklařtırma

G r nt  iřlemede g r nt deki kenarların belirgin hale getirilmesi veya yumuřatılması i in filtreler kullanılmaktadır. Ortalama filtresi, Gauss d zleřtirme filtresi, Medyan filtresi yaygın olarak kullanılmaktadır. Ortalama filtresinde g r nt deki her bir pikselin deęeri komřu piksellerin deęerlerinin ortalaması ile deęiřtirilir. Bu iřlem 3x3

çekirdek matris aracılığıyla gerçekleştirilir. Gauss yönteminde de iki boyutlu bir çekirdek matris resim üzerindeki pikseller ile çarpılarak görüntü yumuşatılır. Ortalama filtresi ve Gauss yöntemi birbirine benzemektedir. Gauss yönteminde kullanılan çekirdek matrisin çan şekline benzer bir yapısı vardır. Medyan filtresinde ise komşu pikseller sıralanır ve sıranın ortasında bulunan değer piksele atanır (Çayıroğlu, 2021).

2.2.6 Keskinleştirme

Görüntüdeki bazı detayların belirgin hale getirilmesi için keskinleştirme filtreleri kullanılmaktadır. Laplace filtresi ile farklı yönlerde bulunan kenarlara aynı tepkinin verilmesi sayesinde sınırların belirlenmesi ve netleştirme amaçlanır. Bu yöntem dış hatlarının bulunması istenen nesnelere uygulanarak, nesne tanıma performansı yükseltilebilir (Perihanoğlu, 2015). Şekil 2.3'te Laplace filtresi ile keskinleştirme işlemi uygulaması gösterilmektedir.



Şekil 2.3 : (a) Orijinal (b) Laplace maskesi uygulanmış (c) Birleştirilmiş son hali (Perihanoğlu, 2015).

2.2.7 Kenar bulma yöntemleri

2.2.7.1 Sobel algoritması

İkili resme dönüştürülen görüntüler üzerinde sınır noktalarının tespiti için geliştirilmiş olan Sobel algoritması birçok uygulamada kullanılmaktadır. Konvolüsyon matrisleri ile resmi tarayarak keskin kenarları ortaya çıkarır. Algoritmada kullanılan iki

konvolüsyon matrisi aşağıdaki gibidir. Bu matrisler dikeyde ve yatayda bulunan kenarları tespit etmek için tasarlanmıştır (Shrivakshan ve Chandrasekar, 2012).


Çizelge 2.1 : Sobel Konvolüsyon Matrisi G_x , G_y

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ 1 & 0 & 1 \end{bmatrix}$$

$$G_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$$

$$G = \sqrt{G_x^2 + G_y^2} \quad (2.1)$$

G değeri hesaplanarak algortmada T değeri ile verilen eşik değeri ile karşılaştırılır. G değerinin T eşliğinden büyük olması x, y koordinatının kenar pikseli olduğunu ifade eder. Şekil 2.4'te örnek bir Sobel filtreleme uygulaması gösterilmektedir.



Şekil 2.4 : (a) Orjinal Görüntü (b) Eşiklenmiş hali (c) Sobel filtresi uygulanmış hali (Hatipoğlu, 2018).

2.2.7.2 Canny kenar bulma algoritması

1986 yılında John F. Canny tarafından geliştirilmiş olan algoritma, çok aşamalı bir kenar tespit yöntemidir. İlk aşamada belirlenen varyans değeri ile Gaussian çekirdeği kullanılarak gürültü temizleme işlemi gerçekleştirilir. Varyans değeri büyük seçildiğinde görüntüdeki gürültünün giderilmesi sağlanmakta ancak kenar belirginliği azalmaktadır. Varyans değeri seçimi bu anlamda önem arz etmektedir. Bu aşamanın ardından kısmi türev almak için dikey ve yatay yönde uygulanan G_x , G_y operatörleri ile görüntü filtrelenir. Gradyan hesabı yapıldıktan sonra kenar yönü ve büyüklüğünün açısı hesaplanır. Ardından kenarlar inceltme işlemine tabi tutulur. Son aşamada görüntü eşikleme işlemi yapılır.

Çizelge 2.2 : G_x Dikey Operatör, G_y Yatay Operatör

$$G_x = \begin{bmatrix} -1 & 1 \\ -1 & 1 \end{bmatrix}$$

$$G_y = \begin{bmatrix} -1 & 1 \\ -1 & 1 \end{bmatrix}$$

$$G = \sqrt{G_x^2 + G_y^2} \quad (2.2)$$

$$Açı(\theta) = \tan^{-1}\left(\frac{G_y}{G_x}\right) \quad (2.3)$$

Örnek bir Canny algoritmasının uygulaması Şekil 2.5'te gösterilmektedir.



(a)



(b)


Şekil 2.5 : (a) Orijinal (b) Canny uygulanmış resim (Canny Edge Detector, 2021)

2.2.7.3 Hough dönüşümü

Hough dönüşümü birçok nesne tespit uygulamasında kullanılmaktadır. Şekillerin varlığını, konumunu, açısını matematiksel olarak tanımlayabilen bir algoritma olduğundan dolayı görüntü işlemede tercih edilmektedir. İris tanıma, levha tespiti, plaka tespiti, daire bulma, doğru tespiti gibi uygulamalarda başarıyla kullanılmaktadır. Örnek bir çalışmada insansız hava araçları için dairesel nesne tespiti için Hough yönteminden faydalanılmıştır (Soyhan ve diğ, 2021). Şekillerin eksik görüntülenmesi gibi problemlili durumlarda Hough dönüşümü ile çözüm üretmek mümkündür. Hough dönüşümünde görüntü üzerindeki kenarlar belirlendikten sonra görüntü ikili resme dönüştürülür. Her kenar pikseli için geometrik şekillerin polar koordinattaki değerlerini içeren bir matris üzerinde oylama işlemi yapılır (Çelik ve Tekin, 2020).

Dairesel Hough dönüşümü uygulamasında Şekil 2.6'da görüleceği üzere görüntüdeki çemberlerin sınır noktalarındaki her piksel için, o pikseli merkez olarak kabul eden ve

aynı yarıçap değerine sahip yeni çemberler çizilir. Çizilen çemberlerin kesişim noktalarının en fazla olduğu yer ise tespit edilmesi beklenen çemberin merkezine denk gelmektedir. Yarıçap bilinmez ise bir aralık belirlenir ve bu aralıkta bulunan her değer için bu işlem merkez belirleme işlemi tamamlanana kadar tekrarlanır (Değirmenci ve diğ, 2019).




Şekil 2.6 : Dairesel Hough dönüşümü (Değirmenci ve diğ, 2019).

2.2.8 Köşe bulma yöntemleri

2.2.8.1 Moravec yöntemi

Moravec yöntemi bir pikselin köşe bilgisi içerip içermediğini algılayabilmek için küçük arama pencereleri kullanır. Merkez olarak kabul edilen pikselin belirlenen bir alandaki 45° aralıklarla 4 farklı yönde komşu piksellere kaydırılarak parlaklık farklılığı tespit edilir. Şekil 2.7’de arama pencerelerinin kaydırma yöntemi gösterilmektedir.



Şekil 2.7 : Moravec pencere kaydırma yöntemi (Aydoğdu, 2010).

$$F_{u,v}(x,y) = \sum_{m,n} w(m,n)[I(x+m,y+n) - I(x+m+u,y+n+v)]^2 \quad (2.4)$$

$$KOÖ = \min(F_{0,1}, F_{1,1}, F_{1,0}, F_{1,-1}) \quad (2.5)$$

I gri seviyeli görüntüdeki piksellerin parlaklıklarını ifade eder. $F_{u,v}(x,y)$ Merkez belirlenen alandaki piksellerin parlaklık değerleri ile pencerenin kaydırıldığı piksellerin parlaklık farkının toplamını ifade eder. Alanın dikey ve yatay noktaları denklemde m ve n harfleri ile gösterilmektedir. Yöntemde parlaklık farklarının çarpıldığı katsayıları belirleyen $w(m,n)$ fonksiyonu alan içinde 1 birim iken alan dışında 0 olmaktadır. Hesaplamaya göre her piksel için 4 farklı yönde bulunan parlaklık fark toplamlarının en küçüğü ilgili piksel için köşe olma ölçüsü ($KOÖ$) olarak kabul edilir. Belirlenen bir eşik değerini aşan pikseller köşe olarak tespit edilir (Aydoğdu, 2010).

2.2.8.2 Harris yöntemi

Harris köşe tespit yöntemi, Moravec algoritması temel alınarak geliştirilmiş olan bir yöntemdir. Genel olarak, komşu piksellerdeki birden fazla yönde bulunan kenarları ifade eden noktaların bulunmasıdır. Şekil 2.8’de gösterildiği üzere görüntü içinde bir algılama penceresi kaydırılarak yoğunluk değişimleri tespit edilir. Yoğunluk değerlerine göre köşe noktaları tanımlanır. Pencere kaydırma esnasında eğer bölge düz ise hiçbir yönde değişim gözlenmez. Eğer bölge kenar bilgisi içeriyorsa, kenar yönündeki yoğunluk değişimi gözlenmez. Ancak bölge köşe bilgisi içeriyorsa her yönde büyük yoğunluk farklılığı gözlemlenir. Harris yöntemi bölgenin kenar, köşe tespiti için matematiksel bir yaklaşım uygular. Görüntüde dönme etkisinden etkilenmeyen yöntem, ölçek değişimlerinden etkilenmektedir. Denklemde (u,v) kayması için yoğunluk değişimi denklem 2.6’daki formül ile hesaplanır (Varol, 2014).

$$E(u,v) = \sum_{x,y} w(x,y)[I(x+u+y+v) - I(x,y)]^2 \quad (2.6)$$

Denklemden $w(x, y)$ pencere fonksiyonunu, $I(x + u + y + v)$ kaydırılan yoğunluğu, $I(x, y)$ piksel yoğunluğunu ifade eder. Algoritma beş adımda gerçekleştirilir.

1. Her piksel için oto korelasyon matrisi hesaplanır.

$$M = \sum_{x,y} \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} \quad (2.7)$$


2. İki boyutlu Gauss fonksiyonu elde edilir.

$$Gauss = \exp(-u^2 + u^2) / 2\delta^2 \quad (2.8)$$

3. Her piksel için köşe cevap ölçüsü bulunur.

$$R = \{I_x^2 x I_y^2 - (I_x^2 I_y^2)\} - k\{I_x^2 + I_y^2\}^2 \quad (2.9)$$

4. Yerel maksimum nokta seçimi yapılır.
5. Eşik değeri ayarlanır ve köşe noktaları bulunur.



Şekil 2.8 : Harris kenar ve köşe bulma yöntemi (Varol, 2014).

2.2.9 Lazer teknolojisine yönelik yapılan çalışmalar

Sac işleme makinelerinde malzemenin yerleşim açısı, işlemenin doğru yapılabilmesi için önem arz etmektedir. Yapılan bir çalışmada lazer kesim makinelerinde işlenecek metal sacların köşesinin bulunması ve açısının hesaplanması için operatör tarafından

50 saniyede yapılan işlem görüntü işleme yöntemlerini kullanarak 5 saniye gibi bir sürede başarıyla gerçekleştirmiştir (Pınar, 2014). Uygulamada görüntülere morfolojik işlemler uygulanmış ve medyan filtresi ile gürültülerin temizlenmesi sağlanmıştır. Elde edilen görüntüler Hough Tekniği, Harris Tekniği ve Yönlendirilebilir Filtre Tekniği olmak üzere üç farklı algoritma test edilmiştir. En başarılı sonuç Yönlendirilebilir Filtre – Hough yöntemlerinin birlikte uygulanması ile elde edilmiştir.

Lazer kesim tezgahlarında sacların yerleştirildiği üçgen şekilli ızgaraların kesim esnasında lazer ışığına denk gelmesi nedeniyle ızgaraların erimesi ve kesim gazının yolunun tıkanmasından dolayı kesim kalitesinin bozulması problemleri yaşanmaktadır. Struckmeier ve arkadaşları bu problemlere çözüm getirecek görüntü işleme temelli bir akıllı bir sistem geliştirmişlerdir (Struckmeier ve diğ., 2020). Izgaraların konumları tespit edilerek, geliştirilen algoritmaya göre işlenecek parçaların en uygun açıya göre yerleşimi yapılmaktadır. Bu sayede lazer ışını ızgaralara denk gelmeyecek şekilde kesim işlemi gerçekleştirilebilmektedir. Üç boyutlu ölçüm yapılan çalışmada kamera ve lazer ölçüm sensörü ile veri elde edilmiştir. Köşe tespiti için Shi-Thomasi algoritması, kenar tespiti için Gauss algoritması ile çözüm üretilmiştir.

Lazer teknolojisi ile yapılan sac işlemlerinde yüzey pürüzlülüğü önemli bir konudur. Özellikle kalın malzemelerde kesim parametrelerine bağlı olarak yüzey pürüzlülüğü artmaktadır. Yapılan bir çalışmada işlenen metal sacların yüzey pürüzlülüğünün analizini görüntü işleme kullanılarak gerçekleştirmiştir (Dhanasekar ve diğ., 2008). Elde edilen görüntüler Gauss filtresi ile gürültülerden temizlenmiş, Butterworth filtresi ile keskinleştirilmiştir. Sonuç olarak yüzey pürüzlülüğü ölçümü için hassas bir çözüm geliştirilmiştir.

Lazer kesim makineleri yüksek ivmeli ve yüksek hızlı işleme yapabilme kabiliyetine sahip olduğundan dolayı, bazı durumlarda mekanik pozisyonlama hatalarından dolayı işlenen geometrilerin doğrulanması gerekebilir. Yapılan bir çalışmada işlenen hatalı ürünlerin tespiti için görüntü işleme ile daha hassas kontrollerin yapılabilirdiği bir sistem geliştirmiştir (Bayram, 2019). Uygulamada dairesel geometriler içeren işlenmiş parçaların görüntüleri bir kamera aracılığıyla alınmakta ve morfolojik aşındırma işlemleri uygulanmaktadır. Dairesel Hough dönüşümü ile dairelerin tespiti ve ölçümleri gerçekleştirilerek, sonuçlar karşılaştırılarak hata tespiti yapılmaktadır.

Lazer kesim makinelerine yönelik çalışmalarda görüleceği üzere, uygun maliyetli kameralı sistemlerle görüntü işleme yöntemleri kullanılarak birçok problemin çözümü mümkün olabilmektedir.


2.3 Öznitelik Çıkarım Yöntemleri

2.3.1 Yerel ikili örüntüler (LBP)

LBP, yerel komşuluk değerlerine göre işlem yapan bir öznitelik çıkarma yöntemidir. Görüntülerdeki benzerlikleri ön plana çıkarmak ve görüntüdeki dokuyu vurgulamak için kullanılmaktadır. Yöntem, Şekil 2.9’da gösterildiği gibi komşu piksel değerlerini, merkez piksel ile kıyaslayarak 8 bitlik ikili bir kodla değiştirerek işlem yapar. Yöntemde kullanılan denklem aşağıda gösterilmiştir. Denklemde g_p komşu pikselleri, g_c merkez pikseli temsil eder.

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (2.10)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.11)$$




Şekil 2.9 : Örnek LBP sonucu (Toptaş, 2018).

Yarıçap parametresi($R=1$) ve dairesel komşuluk değeri($P=8$) olan görüntünün LBP sonucu Şekil 10'da gösterilmektedir. Merkez piksel değeri (44) eşik değer olarak alınır ve komşu piksellerin değerleri ile çıkartılır. İşlem sonucu sıfırdan büyükse ilgili piksel için 1 değeri atanır. Bu şekilde sonuç matrisi elde edilir. Elde edilen bu matristeki sıfırdan bire (0-1), birden sıfıra (1-0) geçiş sayısı sıfır (0), bir (1), iki (2) olan örüntülerden seçilen LBP değerleri doku tanımlamada kullanılmaktadır (Toptaş, 2018).

2.3.2 Gri seviye eş oluşum matrisi (GLCM)

GLCM istatistiksel olasılıkları kullanarak doku analizi gerçekleştiren bir öznitelik çıkarma yöntemidir. Açık ve komşuluk bilgilerini kullanır. GLCM pikseller arasındaki uzaklık (d) ve açı (θ) olduğunda gri seviyesi (i)'den gri seviyesi (j)'ye geçme olasılığını gösterir. Kare bir matris olarak kullanılır. Görüntüde dönmeye karşın doku özelliklerinin değişmediğini tasdiklemek için 4 farklı yönde inceleme yapılır. Açık bilgisi(θ) için genel olarak 0° , 45° , 90° ve 135° , komşuluk bilgisi(d) için ise 1 veya 2 değerleri ile kullanılır (Demirhan ve Güler, 2010). GLCM aşağıdaki denklem ile oluşturulmaktadır. Bu denklemde piksel frekansı (i, j), komşuluk bilgisi(d), açı bilgisi (θ) şeklinde ifade edilmektedir (Toptaş, 2018). Şekil 2.10'da açı bilgisi (θ) örnek olarak gösterilmiştir.

$$P(i, j) = \frac{P(i, j, d, \theta)}{\sum_{i=1} \sum_{j=1} P(i, j, d, \theta)} \quad (2.12)$$



Şekil 2.10 : GLCM yön ve komşuluk Bilgisi (Toptaş, 2018).

GLCM matrisi oluşturulurken en büyük değere göre matris boyutu belirlenir. Seçilmiş olan aç ve komşuluk bilgisine göre pikseller arası geçiş tekrar sayıları tespit edilerek matris oluşturulur. GLCM ile doku özelliklerini içeren enerji, karışıklık, korelasyon, homojenlik ve entropi aşağıdaki denklemlerle bulunur (Toptaş, 2018; Demirhan ve Güler, 2010).

- **Enerji:** $P(i,j)$ elemanlarının karelerinin toplamını ifade eder. Gri değer dağılımı düzgün görüntülerde enerji yüksektir.

$$\sum_{i,j} P_{i,j}^2 \quad (2.13)$$

- **Karışıklık:** Yerel değişim miktarının belirlenmesi ile ifade edilir. Heterojenliği ifade eder.

$$\sum_{i,j} |i - j|^2 P_{ij} \quad (2.14)$$

- **Korelasyon:** Komşu piksellerin doğrusal bağımlılıklarını ölçmek için kullanılır.

$$\frac{\sum_{i,j} (ij) P_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.15)$$

- **Homojenlik:** Gri seviye dağılımının ne kadar homojen olduğunu hesaplamak için kullanılır.

$$\sum_{i,j} \frac{P_{ij}}{1 + |i - j|} \quad (2.16)$$

- **Entropi:** Görüntüdeki karmaşıklığı istatistiksel olarak ifade eder. Enerjiye ters orantılı olarak, matris elemanları küçük ise entropi yüksek olur.

$$-\sum_{i,j} P_{ij} \log P_{ij} \quad (2.17)$$

2.3.3 Gabor filtresi ile öznelik çıkarımı

Gabor filtresi görüntü doku analizi amacıyla iris tanıma, yüz tanıma, parmak izi tanıma, nesne tespiti uygulamalarında kullanılan bir yöntemdir. Gabor çekirdek

matrisi ile istenen açı ve dalga boyuna ayarlanarak istenilen özellikteki dokuların tespiti yapılmaktadır.

$$g(x, y, \lambda, \theta, \sigma) = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \cdot \cos(2\pi \frac{x'}{\lambda}) \quad (2.18)$$

$$x' = x \cdot \cos\theta + y \cdot \sin\theta \quad (2.19)$$

$$y' = -x \cdot \sin\theta + y \cdot \cos\theta \quad (2.20)$$

Verilen formülde x, y giriş sinyallerini, g gabor çekirdeğini, λ aranan desen dalga boyunu, θ desen açısını, σ ise dalga boyuna yakın ya da uzak değerler içeren desenleri tespit için kullanılan Gauss standart sapma değerini ifade eder (Balcılar ve Sönmez, 2008).

2.3.4 SIFT algoritması

SIFT algoritması görüntü kontrast değerinden, ortam ışıklandırmasından ve kamera görüş açısından daha az etkilenmektedir. Görüntünün farklı bölümleri arasında değişmeyen özellikleri tespit ederek nesne algılamaktadır. Şekil 2.11'de gösterildiği üzere algoritma dört aşama içermektedir.



Şekil 2.11 : SIFT algoritması aşamaları.

İlk aşamada uç değer noktalarının belirlenmesi için kademeli olarak filtreleme yapılır. Ölçek uzayı belirlenmesinde Gauss yöntemi kullanılır. Bu yöntem ile görüntünün farklı sigma değerleriyle filtrelenmiş halleri elde edilir. Uç noktaların daha belirgin hale getirilmesi sağlanır. Anahtar noktaların belirlenmesi için uç noktalardan zayıf olanları eşikleme yöntemiyle elenir. Bulunan anahtar noktaların ve yönelim açıları ve büyüklükleri hesaplanır. Son aşamada anahtar noktaların etrafındaki tanımlayıcılar tespit edilir (Karaköse ve diğ, 2017).

2.3.5 SURF algoritması

SURF (Speed Up Robust Feature) algoritması görüntülerde özniteliklerin çıkarımı için kullanılan dönme, ölçeklendirme ve öteleme gibi problemlere karşı dayanıklı sonuçlar üreten bir algoritmadır. SIFT algoritmasına benzer adımların uygulandığı yöntemde önemli iyileştirmeler yapılmıştır. En büyük farklılık hız konusunda SURF algoritmasının daha iyi performans göstermesidir. Hessian matrisi ile birleştirilmiş olan konvolüsyon işlemini temel alınmaktadır. Hessian matrisinin farklılaşan görüntü noktalarını ortaya çıkarma özelliğinden yararlanılarak önemli noktaların tespiti yapılır. Hessian matrisi aşağıda gösterilmektedir. L_{xx} , L_{xy} ve L_{yy} ikinci dereceden alınmış türevin sonucudur (Muzaffer, 2016).

$$H = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix} \quad (2.21)$$

$$L_{xx}(x, \sigma) = I(x) * \frac{d^2}{dx^2} g(\sigma) \quad (2.22)$$

Hessian determinantlarının hesaplanması ile özellik noktaları çıkartılır. Şekil 2.12’de avuç görüntüsünün anahtar noktalarının çıkarımı gösterilmektedir.



Şekil 2.12 : SURF ile öznitelik noktalarının çıkarımı (Boyras ve diğ, 2019).

2.4 Sınıflandırma Algoritmaları

Nesne tespiti için görüntü işleme ve sınıflandırma algoritmaları birlikte kullanılmaktadır. Görüntü işleme kısmında verilerin elde edilmesi ve nesnelerin özniteliklerinin çıkarılması sağlanır. Sınıflandırma aşamasında çıkarılan özniteliklere göre nesneler algoritmalar aracılığıyla sınıflandırılabilir. Sınıflandırma algoritmaları Olasılık, Geometrik, Kural, Benzetim tabanlı olarak gruplandırılmaktadır. En çok bilinen sınıflandırma algoritmaları En yakın komşu, Naive Bayes, Rassal Orman, Karar Ağaçları, Destek Vektör Makineleri, Yapay Sinir Ağları olarak sayılabilir. Bu konularda birçok çalışma yapılmış olup, farklı alanlardaki problemlere çözüm üretilmesi sağlanmıştır. Bu kısımda literatürde yer alan çalışmalar incelenerek, görüntü işleme yöntemleri ve sınıflandırma algoritmalarının kullanım yerleri ve performansları incelenmiştir.

2.4.1 K-En yakın komşu algoritması

Algoritma, veri setine yeni dahil edilen verinin diğer verilere olan uzaklığını hesaplar ve k katsayısı kadar yakın komşunun sınıflarını değerlendirir. Bu yöntemle yeni verinin en yakın olunan sınıfa ait olduğu tahmini yapılır. En yakın olan komşu sayılarının eşit olması durumunu engellemek için K katsayısı tek sayı olarak kullanılır. Veriler arası uzaklık hesabı için ise 3 farklı uzaklık ölçüm metodu kullanılmaktadır (Mete, 2019).

- Euclidean Uzaklık
- Manhattan Uzaklığı
- Minkowski Uzaklığı

2.4.2 Naïve bayes algoritması

Olasılık tabanlı bir sınıflandırma algoritması olan Naive Bayes, istenmeyen e-posta tespiti, metin sınıflandırma gibi uygulamalarda sıklıkla kullanılmaktadır. Naive Bayes algoritması sınıfların örnek verileri üzerinden dağılım fonksiyonunu çıkartır. Sınıfların ve özniteliklerin ortak olasılıklarının tahmini yapılır. Yeni gelen verinin öznitelik vektörüne bağlı olarak sınıfların olasılıkları bulunur ve sınıflandırma yapılır. Algoritmanın temel amacı sınıflandırmada yapılacak hatayı minimuma indirmektedir.

Bayes teorisinin uygulamalarındaki başarı oranı yapay sinir ağlarına yakın sonuçlar verebilmektedir. Yöntemin kolay uygulanabilir olması, hızlı ve az eğitim verisi ile yüksek doğrulukta çalışabilmesi tercih sebepleri arasındadır. Uygulamaya göre farklı tipte yaklaşımlar mevcuttur. Sürekli değerler içeren veriler için Gausssin NB, çok sınıflı verilerde Multinomial NB, ikili tahminlerde Bernoulli NB kullanılmaktadır (Yumak, 2011).

Bayes kuralına göre A örneğinin B sınıfında olma olasılığı aşağıdaki eşitlik ile hesaplanmaktadır. Bu eşitlikte $p(A)$ girdi olasılığını, $p(B)$ çıkış olasılığını, $p(B|A)$ A olayının gerçekleşmesi durumunda B olayının meydana gelme olasılığını, $p(A|B)$ B olayının gerçekleşmesi durumunda A olayının meydana gelme olasılığını ifade eder.

$$P(B|A) = \frac{p(A|B)p(B)}{p(A)} \quad (2.23)$$

Naive Bayes sınıflandırıcısı fonksiyonunun hesaplanması aşağıdaki denklemde verilmiştir.


$$B' = \operatorname{argmax}(P(B = y_n) \prod_{k=1}^l P(A = a_k | B = b_n)) \quad (2.24)$$

Bu yöntemde en yüksek olasılığa sahip duruma göre sınıflandırma yapılır. Denklemde hesaplanan B' hedef sınıfı, b_n ifadesi n. Çıkışı, A ise giriş verisini ifade eder (Açıl, 2019).

2.4.3 Karar ağaçları

Karar ağaçları algoritması, veri setine bir dizi karar kuralları uygulayarak küçük kümelere ayıran bir yapıdır. Verilerin özniteliklerine göre düğüm noktaları oluşturulur. Veri setindeki ortak kümelenmeler dikkate alınarak karar ağacının kısa tutulması ve gereksiz sorgular yapmaktan kaçınılmaya çalışılır. Karar ağaçları uygulanması kolay ve anlaşılır bir yapıdır. Ağaç yapısında kök, dal, düğüm ve yaprak yapıları vardır. Yaprak, tahmin değerini içerir. Yukarıdan aşağıya her adımda düğüm değer kontrolü yapılır. Düğümün hangi dalı takip edeceği belirlenir. Dallar yaprağa ulaştığında sınıflandırma gerçekleştirilmiş olur. Her düğümün bir entropi

değeri bulunur. Bu değere göre düğüm öncelikleri bilinir ve ağaç yapısı dizayn edilir (Er, 2016). Şekil 2.13'te örnek bir karar ağacı gösterilmektedir.



Şekil 2.13 : Düğüm ve karar yapıları (Er, 2016).


Kökte yer alacak olan öznitelik entropi formülü ile hesaplanarak bulunan bilgi kazancına göre belirlenir.

$$H(x) = - \sum_{i=1}^n P_i \log_2(P_i) \quad (2.25)$$

Entropi büyük olursa karar ağacında dallanma artar. Bilgi kazancı en yüksek olan öznitelik kök olarak belirlenir. Bu işlem örnekleri böylecek öznitelik kalmayıncaya dek her düğüm için tekrarlanır (Açıl, 2019).

2.4.4 Rassal orman algoritması


Rassal Orman algoritması başarı oranını arttırmak ve istikrarlı sonuçlar üretmek için birden fazla karar ağacı birlikte kullanıldığı yöntemdir. Rassal Orman sınıflandırıcısı torbalama temelli kolektif bir öğrenme yöntemidir. Tüm değişkenler arasından en iyi dalı bularak her düğümü dallara ayırmak yerine, rastgele seçilen değişkenler arasından en iyisini kullanarak düğümleri dallara ayırır (Fidan, 2020). Şekil 2.14'de örnek Rassal orman algoritma şeması gösterilmektedir.



     2.14 : Rassal Orman algoritması      karar a     g      (Fidan, 2020).

2.4.5 Destek vekt  r makineleri

D    k Vekt  r Makineleri(DVM), iki sınıf aras   bir karar sınırı bulmaya   alı  an vekt  r uzay tabanlı bir sınıflandırma y  ntemidir. DVM istatistiksel bir     renme teorisini baz alarak,   rnek e  itim verilerini bir uzayda haritalandırıp hiperd  zlem belirler. Ama   sınıfların bir hiperd  zlem ve uygun mar  in ile sınırlarının   izilmesidir.       2.15'te   rnek g        yer almaktadır. Do  rusal olmayan bir sınıflandırma yapılması gerekti  inde DVM ile       m   retmek m  mk  nd  r. Kernel adı verilen   ekirdek fonksiyonu kullanılarak hiperd  zlem elde edilir. Do  rusal, Radyal ve Polinom kernel en yaygın olarak kullanılan fonksiyonlardandır (Kaya, 2016).



      2.15 : DVM ile sınıflandırma (Destek vekt  r makinesi, 2021).

2.4.6 Lineer diskriminant analizi

Lineer Diskriminant Analiz (LDA), sınıflandırma, örüntü tanıma ve makine öğrenmesinde kullanılan istatistik tabanlı bir yöntemdir. Basit yapısına karşın kompleks sınıflandırma problemlerinde iyi sonuçlar üretebilmektedir. Doğrusal olarak sınıfların birbirinden ayrılmasını amaçlar. Sınıfları birbirinden en iyi şekilde ayıran değişkenlerin lineer bir kombinasyonunun aranması temeline dayanır. Sınıflar arası varyansın, sınıf içi varyansa oranını maksimuma çıkararak maksimum ayrılabilirliği sağlar. İki sınıfın ayrımında kullanılan denklemde model parametreleri(w), sapma değerleri (b) olarak ifade edilir. μ_1 , μ_2 sınıfların ortalama değer vektörlerini ifade eder (Manshouri, 2019).

$$z(x) = w^t x + b \quad (2.26)$$

$$w = \sum^{-1}(\mu_1 - \mu_2) \quad (2.27)$$

$$b = -w^t \mu \quad (2.28)$$


2.4.7 AdaBoost algoritması

Adaboost algoritması, her özniteliğe özel zayıf birer sınıflandırıcı oluşturan, bu zayıf sınıflandırıcıların birleştirilmesi sayesinde ortaya güçlü bir sınıflandırıcının çıkarılmasını amaçlayan bir algoritmadır. Temel bir öğrenici barındıran algoritma, her iterasyonda bir öğrenme algoritması çağırır. Sınıflandırıcı bu iterasyonlar sonucunda oluşturulur. Oluşturulan sınıflandırıcıya ağırlık katsayıları atanır. Sınıflandırma işlemi zayıf sınıflandırıcıların ağırlık katsayıları dikkate alınarak oylama yöntemi ile gerçekleştirilir. Hata oranı düşük olan sınıflandırıcının oylamadaki ağırlığı daha yüksektir. Adaboost algoritması zayıf sınıflandırıcı tarafından hatalı yapılan sınıflandırılan örnek verilere daha büyük ağırlık vererek, bir sonraki sınıflandırıcının başarısını arttırmayı amaçlamaktadır. Bu sayede zayıf sınıflandırıcılar aracılığıyla güçlü bir sınıflandırıcı tasarlanmış olmaktadır (Barstuğan, 2014).

2.4.8 Yapay sinir ağları

Yapay sinir ağları, insan beyninin yapısına benzetilerek geliştirilmiş olan matematiksel bir algoritmadır. Giriş katmanı, gizli katmanlar ve çıkış katmanı olarak üç bölümden oluşur. Giriş katmanında, veri girdileri alınır. Gizli katmanda birçok

nöron denilen birimler bulunur. Bu nöronlar, gelen veriyi işler ve çıkışına iletir. Nöronlardan gelen verilerin ağırlık katsayıları vardır. Bu katsayılar verinin önemini ve önceliğini belirtir. Şekil 2.16’da görüleceği üzere YSA yapısında nöron bağlantı ağırlıkları, toplayıcı fonksiyonu ve aktivasyon fonksiyonu bölümleri bulunur (Erkınay, 2012; Mete, 2019).



Şekil 2.16 : Yapay nöron modeli (Erkınay, 2012).


Giriş verisi, bağlantı ağırlıkları ile çarpılarak toplayıcıya gönderilir. Eşik değerin eklenmesi ile elde edilen toplam (I_k) aktivasyon fonksiyonundan geçirilerek çıkışa (O_k) iletilir.

$$I_k = \sum X_m W_k + \theta_k \quad (2.29)$$

$$O_k = \psi(I_k) \quad (2.30)$$

YSA, makine öğrenmesinde Denetimli ve Denetimsiz olarak iki gruba ayrılmaktadır. Denetimli öğrenmede, geliştirme aşamasında veriler üzerinde danışman tarafından belirlenen öznitelikler baz alınarak YSA modeli oluşturulur. Denetimsiz öğrenmede ise öznitelikler algoritmalar aracılığıyla danışmansız olarak gerçekleştirilir.

YSA ile nöron giriş değerlerinin genliğini sınırlandırmak için farklı aktivasyon fonksiyonları kullanılabilir. Şekil 2.17’de literatürde yaygın olarak yer alan aktivasyon fonksiyonları gösterilmektedir. Şekil 2.18’de aktivasyon fonksiyonlarının denklemleri ve aralıkları verilmektedir.




Şekil 2.17 : YSA aktivasyon fonksiyonları (a) Doğrusal (b) Rampa (c) Basamak (d) Sigmoid (Erkınay, 2012).

Aktivasyon Fonksiyonu	Denklem	Arahk
Doğrusal Fonksiyon	$f(x) = \begin{cases} x & \text{if } x < 0 \\ 0 & \text{if } x \geq 0 \end{cases}$	(0,1)
Basamak Fonksiyonu	$f(x) = x$	$(-\infty, \infty)$
Sigmoid Fonksiyonu	$f(x) = \frac{1}{1 + e^{-x}}$	(0,1)
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	(-1,1)
ReLU	$f(x) = \begin{cases} x & \text{if } x < 0 \\ 0 & \text{if } x \geq 0 \end{cases}$	$(0, \infty)$

Şekil 2.18 : YSA aktivasyon fonksiyonları denklemleri.

2.4.8.1 Çok katmanlı ileri beslemeli yapay sinir ağları


Çok katmanlı YSA modelinde bir katmanda bulunan nöronların çıkışları diğer katmanın girişleri olacak şekildedir. Giriş ve çıkış katmanı arasında gizli katmanlar bulunur. Bu katmanların sayısı probleme göre değişkenlik gösterebilmektedir. İleri beslemeli bir ağda her katmandaki çıkışlar bir önceki katmana ağırlıklar üzerinden girdi olarak beslenir. Veri akışı yalnızca ileri yöndedir. Bu sayede eğitim süresinin kısaltılması ve eğitilmiş model ile daha hızlı çalışma sağlanmaktadır (Erkınay, 2012; Mete, 2019). İleri beslemeli YSA model örneği Şekil 2.19’da gösterilmektedir.



Şekil 2.19 : İleri beslemeli YSA modeli (Erkinay, 2012).

2.4.8.2 Geri yayılım algoritması

Geri yayılım her bir nöronun hataya etkisinin ne olduğunu hesaplamak için kullanılır. Temel olarak üç aşamadan oluşmaktadır. İlk aşamada giriş eğitim verisinin ileri yayılımı, ikinci aşamada hedef değerlere göre hatanın hesaplanması ve son aşamada hatanın geriye doğru yayılarak ağırlıkların yeniden ayarlanması sağlanır. Eğitim sırasında bu işlem birçok kez tekrarlanır (Mete, 2019). Şekil 2.20’de geri yayılım algoritmasının örnek gösterimi yer almaktadır.




Şekil 2.20 : Geri beslemeli YSA.

2.4.9 CNN-Evrişimli sinir ağları

CNN- Evrişimli sinir ağları modeli insan görme yapısını taklit ederek gerçek dünyada daha başarılı sonuçlar sunan bir yapay sinir ağı yapısıdır. Görüntü matris olarak elde edilir, pikseller ise matrisin bir elemanı olarak kullanılır. CNN mimarisinde bu matrisler birçok defa işlenerek görüntü özellikleri ayrıştırılır. Bu özelliklere göre karar mekanizması oluşturularak, uygulama gereksinimlerine göre kararlar


çıkartılabilmektedir. Evrişimli sinir ağları derin öğrenmenin bir alt dalı olarak kabul edilmektedir. Görsel dijital bilginin analizinde yaygın olarak kullanılmaktadır. Resim sınıflandırma, tıbbi görüntü analizi, doğal dil işleme örnek kullanımlar olarak öne çıkmaktadır (Ergün ve diğ., 2021). Şekil 2.21’de CNN mimarisinin aşamaları gösterilmektedir.




Şekil 2.21 : CNN yapısı (Ergin, 2021).

CNN mimarisinde veri girişi olarak alınan resmin özelliklerinin saptanması işlemi Convolutional Layer ile gerçekleştirilir. Bu işlem için özellik çıkarıcı matris olarak bir konvolüsyon matrisi, resim bilgilerini içeren matris üzerinde gezdirilir. Matris boyutları 3x3, 5x5, 7x7, 9x9, 11x11 boyutlarında seçilebilmektedir. Bu konvolüsyon matrisi ağ algoritmasına göre veya ağ tasarımcısının kararına göre belirlenir. Bu sayede doğru özelliklerin çıkartılması sağlanmaya çalışılır.

Giriş verisinde bulunan negatif değerleri sıfır değerine eşitleme görevini uygulayan ReLu katmanı, Convolutional Layer katmanından sonra devreye girer. Bu katmanın kullanılmasındaki amaç derin ağı doğrusal olmayan bir yapıya sokarak, ağın daha hızlı öğrenmesini sağlamaktır. Şekil 2.22’de giriş verisi üzerinde yapılan doğrultma işleminin bir örneği yer almaktadır. Şekil 2.23’te ise yapılan doğrultma işleminin görüntü üzerinde oluşturduğu etki gösterilmektedir.



Şekil 2.22 : ReLu katmanı ile doğrultma işlemi (Kın, 2019).




Şekil 2.23 : ReLu katmanın görüntüye etkisi (İnik ve Ülker, 2017).

Havuzlama katmanında ise ReLu katmanından alınan girdileri bir sonraki konvolüsyon katmanı için genişlik ve yükseklik verisinin azaltılması işlemi gerçekleştirilir. Boyutlardaki azalma görüntüdeki bilgilerin kaybolmasına neden olur. Bu bilgi kaybı sayesinde sistemin daha doğru öğrenme gerçekleştirmesi ve ezberlemenin önüne geçilmesi sağlanmış olur.

Sınıflandırma katmanı, tam bağlantılı katman sonrasında devreye girer. Katmanın çıkış sayısı sınıflandırılacak nesne sayısına göre belirlenir. Genellikle softmax sınıflandırıcı tercih edilmektedir. En yüksek oranda doğru tahmin edilen sınıf ağ çıkışı olarak kabul edilir (İnik ve Ülker, 2017).

2.4.9.1 AlexNet

AlexNet, Alex Krizhevsky ve arkadaşları tarafından 2012 yılında düzenlenen ImageNet yarışmasında yarışmak için geliştirilmiş olan bir CNN ağıdır. Yüksek başarı oranı ile yarışmayı kazanarak dikkatleri üzerine çekmiştir. Bu başarı derin öğrenme yöntemlerinin sınıflandırmada geleneksel yöntemlerin yerine kullanılmasına önayak olmuştur. 25 katmandan oluşan bu CNN ağında 5 adet konvolüsyon katmanı, 3 adet maxpool katmanı, 2 adet dropout katmanı, 3 adet tam bağlı katman, 7 adet ReLu katmanı, 2 adet normalizasyon katmanı, softmax katmanı, giriş ve çıkış katmanları bulunur. Giriş katmanı $227 \times 227 \times 3$ boyutundaki resimleri kabul eder. Çıkış olarak tahmin değeri verilir (Doğan ve Türkoğlu, 2018). Şekil 2.24'te katmanların yerleşimi ve mimari yapısı gösterilmektedir.



Şekil 2.24 : AlexNet katman yapısı (Doğan ve Türkoğlu, 2018).


2.4.9.2 GoogleNet

GoogleNet, Google firmasında çalışan araştırmacılar tarafından geliştirilmiş olan derin evrişimli sinir ağı Inception Network'ün bir türü olan 22 katmanlı bir ağıdır. Günümüzde yüz algılama, tanıma vb. bilgisayarlı görme problemlerinin çözümünde kullanılmaktadır. GoogleNet, diğer ağlardan farklı olarak konvolüsyon ve havuzlama katmanlarını üst üste istiflemekten uzaklaşan bir mimaridir (Özel ve diğ, 2021). Katmanlarda yığılma durumu hesaplama ve bellek maliyeti gerektirmektedir. Ayrıca katmanların ardışık dizilimi ezberleme problemini de beraberinde getirilebilmektedir. GoogleNet bu problemlerin çözümü için paralel modüller şeklinde yapılar ile

kurgulanmış bir ağıdır (İnik ve Ülker, 2017). Giriş katmanında kabul edilen görüntü boyutları 224x224x3 boyutundadır. Konvolüsyon katmanında kullanılan matrisler 1x1, 3x3, 5x5 boyutlarındadır. Havuzlama matris boyutu 3x3 olarak seçilir (Doğan ve Türkoğlu, 2018). Şekil 2.25 ve Şekil 2.26 GoogleNet mimarisinin katmanlarını ve parametrelerini göstermektedir.

type	patch size/ stride	output size	depth	#1×1	#3×3 reduce	#3×3	#5×5 reduce	#5×5	pool proj	params	ops
convolution	7×7/2	112×112×64	1							2.7K	34M
max pool	3×3/2	56×56×64	0								
convolution	3×3/1	56×56×192	2		64	192				112K	360M
max pool	3×3/2	28×28×192	0								
inception (3a)		28×28×256	2	64	96	128	16	32	32	159K	128M
inception (3b)		28×28×480	2	128	128	192	32	96	64	380K	304M
max pool	3×3/2	14×14×480	0								
inception (4a)		14×14×512	2	192	96	208	16	48	64	364K	73M
inception (4b)		14×14×512	2	160	112	224	24	64	64	437K	88M
inception (4c)		14×14×512	2	128	128	256	24	64	64	463K	100M
inception (4d)		14×14×528	2	112	144	288	32	64	64	580K	119M
inception (4e)		14×14×832	2	256	160	320	32	128	128	840K	170M
max pool	3×3/2	7×7×832	0								
inception (5a)		7×7×832	2	256	160	320	32	128	128	1072K	54M
inception (5b)		7×7×1024	2	384	192	384	48	128	128	1388K	71M
avg pool	7×7/1	1×1×1024	0								
dropout (40%)		1×1×1024	0								
linear		1×1×1000	1							1000K	1M
softmax		1×1×1000	0								


Şekil 2.25 : GoogleNet mimarisi katmanları ve parametreleri (Szegedy ve diğ, 2019).



Şekil 2.26 : GoogleNet mimari şeması (Szegedy ve diğ, 2019).


2.4.9.3 ResNet

Kaiming He ve arkadaşları tarafından 2016 yılında geliştirilmiş olan ResNet mimarisi ILSVRC yarışmasında %3.57 hata oranı ile birincilik kazanmıştır. Bu mimaride katman sayısındaki derinlik arttırılarak daha yüksek başarı oranı yakalamak amaçlanmıştır. Ancak katman sayısının artışı bilgi kaybı sorunu oluşabilmektedir. ResNet mimarisinde bu sorunun önüne geçmek için ara katmanları birbirine bağlayan artık (Residual) bloklar eklenmektedir. Şekil 2.27’de artık blok yapısı gösterilmektedir. Bu bloklar sayesinde daha derin mimari tasarımının önü açılmış olmaktadır. ResNet birçok farklı katman sayısına sahip türevlere sahiptir. ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152 literatürde yer edinmiş, yaygın kullanımı olan türevlerdendir (Tokmak ve Kırac, 2021).



Şekil 2.27 : Resnet artık blok (Aksoy ve diğ, 2021).

Resnet mimarisi Şekil 2.28’de gösterildiği gibi artık bloklardan oluşmaktadır. Giriş katmanını 224x224x3 boyutlu resimleri kabul eder.



Şekil 2.28 : ResNet mimarisinin gösterimi.

2.5 Benzer Sınıflandırma Çalışmaları

Endüstride ve günlük hayatta gerçekleştirilen nesne tespit uygulamalarının birçoğunda şekillerin sınıflandırılması gerekmektedir. Bu ihtiyaç doğrultusunda birçok farklı alanda özel algoritmalar geliştirilmiştir. Geometrik şekillerin tespiti, trafik levhalarının tespiti, metin sınıflandırma, obje tanıma uygulamalarının birçok ortak özelliği bulunmaktadır. Büyük veri setleri ile çalışılması veya gerçek zamanlı tespit yapılması gerektiğinde, algoritmaların eğitilme ve çıktı verme sürelerinin düşürülebilmesi amacıyla daha özel metotlarla çalışmaları amaçlanabilmektedir. Benzerlik göstermesine rağmen geometrik şekil tespitinde kullanılan bir yöntem, trafik levha tespitinde istenen hızda veya doğrulukta sonuç veremeyebilir. Buradaki kritik nokta geliştirilen algorithmada kullanılan örneklerin doğru seçilmesi ve eğitim aşamasının amaca uygun şekilde gerçekleştirilmesidir. Bu bağlamda tez çalışmasının konusu olan özel şekilli profillerin sınıflandırılması ile benzer özellikler barındıran çalışmalar incelenmiş ve kullanılan algoritmalar sunulmuştur.

Otonom araç sistemlerinde görüntü işleme teknikleri kullanılarak, akıllı sistem tasarımları geliştirilmektedir. Trafikte otonom olarak çalışan bir aracın, etrafındaki birçok nesneyi algılayabilmesi ve araç kontrolünü kurallara uygun şekilde gerçekleştirebilmesi gerekir. Qinyang Li ve arkadaşlarının gerçekleştirmiş olduğu çalışmada otonom araç navigasyonu sistemi tasarlanmış, lazer tarayıcılar ve yerleşik kameralar kullanılarak görüntü işleme ile gerçek zamanlı şerit tespiti yapılmıştır (Li ve diğ, 2013). Sürüş esnasında alınan yol görüntülerine Top-Hat Dönüşümü, Perwitt Dikey Gradyan, Adaptif Eşikleme işlemleri uygulanmıştır. Bu sayede aracın yolunu takip etmesi sağlanmıştır. Yolun sürüşe uygun olup olmadığı ise sınıflandırma aşamasında Bayesian algoritması ile belirlenmiştir.

Üretim aşamalarında karşılaşılan bazı problemlerin sonucunda hatalı ürünler ortaya çıkmaktadır. Ürünlerdeki hataların tespiti genellikle operatörler aracılığıyla gerçekleştirilmektedir. Ancak bazı durumlarda insan gücü yetersiz kalmakta veya zaman kaybına neden olmaktadır. Görüntü işleme metotları ile ürün hata tespiti daha hızlı ve verimli şekilde yapılabilmektedir. Al-Salihi (2018) yaptığı çalışmada görüntü işleme metotları kullanılarak operatör olmaksızın yeni yapılmış bir kanalizasyon kanalının sağlamlık kontrolünü gerçekleştirebilen, çatlak tespit eden bir yöntem geliştirilmiştir. Alınan görüntüler Sobel, Prewitt, Robert's Cross, Canny, Median

filtreleri kullanılarak gürültü yok etme, yumuşatma, kenar artırma özelliklerini geliştirmek için filtre edilmiştir. Daha sonra ise görüntüden özellik çıkarabilmek için K-Ortalama kümeleme, kenar tespiti, renk uzayı tabanlı bölütleme, görüntü bölütleme olmak üzere 4 farklı algoritma kullanılmıştır.


Gıda ambalajı üretimi esnasında ürün ambalajlarının yüzeylerindeki hataların tespiti için Çağıl G. ve arkadaşlarının gerçekleştirdiği çalışmada, görüntü işleme teknikleri ile birden fazla hatanın tespiti sağlanmıştır (Çağıl ve diğ., 2019). Boya, ayarsızlık, bıçak çizgisi hatalarının tespiti için geliştirilen sistemde, maskeleme ile mavi renge göre düşük ve yüksek olarak iki dizi oluşturulmuş, görüntü HSV formatında değerlendirilmiştir. Kenar tespiti için görüntü gri tona dönüştürülmüş ve arka plandaki gürültülerin en aza indirgenmesi amaçlanmıştır. Elde edilen görüntüler, hatasız olan görüntülerle benzerlik karşılaştırmasına tabi tutularak hatalar tespit edilmiştir. Alınan sonuçlarda, operatörlerin tespit edemediği birçok hata sistem tarafından tespit edilebilmiştir.

Sofu (2014) yaptığı çalışmada otomatik elma sınıflandırma sistemi tasarlamış ve görüntü işleme yöntemlerini kullanarak büyüklük, renk, leke niteliklerine göre elmaların sınıflandırılmasını sağlamıştır. Sistem üç farklı hızda denemiş olup %69 ortalama verim ile çalışmaktadır.

Hasta teşhisinde sınıflandırma algoritmalarının kullanımı mümkündür. Hastalık için tanı koymak makineler için kompleks ve hata kaldırmaz bir durum olmasından dolayı, algoritmalar doktorlara yardımcı olacak şekilde tasarlanmaktadır. Erken teşhis ve gözden kaçması muhtemel durumların tespiti için bu yöntemlerden yararlanılmaktadır. Gökçe (2014) gerçekleştirdiği çalışmada retinal göz hastalığı olan makula dejenerasyonunun tespiti için görüntü işleme ile bir yöntem geliştirmiş ve iyi çekilmiş görüntülerle %85 doğrulukla sonuç elde etmiştir. Alınan gri seviyeli görüntüler üzerinde kan damarlarının çıkartılması için Kirsch doğrusal olmayan kenar bulma algoritması kullanılmıştır. Makulanın tespiti yapıldıktan sonra, çıkarılan 7 ayrı özneliğe göre yapay sinir ağları kullanılarak hastalıklı veya sağlıklı olarak sınıflandırma işlemi gerçekleştirilmiştir.


Sınır tabanlı şekil tanıma yöntemlerinden biri olan Kabuk Zincir Kodu, pikseller arası geçişler dikkate alınarak geliştirilen bir yöntemdir. Şekil 2.29'da gösterildiği üzere sınır noktalar ile şekillerin ağırlık merkezi arasındaki öklid uzaklıkları hesaplanarak

oluşturulan kodlar aracılığıyla şekiller tanımlanır. Kabuk zincir kodları Levenshtein mesafesi ile karşılaştırılır. Aynı şekillerde Levenshtein mesafesi sıfırdır. Aralarında benzerlik bulunmayan şekillerin mesafe değeri maksimum karakter uzunluğu kadardır. Şekillerin ölçeklerinin farklı olması durumunda başarı oranının düşmesinden dolayı zincir kodların histogramlarının alınarak sabit uzunlukta vektörlere dönüştürülmesi gerekmektedir (Tuna, 2019).



Şekil 2.29 : Kabuk zincir kodunun üretilmesi (Tuna, 2019).


Kabuk zincir kodu yöntemine benzer bir yaklaşım ise şekillerin iskeletlerinin çıkartılarak tanımlanmasıdır. İskelet noktalarının, kritik olan diğer noktalara olan uzaklığı hesap edilerek şekiller arasındaki benzerlik oranı bulunmaktadır. Yapılan çalışmada bu yöntemle ileri beslemeli yapay sinir ağları dahil edilerek şekil tespitinde başarı oranları yükseltilmiştir (Bölük, 2016). Şekil 2.30'da örnek bir şekil iskeleti çıkarımı gösterilmektedir.



Şekil 2.30 : Şekil iskeleti ve kritik noktaların bulunması (Bölük, 2016).

Boruların birçok farklı şekle sahip olmasından dolayı, endüstride otomatik tanımlayıcı sistemler geliştirmek için yalnızca makine görmesi yöntemleri kullanılması yetersiz olabilmektedir. Huang ve arkadaşları yaptıkları çalışma ile birçok kompleks yapıdaki boruların sınıflandırma işlemini %94 doğruluk oranıyla gerçekleştirmişlerdir (Huang ve diğ., 2020). Çalışmada görüntüler ön işlemede filtrelenerek gürültülerden arındırılmış, özellik çıkarımı için çoklu şekil tanımlayıcı yöntemler kullanılmıştır. Sınıflandırma aşamasında Rassal Orman algoritmasından yararlanılmıştır.

Şeker (2018) yaptığı çalışmada görüntü işleme ile sıcak haddehaneden çıkan profil kesitlerinin ölçülerinin çıkarılmasını sağlamıştır. Sıcak çekme profillerde operatörlerin ölçüm yapması imkansızdır. Bu problemin çözümü için Şekil 2.31’de gösterildiği gibi dört köşeden dört ayrı kamera ile görüntüler alınmakta ve profil üzerine kırmızı renkte lazer ışığı çizgi şeklinde gönderilmektedir. Kameralar aracılığıyla alınan görüntülerdeki lazer ışığının tespiti için morfolojik işlemler uygulanır. Hough dönüşümü ile görüntüdeki paralel ve dik doğrular tespit edilir. Birbirine paralel doğrular arasındaki uzaklık hesaplanarak profil ebatları tespit edilir.




Şekil 2.31 : Profil ölçüm sistemi (Şeker, 2018).

Balq (2019) çalışmasında görüntü işleme teknikleri ile çoktan seçmeli sınavlarda kullanılan optik işaret tanıma sistemi gerçekleştirmiştir. Her bir sınav kâğıdı için işlem süresi yaklaşık olarak 1 saniye olarak hesaplanmış olup %97,6-%100 oranında doğruluk elde edilmiştir.

Albera (2016) yaptığı çalışmada görüntü işleme ve sınıflandırma algoritmalarını kullanarak araç logo tanıma deneyleri yapılmıştır. Ön işlemede alınan resim gri seviyeli olarak filtre edilmektedir. İşlem hızını arttırmak için logo alanı kırpılarak 100x100 piksellik bir resim elde edilir. Mevcut veri tabanından alınan resimler eğitim


ve test için kullanılmıştır. SURF, LBP ve GLCM tanımlayıcı yöntemleri test edilmiş, sınıflandırıcı olarak k-NN algoritmasından yararlanmıştır. Çalışma sonuçlarına göre %99,5 doğruluk oranı ile SURF algoritması en başarılı olmuştur.

Gomez ve arkadaşları yaptıkları çalışmada görüntü işleme sistemi ile entegre edilmiş robotlu bir sistemde konveyör üzerinde hareket eden Şekil 2.32’de görülen basit geometrik şekillere sahip nesnelerin tespitini gerçekleştirmişlerdir. Nesnelerin pozisyonları ve merkez noktalarının hesaplanması için Hu Moments (Image Moment, 2021) teorisi kullanılmıştır. Nesne konumuna göre kinematik hesaplamalar ile robot manipülatör için yol belirlenmiş ve nesne toplama işlemi gerçekleştirilmiştir (Gómez ve diğ, 2015).



Şekil 2.32 : Geometrik şekiller (Gómez ve diğ, 2015).


Çapkan (2018) çalışmasında kameraya sahip robotlu bir sistem tasarımı gerçekleştirmiştir. Sistem görüntü işleme ve yapay sinir ağları kullanarak nesne tespiti yapmaktadır. Kenar tanıma için Prewitt, Roberts, Sobel, Canny gibi geleneksel kenar tanıma metotlarının yerine geliştirilen Şahin Göz kenar tanıma metodu kullanılmıştır. Alınan resimlere kenar tanıma metodu uygulandıktan sonra eğitilmiş olan ResNet ağı ile kare, üçgen ve daire nesnelerin sınıflandırma işlemi gerçekleştirilmiştir. Şekil 2.33’te test edilen şekiller gösterilmektedir.



Şekil 2.33 : Test edilen şekiller (Çapkan, 2018).

Zhang (2013) şekil genişlik modeli tabanlı trafik levha tespiti konusunda çalışmışlardır. Çalışmada üçgen, kare ve dairesel levhaların karmaşık arka plana sahip görüntülerde kontur analizi, kenar tespiti ve şablon eşleştirme yöntemleriyle tespiti gerçekleştirilmiştir.

Baştürk ve Günay (2009) yaptıkları çalışmada diferansiyel evrim algoritması ile optimize edilmiş bir hücresel sinir ağı CNN ile görüntülerde kenar tespit çalışması yapmışlardır. 6 farklı resim üzerinde CNN ve popüler kenar bulma metodları olan Sobel, Prewitt ve Canny karşılaştırmışlardır. Şekil 2.34'te gösterilen resimlerde en iyi performans CNN ile alınmıştır.



Şekil 2.34 : Kenar tespit algoritmalarının karşılaştırılması (Alper Baştürk, 2009)

3. MATERYAL ve YÖNTEM

Endüstride karşılaşılan bir problemin çözümü için gerçekleştirilen bu tez çalışmasında, kullanılan donanım ve yazılım araç gereçlerinin mevcut sistemlere entegre edilebilecek şekilde seçilmesi planlanmıştır. Bir kamera, aydınlatma bulunan test düzeneğiyle, üç boyutlu yazıcı ile imal edilen boru-profil örnek nesneleri kullanılmıştır. Bu bölümde kullanılan donanımlar ve geliştirilen yöntem detaylı olarak açıklanacaktır.

3.1 Test Düzeneği ve Kullanılan Donanımlar

3.1.1 Kamera

Gerçekleştirilecek uygulamada nesnelerin iki boyutlu görüntülerinin alınması gerekmektedir. Kamera seçiminde uygulamanın gereksinimlerine göre birçok parametreye dikkat etmek gerekmektedir. Kamera görüş açısı, lens odaklama özelliği, çözünürlük ve bir saniyede alınabilecek görüntü sayısı(fps) önemli parametrelerdir. Hassas ölçüm gerektiren uygulamalarda kullanılan kamera sistemlerinde kamera sensör tipi, sensör boyutu, lens çalışma mesafesi, büyütme oranı vb. parametreler hesaba katılmalıdır. Bu uygulamada şekil sınıflandırma yapılacağı için 5 mega piksel çözünürlüğe sahip, 60° görüş açısına sahip, Şekil 3.1’de görüntüsü verilen Logitech C270 model kamera kullanılmıştır.




Şekil 3.1 : Logitech C270 kamera (Logitech, 2021).

3.1.2 Aydınlatma

Kamera aracılığıyla görüntü alma işleminin başarılı bir şekilde yapılabilmesi için ortam aydınlatmasının sağlanması gerekmektedir. Görüntü işleme yöntemlerinin performanslarını doğrudan etkileyen ışık şiddeti, belirli bir seviyede sabit tutularak başarılı bir şekilde uygulama yapılabilir. Nesne tespitinde kenar algılama yöntemleri kullanıldığı için nesnenin dış konturlarının görüntüde belirgin şekilde gözlemlenebilmesi çok önemlidir. Uygulama esaslarına göre aydınlatma şekli de önem arz etmektedir. Yanlış aydınlatma seçimi sonucunda yansıma yapan ışık görüntüyü bozabilir ve sistemi yanıltabilir. Metal yüzeylerden görüntü alınan uygulamalarda yuvarlak aydınlatmalar, kırmızı renkli olarak kullanılmaktadır. Bazı kameralarda, lens tarafında aydınlatma yapılarak, doğrudan nesneye ışık tutmaktan kaçınılmaktadır. Bu yöntemler görüntü işlemede başarı oranını artırmaktadır. Endüstride kullanılan sistemlerin birçok farklı ortam şartına maruz kaldığı düşünülerek ürün seçimi yapılması gerekmektedir. Bu çalışmada yansıma problemini en aza indirmek ve ışık dağılımının homojenliğini sağlayabilmek adına halka tipi aydınlatma kullanılmıştır. Halka aydınlatma kamerayı çevreleyecek şekilde montelenmiş ve görüntü alanına doğru ışık yaymaktadır.

3.1.3 Üç boyutlu örnek şekillerin tasarımı ve imalatı

Uygulamada test edilmek üzere endüstride en çok kullanılan 30 farklı boru ve profil şekilleri seçilmiştir. Kare, dikdörtgen gibi çokça kullanılan profillerin de bulunduğu veri setini geniş tutmak ve endüstri ihtiyaçlarını karşılayabilecek bir yöntem sunmak adına birçok farklı özel şekilli parçalar seçilmiştir. Seçilen şekillerin üç boyutlu tasarımları Solidworks programı ile oluşturulmuştur. Şekil detaylarının gerçek profillere benzerliğini sağlamak adına üç boyutlu yazıcı ile hassas üretim gerçekleştirilmiş ve Şekil 3.2’de gösterilmekte olan örnek parçalar elde edilmiştir. Parça boyutları olarak 20mm en, 20mm boy, 5mm yükseklik değerleri seçilmiştir. Üretilen parçalar prototip uygulamada kullanılacağından dolayı küçük boyutlarda tasarlanmış ve üç boyutlu yazıcıda üretim sürelerinin kısaltılması amaçlanmıştır. Bu sayede üretim hassasiyetinden ödün vermeden kısa sürede parça üretimleri gerçekleştirilmiştir. Parçaların üretimi bir gün içerisinde tamamlanmıştır.



Şekil 3.2 : Üç boyutlu yazıcı ile üretilen parçalar.


3.1.4 Derin öğrenme veri setinin oluşturulması

Uygulamada test edilecek olan derin öğrenme algoritmalarının eğitiminde kullanılmak üzere veri oluşturulması gerekmektedir. Literatürde birçok konuda yapılan çalışmalara istinaden oluşturulmuş olan hazır veri setleri bulunmaktadır. Bu tez çalışmasının konusuna benzer olan harf, şekil, nesne tespiti yapılan çalışmalarda kullanılan veri setleri uygun görülmemiştir. Özel şekillerde yüksek doğrulukta sınıflandırma işlemini gerçekleştirmek için uygulamaya özel veri setinin oluşturulması gerekmektedir.

Veri seti oluşturulurken kamera aracılığıyla her bir parça için beş adet farklı açılarda resim alınmıştır. Alınan resimlerin ölçüleri 640x480 olduğu için derin öğrenme algoritmalarındaki ölçekleme işlemlerinde resim detaylarında bozulma yaşanabileceği için ölçüler 640x640 olacak şekilde resim boyutlandırması Padding (Doldurma) yöntemiyle ayarlanmıştır. Veri setinde her sınıf için bir klasör bulunmaktadır. Toplamda 150 adet resim elde edilmiştir. Derin öğrenme algoritmalarının çalışma performansları veri setinin çeşitliliği ile orantılı artış göstermektedir. Bu nedenle veri setinde bulunan resimlerin veri artırma teknikleri kullanılarak çoğaltılması yaygın kullanılan yöntemlerdir. Veri setindeki görüntüler bu yöntemle işlenerek yeni resimler olarak veri tabanına eklenmiş ve toplam 1500 adet resim içeren veri tabanı oluşturulmuştur. Veri tabanında oluşturulmuş olan klasörlere sınıf isimlerinin ataması yapılmıştır. Otuz farklı şekil için sınıf isimleri Çizelge 3.1’de verilmektedir. Şekil 3.3’te şekillerin isimleri ile görselleri gösterilmektedir. Veri tabanının evrensel olabilmesi ve yazılım araçlarında kullanılabilirlik açısından sınıf isimleri İngilizce tanımlanmıştır.

Çizelge 3.1 : Şekil Ad Listesi


Şekil Adları	
C_Type	Round
C_Type_2	RoundWithRectHole
Egg_Type	Round_C_Type
FullSquare	ShapedRect_Type_1
HalfRound	ShapedRect_Type_2
Hexagon	ShapedRound_Type_1
HourGlass	ShapedRound_Type_2
I_Type	Square
KeyHole	SquareWithHole
L_Type	T_Type
Obround	Trapezoid
Pentagon	Triangle
PostBox	U_Type
Rectangle	U_Type_2



Şekil 3.3 : Sınıf isimleri ile şekillerin gösterimi.


3.1.4.1 Kullanılan veri arttırma yöntemleri

Matlab yazılım geliştirme ortamında her bir sınıf için veri arttırma metotları birer birer uygulanmıştır. Bu işlemler için gerekli yazılım geliştirilmesi yapılarak, kolayca veri artırımı sağlanmıştır. Uygulanan görüntü işleme metotları ve resim çıktıları aşağıda listelenmektedir. Şekil 3.4'te veri tabanında bulunan işlenmemiş orijinal resim gösterilmektedir.




Şekil 3.4 : Orijinal resim.

1. **Döndürme:** Bu yöntem ile resimlere -90 , 90 dereceler arası rastgele döndürme işlemi uygulanmıştır. Şekil 3.5'te döndürme uygulanmış resim görülmektedir.




Şekil 3.5 : Döndürülmüş resim.

2. **Yansıtma:** Bu yöntem ile resimlerin yansımaları yeni birer resim olarak alınmıştır. Şekil 3.6’da yansıtılmış resim görülmektedir.




Şekil 3.6 : Yansıtılmış resim.

3. **Kırparak dikey döndürme:** Bu yöntem ile resimler -30, 30 dereceler arası kırpılarak dikeyde döndürme işlemine tabii tutulmuştur. Şekil 3.7’de kırpılmış ve döndürülmüş resim görülmektedir.




Şekil 3.7 : Kırpılarak döndürülmüş resim.

4. **Parlaklık bozulması:** Resimlerde parlaklık değeri 0 ile 1 arasındaki değerler ile ifade edilmektedir. Bu yöntem ile resmin parlaklığı -0,3 ile -0.1 değerleri arasında rastgele öteleme işlemine tabii tutularak yeni resimler elde edilmiştir. Şekil 3.8’de parlaklığı ile oynanmış resim görülmektedir.




Şekil 3.8 : Parlaklığı bozulan resim.

5. **Kontrast bozulması:** Resim karışıklığının çeşitlendirilebilmesi için 1.2 ve 1.4 değerleri arası rastgele kontrast ölçeklendirmesi ile yeni resim elde edilmiştir. Şekil 3.9’da kontrastı değiştirilmiş resim görülmektedir.



Şekil 3.9 : Kontrastı bozulan resim.

6. **Gürültü:** Resim üzerine rastgele renklerle yapay gürültüler oluşturulmuştur. Şekil 3.10’da gürültü eklenmiş resim görülmektedir.




Şekil 3.10 : Yapay gürültülü resim.

7. **Bulanıklaştırma:** Gaussian filtresi ile görüntü netliği rastgele değerler ile beslenerek farklı netliklerde görüntüler elde edilmiştir. Şekil 3.11’de bulanıklaştırılmış resim görülmektedir.



Şekil 3.11 : Bulanıklaştırılmış resim.

- 8. Renk saflık bozulması:** Renk saflık değeri 0 ile 1 arası değerler ile ifade edilir. Bu yöntem ile resmin saflığı -0.4 ile -0.1 değerleri arası rastgele öteleme işlemine tabii tutularak yeni resimler elde edilmiştir. Şekil 3.12’de renk saflığı değiştirilmiş resim görülmektedir.



Şekil 3.12 : Renk saflığı değiştirilmiş resim.

- 9. Renk tonu bozulması:** Renk tonu 0.05 ile 0.15 değerleri arası pozitif öteleme işlemine tabii tutulmuş yeni resimler elde edilmiştir. Şekil 3.13’te renk tonu bozulmuş resim görülmektedir.




Şekil 3.13 : Renk tonu değiştirilmiş resim

3.2 Veri Seti Görüntü Ön İşleme Algoritması


Oluşturulan veri tabanı görüntü işleme yapılmadan derin öğrenme veya öznitelik çıkarma yöntemleri kullanılabilmektedir. Ancak uygulamanın doğruluk ve performansını arttırmak için görüntü işleme yöntemleri kullanılmaktadır. Bu çalışmada her iki durum da göz önüne alınarak, uygulama sonuçları karşılaştırmasını gerçekleştirmek amaçlanmıştır. Bu doğrultuda hazırlanan veri tabanındaki tüm resimlere sınıflandırma öncesinde ön görüntü işleme yöntemleri uygulanmıştır. Uygulanan görüntü işleme adımları aşağıdaki gibidir.

1. Veri tabanından resmin alınması. Şekil 3.14'te alınan resim örneği verilmektedir.



Şekil 3.14 : Veri tabanından alınan resim.

2. Renkli resimden gri seviyeli resme dönüşüm. Şekil 3.15'te gri seviyeli resim verilmektedir.




Şekil 3.15 : Gri resme dönüştürülmüş resim.

3. Gaussian filtresi ile görüntü yumuşatma. Şekil 3.16’da yumuşatma uygulanmış resim gösterilmektedir.



Şekil 3.16 : Gaussian filtresi ile yumuşatılmış resim.

4. Gri seviyeli resimden ikili resme dönüşüm. Şekil 3.17’de ikili dönüşüm uygulanmış resim gösterilmektedir.



Şekil 3.17 : İkili dönüşüm uygulanmış resim.

5. Gürültü temizlemek için görüntü açma işlemi. Şekil 3.18’de açma işlemi uygulanmış resim gösterilmektedir.




Şekil 3.18 : Morfolojik açma işlemi uygulanmış resim.

6. Gürültü temizlemek için açılmış görüntü kapama işlemi. Şekil 3.19’da kapama işlemi uygulanmış resim gösterilmektedir.



Şekil 3.19 : Morfolojik kapama işlemi uygulanmış resim.

7. Canny metodu ile kenar algılama. Şekil 3.20’de kenar algılama metodu uygulanmış resim gösterilmektedir.




Şekil 3.20 : Canny kenar algılama metodu uygulanmış resim

Ön görüntü işleme algoritmasının uygulanması ile şekil hatlarının ortaya çıkarılması ve öznitelik detaylarının belirginleşmesi sağlanmış olmaktadır. Veri tabanında bulunan gürültülü resimlerdeki gerekli olan filtreleme de yapılmış olmaktadır. Bu sayede sınıflandırma işleminde başarı yüzdesinin artış göstermesi öngörülmektedir. Ancak bu yöntemle eğitilmiş sınıflandırıcıların uygulama anında da işlenmiş görüntüler üzerinde kullanılması gerekmektedir. Bunun nedeni şekil detaylarının birebir öğretilmiş olması ve gürültü detaylarının sınıflandırıcıya öğretilmemiş olmasıdır.


3.3 Derin Öğrenme Algoritmaları

Uygulamada derin öğrenme algoritmalarının eğitimi için Matlab programında bulunan Deep Network Designer aracı kullanılmıştır. Transfer öğrenme yöntemi olarak bilinen daha önceden tasarlanmış ağların son üç katmanının yenilenerek uygulamaya özel çalıştırılabilmesi yöntemi kullanılmıştır. Şekil 3.21’de son üç katmanın gösterimi yer almaktadır. Oluşturulan veri tabanı, arttırılmış veri tabanı, işlenmiş veri tabanı ayrı ayrı eğitime tabi tutulmuştur. Eğitilecek ve test edilecek resim sayıları farklı oranlarda denenerek algoritmalar eğitilmiştir.




Şekil 3.21 : Derin ağ son üç katmanı.

Matlab Deep Network Designer uygulaması 3 adımdan oluşmaktadır. İlk adımda Şekil 3.22’de görüldüğü üzere ağ dizaynı bulunur gerekiyorsa katmanlarda düzenlemeler yapılabilir.




Şekil 3.22 : Matlab Deep Network Designer görüntüsü

Derin ağ eğitiminde kullanılacak olan veri seti Data sekmesinde seçilmektedir. Şekil 3.23'teki gibi yazılımsal veri seti ya da veri klasörü ile veri aktarımı yapılabilir. Veri aktarımı sırasında istenirse verilerde rastgele veri artırma yöntemleri uygulanabilmektedir. Eğitim ve test veri sayısı da bu sekmede seçilmektedir.



Şekil 3.23 : Deep Network Designer veri seçimi.

Derin ağların eğitimi gerçekleştirmesi için geliştirme ortamına bağlı olarak seçilmesi gereken parametreler bulunmaktadır. Şekil 3.24'te Deep Network Designer parametre sayfası gösterilmektedir. Bu uygulamada derin ağların eğitimi için MaxEpoch döngü parametresi 5 ve 32 olarak iki farklı değer ile test edilmektedir. Bu parametre ataması ayarlar sekmesinde eğitim öncesi düzenlenmektedir.



Şekil 3.24 : Deep Network Designer parametre sayfası.

3.4 Uygulama Yazılımının Geliştirilmesi

Endüstride karşılaşılan bir problemin çözümü için gerçekleştirilen bu tez çalışmasında, kullanılan donanım ve yazılım araç gereçlerinin mevcut sistemlere entegre edilebilecek şekilde seçilmesi planlanmıştır. Kurulan test düzeneğiyle birlikte, üç boyutlu yazıcı ile elde edilen boru-profil örnek nesneleri kullanılmıştır.

Uygulama aşaması öncesinde oluşturulmuş veri tabanları ile derin öğrenme algoritmaları farklı kombinasyonlar ile eğitilerek ağ modelleri elde edilmiştir. Gerçek zamanlı alınan görüntüdeki şekillerin tespiti için eğitilmiş modeller yazılımda kullanılarak uygulama geliştirilmiştir. Eğitilmiş modeller yazılıma aktararak direkt kullanılabildikleri için zaman tasarrufu sağlanmaktadır.

Gerçek zamanlı olarak alınan görüntüler, taranarak sınıflandırma işlemi görüntüye uygulanır. Sınıflandırma sonucu görüntü üzerine yazdırılır. Yüksek doğruluk sağlayan eğitilmiş modellerin şekil sınıflandırmada başarıyla uygulanabilir olduğu gözlemlenmektedir. Geliştirilen uygulamanın çıktıları bulgular ve tartışma bölümünde paylaşılmaktadır.

4. BULGULAR VE TARTIŞMA

Çalışmada görüntü işleme, öznitelik çıkarma, sınıflandırma konularında literatürde başarı ile uygulanan yöntemler incelenmiş ve özel şekilli profillerin sınıflandırılması problemine hızlı, yüksek doğruluk sağlayan bir çözüm bulunmak istenmiştir. Üç boyutlu yazıcı ile imal edilmiş parçaların görüntülerinin alınması ile problem çözümü için benzer çalışmalarda uygulanan yüksek başarı oranına sahip olan yöntemlerden faydalanılmıştır. Bu aşamada amaçlanan hedef yöntemin uygulanabilirliği, çalışma performansı ve doğruluk oranıdır. Endüstride yapılan görüntü işleme uygulamalarında karşılaşılan doğru görüntü alma, ışıklandırma ve bilgisayarların işlem performansına dayalı yavaşlık problemlerine karşın en uygun yöntemin uygulanmasıdır. Bu ihtiyaçlar doğrultusunda görüntü üzerinde uygulanması gereken gürültü temizleme ve iyileştirme işlemleri için bir algoritma geliştirilmiştir. Doğru verinin alınması ile çalışmanın başarı oranını arttırmak mümkün olmaktadır.

Görüntülerde sınıflandırma işlemini gerçekleştirmek için literatürde birçok yöntem mevcuttur. Öznitelik çıkarma yöntemleri ile sınıflandırıcıların bir arada kullanıldığı uygulamalarda başarı yakalanabilmektedir. Boru-Profil sınıflandırma işlemi için HOG(Histogram of Oriented Gradients) yöntemi ile şekil öznitelikleri çıkarılarak çoklu DVM(Destek Vektör Makineleri) sınıflandırıcı ile %83 oranında doğrulukla uygulama gerçekleştirilmiştir. Bu yöntemde karşılaşılan problem özniteliklerin çıkarılmasının uzun süreler alması ve test aşamasında alınan görüntüdeki gürültülerden dolayı öznitelik çıkarımında doğruluğun düşmesidir. Bu yöntemle gerçek zamanlı resim sınıflandırma işlemi çok mümkün gözükmemektedir. Yöntem uygulandığı zaman uzun süreler alması ve işlemci gücüne ihtiyacının fazlalığı endüstri uygulamaları için uygun bulunmamıştır. Diğer öznitelik çıkarım yöntemlerinde de benzer problemler ile karşılaşıldığından dolayı sınıflandırma işlemi için literatürde geliştirilmiş olan ve uygulamaya özel eğitilebilen derin ağlar ile uygulama geliştirilmiştir. Çok sayıda resim üzerinde hızlı öğrenme ve sınıflandırma yapabildiği bilinen GoogleNet ve ResNet derin ağları yaşanan problemlerin çözümü için uygun görülerek test edilmiştir.

Derin ağlar ile resim sınıflandırmak için eğitim amacıyla kullanılacak resimlerin elde edilmesi veya türetilmesi gerekmektedir. Bu çalışmada elde edilen resimler görüntü işleme ile çoğaltılarak veri çeşitliliği artırılması amaçlanmıştır. Ham veri seti yalnızca el ile alınmış resimlerden oluşmaktadır. Arttırılmış veri seti görüntü işleme yöntemleri ile türetilmiş resimlerden oluşmaktadır. İşlenmiş resim veri setinde ise geliştirilen gürültü temizleme yöntemlerinin uygulandığı resimler bulunmaktadır. Elde edilen farklı veri kümeleri ile GoogleNet ve Resnet ağları eğitilmiş ve test edilmiştir. Hangi ağın daha doğru sonuçlar ürettiğini ve eğitimde ne kadar süreye ihtiyaç duyduğu gibi bilgilerin elde edilmesi için farklı veri tabanları ile farklı parametrelerde eğitimler gerçekleştirilmiştir.

Kamera aracılığıyla elde edilen 30 sınıf için 5 farklı resmin bulunduğu ham veri seti ile yapılan eğitimlerde veri setinin %70'i eğitim, %30'u test için kullanıldığında aşağıdaki sonuçlar elde edilmiştir. 5 Epoch (Tam Döngü) ile tamamlanan eğitim sonucunda ResNet daha uzun eğitim süresi ile %83 doğrulukla daha başarılı çıktı üretmiştir. Ancak görüntü sınıflandırmada daha yüksek doğruluk sağladığı bilinen bu yöntemlerin eğitildiği veri setindeki resim sayısının az olması doğruluk oranını düşürmüştür. Çizelge 4.1'de ham veri eğitim verisi ve test sonuçları yer almaktadır.

Çizelge 4.1 : Ham veri seti eğitimi test sonuçları.

Derin Ağ	Veri Tipi	Veritabanı	Eğitim Oranı	Doğrulama Oranı	Eğitim Süresi(Dakika)	Döngü Sayısı	Doğruluk
GoogleNet	İşlenmemiş Resim	Ham Veri Seti	%70	%30	2	5	0,5667
ResNet	İşlenmemiş Resim	Ham Veri Seti	%70	%30	5	5	0,8333

Bazı durumlarda veri seti oluşturmak mümkün olmayabilir ve az veri ile eğitim gerekebilir. Benzer durumlarda doğruluğu arttırmak için tam döngü sayısı arttırılarak daha uzun süre eğitim yapılarak derin ağın şekil öznitelikleri tanınması sağlanabilir. Bunun test edilmesi için aynı veri setinde eğitim döngüsü 32 Epoch olarak seçilerek sonuçlar elde edilmiştir. Bu değişimle eğitim süreleri artmış ve doğruluk değerlerinde bariz yükseliş gözlemlenmiştir. İki derin ağın da başarı oranı artmış ve ResNet %99,56 doğruluğa ulaşmıştır. Eğitim ve test sonuçları Çizelge 4.2'te gösterilmektedir.

Çizelge 4.2 : Ham veri seti 32 tam döngü sonuçları.

Derin Ağ	Veri Tipi	Veritabanı	Eğitim Oranı	Doğrulama Oranı	Eğitim Süresi(Dakika)	Döngü Sayısı	Doğruluk
GoogleNet	İşlenmemiş Resim	Ham Veri Seti	%70	%30	12	32	0,8
ResNet	İşlenmemiş Resim	Ham Veri Seti	%70	%30	27	32	0,9956

Ham veri setinde yüksek döngü sayısı ile doğruluk artmasına karşın veri çeşitliliğin az olması eğitilmiş modelin gerçek ortamda elde edilecek resimlerde aynı doğrulukla sonuç üretmesini sağlayamayabilir. Bunun nedeni öğretilmeyen detaylar ile karşılaşıldığında derin ağın bunu algılayamamasıdır. Bu hali ile eğitilmiş modelin kullanılması gerçek uygulamada problemler oluşturabilmektedir.

Derin ağın daha dayanıklı ve şekil detaylarını daha doğru öğrenmesi için işlenmemiş resimlerden oluşan arttırılmış veri tabanı ile eğitim ve test gerçekleştirilmiştir. Ham veri setinde her sınıf için 5 farklı resim bulunurken, arttırılmış veri tabanında her sınıf için 50 adet resim bulunmaktadır. Çizelge 4.3'te eğitim ve test sonuçları yer almaktadır.

Çizelge 4.3 : Arttırılmış veri seti eğitimi test sonuçları.

Derin Ağ	Veri Tipi	Veritabanı	Eğitim Oranı	Doğrulama Oranı	Eğitim Süresi(Dakika)	Döngü Sayısı	Doğruluk
GoogleNet	İşlenmemiş Resim	Arttırılmış	%70	%30	22	5	0,9444
ResNet	İşlenmemiş Resim	Arttırılmış	%70	%30	62	5	0,9911

Arttırılmış veri seti ile gerçekleştirilen eğitim ve test sonuçlarında yüksek doğrulukla sınıflandırılma işlemi gerçekleştirilmiştir. ResNet ile 62 dakika süren eğitim ile %99,11 doğruluk elde edilmiştir. GoogleNet ile 22 dakika eğitim süresi ile %94,44 doğruluk elde edilmiştir. Bu kıyaslamada GoogleNet ile daha hızlı eğitim gerçekleştirildiği tespit edilmiştir. Derin ağların doğruluk oranlarının değişimini ve süreleri kıyaslamak için 32 tam döngü ile Çizelge 4.4'teki sonuçlar elde edilmiştir.

Çizelge 4.4 : Arttırılmış veri seti 32 tam döngü eğitim test sonuçları.

Derin Ağ	Veri Tipi	Veritabanı	Eğitim Oranı	Doğrulama Oranı	Eğitim Süresi(Dakika)	Döngü Sayısı	Doğruluk
GoogleNet	İşlenmemiş Resim	Arttırılmış	%70	%30	123	32	0,9956
ResNet	İşlenmemiş Resim	Arttırılmış	%70	%30	293	32	0,9967

32 tam döngü ile eğitimde iki derin ağ için de doğruluk artışı gözlemlenmiştir. Eğitim sürelerine bakıldığında GoogleNet daha kısa sürede yüksek doğrulukla sonuç üretmiştir. Ancak 5 tam döngüdeki süre verilerine göre ResNet 3 kat daha yavaş eğitilirken 32 tam döngüde yaklaşık 2 kat daha yavaş olduğu gözlemlenmiştir. 32 tam döngüde de ResNet daha yüksek doğruluk sağlamıştır.

Derin ağ eğitiminde öznitelik detaylarının daha doğru öğretilmesi ve doğruluğu arttırmak amacıyla arttırılmış veri tabanı üzerinde görüntü işleme yöntemleri uygulanmıştır. Geliştirilen görüntü işleme algoritmasının uygulandığı işlenmiş resim veri seti eğitimde kullanılarak test sonuçları kıyaslanmıştır. 5 tam döngü için Çizelge 4.5'deki sonuçlar elde edilmiştir.

Çizelge 4.5 : İşlenmiş resim veri seti eğitim ve test sonuçları.

Derin Ağ	Veri Tipi	Veritabanı	Eğitim Oranı	Doğrulama Oranı	Eğitim Süresi(Dakika)	Döngü Sayısı	Doğruluk
GoogleNet	İşlenmiş Resim	Arttırılmış	%70	%30	23	5	0,9867
ResNet	İşlenmiş Resim	Arttırılmış	%70	%30	51	5	0,9956

Elde edilen sonuçlar işlenmemiş veri seti ile kıyaslandığı zaman iki derin ağın da doğruluk oranlarında iyileşme görülmektedir. GoogleNet eğitim süresi değişmezken, ResNet eğitim süresi işlenmemiş veri setine göre %21 daha kısa sürede, yüksek doğrulukla sonuç üretmiştir. GoogleNet doğruluk oranı %94,44'ten %98,67'ye çıkarken, ResNet doğruluk oranı %99,11'den %99,56'ya yükselmiştir. İşlenmiş veri seti 32 tam döngü ile eğitildiğinde Çizelge 4.6'deki sonuçlar elde edilmiştir.

Çizelge 4.6 : İşlenmiş resim veri seti 32 tam döngü eğitim ve test sonuçları.

Derin Ağ	Veri Tipi	Veritabanı	Eğitim Oranı	Doğrulama Oranı	Eğitim Süresi(Dakika)	Döngü Sayısı	Doğruluk
GoogleNet	İşlenmiş Resim	Arttırılmış	%70	%30	123	32	1
ResNet	İşlenmiş Resim	Arttırılmış	%70	%30	286	32	0,9978

İşlenmiş veri setinde 32 tam döngüde iki derin ağ işlenmemiş veri setindeki ile aynı eğitim süresinde daha yüksek doğruluk sağlamıştır. GoogleNet %100 doğruluk oranı ile testlerde ilk defa ResNet'ten daha yüksek doğruluk oranı göstermiştir. Bu sonuçlara bakıldığında uygulamada GoogleNet daha kısa sürede daha yüksek doğruluk sağlamıştır.

Eğitim oranının yüksek olduğu durumlarda yakın doğruluk sonuçlarının çıkması derin ağların kıyaslanmasını güçleştirebilmektedir. Derin ağın veri ezberleme problemi yaşadığı anlaşılmayabilmektedir. İki derin ağın da ürettiği çıktıların doğrulanması için eğitim ve test verilerinin oranları değiştirilerek yeniden eğitim ve test gerçekleştirilmiştir. İşlenmiş veri setinde %70 eğitim %30 test verisi ile başarılı sonuçlar üreten GoogleNet ve ResNet %70 test %30 eğitim verisi ile Çizelge 4.7’deki sonuçları üretmiştir.

Çizelge 4.7 : Eğitim oranı düşürülmüş veri seti ile eğitim ve test sonuçları.


Derin Ağ	Veri Tipi	Veritabanı	Eğitim Oranı	Doğrulama Oranı	Eğitim Süresi(Dakika)	Döngü Sayısı	Doğruluk
GoogleNet	İşlenmiş Resim	Arttırılmış	%30	%70	14	5	0,8505
ResNet	İşlenmiş Resim	Arttırılmış	%30	%70	31	5	0,9619
GoogleNet	İşlenmiş Resim	Arttırılmış	%30	%70	48	32	0,999
ResNet	İşlenmiş Resim	Arttırılmış	%30	%70	153	32	0,9752

Eğitim veri oranı düşürüldüğünden dolayı eğitim sürelerinde azalma gözlemlenmiştir. Sonuçlara bakıldığında eğitim verisindeki azalma ve test verisindeki çoğalmaya istinaden iki derin ağın doğruluk sonuçlarında düşüş gözlemlenmiştir. Tam döngü sayısı 5 iken ResNet daha yüksek doğruluk sağlamıştır. Tam döngü sayısı 32 iken GoogleNet daha yüksek doğruluk sağlamıştır. Eğitim veri oranlarına göre kıyas yapıldığında ise GoogleNet %70 eğitim verisi ile %100 doğruluk sağlarken, %30 eğitim verisi ile %99,9 doğruluk sağlamıştır. GoogleNet bu doğruluk oranlarına ResNet derin ağına göre daha kısa eğitim sürelerinde ulaşmıştır. Bir önceki sonuçlardaki başarı oranlarını yakalayan GoogleNet bu veri setinde ResNet’e göre daha hızlı ve daha yüksek doğrulukla başarılı olmuştur. ResNet ise görüldüğü üzere veri sayısı az olduğu durumlarda GoogleNet’e göre daha başarılı sonuçlar üretmiştir. İşlenmemiş veri setinde iki derin ağ da yüksek doğruluk sağlamakla beraber, eğitim süreleri dikkate alındığında ResNet daha uzun eğitim gerçekleştirmiştir.

En yüksek doğruluk oranını sağlayan işlenmiş veri seti ile eğitilmiş GoogleNet modeli gerçek zamanlı uygulamada test edilmiştir. Sınıflandırma süresi yaklaşık olarak 50 ile 100 milisaniye aralığındadır. Endüstriyel olarak uygulanabilirlik adına eğitim süresinin ResNet derin ağına göre daha kısa olması da problemin çözümünde GoogleNet ile sınıflandırmanın daha uygun olduğunu göstermektedir.

Gerçek zamanlı sınıflandırma uygulaması 8 çekirdekli Intel Core i7-3630QM 2.40Ghz işlemcili, 8GB Ram belleğe ve GeForce GT 630M ekran kartına sahip bilgisayar ile Matlab programında geliştirilen yazılım ile gerçekleştirilmiştir. Eğitilmiş modellerin herhangi bir işleme gerek kalmadan kullanılması mümkündür. Kamera aracılığıyla alınan görüntüler derin ağ modelinin giriş katmanının kabul ettiği şekilde hazırlanarak test edilmektedir. Test aşamasında örnek parçalar kameranın önüne konularak modelin sınıflandırma yapması beklenmektedir. Sınıflandırma işlemi sonrası yazılım çıktısı olarak model doğruluk verisi, tahmin edilen şekil sınıfı ve sınıflandırma süresi verileri elde edilmektedir.

Test uygulamasında kameradan alınan görüntüler üzerinde ön işleme yapılmamıştır. Bunun nedeni ışıklandırma ve ortam şartlarına göre resim ön işlemede parametre atamasının her koşulda aynı veriyi sağlayamamasıdır. Eğitim aşamasında uygulanan ön işleme algoritmasının farklı ortam ışığında uygulanması halinde Şekil 4.1’de yer alan görüntü elde edilmektedir. Bu durum istenmeyen ve eğitilmiş modellerin anlamlandıramayacağı veriler oluşturmaktadır.



Şekil 4.1 : Farklı ortam ışığında görüntü ön işleme uygulanmış resim.


Endüstriye yönelik hazırlanan bu çalışmanın ihtiyacı, alınan görüntüdeki farklılıklara ve bozukluklara karşı güçlü ve hızlı çalışan bir sistemdir. Öznitelik çıkarımının başarıyla yapıldığı uygulamalarda eğitilmiş derin ağ modelleri bu gereksinimi sağlamaktadır. İlk olarak yapılan test sonuçlarında işlenmiş resimlerle eğitilmiş GoogleNet, giriş görüntüsü işlenmemiş olmasına rağmen yüksek doğrulukla sınıflandırma işlemini gerçekleştirmiştir. Bu başarının sağlanabilmesi şekil özniteliklerinin doğru şekilde derin ağ modeline eğitilmiş olmasıdır.

Gerçek zamanlı testlerde işlenmiş veri seti ile eğitilen GoogleNet modeli test sonuçları Çizelge 4.8'deki gibidir. GoogleNet modeli %11,4 hata oranıyla 35 sınıflandırma işleminde 31 doğru 4 yanlış sınıf tahmininde bulunmuştur. Model doğruluk oranlarının ortalaması %87,67 olarak hesaplanmıştır. Sınıflandırma süresinin ortalaması ise 89 milisaniedir. Model özgün parçalarda yüksek doğruluk sağlarken, birbirine benzer özniteliklere sahip şekillerde daha düşük doğruluk ile sınıflandırma işlemini gerçekleştirmiştir. Bu test aşamasında dikkat çeken nokta Pentagon(Beşgen) şekilli profilin kare, dikdörtgen ve trapezoid şekillere benzetilerek yanlış sınıflandırma yapılmasıdır.


Çizelge 4.8 : Eğitilmiş GoogleNet modeli gerçek zamanlı uygulama test sonuçları

Test Edilen Şekil	Modelin Tahmini	Model Doğruluk Değeri	Tahmin Süresi(ms)	Sonuç
HalfRound	HalfRound	0.9997	90	Doğru
RoundC_Type	RoundC_Type	0.9996	86	Doğru
Triangle	Triangle	1	94	Doğru
W_Type	W_Type	0.999	94	Doğru
ShapedRect_Type_2	ShapedRect_Type_2	0.759	85	Doğru
L_Type	L_Type	0.9936	88	Doğru
T_Type	T_Type	0.9542	89	Doğru
C_Type_2	C_Type_2	0.9991	87	Doğru
Z_Type	Z_Type	0.9988	88	Doğru
KeyHole	KeyHole	0.9556	88	Doğru
Trapezoid	Trapezoid	0.7134	93	Doğru
Pentagon	Trapezoid	0.8582	83	Yanlış
Pentagon	Rectangle	0.4543	89	Yanlış
Pentagon	Square	0.8217	89	Yanlış
Pentagon	Pentagon	0.6388	90	Doğru
Round	Round	1	94	Doğru
ShapedRect_Type_1	ShapedRect_Type_1	0.9896	90	Doğru
ShapedRound_Type_2	ShapedRound_Type_2	0.6685	92	Doğru
Egg_Type	Egg_Type	0.9425	87	Doğru
PostBox	PostBox	0.8488	88	Doğru
ShapedRound_Type_1	ShapedRound_Type_1	0.985	89	Doğru
Hexagon	Hexagon	0.9986	86	Doğru
FullSquare	FullSquare	1	89	Doğru
RoundWithRectHole	RoundWithRectHole	0.9787	91	Doğru
I_Type	I_Type	0.355	91	Doğru
Triangle	Triangle	0.9962	92	Doğru
Rectangle	Rectangle	0.9999	91	Doğru
Obround	Obround	0.9926	87	Doğru
U_Type_2	U_Type_2	0.9957	93	Doğru
HourGlass	HourGlass	0.9991	87	Doğru
SquareWithHole	SquareWithHole	0.9432	95	Doğru
C_Type	ShapedRect_Type_2	0.42	84	Yanlış
C_Type	C_Type	0.8048	90	Doğru
Square	Square	0.9978	88	Doğru
U_Type	U_Type	0.6268	88	Doğru


Uygulamada gerekleřen sınıflandırma iřlemi őrnekleri řekil 4.2’de gősterilmektedir.




(a)



(b)



(c)



(d)

řekil 4.2 : Gerek zamanlı test uygulaması sınıflandırma sonularının gőrőntőleri.

izelge 4.8’de elde edilen sonulara gőre modelin eėitim testleri %100 doėruluk saėlasa bile birbirine benzer řekillerde ayırıcı őzniteliklerin yeterli olmadığı gőrőlmektedir. Modelin bu probleme özőm őretememesinin nedeni őzniteliklerin ezberlenmesi olabilmektedir. Bu durum gőz őnőne alınarak eldeki veri tabanının geniřletilmesi iin iřlenmiř resimler ile iřlenmemiř resimler bir arada toplanarak 3000 resimlik veri tabanı oluřturulmuřtur. Bařarısı bilinen GoogleNet aėı yeni veri seti ile eėitime tutulmuř ve eėitim sonrası ıktılarda aynı doėruluk yőzdesi gőzlemlenmiřtir. Veri artıřından dolayı eėitim sőresi 2 kat artmıřtır. Eėitim sonuları izelge 4.9’da gősterilmektedir.

Çizelge 4.9 : İşlenmiş ve İşlenmemiş resimlerin oluşturduğu veri seti ile GoogleNet eğitimi sonuçları

Derin Ağ	Veri Tipi	Veritabanı	Eğitim Oranı	Doğrulama Oranı	Eğitim Süresi(Dakika)	Döngü Sayısı	Doğruluk
GoogleNet	İşlenmiş Resim	Arttırılmış	%70	%30	123	32	1
GoogleNet	İşlenmiş ve İşlenmemiş Resim	Arttırılmış	%70	%30	265	32	1

Eğitilen yeni GoogleNet modeli gerçek zamanlı uygulamada aynı yöntemle test edilmiştir. Çizelge 4.10’da elde edilen test sonuçları paylaşılmıştır.

Çizelge 4.10 : Yeni oluşturulan veri seti ile elde edilen GoogleNet test sonuçları

Test Edilen Şekil	Modelin Tahmini	Model Doğruluk Değeri	Tahmin Süresi(ms)	Sonuç
Hexagon	Hexagon	1	94	Doğru
PostBox	PostBox	0.9988	67.3	Doğru
Square	Square	1	96.9	Doğru
ShapedRound_Type_2	ShapedRound_Type_2	1	90.5	Doğru
C_Type	C_Type	0.997	88.3	Doğru
SquareWithHole	SquareWithHole	1	86	Doğru
U_Type_2	U_Type_2	0.9902	83.9	Doğru
KeyHole	KeyHole	1	85.1	Doğru
ShapedRound_Type_1	ShapedRound_Type_1	1	94.2	Doğru
RoundC_Type	RoundC_Type	1	82.6	Doğru
Trapezoid	Trapezoid	0.9925	94.4	Doğru
Obround	Obround	1	91.842	Doğru
I_Type	I_Type	0.9926	82.9	Doğru
Pentagon	Pentagon	1	91.2	Doğru
Egg_Type	Egg_Type	1	86.8	Doğru
HalfRound	HalfRound	1	88.025	Doğru
ShapedRect_Type_1	ShapedRect_Type_1	1	86	Doğru
HourGlass	HourGlass	1	101.5	Doğru
Rectangle	Rectangle	1	93.2	Doğru
Z_Type	Z_Type	1	86.5	Doğru
C_Type_2	C_Type_2	1	93	Doğru
L_Type	L_Type	1	87.9	Doğru
Triangle	Triangle	1	89.4	Doğru
W_Type	W_Type	1	95.5	Doğru
U_Type	U_Type	0.9641	89.7	Doğru
Round	Round	1	87.269	Doğru
ShapedRect_Type_2	ShapedRect_Type_2	1	89	Doğru
FullSquare	FullSquare	0.9997	88	Doğru
RoundWithRectHole	RoundWithRectHole	1	94.1	Doğru
T_Type	T_Type	0.997	93.7	Doğru

Test sonuçları incelendiğinde model istenilen ihtiyacı tam anlamıyla karşılayarak %100 doğruluk sağlamıştır. 30 test için de doğru sonuç üreten GoogleNet modeli, bir önceki teste göre model doğruluk değerlerinde de gözle görülür iyileştirme sağlamıştır. Eğitim süresi 2 kat daha fazla sürmesine karşın modelin gerçek zamanlı testteki sınıflandırma süresi ortalama 89 milisaniye olarak aynı çıkmıştır. Model doğruluk

oranı ortalaması ise %99,773 olarak hesaplanmıştır. En düşük model doğruluğu %96,41 olarak U_Type sınıflandırmasında elde edilmiştir. Bir önceki testte karşılaşılan Pentagon, Square, Trapezoid benzerliğinden dolayı yanlış sınıflandırma problemi ile bu testte karşılaşılmasıdır. Modelin hem işlenmiş hem işlenmemiş resimlerle eğitilmiş olması özniteliklerin doğru öğrenimi ile resim gürültülerinin de öğrenimini sağlamış ve ezberlemenin önüne geçmiştir. GoggleNet modelleri için yapılan iki farklı gerçek zamanlı testte elde edilen sonuçlar Çizelge 4.11’de verilmektedir.

Çizelge 4.11 : GoogleNet modelleri gerçek zamanlı test sonuçları

Derin Ağ	Veri Tipi	Model Doğruluk Ortalaması	Ortalama Tahmin Süresi(ms)	Gerçek Zamanlı Test Hata Oranı
GoogleNet	İşlenmiş Resim	0,8767	89	%11,4
GoogleNet	İşlenmiş ve İşlenmemiş Resim	0,9977	89	%0

İşlenmiş resimlerin bulunduğu veri seti ile eğitilmiş 50 katmanlı ResNet, işlenmemiş görüntüler üzerinde test edildiğinde model çıktı üretememiştir. Çıktı üretememesinin sebebi derin ağ modelinin giriş verisi ile eğitim verisinin boyut ve tür farklılığıdır. Bu nedenle işlenmemiş veri seti ile eğitilmiş %99,67 verisine sahip 50 Katmanlı ResNet modeli gerçek zamanlı testler için kullanılmıştır. Çizelge 4.12’de verilen sonuçlar incelendiğinde ResNet derin ağı 31 adet sınıflandırma için 26 doğru 5 yanlış sınıf tahmini ile %19,3 hata oranı ile sınıflandırma gerçekleştirmiştir. Modelin doğruluk değerlerinin ortalaması %81,66 olarak hesaplanmıştır. Model basit şekillerde yüksek doğruluk oranı ile sınıflandırma yaparken, kenar sayısı çok olan özel şekillerde düşük doğrulukla sınıf tahmini gerçekleştirmiştir. ResNet tahmin sürelerinin ortalaması 167 milisaniyedir. Bu veriler ile ResNet, GoogleNet’e oranla 2 kat daha yavaş sınıflandırma gerçekleştirmiştir. ResNet mimarisi ardışık katmanlardan oluştuğundan dolayı bu sınıflandırma testlerinde GoogleNet’e göre yavaş kalmıştır. GoogleNet içerdiği paralel inception modül yapısı ile daha hızlı işlem kabiliyetine sahip olduğu için kısa sürede sınıflandırma gerçekleştirmiştir. ResNet derin ağ modelinin hatalı tahminde bulunduğu Trapezoid, Square, I_Type, Z_Type şekiller için benzer özniteliklerin ezberleme problemi yol açtığı düşünülebilir. Eğitim verisi ResNet için yeniden düzenlenirse, tahmin başarısı artırılabilir. ResNet eğitim süresi uzun olması

ve bu çalışma için GoogleNet'in gerekli ihtiyacı karşılamasından dolayı yeniden ResNet eğitime gerek duyulmamıştır.

Çizelge 4.12 : İşlenmemiş veri seti ile eğitilen ResNet modeli gerçek zamanlı test sonuçları

Test Edilen Şekil	Modelin Tahmini	Model Doğruluk Değeri	Tahmin Süresi(ms)	Sonuç
ShapedRound_Type_2	ShapedRound_Type_2	0.9941	160	Doğru
Pentagon	Pentagon	0.3618	168	Doğru
U_Type_2	U_Type_2	0.9002	131	Doğru
RoundC_Type	RoundC_Type	0.9951	164	Doğru
PostBox	C_Type	0.4178	156	Yanlış
C_Type	C_Type	1	167	Doğru
Hexagon	Hexagon	1	159	Doğru
Obround	Obround	0.9657	171	Doğru
KeyHole	KeyHole	0.6578	158	Doğru
FullSquare	FullSquare	0.999	158	Doğru
U_Type	U_Type	0.7575	166	Doğru
ShapedRound_Type_1	ShapedRound_Type_1	1	163	Doğru
Rectangle	Rectangle	0.9463	159	Doğru
Square	Square	0.9939	175	Doğru
L_Type	Z_Type	0.6171	170	Yanlış
HalfRound	HalfRound	0.6399	173	Doğru
SquareWithHole	SquareWithHole	1	174	Doğru
Triangle	Triangle	0.9952	164	Doğru
ShapedRect_Type_2	ShapedRect_Type_2	0.9938	173	Doğru
Egg_Type	Egg_Type	0.9467	178	Doğru
C_Type_2	C_Type_2	0.9017	174	Doğru
I_Type	I_Type	0.9843	177	Doğru
T_Type	FullSquare	0.3788	157	Yanlış
ShapedRect_Type_1	ShapedRect_Type_1	0.9969	169	Doğru
Trapezoid	Trapezoid	0.6235	174	Doğru
Trapezoid	Square	0.3999	176	Yanlış
W_Type	W_Type	0.9685	166	Doğru
Round	Round	1	154	Doğru
HourGlass	HourGlass	0.9978	177	Doğru
RoundWithRectHole	C_Type	0.4681	176	Yanlış
RoundWithRectHole	Hexagon	0.4143	181	Yanlış

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında endüstride sac işleme yapan lazer kesim makineleri için özel şekilli boru profillerin görüntü işleme ile sınıflandırılması amaçlanmıştır. Geliştirilen yöntemin endüstride kullanılan bilgisayar tabanlı sistemlere kolay uygulanabilir olması dikkate alınmıştır. Endüstride çalışma ortamı kaynaklı problemlerin bilgisayar tabanlı sistemlerde kararlılığı etkileyen bir durum olduğu bilinmektedir. Bu çalışmada geliştirilen yöntemin yüksek doğruluk, hız ve verimlilik açısından endüstri koşullarına karşı dayanıklı olması hedeflenmiştir.

Boru-profillerin sınıflandırılma işlemi için görüntü işlemede yüksek doğrulukla sınıflandırma gerçekleştirdiği bilinen GoogleNet ve 50 katmanlı ResNet derin öğrenme modelleri kullanılmıştır. Derin ağların şekillerin öz niteliklerini öğrenebilmesi için veri oluşturulması gerekmektedir. Kamera aracılığıyla farklı açılarda alınan örnek görüntüler her bir sınıf için veri tabanına eklenmiştir. Veri arttırma yöntemleri kullanılarak görüntüler çoğaltılmış ve model eğitiminde başarı oranı artırılması amaçlanmıştır. Derin ağların şekil öz niteliklerini daha iyi öğrenebilmesi için veri tabanında bulunan görüntüler geliştirilen bir algoritma ile ön işleme yapılarak eğitimde kullanılmıştır. Veri arttırma ve görüntü ön işleme yöntemlerinin model eğitimi başarısında etkisini gözlemlemek için farklı veri tabanları ile eğitimler gerçekleştirilmiştir. Sonuç olarak uygulanan iki yöntemin de başarı oranlarını arttırdığı gözlemlenmiştir.

Gerçekleştirilen eğitimlerin sonuçlarına göre GoogleNet eğitimleri ResNet eğitimlerine kıyasla daha kısa sürede gerçekleştirilmiştir. İşlenmemiş veri tabanında ResNet ortalama test doğruluğu daha yüksek iken, işlenmiş veri tabanında ise GoogleNet daha yüksek doğruluk sağlamıştır. Gerçek zamanlı sınıflandırma testlerinde ise modellerin doğruluğu test edildiğinde benzer şekillerde hatalı tahminler yapıldığı gözlemlenmiştir. Bu problemin çözümü için yüksek doğruluğa sahip GoogleNet, işlenmiş ve işlenmemiş resimlerin bulunduğu veri tabanı ile 32 tam döngü ile yeniden eğitilip test edilmiştir. Eğitilen model gerçek zamanlı uygulamada %99,77 model doğruluğu ile test edilen tüm sınıflarda doğru tahmin üretmiştir. Sınıflandırma tahmin süresi ortalama 89 milisaniye olarak gözlemlenmiştir. GoogleNet modeli uygulama ihtiyaçlarını istenen seviyede karşılamıştır. Eğitim süresi, model doğruluğu, sınıf tahmin süresi olarak en başarılı çıktıyı üretmiştir.

Bu çalışmada sınıflandırma işleminde özel şekilli 30 farklı sınıfın dahil olduğu bir derin ağ eğitimi yapılmıştır. Endüstride birçok farklı alanda boru-profiller kullanılmaktadır. Uygulama ihtiyaçlarına göre boru-profiller seçilerek daha az sınıfın dahil olduğu derin ağ eğitimleri benzer yöntemle yüksek doğrulukla sınıflandırma işlemi gerçekleştirebilir. Bu uygulamada teste dahil edilmemiş olan özel şekilli boru ve profiller için de veri tabanı genişletilerek eğitimler tekrarlanabilir. Bu çalışma için oluşturulmuş veri tabanı yeni eğitilecek özel şekillerin sınıflandırılması için kullanıma uygundur.

Boru-profillerin sınıflandırması farklı bir yöntem önerisi olarak özneliklerin derin ağlar kullanılarak çıkarımı ve literatürde kullanılan başarılı sınıflandırıcılar ile gerçekleştirilebilir. Çoklu destek vektör makineleri, çoklu Naive Bayes yöntemi çok sınıflı boru-profil veri tabanında sınıflandırma işlemi için kullanılabilir. Sınıf sayısı azaltılması durumunda işlem kolaylığı ve performans göz önüne alınırsa karar ağaçları veya en yakın komşu algoritmaları ile çözüme gitmek mümkündür.

6. KAYNAKÇA

- Açıl, T.** (2019). *Güncel Makine Öğrenmesi Teknikleri ile İris Görüntülerinden Cinsiyet Analizi*. Yüksek Lisans Tezi, İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü, İskenderun.
- Aksoy, B., Sayın, H., & Salman, O.** (2021). Resnet34 Derin Öğrenme Mimarisi Kullanarak Yüz Görüntülerinden Vücut Ağırlığı Tahmini Uygulaması. *International Journal of Engineering and Innovative Research*, 3(1), 12-19.
- Albera, S. A.** (2016). *Vehicle Logo Recognition Using Image Processing Methods*. Yüksek Lisans Tezi, Atılım Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Alper Baştürk, E. G.** (2009). Efficient edge detection in digital images using a cellular neural network optimized by differential evolution algorithm. *Expert Systems with applications*, 36(2), 2645-2650.
- Al-Salihi, M. Q.** (2018). *Detection of imperfections in non-metal sewer pipes by image processing*. Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.
- Atalı, G., Özkan, S., & Karayel, D.** (2016). Morfolojik Görüntü İşleme Tekniği ile Yapay Sinir Ağlarında Görüntü Tahribat Analizi. *Akademik Platform Mühendislik ve Fen Bilimleri Dergisi*, 4(1), 1-7.
- Augment Images for Deep Learning Workflows Using Image Processing Toolbox.** (2021,06,08),Mathworks:<https://www.mathworks.com/help/deeplearning/ug/image-augmentation-using-image-processing-toolbox.html> adresinden alındı
- Aydın, K., & Karaağaç, İ.** (2018). Lazer Kaynağı ve Lazer Kaynağının Başlıca Uygulamaları. *El-Cezeri Fen ve Mühendislik Dergisi*, 5(2), 693-705.
- Aydoğdu, M. F.** (2010). *FPGA-Tabanlı, steryo görmeye sahip bir robotta üç boyutta eş zamanlı konumlama ve haritalama*. Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Balcılar, M., & Sönmez, A. C.** (2008, Ekim). *Geometrik Düzeltme ve Gabor Filtreleriyle Araç Plaka Tespiti*. Yıldız Teknik Üniversitesi, Bilgisayar Mühendisliği. Bursa: ELECO.
- Balq, A. A.** (2019). *Görüntü İşleme Tekniklerini Kullanarak Optik İşaret Tanıma Sistemi*. Doktora Tezi, Kastamonu Üniversitesi, Fen Bilimleri Enstitüsü, Kastamonu.
- Barstuğan, M.** (2014). *Özellik Çıkarma ve DVM Tabanlı Adaboost Algoritması ile Biyomedikal Veri Sınıflandırma*. Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Bayram, R. B.** (2019). *Metal Sektörü İçin Görüntü İşleme Tabanlı Bir Kusurlu Ürün Tespit Sistemi*. Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bursa.

- Bölük, S. A.** (2016). *İskeletsel Kritik Noktalar İle Şekil Tanıma*. Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü.
- Boyraz, Ö. F., Pala, M. A., Çimen, M. E., Boz, A. F., & Yıldız, M. Z.** (2019). Mikrobilgisayar Tabanlı El-Bilek Damar Örüntüleri Kullanılarak Biyometrik Kimlik Doğrulama İşleminin Yapılması. *Academic Perspective Procedia*, 2(3), 593-600.
- Çağır, G., Okçu, F., & Güngör, N. H.** (2019). Ambalaj Yüzeylerindeki Hataların Görüntü İşleme Tekniği İle Tespiti. *Zeki Sistemler Teori ve Uygulamaları Dergisi*, 2(3), 37-45.
- Canny Edge Detector.** (2021, 01 31). <http://www.janfranco.com/computer-vision/Canny-Edge-Detection/> adresinden alındı
- Çapkan, Y.** (2018). *Robotlarla Nesne Tanıma*. Yüksek Lisans Tezi, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük.
- Çayıroğlu, İ.** (2021, 01 26). www.ibrahimcayiroglu.com:2480/Dokumanlar/GoruntuIsleme/Goruntu_Isleme_Ders_Notlari-5.Hafta.pdf adresinden alındı
- Çelik, A., & Tekin, E.** (2020). Hough Transform Görüntü İşleme Yöntemiyle Ekim Makineleri İçin Tohum Sayma Uygulaması. *Avrupa Bilim ve Teknoloji Dergisi*, 260-267.
- Değirmenci, E., Kaloğlu, A. H., Güven, E., Durak, S., & Orbuk, H.** (2019). İçme Sularında Bulunan E. Coli Bakterilerinin Görüntü İşleme Yöntemleriyle Tespiti. *Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34(3), 235-246.
- Demirhan, A., & Güler, İ.** (2010). Özörgütlemeli Harita Ağları ve Gri Düzey Eş Oluşum Matrisleri ile Görüntü Bölütleme. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 25(2), 285-291.
- Destek vektör makinesi.** (2021, 01 28). Veri Bilimcisi: <https://veribilimcisi.com/2017/07/19/destek-vektor-makineleri-support-vector-machine/> adresinden alındı
- Dhanasekar, B., Mohan, N. K., Bhaduri, B., & Ramamoorthy, B.** (2008). Evaluation of surface roughness based on monochromatic speckle correlation using image processing, 32(3). *Precision Engineering*, 32(3), 196-206.
- Doğan, F., & Türkoğlu, İ.** (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- Er, O.** (2016). *Yapay Sinir Ağları, Lojistik Regresyon ve Karar Ağaçları Uygulamaları ile Kariyer Başarısı Tahmini: Akademisyenler Üzerine Bir Araştırma*. Doktora Tezi, Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Isparta.
- Erdilek, N., & Çelikkol, B.** (2018). Diş Hekimliğinde Güvenli Lazer Kullanımı. *Süleyman Demirel Üniversitesi Tıp Fakültesi Dergisi*, 481-486.
- Ergin, T.** (2021, 06 27). *CNN Nedir, Nasıl Çalışır?* medium.com: <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> adresinden alındı

- Ergün, G. B., Güney, S., & Ergün, T. G.** (2021). Köpeklerde Uzun Kemiklerin Evrişimsel Sinir Ağları Kullanılarak Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 33(1), 125-132.
- Erkınay, Z. M.** (2012). *Dismorfik Hastalıkların Sinyal İşleme Yöntemleri Kullanılarak Sınıflandırılması*. Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Fidan, H.** (2020). *Random Forest (Rasgele Orman) Algoritması Temelli Süreç İzleme Yönteminin Ambulator Kan Basıncı İzlemede Hipertansiyon Erken Tanısı İçin Kullanımı*. Yüksek Lisans Tezi, Muğla Sıtkı Koçman Üniversitesi, Fen Bilimleri Enstitüsü, Muğla.
- Gökçe, M.** (2014). *Sayısal Görüntü İşleme ile Göz Hastalıklarının Teşhisi İçin Bir Yardımcı Sistem Tasarımı*. Yüksek Lisans Tezi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü).
- Gómez, A. B., Rodríguez, J. C., Londoño, J. M., & Velásquez, E. P.** (2015). Image recognition application for robotic manipulation of moving objects. *IEEE 2nd Colombian Conference on Automatic Control (CCAC)*, (s. 1-5). Medellin, Colombia.
- Gönenç, S., & Öner, Y.** (2021). Zeytin Tanelerinin Türünün Belirlenmesinde Görüntü İşleme ve Kümeleme Yöntemlerinin Kullanımı. *The Journal of International Scientific Researches*, 6(2), 137-151.
- Hatipoğlu, R. S.** (2018). *Elektronik Malzeme Montajı Yapan Al ve Yerleştir Makineleri İçin Görüntü İşleme Yazılımının Geliştirilmesi*(Yüksek Lisans, Selçuk Üniversitesi Fen Bilimleri Enstitüsü). Konya.
- Huang, H., Liu, J., Liu, S., Wu, T., & Jin, P.** (2020). A method for classifying tube structures based on shape descriptors and a random forest classifier. *Measurement*(158).
- I. Onderova, J. O.** (2018). Automatic handling equipment for laser cutting. *Machine Design*, 10(3).
- Image Moment.** (2021, 01 02). Wikipedia: https://en.wikipedia.org/wiki/Image_moment adresinden alındı
- İnik, Ö., & Ülker, E.** (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Karaköse, M., Yetiş, H., & Müezzinoğlu, T.** (2017). Optimizasyon Tabanlı Adaptif Görüntü Mozaikleme Algoritması. *Bilişim Teknolojileri Dergisi*, 10(4), 389-400.
- Kaya, K.** (2016). *Destek Vektör Makineleri Yardımıyla Tüketici Kredilerinin Sınıflandırılması*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Kın, Z. B.** (2019). *Türk İşaret Dili Alfabesinin Derin Öğrenme Yöntemi ile Sınıflandırılması*. Yüksek Lisans Tezi, Başkent Üniversitesi , Fen Bilimleri Enstitüsü, İstanbul.
- Lazer.** (2021, 01 23). Wikipedia: <https://tr.wikipedia.org/wiki/Lazer> adresinden alındı

- Li, Q., Chen, L., Li, M., Shaw, S.-L., & Nüchter, A.** (2013). A Sensor-Fusion Drivable-Region and Lane-Detection System for Autonomous Vehicle Navigation in Challenging Road Scenarios. *IEEE Transactions on Vehicular Technology*, 63(2), 540-555.
- Logitech.** (2021, 01). <https://www.logitech.com> adresinden alındı
- Manshouri, N.** (2019). *İki ve Üç Boyutlu Videoları İzlerken Kaydedilen EEG Sinyallerinin Karşılaştırılması ve Sınıflandırılması*. Doktora Tezi, Karadeniz Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Mete, B. R.** (2019). *Derin Öğrenme ile Görüntü Sınıflandırma*. Yüksek Lisans Tezi, İstanbul Üniversitesi, CerrahPaşa Lisansüstü Eğitim Enstitüsü, İstanbul.
- Muzaffer, G.** (2016). *Anahtar Noktası Tabanlı Kopyala Yapıştır Sahteciliği Tespiti*. Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Özel, M. A., Baysal, S. S., & Şahin, M.** (2021). Derin Öğrenme Algoritması (YOLO) ile Dinamik Test Süresince Süspansiyon Parçalarında Çatlak Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*(26), 1-5.
- Perihanoğlu, G. M.** (2015). *Dijital Görüntü İşleme Teknikleri Kullanılarak Görüntülerden Detay Çıkarımı*. Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Pınar, İ.** (2014). *Lazer Kesim Makineleri İçin Görüntü İşleme Uygulamaları*. Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Şeker, Ş.** (2018). *Görüntü Tanıma Yöntemi ile Profil Kesit Ölçülerinin Çıkarılması*. Yüksek Lisans Tezi, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük.
- Shrivakshan, G. T., & Chandrasekar, C.** (2012). A Comparison of various Edge Detection Techniques used in Image Processing. *International Journal of Computer Science Issues (IJCSI)*, 9(5), 269.
- Small Tube Products.** (2020, Ağustos). <http://www.smalltubeproducts.com/shape-tube-profiles> adresinden alındı
- Sofu, M. M.** (2014). *Otomatik Elma Sınıflandırma Makina Tasarımı ve Prototip İmalatı*. Doktora Tezi, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı, Isparta.
- Soyhan, İ., Gürel, S., & Tekin, S. A.** (2021). Yapay Zeka Tabanlı Görüntü İşleme Tekniklerinin İnsansız Hava Araçları Üzeride Uygulamaları. *Avrupa Bilim ve Teknoloji Dergisi*(24), 469-473.
- Struckmeier, F., Zhao, J., & Leon, F. P.** (2020). Measuring the supporting slats of laser cutting machines using laser triangulation. *The International Journal of Advanced Manufacturing Technology*, 108(11), 3819-3833.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A.** (2019). Going Deeper with Convolutions. *IEEE Conference on Computer Vision and Pattern Recognition*, 1-9.
- Tokmak, M., & Kırac, A.** (2021). Evrimsel Sinir Ağları ile Örümcek Kuşugillerin Bazı Türlerinin Sınıflandırılması. *Bilge International Journal of Science and Technology Research*, 5(1), 72-79.


- Toptaş, M.** (2018). *Orman Yangınlarının Görüntü İşleme Yöntemleri ile Tespit Edilmesi ve Sınıflandırılması*. Yüksek Lisans Tezi, İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Malatya.
- Tuna, H.** (2019). *Kabuk Zincir Koduyla Şekil Tanıma*. Doktora Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Ankara.
- Varol, A. H.** (2014). *Görüntü Mozaikleme ile Panoramik Görüntü Üretimi*. Yüksek Lisans Tezi, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Xulan Zhang, D. Y.** (2013). Traffic Sign Detection Based on Shape Model, In Informatics and Management Science II. *Springer*, 253-260.
- Yüce, C.** (2019). Paslanmaz Çelik Malzemelerin Fiber Lazer Kesiminde Proses Parametrelerinin Optimizasyonu. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 24(2), 685-696.
- Yumak, B.** (2011). *Elektronik Postaların Ayırıştırılmasında Naive Bayesian ve Bulanık Mantık Yöntemlerinin Karşılaştırılması*. Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Ankara.



EKLER


EK A: İşlenmiş Veri Seti GoogleNet Eğitim Sonuçları

EK B: İşlenmiş Veri Seti ResNet Eğitim Sonuçları




Şekil A.1 : İşlenmiş Veri Seti GoogleNet Eğitim Sonuçları

EK B



Şekil B.1 : İşlenmiş Veri Seti ResNet Eğitim Sonuçları

ÖZGEÇMİŞ



Ad-Soyad : Ahmet Muhammed YAHŞİ

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2015, Karabük Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği
- **Yüksek Lisans** : 2021, Bursa Teknik Üniversitesi, Mekatronik Mühendisliği Anabilim Dalı

MESLEKİ DENEYİM VE ÖDÜLLER:

- Yazılım Geliştirme Mühendisi – ERMAKSAN Makine