

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

ENDÜSTRİYEL UYGULAMALARDA NESNE YÜZEY HATALARININ
BİLGİSAYARLA GÖRME TABANLI TESPİTİ

Serhat TURAL

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA
2023

Her hakkı saklıdır

ÖZET

Doktora Tezi

ENDÜSTRİYEL UYGULAMALARDA NESNE YÜZEY HATALARININ BİLGİSAYARLA GÖRME TABANLI TESPİTİ

Serhat TURAL

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Refik SAMET

Günümüzde makinalar ile yapılan kontrollere göre birçok dezavantajı olmasına rağmen insan gözü ile yapılan kontroller endüstride sıklıkla kullanılmaya devam etmektedir. Makinalar kolay algılanabilir, yüzey dokusu homojen tek düze olan, kusursuz yüzeyin kusurdan net ayrıştığı, şekil olarak düzensiz yansıtma yapmayan, kusurların tespiti için sofistike algoritmaların ve yüksek hesaplamının gerekmediği nesne yüzeylerinde yüksek başarımla kalite kontrolünü gerçekleştirebilirler. Fakat karışık ve düzensiz yüzey dokusuna sahip, materyal özelliklerinden dolayı ışığı yansıtan, şeklinden dolayı düzensiz yansıma yapan nesnelerin kalite kontrolünde bilgisayarla görme tabanlı sistemler kusurlarının tespitinde insan yetisine göre yetersiz kalmaktadırlar. Bu durum özellikle kusurların yüzey dokusundan ayırmanın zor olduğu görüntülerde yaşanır. Diğer bir problemde geliştirilen yöntemlerin talep edilen süre sınırları içerisinde kusurların tespiti ve ayrıştırmasının sıklıkla yapılamamasıdır.

Bu çalışmada askeri fişek kovanlarının kalite kontrolünü uçtan uca yapan bir sistem önerilmiştir. İlk olarak sistemin mekanik, elektronik, haberleşme ve ışıklandırması için uygun tasarımı yapılmıştır. Tasarlanan sistem üzerinden görüntüler alınıp kovan yüzeyleri için bir veri seti oluşturulmuştur. Kovan veri setinin oluşturulması için kameralardan alınan ham görüntüler geliştirilen yeni yöntemler ile işlenip kovan yüzeyi sonraki işlemler için istenilen pozisyonda ayrıştırılmıştır. Askeri fişek kovanları metalik, şekil olarak düz yüzeye sahip olmayan, düzensiz yüzey dokusuna sahip ve oldukça yansıtıcıdır. Bu özellikler kovanların yüzey hatası tespiti zorlu bir problem yapar. Üretim kusurlarını bilgisayarla görme tabanlı tespit etmek ve kovan yüzeyinin kendine has dokusundan ayırt etmek için yüksek doğruluk oranlarında ve düşük hızlarda çalışabilen çeşitli yöntemler önerilmiştir. Hem görüntü işleme teknikleri ile hem de insan yetisinden etkilenecek geliştirilen derin sinir ağları ile ilgili yüksek başarımla çalışan yöntemler önerilmiş ve literatüre yeni katkılar sağlanmıştır. Deneysel sonuçlar prototipten alınan gerçek görüntüler kullanılarak gerçekleştirilmiş ve başarılı sonuçlar elde edilmiştir.

Ocak 2023, 127 sayfa

Anahtar Kelimeler: Görüntü İşleme, yapay görme, yüzey hatası tespiti, otomatik nesne inceleme, derin öğrenme, hata segmentasyonu, nesne sınıflandırması.

ABSTRACT

Doctor of Philosophy

MACHINE VISION BASED DETECTION OF OBJECT SURFACE DEFECTS ON INDUSTRIAL APPLICATIONS

Serhat TURAL

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Prof. Dr. Refik SAMET

Although there are many disadvantages compared to the controls made with machines, controls made with the human eye continue to be used frequently in the industry. Machines can perform quality control with high performance rates on object surfaces that are easily perceptible, whose surface texture is homogeneous and uniform, where the flawless surface is clearly separated from the defect, which does not reflect irregularly in shape, and where sophisticated algorithms and high calculations are not required for the detection of defects. However, in the quality control of objects with mixed and irregular surface texture, reflecting light due to their material properties, and irregular reflection due to their shape, computer vision-based systems are insufficient for detecting defects compared to human abilities. This is especially true in images where imperfections are difficult to distinguish from the surface texture. Another problem is that the defect detection and separation cannot be done frequently within the requested time limits of the developed methods.

In this study, a system that performs end-to-end quality control of military cartridge cases is proposed. First of all, a suitable design for the mechanical, electronic, communication and lighting of the system was made. Images were taken from the designed system and a data set was created for the hive surfaces. In order to create the hive data set, the raw images taken from the cameras were processed with the new methods developed and the hive surface was separated at the desired position for further processing. Military cartridge cases are metallic, not flat in shape, have an irregular surface texture and are highly reflective. These features make surface defect detection of hives a challenging problem. Various methods have been proposed that can operate at high accuracy rates and low speeds to detect manufacturing defects based on computer vision and distinguish them from the unique texture of the hive surface. High-performance methods have been proposed for deep neural networks developed both by image processing techniques and by being influenced by human ability, and new contributions have been made to the literature. Experimental results were carried out using real images taken from the prototype and successful results were obtained.

January 2023, 127 pages

Key Words: Image Processing, machine vision, surface defect detection, automated inspection, deep learning, defect segmentation, object classification.

TEŞEKKÜR

Bu tez çalışmasının planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren ve akademik ortamda olduğu kadar beşeri ilişkilerde de engin fikirleriyle yetişme ve gelişmeye katkıda bulunan sayın hocam Prof. Dr. Refik SAMET' e sonsuz teşekkürlerimi sunarım.

Sevgili aileme manevi hiçbir yardımı esirgemedi yanımda oldukları için tüm kalbimle teşekkür ederim.

Serhat TURAL
Ankara, Ocak 2023

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	ii
TEŞEKKÜR	iii
SİMGELER DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ.....	1
1.1 Tezin Kapsamı	3
1.2 Tezin Özgün Değeri	4
1.3 Tezin Yapısı.....	6
2. KAYNAK ÖZETLERİ VE LİTERATÜR DEĞERLENDİRMESİ	7
3. BİLGİSAYARLARLA GÖRME TABANLI ENDÜSTRİYEL SİSTEMLERİN TASARIMI	18
3.1 Genel Mimari	18
3.2 Görüntü Alma İşlemleri.....	19
3.3 Yazılım Mimarisi	21
4. NESNE TESPİTİ VE ARKA PLANDAN AYRIŞTIRILMASI	24
4.1 İlgili Çalışmalar	25
4.2 Segmentasyon Yöntemleri	26
4.2.1 Global eşikleme	27
4.2.2 OTSU eşikleme.....	28
4.2.3 Adaptif eşikleme	29
4.2.4 Canny edge detector	32
4.2.5 Watershed.....	33
4.3 Kovan Açısının Düzeltilmesi.....	34
4.3.1 PCA yöntemi ile eğilme açısının bulunması	35
4.3.2 En uzun çizgiler ile eğilme açısının bulunması	38
4.3.3 En küçük dikdörtgen yöntemi ile eğilme açısının bulunması.....	39
4.4 Kovan Tespiti ve Arka Plan Ayrılması İçin Önerilen Yöntem	40
5. NESNE YÜZEY HATALARININ BİLGİSAYAR GÖRME TABANLI TESPİTİ	42
5.1 Gri Düzey Eş Oluşum Matrisleri (GLCM)	42
5.2 Dalgacık Dönüşümü (Wavelet Transform)	44
5.3 Hu-Moments ile Hata Bulma	47
5.4 Görüntü İşleme Tabanlı Önerilen Metodoloji	49
6. DERİN ÖĞRENME YÖNTEMLERİ İLE YÜZEY HATALARININ TESPİTİ	52
6.1 Derin Konvolüsyonel Sinir Ağları.....	57
6.1.1 Sınıflandırma amaçlı derin konvolüsyonel sinir ağları.....	59
6.1.2 Bölütleme amaçlı derin konvolüsyonel sinir ağları	62
6.1.3 Önceden eğitilmiş CNN modellerinin tartışılması.....	63
6.2 Öğrenme Aktarımı (Transfer Learning).....	65
6.3 Derin Öğrenme Tabanlı Kovan Yüzey Hata Tespiti İçin Önerilen Metodoloji	67
6.3.1 Verisetinin hazırlanması	68

6.3.2	Fişek kovan görüntülerinin sınıflandırılması.....	69
6.3.3	Fişek kovan görüntülerindeki hataların etiketlenmesi	69
6.3.4	Sonuçların değerlendirilmesi.....	70
7.	KOVAN YÜZEY HATALARININ TESPİTİ UYGULAMASI.....	72
7.1	Görüntü Alma Bileşenleri	73
7.2	Görüntü İşleme Yazılımı Bileşenleri.....	73
7.3	Kovan Yüzeyinin Tespiti ve Ayrıştırılması Uygulaması	74
7.3.1	Global eşikleme	74
7.3.2	OTSU eşikleme.....	75
7.3.3	Canny kenar bulma	76
7.3.4	Watershed.....	77
7.3.5	Adaptif eşikleme	78
7.4	Kovan Yüzey Tespiti ve Ayrıştırılması Yöntemlerinin Karşılaştırılması	80
7.5	En Küçük Dikdörtgen Yöntemi ile Kovan Açı Düzeltme Uygulaması	81
7.6	Eşik Değeri ve Morfolojik İşlemlerle Hata Bulma	82
7.7	GLCM Yönteminin Uygulanması ve Sonuçlarının Değerlendirilmesi.....	84
7.8	Dalgacık Dönüşümü Uygulaması ve Sonuçlarının Değerlendirilmesi	86
7.9	Bilateral Filtre Temelli Hata Bulma Algoritması Sonuçları	87
7.10	Geliştirilen Yazılımın Arayüz Çıktıları	88
8.	KOVAN YÜZEY HATALARININ DERİN ÖĞRENME TABANLI TESPİTİ UYGULAMASI.....	90
8.1	Verisetinin Hazırlanması	90
8.2	Fişek Kovanları Verisetinin Sınıflandırılması	94
8.2.1	Uygulama düzeneğinin hazırlanması.....	94
8.2.2	Uygulama sonuçları.....	94
8.2.3	VGG16 modeli ile kovan yüzey hata sınıflandırma örneği.....	97
8.3	Fişek Kovanlar Yüzey Kusurlarının Segmentasyonu	99
8.3.1	Uygulama düzeneğinin hazırlanması.....	100
8.3.2	Uygulama sonuçları.....	100
8.3.3	Geliştirilmiş U-NET	101
8.3.4	ResUnet gerçekleştirimi	103
8.3.5	DeepLabv3+ gerçekleştirimi.....	105
8.4	Bulgular ve Tartışma.....	108
9.	SONUÇ	110
	KAYNAKLAR	112
	EK 1 Eğitim İterasyonlarında Oluşan Kayıp ve Doğruluk Değerleri.....	123

SİMGELER DİZİNİ

ASPP	Atrous Spatial Pyramid Pooling
CNN	Convolutional Neural Networks
DVM	Destek Vektör Makineleri
DWT	Discrete Wavelet Transform
ESA	Evrişimsel Sinir Ağları
FCM	Fuzzy C-Means Clustering
FD	Frequency Domain
GLCM	Gray Level Co-occurrence Matrix
HDWT	Haar Discrete Wavelet Transform
JI	Jaccard Index
LBP	Local Binary Pattern
mIoU	Mean Intersection over Union
PCA	Principal Component Analysis
SVM	Support Vector Machine
SWT	Stationary Wavelet Transform
WT	Wavelet Transform

ŞEKİLLER DİZİNİ

Şekil 1.1 İnsan faktörü ile yapılan örnek kalite kontrol işlemi	3
Şekil 3.1 Çalışmanın Genel Konuları	18
Şekil 3.2 Deney Düzenegi Tasarımı.....	20
Şekil 3.3 Genel Haberleşme Mimarisi (Çoklu Bilgisayar)	21
Şekil 3.4 Yazılım Mimarisi Tasarımı (Tekli Bilgisayar, Multithread)	22
Şekil 3.5 Yazılım Mimarisi Tasarımı (Çoklu Bilgisayar).....	23
Şekil 4.1 PCA'nın geometrik yorumu (Shokouh 2013).....	35
Şekil 4.2 Kontrast arka planlı örnek görüntülerde PCA ile açı hesaplama	37
Şekil 4.3 Kovan örnek görüntüsünde PCA ile açı hesaplama.....	38
Şekil 4.4 Kovan örnek görüntüsünde çizgi bulma yöntemi uygulanması.....	39
Şekil 4.5 En küçük dikdörtgen yöntemi	39
Şekil 4.6 Convex hull ve rotating calipers yöntemi	40
Şekil 4.7 Önerilen yöntemin adımları	41
Şekil 5.1 Gri düzey eş oluşum matrisi	42
Şekil 5.2 Bir sinyalin ikinci seviye dalgacık paket ayrışımı (Bayram vd. 2014).....	46
Şekil 5.3 Manyetik karo örnek hata ve tespiti (Yang vd. 2016)	47
Şekil 6.1 CNN Yapısı.....	58
Şekil 6.2 CNN Örnek Uygulama	58
Şekil 6.3 Çalışmada uygulanan öğrenme aktarımı.....	64
Şekil 6.4 Önerilen metodolojinin akış şeması.....	68
Şekil 7.1 İşlenmemiş Kovan Görüntüsü	72
Şekil 7.2 Örnek kovan görüntüsünün histogramı.....	74
Şekil 7.3 Örnek değerler için global eşikleme uygulaması.....	75
Şekil 7.4 OTSU sonucu ile yakın eşik değerlerinin karşılaştırılması	75
Şekil 7.5 Watershed algoritması sonucu örnek bir bölütleme.....	78
Şekil 7.6 En küçük dikdörtgen ile açı düzeltme.....	82
Şekil 7.7 Orijinal ham görüntü.....	83
Şekil 7.8 İlgi alanının çıkarılması	83
Şekil 7.9 Yan yüzey kısmının ayrılması	83
Şekil 7.10 Sobel filtresi uygulanması.....	84
Şekil 7.11 Eşik değeri uygulanması	84
Şekil 7.12 Morfolojik kapama işlemi.....	84
Şekil 7.13 Küçük boyutlu hataları elenmesi	84
Şekil 7.14 GLCM örnek görüntüler ve sonuçları.....	85
Şekil 7.15 Dalgacık dönüşümü örnek görüntüler ve sonuçları	87
Şekil 7.16 Örnek Kovan Görüntüsünde Bilateral süzgeç Sonuçları	88
Şekil 7.17 Son kullanıcı arayüzü hatalı kovan örneği.....	89
Şekil 7.18 Son kullanıcı arayüzü hatasız kovan örneği.....	89
Şekil 8.1 Askeri fişek kovan örnekleri.....	90
Şekil 8.2 Kusurlu olmayan (a) ve kusurlu olan (b) silindirik fişek kovanı yüzeyinden 60 derece açı ile alınan görüntüler	91
Şekil 8.3 Kusurlu olmayan (a) ve kusurlu olan (b) silindirik fişek kovanı gövde yüzeyinin çıkarılması	92
Şekil 8.4 Kusurlu olmayan (a) ve kusurlu olan (b) silindirik fişek kovanı gövde yüzeylerinin alt parçalara ayrılması	92

Şekil 8.5 Kusurlu olmayan (a) ve kusurlu olan (b) olarak sınıflandırılmış veriseti	93
Şekil 8.6 Kusurlu bölgelerin etiketlenmiş maskeleri	93
Şekil 8.7 VGG16 Modeli Mimarisi.....	97
Şekil 8.8 Eğitim sonucu kayıp ve doğruluk grafikleri	98
Şekil 8.9 Test Verisi Tahminleri	99
Şekil 8.10 Geliştirilmiş U-NET	102
Şekil 8.11 Standart ((a), (b)) ve Geliştirilmiş U-Net ((c) ve (d)) Kodlayıcı/Çözücü Blokleri	103
Şekil 8.12 Geliştirilmiş ResUnet'in Kodlayıcı/Kod Çözücü Blokları.....	104
Şekil 8.13 DeepLabv3+ Mimarisi	105
Şekil 8.14 Hata segmentasyonu için test setinde elde edilen sonuçlardan örnekler	107



ÇİZELGELER DİZİNİ

Çizelge 2.1 Dokusal Yüzey Hata Bulma Algoritmaları Genel Tasnifi	7
Çizelge 2.2 Dokusal Yüzey Hata Bulma Algoritmaları Genel Değerlendirmesi.....	17
Çizelge 6.1 ImageNets veri setinde önceden eğitilmiş Derin CNN modellerinin detayları ve performansı	65
Çizelge 6.2 Karışıklık matrisi (Confusion matrix).....	70
Çizelge 7.1 Canny kenar bulma sonuçlar tablosu	76
Çizelge 7.2 Adaptif eşikleme sonuçlar tablosu	79
Çizelge 7.3 Bölütleme Algoritmalarının karşılaştırma tablosu.....	80
Çizelge 8.1 Askeri fişek kovanlarının sınıflandırılması uygulama sonuçları	96
Çizelge 8.2 Derin CNN'lerin önceden eğitilmiş modellerinde optimize edicilerin performansının değerlendirilmesi	97
Çizelge 8.3 CNN ve Morfolojik Hata Bulma Karşılaştırması	99
Çizelge 8.4 Fişek kovanlarının kusur segmentasyonu uygulama sonuçları.....	101
Çizelge 8.5 Geliştirilmiş U-Net ve ResUnet modelleri arasında karşılaştırma.....	106

1. GİRİŞ

Teknolojinin gelişmesiyle birlikte endüstriyel uygulamalarda büyük gelişmeler olmuştur. Hızla gelişen teknolojiler ile birlikte üretimde insan gücüne dayanan sistemler yerini makineler ve otomasyon sistemlerine bırakmıştır. Bununla birlikte üretilen ürünlerin kalite problemlerinin tespiti de üretimin önemli bir aşaması haline gelmiştir. Ürünlerin kalite problemlerinin zamanında ve uygun maliyet ile tespit edilmesi işletmeler için çok önemlidir. Savunma, sağlık ve ilaç sanayi gibi alanlarda ise başarılı bir kalite kontrolü kritik önemde ve maliyeti yüksek bir süreçtir. Üretim hatlarında zamanında tespit edilemeyen kalite problemleri zaman, maliyet ve prestij kaybına neden olur. Zamanında tespit edilen ve sınıflandırılabilen kalite problemleri üretim hattındaki sorunların erken fark edilmesine ve üretim aşamalarında iyileştirme yapılmasına imkân sağlar. Üretilen hatalı ve standart kalitede olmayan ürünlerin son kullanıcılara ulaşmadan önce tespiti yapılır bu sayede ürünlerin geri dönüş ve iadeleri azaltılmış olur. Kullanıcı sağlığına ve hayatında etki edebilecek düşük kalitede ve standartların altında üretilmiş ürünler kullanıcılara ulaşması önlenmiş olur. Üretilen ürünlerin kabul edilmiş kalite standartları seviyesinde sunulması çok önemlidir.

Teknolojik gelişimin sonucu olarak tüm dünyada seri üretim teknolojilerinde insan faktörü azalıp yerini makineler almaktadır. Bu sayede daha ucuz, daha hızlı ve daha güvenilir üretim yapılmaktadır. Günümüzde kalite kontrolü hem insan işgücü ile hem de insansız teknolojiler ile yapılmaktadır. İnsan gücünün daha çok kullanıldığı durumlarda makinaların kullanıldığı ortamlara göre çeşitli dezavantajlar ortaya çıkmaktadır. Maliyet, tutarlılık, üretim hızı altında kontrol kapasitesi, insan gözünün kısa süre odaklanabilmesi, insan beyninin bazı hataları algılayamaması, insan faktörü ve duyguları gibi insan kaynaklı birçok etken üretimde kalite için yapılan hata tespiti ve ayırma sürecine olumsuz olarak etki edebilmektedir. İnsan ile yapılan kontrollerin tüm bu dezavantajlara rağmen kalite kontrolünün makinalar tarafından yapılması çeşitli teknik zorlukları barındırdığı ve günümüzde hala istenilen standartlara ulaşamadığı için işletmelerde insan kullanılarak yapılan kalite kontrolleri yoğun olarak devam etmektedir.

Üretilen ürün ve üretim sürecine bağlı olarak birçok farklı yöntem ile kalite kontrolleri yapılırsa da en yaygın olarak yapılan kalite kontrol yöntemi dış yüzeyin gözlemlenmesi ile yapılan yöntemdir. Seri üretim hatlarının sonunda yoğun olarak insanlar gözleri ile bantlarda akan ürünleri kontrol eder ve yeterli kalite de olmayan ürünleri ayırırlar. Bu işlem sıklıkla sadece dış yüzeyin insan gözü ile kontrolü şeklinde gerçekleşir. Kontrol edilen ürünler son derece çeşitli olabilir. Kumaş, metal şerit, cep telefonu, elektronik devre kartı, cıvata, vb. gibi ürünler olabilir.

İnsan gözü ile yapılan kontrollerde (Şekil 1.1) ürünün yüzeyindeki görünür hatalar incelenir. İnsan göz yapısı ve algılaması kenarlar ve desenler üzerine yoğunlaşır. Fakat bir nesnenin desenleri içindeki hataları algılamakta zayıf kalabilmektedir. Çeşitli göz yanılgıları oluşabilmektedir. Belirli bir sürenin sonunda insanlar odaklarını kaybetmekte ve kontrol aşamasında göz yorulmaktadır ve hataları algılamak zorlaşmaktadır. Buna rağmen insan beyni makinelerin doğru karar vermekte zorlandığı yüzeylerde, hatalı hatasız sınıflandırmasını hızlıca öğrenebilmekte ve yapabilmektedir. Fakat son zamanlarda gelişen görüntü işleme ve yapay görme algoritmaları ile kendi kendine öğrenebilen ve gerçek zamanlı çalışabilen algoritmalarda gelişmeler olmaktadır ve bu alanda yoğun bir ilgi bulunmaktadır. Bu gelişmelerin bir yansıması olarak geliştirilen yeni yöntemler kullanılarak insan kontrolünün yerini alabilecek nesne yüzey hatalarının tespiti için kalite kontrol sistemleri üzerinde yoğun şekilde çalışmalar yapılmaktadır. Bilgisayar ile görme algoritmalarının birçok alanda yaygın olarak kullanılmaktadır ve kullanım alanları hızla yaygınlaşmaya devam etmektedir. Bu kullanım alanlarından biri de endüstriyel olarak üretilen ürünlerin yüzey hatalarının tespitidir. Bu alan bilgisayar ile görme yöntemlerinin uygulanabilmesi için açık bir alandır. Desen tabanlı ayırma ve kontrol görüntü işlemede önemli bir çalışma alanıdır. Birçok farklı araştırma alanına uygulanabilir niteliktedir. Özellikle seri üretim tesislerinde kalite kontrol aşamasında insan gözü ile kontrole göre büyük avantajlara sahiptir. İnsan yerini makineler almaktadır. Endüstride makineleşmeyi kullanan işletmeler diğer işletmelere göre maliyet, kalite ve hız gibi avantajları olur. Makineleşen endüstri tesislerinde kullanılan en önemli araçlardan biri de kameralardır. Makine ile görme (Machine Vision) alanı mekanik ve görüntü işlemenin entegre çalıştığı çalışma alanıdır.



Şekil 1.1 İnsan faktörü ile yapılan örnek kalite kontrol işlemi

Yüzey kalite kontrolü sanayide üretim sürecinin en kritik aşamalarından biridir. Kalite kontrol, ürünün yüzeyinde bir hata (kusur) olup olmadığı sorusuna cevap verir. Kalite kontrolü genellikle insan gözü kullanılarak manuel olarak yapılır. Manuel kalite kontrolünün dezavantajları yüksek hata oranı (düşük doğruluk ve güvenilirlik), birim zamanda düşük sayıda ürün kontrolü (düşük performans) ve yüksek gider oranıdır (yüksek maliyet). Çözüm, yapay görme sistemlerini kullanan otomatik kalite kontrolüdür. Bu sistemler, üretim sürecinde kameralar tarafından çekilen görüntüleri gerçek zamanlı olarak işleyerek ürünleri sınıflandırır ve yüzeylerindeki kusurları bölütlere (segmentlere) ayırır. Metalik, silindirik, düzensiz yüzey dokusuna ve yüksek yansıtıcı yüzeye sahip nesnelerin kalite kontrolleri bazı zorlukları barındırır. Bu tip yüzeye sahip nesnelerde gerçek hatayı tespit etmek yansıma ve düzensiz yüzey dokusundan dolayı zordur. Nesne yüzey hatalarının bilgisayarla görme tabanlı tespiti zorlu bir problemdir.

1.1 Tezin Kapsamı

Seri üretim yapan endüstriyel kuruluşlarda nesne yüzey hatalarının bilgisayarla görme tabanlı tespiti birçok alt bileşeninin birbiri ile kusursuza yakın şekilde çalışması ile başarılı olabilir. Bu bileşenler en temelde nesneyi hareket ettiren ve ayıran mekanik kurulum (hareket ve ayırma), görüntü alma (kamera, lens, ışıklandırma), görüntü işleme

ve haberleşme olarak ayrılabilir. Bu bileşenlerden herhangi birinin istenen başarımda olamaması tüm sistemin beklenen standartların altında sonuç vermesine neden olur. Bu çalışmada endüstriyel uygulamalarda nesne yüzey hatalarının bilgisayarla görme tabanlı tespiti için insan kontrolünün yerini alabilecek standartta tüm alt bileşenleri içeren özgün bir sistem önerilmiş, önerilen yöntemler ile prototip geliştirilmiş ve önerilen yöntemler uygulanmıştır. Düzensiz ve rastgele desenli, düz olmayan, silindirik, düzensiz parlama yüzeylerine sahip olan nesnelerin kontrolü için görüntü işleme ve derin öğrenme tekniklerinin kullanıldığı bilgisayar ile görme algoritmaları geliştirilmiştir.

Kamerallardan ham görüntü alma ile başlayan, bunları gerçek zamanlı işlenebilecek hale getiren bir yazılım altyapısı ve en sonunda da hatalı/hatasız ayrımını yapan bir sistem geliştirilmiştir. Tümüyle özgün geliştirilen sistem haricinde ham kamera görüntüsü üzerinden nesne tespiti ve nesnenin arka plandan ayrılması için yeni yöntemler önerilmiş, ayrılan yüzey üzerinde hata tespiti için kullanılan yöntemlere katkı sağlanmıştır. Yüzey üzerinde hata tespiti için görüntü işleme ve derin öğrenme yöntemleri önerilmiştir. Kritik ürünlerin gerçek ortamda kontrolünde kullanılabilecek hız ve doğrulukta yeni yöntemler önerilerek katkı sağlanmıştır.

1.2 Tezin Özgün Değeri

Endüstriyel üretim teknolojisinde birçok bilgisayar ile görme algoritması başarılı olarak kullanılmaktadır. Barkod okuma, karakter tanıma, şekil ve geometri tanıma, renk kontrolü gibi teknolojiler, bilgisayar ile görme yöntemleri kullanarak geliştirilmiştir. Bununla birlikte, yüzey hatalarının zayıf bir şekilde belirlendiği ve yüzeyin çeşitli yapılar gösterdiği, düz bir geometriye sahip olmayan, yüzeyinde düzensiz parlamalar olan, düzensiz yüzey desenine sahip olan nesnelerin muayenesi gibi sofistike makine görme problemleri için insan ile yapılan yüzey kontrolleri çoğunlukla devam etmektedir. Son yıllarda bilgisayar ile görme alanında yoğun çalışmalar ve yüksek bir ivme ile gelişmeler olmasına rağmen yoğun parlama yapan, düzensiz desene sahip olan, yüzey deseni ile hata desenin zor ayrıştığı yüzeylerde bilgisayarla görme tabanlı hata tespiti, talep edilen hız ve doğruluk standartlarında olmadığı gözlemlenir. Çoğu gelişmiş işletmelerde dahi istenilen bu standartlar yakalanamadığı için insan gözü ile yapılan yüzey hata kontrollerinin

kullanımı yoğun olarak devam etmektedir. Düzenli desenli, yüzeyde hata ile nesne desenin birbirinden kolayca ayrıldığı, parlama sorunu olmayan materyallerde hata tespiti nispeten kolay ve istenilen standartlarda olmasına rağmen silindirik, yüzeyinde rasgele desenler barındıran, düzensiz parlama yapan materyallerde yapılan güncel hata bulma çalışmaları genellikle istenilen standartların ve hızın altındadır. Standart yöntemlerin çoğu materyalin bazı yüzey desenlerini hata olarak algılamakta, bazı yüzey hatalarını ise materyalin yüzey deseni olarak algılamaktadır. Bazı çalışmalarda önerilen yöntemlerin ise gerçek dünyada kullanılamayacak şekilde ürün üretim hızlarının çok altında hesaplama yapabilen, online olarak kullanılmasının mümkün olmadığı ancak offline olarak çalışabilecek kapasitede tasarlandığı görülmüştür. Mevcut yöntemler özellikle örnekler üzerinden insan gibi öğrenebilme yönünden zayıftırlar. Çok hassas ve çok detaylı bir kurulum ve konfigürasyona ihtiyaç duyarlar. En önemlisi de periyodik olmayan ve rasgele, düzensiz yüzey desenleri için kalite kontrol algoritmalarının yetersizliğidir. Genellikle periyodik ve düzenli desenlerde başarılı sonuçlar alınsa da periyodik olmayan ve düzensiz doğal desenlerde çok başarılı sonuçlar alınamamaktadır. Metal gibi yüzeyler doğasından dolayı üzerlerinde rasgele ve düzensiz desenleri barındırır. Düz olmayan, silindirik ve kompleks geometride nesnelerde ise yüzey hata kontrolü yapmak düzensiz parlamadan dolayı ekstra zorlukları içinde barındırır.

Yukarıda belirtilen problemin çözümü ile ilgili literatürde görüntü işleme (Tural ve Samet 2017) ve derin öğrenme tabanlı çalışmalar mevcuttur. Görüntü işleme teknikleri ile ilgili mevcut çalışmalar, yukarıda belirtilen nesnelerin incelenmesi (hataların tespiti, sınıflandırılması ve bölütlenmesi) için verimli değildir. Ayrıca, kullanılan algoritmalar ve yöntemler gerçek zamanlı çalışma için optimize edilmemiştir. Son yıllarda hata tespiti, sınıflandırma ve bölütleme ile ilgili çalışmaların ağırlıklı olarak derin öğrenme temelli olduğu görülmektedir. Derin öğrenme teknikleriyle ilgili mevcut çalışmalar, insan duyusu gibi davranmaya başlar ve bu tür kusurları daha iyi tespit edebilir. Literatür incelendiğinde, derin öğrenme tekniklerini kullanarak kusurları tespit etmek, nesneleri sınıflandırmak ve kusurları bölütlere ayırmak için az sayıda çalışma vardır. Askeri fişek kovanı gibi kalite kontrolü kritik öneme sahip nesnelerde yüksek doğruluk oranları talep edilmektedir. Mevcut yöntemler incelendiğinde doğruluk oranlarının bu gibi kritik görevlerde kullanılmaya uygun olmayacak şekilde düşük oldukları görülmüştür. Öte

yandan, literatürde askeri kovanları sınıflandırmak ve kusurları bölütlemek için kullanılan derin öğrenme teknikleriyle Samet ve Tural (2020), Tural vd. (2022) dışında bir çalışma yoktur.

Kusurların zayıf bir şekilde belirlendiği ve yüzeyin çeşitli yapılar gösterdiği, düz bir geometriye sahip olmayan, yüzeyinde düzensiz parlamalar olan, düzensiz yüzey desenine sahip olan nesnelerin kalite kontrolü uygulamalarında en kritik bileşenlerden biri yazılım ve hata bulma algoritmalarıdır. Bu tezde özgün görüntü işleme ve derin öğrenme algoritmaları ile hata bulma yöntemleri geliştirilmiş ve gerçek bir sistem üzerinde test edilmiştir.

1.3 Tezin Yapısı

Tez kapsamında endüstriyel uygulamalarda nesne yüzey hatalarının bilgisayarla görme tabanlı tespiti için gerekli tüm aşamalar detaylı olarak açıklanmış ve çalışan bir prototip üzerinde uygulamalı sonuçlar ortaya konulmuştur. Bu tez 9 ana bölümden oluşmaktadır. İkinci bölümde genel terminoloji, tez konusu ile ilgili güncel teknolojilerin durumu özetlenmiş, kullanılan yöntemlerin genel tasnifi verilmiş ve literatürde yapılan çalışmaların değerlendirmelerine yer verilmiştir. Tezin Üçüncü bölümde sistem mimarisi, mekanik ve görüntü alma bileşenleri detaylı olarak açıklanmıştır. Silindirik nesne yüzeyinin tüm dış yüzeyinin istenilen hızlarda görüntüsünü almak için mekanik tararım, düz olmayan ve düzensiz parlama yapan nesne yüzeyleri için düzensizliği en aza indirecek kamera, lens ve ışıklandırma konfigürasyonun açıklamaları bu bölümde verilmiştir. Dördüncü bölümde ham görüntünün işlenmesi, nesne tespiti, arka planın ayrılması, nesne yüzeyinin tespiti ve hata bulma algoritmalarında yapılan çalışmalar ve katkılar özetlenmiştir. Beşinci bölümde nesne yüzey hatalarının bilgisayar görme tabanlı tespiti için önerilen görüntü işleme teknikleri verilmiştir. Altıncı bölümde görüntü işleme tabanlı önerilen ve geliştirilen yöntemlerin askeri fişek kovanları üzerinde uygulaması yapılmıştır, sonuçları verilmiştir. Yedinci bölümde derin öğrenme yöntemleri ile yüzey hatalarının tespiti ve bölütlenmesi için yöntemler önerilmiştir. Sekizinci bölümde derin öğrenme tabanlı önerilen yöntemlerin askeri kovan fişekleri üzerinde uygulaması yapılmıştır. Dokuzuncu bölümde araştırmasının sonuçları ve öneriler paylaşılmıştır.

2. KAYNAK ÖZETLERİ VE LİTERATÜR DEĞERLENDİRMESİ

Mevcut literatür çalışmalarında yüzey hatalarını incelemek için kullanılan yöntemler genel olarak istatistiksel, yapısal, süzgeç ve model tabanlı olmak üzere dört ana grupta sınıflandırılabilir. Bazı çalışmalarda melez yöntemler ile istatistiksel ve sinyal algoritmalar birlikte uygulanmıştır. Bu yöntemlerden farklı olarak 3 boyutlu model çıkaran algoritmalarda işlem yavaşlığından dolayı nadiren olsa da kullanılmıştır. Hatanın özellikleri çıkarıldıktan sonra hata tespiti için ise eğitmenli ve eğitmensiz olmak üzere iki ana grupta sınıflandırma metodları önerilmiştir. Eğitmenli metodlar çevresel şartlardan etkilendiği için çeşitli zorluklara sahiptir. Eğitmensiz yöntemler çevresel şartlardan daha az etkilendiği için ve farklı ürünlere uyarlamak daha kolay olduğu için öne çıkmaktadır. İncelenen desenler ise periyodik, periyodik olmayan, düzenli ve düzensiz olmak üzere 4 gruba ayrılabilir. Düzenli desenlerde işlem yapmak kolay iken düzensiz ve periyodik olmayan doku desenlerine sahip yüzeylerde hata bulma algoritmaları hataya yer olmayan kritik ürünlerin kontrolünde yetersiz kalmaktadırlar.

Çizelge 2.1 Dokusal Yüzey Hata Bulma Algoritmaları Genel Tasnifi

Yöntem Grubu	Metot
İstatistiksel (Statistical)	1. Histogram Özellikleri (Histogram properties)
	2. Co-occurrence Matris (Co-occurrence matrix)
	3. Yerel ikili desen (Local Binary Pattern)
	4. Gri Seviye İstatistiği (Other graylevel statistics)
	5. Otokorelasyon (Autocorrelation)
	6. Kayıt Tabanlı (Registration-based)
Yapısal (Structural)	1. İlkel Ölçüm (Primitive measurement)
	2. Kenar Özellikleri (Edge Features)
	3. İskelet Gösterimi (Skeleton representation)
	4. Morfolojik Operasyonlar (Morphological operations)
Süzgeç Tabanlı (Filter based)	1. Uzamsal Alan Filtreleri (Spatial domain filtering)
	2. Frekans Bölgesi Analizi (Frequency domain analysis)
	3. Ortak Uzamsal/Mekansal Frekans (Joint spatial/spatial-frequency)
Model Tabanlı (Model based)	1. Fraktal Modeller (Fractal models)
	2. Rastgele Alan Modeli (Random field model)
	3. Texem Model
Doku Analizsel (Texture analysis)	1. Yapay Sinir Ağları (Neural network) 2. Yapay Zeka (Artificial Intelligence)
Fotometrik Stereo	1. Photometric Stereo

Görüntü işleme teknikleri ile hata bulma algoritmaları genel olarak Çizelge 2.1 gösterildiği gibi sınıflandırılmıştır (Xie, 2008) ():

Latif-Amet ve arkadaşları hibrit olarak istatistiksel ve uzaysal dönüşüm yöntemlerini kullanarak kumaş üzerinde hataların bulunmasında yenilikçi bir yöntem önermişlerdir. Önceki mevcut çalışmalar problemi sadece tek bir alanda incelerken, bu çalışmada farklı alanlardaki çözüm yöntemleri birlikte kullanılmıştır. Yöntem önce dalgacık dönüşümü ile görüntüyü alt bantlarına ayırır. Daha sonra bu alt bantlarda co-occurrence özellikleri çıkarılır. Bir sınıflandırma algoritması ile de ayırma işlemini gerçekleştirirler. Sonuçlar göstermiştir ki bu yöntem gerçek zamanlı olarak üretimde kullanılabilir verimliliktedir. (Latif-Amet vd., 2000).

Mosorov ve Tomczak yüzey desenleri üzerinde hata tespiti için fuzz-c ortalama kümelemesi kullanarak bir çözüm geliştirmişlerdir. En önemli farklılıkları hatalı ve hatasız örnekler ile sistemi eğitim aşamasından geçirmelerine gerek olmamasıdır. Yüzey desen kontrolünde çoğu sistem çok sayıda eğitim için seçilmiş örnekler ile eğitim aşamasından geçirilerek çalışır. Bu aşama sübjektif ve insan hatasına açıktır. Ayrıca farklı materyaller için kullanılmaya uygun değildir. Önerilen çalışmanın yenilikçi yönü ise herhangi bir eğitim aşaması yoktur. Çalışmada görüntü birbiri ile kesişmeyen küçük pencerelere bölünür. Sonrasında Principle Component Analysis (PCA) yöntemi her bölünen parçaya uygulanır. Bu sayede her parça için bir özellik vektörü oluşturulur. Daha sonra the Fuzzy C-Means Clustering (FCM) yöntemi kullanılarak hatalı ve hatasız örnekler sınıflandırma yapılır (Mosorov ve Tomczak 2014).

Asha ve arkadaşları desenli periyodik duvar kağıtlarının üzerindeki hataları bulmak için gabor dalgacığı ile bir çözüm önermişlerdir. İlk olarak optimum gabor çekirdeği katsayısını bulup Gabor dalgacığı dönüşümü kullanmışlardır. Gabor uzayında hataların tespiti içinde hiyerarşik kümeleme yöntemi önermişlerdir (Asha vd. 2011).

Mohan ve Haripasad seramik fayansların yüzey kalite kontrolü için Haar Discrete Wavelet Dönüşümü ve Öklit Uzaklık yöntemlerinin kullanılarak yeni bir sistem

önermişlerdir. Çalışmalarında endüstride üretilen materyallerin görsel yüzey kontrolünü ele almışlardır. Üretilen materyallerin yüzey pürüzsüzlüğü, çatlak olmaması, kusursuz olması gerekmektedir. Çalışmalarında Haar Discrete Wavelet Transform (HDWT) yöntemi kullanarak öznel çıkarma işlemini gerçekleştirmişlerdir. Önerdikleri sistem iki ana aşamadan oluşmaktadır. İlk adım kusursuz yüzeyi olan bir materyal görüntüsü referans görüntü olarak ve yüzey kontrolü yapılacak görüntüler test görüntüsü olarak seçilmiştir. Bu seçilen görüntüler dalgacık dönüşümünden geçirilmiştir ve sonuçları hesaplanmıştır. İkinci adım, test görüntüsünün kusurlu olup olmadığını belirlemek için Öklid Uzaklık İlişkisi Yöntemi ile referans görüntü arasındaki benzerliği karşılaştırmaktır (Mohan ve Haripasad 2015).

Rallo ve arkadaşları gabor filtresi kullanarak yüzeylerde hata tespiti için eğitimsiz bir yöntem önermişlerdir. Gabor filtre kullanılan çoğu yöntemde gabor filtresinin parametrelerinin seçimi deneme yanılma yoluyla yapılır. Bu çalışmada ise tamamen otomatik olarak çalışabilen gabor tabanlı bir yöntem geliştirilmiştir. Önerilen yöntem rastgele desende, periyodik ve periyodik olmayan yüzeylerde çalışabilme kabiliyetine sahiptir. Yöntemlerin en önemli özelliği eğitim gerektirmemesi ve çevresel şartlardan etkilenmemesidir. Özellikle tekstilde kullanılan mevcut yöntemlerin çoğu ise adaptif yapay sinir ağları ile geliştirilmiştir. Bu yüzden mevcut yöntemler eğitim aşaması gerektirir ve eğitim aşaması için örneklerin seçimi önemlidir. Ayrıca eğitim tamamlandıktan sonra çevresel değişen koşullardan çok kolay etkilenirler, yeniden eğitilmeleri gerekir. Yine de bu yönteminde dezavantajları vardır. Kumaş benzeri ürünlerin kontrolünde başarılı şekilde çalışsa da her çeşit desende yöntemin sağlıklı çalışmadığı görülmüştür (Rallo vd. 2009).

Fathi ve Eskandari fayans parçaların yüksek frekans dağılımına göre hata kontrolü için bir çalışma yapmışlardır. Bu metot insanların gözle algılamasına benzer bir yöntemden faydalanmıştır. İnsan gözünün kenar kısımlara algısı daha iyidir. Önerilen yöntemde Undecimated Discrete Wavelet Packets dönüşümü görüntüler üzerinde uygulanmıştır. Daha sonra yüksek frekans alt bantlarında lokal entropi'ler hesaplanmıştır. İstatiksel özellikler çıkarma için hatalı fayans içeren görüntüler seçilmiştir. Son aşamada ise geri

beslemeli yapay sinir ağıları (back propagation neural network) hatalı alanları bulmak için kullanılmıştır (Fathi ve Eskandari 2013).

Campos ve arkadaşları çalışmalarında otomotiv üretimindeki metal parçaların görsel yüzey kontrolünü incelemişlerdir. İnceledikleri parçaları 3 tip hata içerebilecek şekilde sınıflandırmışlardır. Bu hatalar şunlardır: Merkez delik tamamen veya kısmen tıkalı, dış yok ve kaynakta çapak var. Her hata çeşidinin tespiti için farklı tipte görüntü işleme algoritmaları önermişlerdir. Deney kurulumunda sabit pozisyonda kamera ve aydınlatma kullanıldı. Kapalı delik tipi hatalar için iki farklı yöntem önermişlerdir. İlk yöntemde hough circles algoritması ile daire bulmadan faydalanır. İkinci yöntemde ise kenar bulma ve dikdörtgen ile merkez bulma algoritmalarından faydalanır. Cıvata dişlilerinde ortaya çıkabilen hatayı tespit etmek için cıvata gövdesinin alınan görüntü üzerinde belirlenmesine ihtiyaç vardır. Cıvata gövde kısmının tespit edilip, dişlilerin yerinde olup olmadığı kontrol edilmek istenmiştir. Bunun için dış bölümünden elde edilen bir çizgi profil üzerindeki değerler kontrol edilir. Dişli kontrolü için alınan değerlerde periyodik şekilde ve keskin geçişler olup olmadığı kontrol edilir. Alınan çizgi profilde geçişler periyodik ve keskin değil ise dişlilerin açılmadığı sonucuna varılır. Kaynak noktalarında çapak kontrolü için ilk aşamada görüntüdeki parçada eğim var ise parça düz duracak hale getirilir. Görüntü alma anında mekanik hareketten dolayı parçalar farklı konumlarda olabilir. Hesaplamaların kolay yapılması için parçalar düz konuma getirilir. Parça açısının düzeltilip düz konuma getirmek için kenar çıkarma ve sınırlayıcı dikdörtgen bulma yöntemleri kullanılarak döndürme açısı hesaplanır. Hesaplanan açıyla göre görüntü döndürülür. Bulunan açılara göre görüntü 10 adet eşit parçaya ayrılır. Her parçanın alabileceği açı değerleri önceden bellidir. Bölünen parçaların hesaplanan açı değerleri, önceden belirlenmiş açı değerleri dışında sapma yapıyorsa kaynakta çapak var anlamına gelir. C++ yazılım dili ve OpenCV görüntü işleme kütüphanesi kullanarak algoritmalarının gerçekleştirimini yapmışlardır. Her kusur için, sistemde daha yüksek esnekliği sağlayabilmek için çeşitli kurulum parametreleri tanımlanmıştır. Laboratuar prototipi üzerinde yapılan testlerde, iyi sonuç aldıklarını iddia etmişlerdir (Campos vd. 2008).

Timm ve Barth rastgele ve düzensiz desenli yüzeylerin hata kontrolü için Weibull özellikleri kullanarak parametre gerektirmeyen bir yöntem önermişlerdir. Gabor dönüşümü gibi mevcut yöntemlere göre yüksek doğruluk ve eğitim gerektirmemesi yanında, gerçek zamanlı kullanımda da oldukça başarılı olduklarını iddia etmektedir. Yöntem weibull fit kullanarak lokal gradient genliklerinin dağılımını hesaplayarak çalışır (Timm ve Barth, 2011).

Xie ve Mirmehdi rastgele desenler üzerinde hata bulma için çok az örnek ile eğitilen yeni bir yöntem önermişlerdir. Rastgele desende incelenecek her nesnenin desenleri farklı olabilir. Özellikle seramik gibi nesnelerin hata kontrolü için denemelerde başarılı olmuşlardır. Gerçek zamanlı kullanım için geliştirmeler gerekmektedir. Multiscale yaklaşımı ile hesaplama zamanlarını düşürmeye çalışmışlardır (X. Xie and M. Mirmehdi 2005).

Jijina ve arkadaşları (2013) gerçek zamanlı olarak metal hatalarının bulunması ve sınıflandırmasının görüntü işleme ile gerçekleştirilmesi üzerine çalışmışlardır. Bu çalışma, güvenilir ve verimli olmaktan uzak kontrol yöntemlerinden farklı olarak gerçek zamanlı ve güvenilir bir yöntem önermektedir. Hata tespiti ve hata sınıflandırması için çözümler sunulmuştur. Kusurlu bölgeler morfolojik teknikler kullanılarak tespit edilmiş ve bölütlere ayrılmıştır. Hatalı bölgeyi karakterize etmek için Gri Düzey Eş Oluşum Matrisi (GLCM) özelliklerini, geometrik özellikleri ve momentleri kullanılmıştır. Doğru sınıflandırma için bir geri yayımlı sinir ağı (Back propagation neural network) kullanılmıştır. Uygulama Matlab'da geliştirilmiş ve test edilmiştir. Hata tespiti ve sınıflandırmada iyi sonuçlar alındığı sonucu çıkarılmıştır.

Xue-w ve arkadaşları parlak metal ürünlerin yüzey hatalarının bulunması üzerine bir çalışma yapmışlardır. Otomatik hata bulma işini 4 aşamada özetlemişlerdir: Görüntü alma, ön işleme, özellik çıkartma, sınıflandırma. Bu çalışmada, metal yüzeyindeki kusurlu olmayan gürültüyü azaltmak ve ortadan kaldırmak için dalgacık dönüşümü yöntemi kullanılmıştır. Sonraki aşamada segmentasyon için OTSU eşikleme algoritması kullanılmıştır. Son aşamada spektrum bazında 5 farklı veriyi sınıflandırma algoritmasına göndermiştir. SVM (Support Vector Machine) algoritması kullanılarak hata

sınıflandırması yapılmıştır. Sonuç olarak 7 farklı hata çeşidinin sınıflandırılması sağlanmıştır. Hata ile ayrımının zor olduğu gürültü azaltmada dalgacık dönüşümünün başarılı olduğu gözlemlenmiştir (Xue-w vd. 2011).

Li ve Ren, Demiryolu raylarında yüzey hatalarının güvenlik ve konfora etkisi çok fazladır. Işık düzensizliği ve rayların parlama farklılığı bu hatların bir kamera sistemi ile tespitini zorlaştırmaktadır. Bu makale demiryolu rayları üzerinde ayırık yüzey hataları için kamera ile gerçek zamanlı kontrol yöntemi önermektedir. İlk olarak kamera ile görüntü alınır ve demiryolu rayı takip algoritması ile ilgilenilen ray kısmı tüm görüntüden çıkarılarak elde edilir. Çıkarılan ray görüntüsü üzerinde doğrusal olmayan ve aydınlanma bağımsız olarak lokal normalizasyon teknikleri kullanılarak kontrast iyileştirme uygulanır. Daha sonra hata bulma aşamasına geçilir. Hatalar önce yatay sonra dikey profil bazlı projeksiyon ile lokalizasyon yapılarak bulunur. Yapılan test sonuçlarında tip 1 hataları için %93 ve tip2 için %80 lik doğruluk oranları yakalanmıştır. Daha da önemlisi önerilen yöntem gerçek zamanlı çalışabilmektedir. 216 km/s hızla giden bir trende bile gerçek zamanlı hataların tespiti yapılabilmektedir. Kullanılan yöntem basit, hızlı ve başarılı bir sonuç almalarına olanak sağlamıştır (Li ve Ren 2012).

Büyük ölçekte LED üretimi yapan fabrikalarda hatalı ürünlerin ortaya çıkması kaçınılmaz bir durumdur. LED imalatında meydana gelen bu hataların birçok farklı türü vardır. Çoğu LED üretim tesisi kusurlu ürünleri insan gözüyle tespit etmeye çalışır, ancak bu yöntem zaman alıcıdır, sübjektiftir ve hatalı sonuçlara eğilimlidir. Bu nedenle LED ürünlerin bilgisayarlı görü tabanlı kontrolünü sağlayacak sistemler önerilmiştir. Önerilen otomatik optik inceleme sistemi, hataları %95'e varan doğrulukta tespit edebilmiş ve inceleme hızı, görüntü başına 0,3 saniyenin altında olmuştur. İnceleme için iki farklı tipte LED ürünü seçilmiştir. Yöntem olarak önce bölütleme işlemini yapmışlardır. Bölütleme için OTSU eşik bulma algoritmasını kullanmışlardır. Görüntü üzerinde çıkardıkları bölgenin yatay ve dikey (x ve y) eksenine göre yaptığı açı kadar sapmış olduğu çıkarımını yapmışlardır. Son olarak ilgili bölge bulunarak üzerinde farklı tipte hatalar için testler yapılmıştır (Perng vd. 2011).

Li ve arkadaşları tarafından kumaş üretiminde hızlı hata tespiti için algoritmalar önerilmiştir. Görüntü üst üste binmiş 3 ana katmandan oluşur, bunlar periyodik kumaş arka plan deseni, gürültülü görüntü ve hatalı görüntü. Böl ve fethet mantığıyla görüntü katmanlara ayrılıp işlenir. Arka plan desenini ayırmak için ortalama örnekleme algoritması kullanmışlardır. Varyans örneklemesi kullanılarak hatalı görüntü katmanı ayırması yapılır. Daha sonra OTSU algoritması kullanılarak hatalı görüntü üzerinde bölütleme yapılmıştır. Etiketleme algoritması ile de hata pozisyonları belirlenir ve son aşamaya gelinmiş olur. Yapılan deneyler göstermiştir ki katmanlara ayırarak yapılan bu yöntem hem hataları bulmada başarılı olmuştur hem de gerçek zamanlı şekilde çalışmayı başarmıştır (Li vd. 2013).

Sun ve arkadaşları makina ile görme teknikleri ile elektrik kontaklarının kontrolünü gerçekleştirmişlerdir. Elektronik kontakların incelenmesi, elektrik endüstrisi için büyük önem taşımaktadır. Tüm dış yüzeyin kontrolü gerçekleştirilmiştir. Kontrol sürecini üç bölüme ayırmışlardır: aşağıdan, yukarıdan ve yanlardan olacak şekilde üç farklı kontrol için görüntüler alınır. Araştırmalarında başarılı sonuçlar elde etmek için üç kontrol bölümünde farklı ön işleme yöntemleri ve algoritmalar kullanılmıştır. En büyük ve en küçük daireyi oturtma, dairesel segmentasyon gibi işlemler kullanılarak hata bulmuşlardır. Elektrik kontağının üst ve alt yüzeylerinin kontrolü için dairesel düzgünlüğünü kontrol edilmiştir. Yan yüzeyler için yüzeydeki bozuklukları ve çizikleri kontrol edilmiştir. Önerdikleri yöntemle yaptıkları testlerde yaklaşık olarak 1,5 saniye gibi uzun bir kontrol işlemlerini gerçekleştirmişlerdir. Kenar kırıklarını algılama işlemi uyguladıkları kontrol sisteminde en uzun zaman alan işlemidir. Kenar kırıkları haricinde yapılan kontroller yaklaşık 0,1 saniye sürede tamamlanır. Deney düzeneğinde profesyonel bir aydınlatma düzeneği kullanılmamıştır (Sun vd. 2010).

Çavdarlı ve Seke ağaç yüzeyleri üzerinde hata kontrolü için çoklu çerçeve bazlı bir yöntem önermişlerdir. Diğer sistemlerden farklı olarak renk ve desen değişikliklerinden etkilenmediklerini iddia etmişlerdir. Yaptıkları çalışmayı özellikle parke üretimi kontrolü için test etmişlerdir. Işığın farklı açılarda vererek bazı hataları daha görünür hale getirmişlerdir. Literatürde karşılaştırma için benzer yöntemi kullanan bir çalışmaya rastlanılamamıştır. Bu yüzden diğer çalışmalardan farklıdır. Avantajlarından biri de

algoritmalarının gerçekleştiriminin kolay olması ve fiziksel ortamın hazırlanmasının basit olmasıdır (Çavdarlı ve Seke 2010).

Fotometrik stereo diğer yöntemlere göre farklıdır. Diğer yöntemler 2 boyutlu uzay üzerinde hata bulmaya çalışırken, fotometrik stereo yöntemi ile tek kamera kullanılarak 3 boyutlu bir model oluşturulur. Bu yöntemin kullanımı desensel hatalardan ziyade çizik, ezik, şişkinlik gibi fiziksel olarak nesnelerin şeklindeki bozuklukların kontrolünde etkili bir yöntemdir. Farklı açılardaki ışık kaynaklarından gelen yansımalar yüzey normaleri hesaplanarak tek kamera ile 3 boyutlu model oluşturulur. Dezavantaj olarak hesaplama zamanları yüksektir, her zaman gelecek zamanlı uygulamalarda kullanılamayabilir.

Farooq ve arkadaşları da fotometrik stereo yöntemi kullanarak seramik parçaların kontrolü üzerine bir çalışma gerçekleştirmişlerdir. Gerçek zamanlı olarak üretim hattında kullanılabilir olduğunu iddia etmişlerdir. Özellikle yapısal ve fiziksel hataların rastgele desenli bir yüzeyde tespitinin zor olduğundan bahsetmişlerdir. Kullandıkları yöntemi ticari olarak ta sunmuşlardır. Fotometrik stereo yöntemini özellikle hareket eden üretim hatlarına uygulamak zordur. Bu çalışmada bunu başardıklarını iddia etmektedirler (Farooq vd. 2005).

Jahanbin ve arkadaşları support vektör makinaları kullanarak otomatik kalite kontrol yapan bir sistem önermişlerdir. İstatiksel ve sinyal alanını kullanarak hibrit bir yöntem kullanmışlardır. Ayırık dalgacık dönüşümü ve Gray-level co-occurrence matris yöntemini kullanarak lokal özellikleri çıkarmışlardır. Daha sonra SVM ile hatalı ve hatasız örnekleri sınıflandırma yapmışlardır. LabVIEW ile uygulamasını yapmışlardır ve gerçek zamanlı olarak çalışabildiğini iddia etmişlerdir. Özellikle düzenli olmayan doğal desenler üzerinde başarılı sonuçlar aldıklarını iddia etmişlerdir (Jahanbin vd. 2009).

Frayman ve arkadaşları alüminyum dökümlerde yüzey kusurlarını tespit etmek için bilgisayarlı görü yöntemi ile ilgili bir çalışma gerçekleştirmişlerdir. Çeşitli boyut ve şekillerdeki kusurları tespit etmek için hibrit görüntü işleme algoritmalarını kullanan bir yöntem uygulamışlardır. Hata bulma algoritmaları iki ana parçadan oluşur. İlki genetik algoritmanı kullanıldığı parametre öğrenme aşaması. İkinci aşama ise birinci aşamada

parametreleri kullanarak yapılan hata tespitidir. Gerçekleştirilen uygulamada bazı hataların tespitinde %99 oranında doğruluk elde edildiği iddia edilmiştir (Frayman vd. 2006).

Michaeli ve Berdel, (2011) plastik gibi düzensiz desenli materyallerin hata kontrolü üzerinde çalışma yapmışlardır. Mevcut çalışmalar düzenli veya periyodik ürünler için iyi sonuç verirken onlar düzensiz yüzeyler içinde başarılı sonuçlar almışlardır. Önerdikleri algoritma local binary pattern yöntemini kullanarak yüzey özelliklerini çıkartır. Sınıflandırma için yarı eğitimli bir yöntem kullanmışlardır. Gerçek zamanlı çalışabilmesi içinde paralelleştirme teknikleri uyguladıkları görülmüştür. Bu sayede gerçek zamanlı çalışabilir bir teknik geliştirmişlerdir.

Chen ve Zhang (2013) zırh plakaları üstünde hata bulan istatistiksel tabanlı bir yöntem geliştirmişlerdir. Yöntem olarak CCD kamera ile alınan görüntülerde gri seviyedeki değişikliklerin oranını kullanmışlardır. Özellikle GLCM (Gray Level Co-Occurrence Matrix) yöntemine göre daha başarılı ve daha hızlı bir yöntem olduğundan bahsetmişlerdir. Önerilen yöntemde çevresel faktörlerden çok kolay etkilenme vardır. Alınan görüntülerde çevresel veya donanımsal bazlı değişikliklerde iyi sonuç vermemektedir.

Feng vd. (2016) kumaş yüzeylerde hata bulmak için donanımsal olarak hızlandırılmış ve paralelleştirilmiş bir yöntem önermişlerdir. Small-scale over-completed dictionary (SSOCD) tabanlı olarak desen özelliklerini çıkartmışlardır. Bu yöntemin mevcutta desen özelliklerini çıkartmak için kullanılan yöntemlerden daha doğru ve donanım üzerinde paralelleştirmeye daha uygun olduğunu söylemektedirler. Sonuç olarak üretimde kullanılmaya uygun ve gömülü kartlar üzerinde çalışabilecek bir yöntem olarak önerilmiştir.

Choi ve Kim (2012) eğitim ve öğretici gerektirmeyen yöntem geliştirmişlerdir. Yöntem iki basamaklı bir şekilde çalışır. İlki global tahminleme, ikincisi lokal düzeltmedir. Global olarak spektrum tabanlı yaklaşımla hataların yeri tahmin edilir. Daha sonra hatalı ve

hatasız bölgelerin piksel dağılımlarından faydalanılarak lokal bazlı düzeltme işlemi yapılır. Yöntemin önemli bir avantajı ise eğitim gerektirmemesidir.

Jia ve arkadaşları (2004) SVM tabanlı ve gerçek zamanlı çalışan bir yöntem önermişlerdir. SVM tabanlı eğitilen bir sistem önermişlerdir. Bahsedilen yöntem ile 1 MB lık görüntüler üzerinde 6 ms gibi gerçek zamana uygun çok kısa bir zaman aralığında kontrol gerçekleştirmişlerdir. Mevcut çalışmalar içinde görülen en kısa kontrol süresidir. Dezavantaj olarak 1000 gibi çok fazla sayıda örnek ile eğitilmesi gösterilebilir. Filtre bazlı bir tarama yöntemi ile yüzey özelliklerini çıkarmışlardır.

Literatürde başlıca çalışma yapılan ve yaygın kullanılan yöntem ve metodolojilerin güçlü ve zayıf yönlerinin özeti Çizelge 2.2 verilmiştir (Patel ve Bhaidasna 2016).

- Kenar tabanlı yöntemler, kusurları etkili ve doğru bir şekilde belirler. Çatlak ve delikler haricindeki diğer çeşitli hatalarda iyi sonuçlar vermez.
- Morfoloji tabanlı yöntemler, iyi olmayan ışıklandırma parlamalarında daha yumuşak bit görüntü sağlar. Hata boyutuna ve şekline çok duyarlılık gösterir.
- Dalgacık Dönüşümü tabanlı yöntemler, yatay, dikey ve çapraz çizgi şeklinde hatalarda iyi performans gösterir. Görüntüde yumuşak geçişli kenarlarda ve renk tonu farklılıklarında hataları bulmada zorluk çeker.
- Eşikleme Tabanlı yöntemler için eşikleme değerinin otomatik seçildiği algoritmalar ön plana çıkmıştır. Histogram sonucu çok belirgin vadi ve tepeli olması durumunda iyi sonuç verebilir.
- Co-occurrence Matris yöntemi, daha yumuşak, parlaklığı değişmeyen görüntülerde hata bulmada başarılıdır. Az değişen ve çok sabit ışıklandırma ortamlarında iyi sonuçlar verebilir. İşlemci hesaplama gereksinimi yüksektir.

Literatürdeki çalışmalar incelendiğinde bazılarının gerçek zamanlı çalışmalara uygun olmadığı, bazılarının ise çok fazla veri seti ile eğitilmesi gerektiği görülmüştür. Çalışmaların çoğu incelendiğinde periyodik olmayan ve rasgele, düzensiz yüzey desenleri kontrolünde algoritmaların yetersiz kaldığı görülmüştür. Literatürdeki yöntemler ayrıca yüksek oranda doğru sonuçlar üretseler de %90 üstüne çok çıkamamışlardır. Hata bulmadaki bu oran kritik ürünlerin kontrolünde yeterli olamamaktadır. Tez kapsamında

düzensiz yüzey desenine sahip nesnelerin, gerçek zamanlı olarak çalışan, ürünlerin tüm yüzey alanın kontrolünü sağlayan algoritmalar ve sistem geliştirilmiştir.

Çizelge 2.2 Dokusal Yüzey Hata Bulma Algoritmaları Genel Değerlendirmesi


Metot	Güçlü Yönleri	Zayıf Yönleri
Kenar Tabanlı	Kusurları etkili ve doğru bir şekilde belirler.	Çatlak ve delikler haricindeki diğer çeşitli hatalarda iyi sonuçlar vermez.
Morfoloji Tabanlı	İyi olmayan ışıklandırma parlamalarında daha yumuşak bit görüntü sağlar.	Hata boyutuna ve şekline çok duyarlılık gösterir.
Dalgacık Dönüşümü Tabanlı	Yatay, dikey ve çapraz çizgi şeklinde hatalarda iyi performans gösterir.	Görüntüde yumuşak geçişli kenarlarda ve renk tonu farklılıklarında hataları bulmada zorluk çeker.
Eşikleme Tabanlı	Eşikleme değeri otomatik olarak seçilebilir.	Histogram sonucu çok belirgin vadi ve tepeli olması durumunda iyi sonuç verebilir.
Co-occurrence Matris	Daha yumuşak, parlaklığı değişmeyen görüntülerde hata bulmada başarılıdır.	Az değişen ve çok sabit ışıklandırma ortamlarında iyi sonuçlar verebilir. İşlemci hesaplama gereksinimi yüksektir.
İstatiksel Tabanlı	Yapay olarak oluşturulmuş statik desenli kumaş, halı vb. nesnelerin kontrolünde iyi sonuçlar verebilir.	Görüntünün tamamını inceler, lokal hataları göz ardı eder.
Yapısal Tabanlı	Frekans geçişi yüksek, arka plan ile zıtlığı yüksek hataları bulabilir. Hesaplaması kolaydır.	Hata boyutuna ve şekline çok duyarlılık gösterir. Yumuşak geçişli hataları algılamakta zorlanır. Yüzey dokusu ile benzer hataları ayırmakta zorlanır.
Süzgeç Tabanlı	Sabit, periyodik desenli, değişmeyen pozisyonda ve sabit alınmış nesne yüzey görüntülerinde iyi ve hızlı sonuçlar alınabilir.	Görüntünün çevresel etkenlerden dolayı hep aynı olmadığı, rastgele, düzensiz dokulu yüzeylerde iyi sonuç vermez.
Model Tabanlı	Bölünmüş küçük ölçekli çerçeveler üzerinde çalışır. Karmaşık desenli yüzey doku hatalarında iyi sonuçlar verir.	Hesaplama karmaşıklığı yüksektir, bazı parametrelerin optimum seçilmesine çok bağımlıdır, bu parametreleri belirlemek zordur. Eğitim aşaması gerektirir.
Doku Analizsel	İnsan beynine benzer bir öğrenme modelini temel alır. Bu sayede yoruma dayalı bazı hataları algılama oranı daha yüksektir.	Eğitim için veri seti hazırlanması gerektirir. Hesaplama karmaşıklığı yüksektir ve kontrol zamanı yavaştır. Kritik uygulamalar için doğruluğu uygun değildir.
Fotometrik Stereo	Girinti çıkıntı gibi 3 boyutlu olarak yüzeylerin incelenmesinde iyi sonuçlar verdiği görülmüştür.	Hesaplama karmaşıklığı yüksektir, daha yüksek maliyetlidir, sadece yüzey girinti çıkıntı şeklindeki hataları algılamak için kullanılabilir.

3. BİLGİSAYARLARLA GÖRME TABANLI ENDÜSTRİYEL SİSTEMLERİN TASARIMI

Endüstriyel uygulamalarda nesne yüzey hatalarının bilgisayarla görme tabanlı tespiti çok eksenli bir çalışma gerektirir. Talep edilen gerçek zamanlı çalışma hızlarına ulaşabilmek ve bilgisayar ile görü bileşenine en iyi görüntüyü aktarabilmek için bu farklı eksenlerdeki bileşenlerin her birinde iyileştirmeler ve optimizasyonlar yapmak gerekir. Farklı eksenlerdeki bu bileşenleri 2 ana gruba ayrılabilir (Şekil 3.1). Bunlardan ilki nesnenin en iyi şekilde işlenmesine imkân kılan görüntü alma bileşenleridir. İkincisi ise alınan ham görüntünün işlenip sonuç üreten yazılım bileşenleridir.

3.1 Genel Mimari

Araştırmada donanımsal ve yazılımsal bileşenlerin en uygun şekilde çalışabilmesi için geliştirmeler ve testler yapılmıştır. Bu adımların başında aydınlatma ve görüntü alma işlemleri gelmiştir. Görüntü alma bileşenleri kamera, lens, filtre ve ışıklandırma olarak toplanabilir. Görüntü alma işleminden sonra görüntüde ön işlemlerin yapılması gerekmektedir. Bu ön işlemler görüntü işlenecek ilgili alanın bulunması (region of interest), bu görüntüden kovan şeklinin çıkarılması ve kovanın incelenecek farklı kısımları için görüntünün ayrılması işlemleridir. Bu ön işlemlerden sonra hata bulma ve sınıflandırma aşamalarına geçilebilir. Şekil 3.1’de çalışmanın genel mimarisel konuları verilmiştir.




Şekil 3.1 Çalışmanın Genel Konuları

3.2 Görüntü Alma İşlemleri

Silindirik cisimlerin tüm yüzey kontrolü için özel bir düzeneğe ve mekaniğe ihtiyaç vardır. Nesnenin tüm yüzeyini inceleyebilmek için nesne döndürülerek görüntü alınabilir veya farklı açılardan tüm yüzeyi kapsayacak şekilde aynı anda birden fazla görüntü alınabilir. Nesnenin döndürülmesi hem mekanik kısmı yavaşlatacak hem de ardışık görüntüleri işlemek zaman alacağından hızlı karar verme yönünden zayıf kalacaktır. Farklı açılardan tüm yüzeyi kapsayacak şekilde eş zamanlı olarak alınan bir düzenekte ise paralel işleme yöntemleri kullanılarak daha hızlı karar veren bir sistem oluşturulabilir. En hızlı şekilde aynı anda görüntülerin alınmasına ve işlenmesine imkân veren mimari Şekil 3.2 verilmiştir. Bir sensor yardımıyla kameraların görüş açısına giren silindirik cismin aynı anda birden fazla kamera ile tüm yüzeyinin görüntüsü alınır. Hız kriterleri göz önünde bulundurulduğunda cismin sistem içinde durdurulup görüntüsün alınması mümkün değildir. Bu sebepten ötürü cisim hareket halindeyken görüntüsünün alınması önemli bir husustur.

Hareket halindeki bir cismin görüntüsünün alınması ise beraberinde yeni zorlukları getirir. Bu aşamada kamera ve lens parametrelerinin seçimi için titiz ve detaylı bir çalışma yapılmasını gerektirir. Hareket halindeki cisimlerin görüntüsünün işlemeye uygun şekilde alınması için en önemli parametreler kamera sensörü, kamera deklanşör hızı (shutter speed) değerleridir. Kameradaki bazı sensör tipleri görüntüyü satır satır alırken, bazıları ise tek zamanda alabilmektedir. Deklanşör hızı kameranın deklanşörünün görüntü alma sırasında bir saniyede açılıp kapanma süresi olarak ifade edilebilir. Deklanşör hızı düşük ise daha fazla sensöre erişeceğinden daha kaliteli bir görüntü oluşur. Fakat hareketli görüntülerde bu hızın düşük olması görüntüde bulanıklaşma olarak etki eder.


Doğal bir ışıklandırma ortamında silindirik cisimlerin parlaması eşit olarak dağılım göstermez. Görüntü alma birimine yakın noktalarda ışık dik açı ile kırıldığından yoğun iken, ışığın dik kırıldığı merkez çizgisinden uzaklaştıkça açıdan dolayı ışık yoğunluğu azalır. Mekanik tasarım ve kamera yerleşimleri ile bağlantılı olarak silindirik nesneye her noktadan dik şekilde ışık düşürebilmek için dairesel bir ışık kaynağı seçilebilir.



Şekil 3.2 Deney Düzeneği Tasarımı

Endüstriyel uygulamalarda nesne yüzey hatalarının bilgisayarla görme tabanlı tespitinde çeşitli mimariler ve haberleşmeler vardır. Karışık olmayan, fazla hesaplama gücü istemeyen, sadece temel görüntü işleme adımlarını olan, fazla giriş çıkış gerektirmeyen durumlarda basit mimariler nispeten başarılı olsa da gerçek ortam için yetersizlerdir. Tek bilgisayar üzerinde hem görüntü alma bileşenlerini kontrolü (mekanik, kamera, sensor) hem de görüntü işleme algoritmalarının çalıştırılması sistemde istenmeyen yavaşlıklara sebep olabilir. Gerçek zamanlı olmayan bir bilgisayar sisteminde işlem zamanı her seferinde farklı olabilmektedir. Bu sebepten ötürü görüntü alma bileşenlerini kontrolünü yapan birim ile görüntü işleme yapılan birim tamamen ayrılmıştır. Görüntü alma bileşenleri girdi, çıktı sinyallerini işler üzerinde hesaplama ağırlıklı bir işlem çalışmaz. Bu sebeple mikroişlemci mimarisi mekanik (besleme, hareket, ayırma), sensor, kamera, ışıklandırma bileşenlerinden alacağı girdi sinyallerini işleyerek çok hızlı şekilde karar vererek, diğer bileşenlere çıktı olarak iletebilir. Bu işlemler hesaplama gücü gerektirmeyeceğinden gerçek zamanlı olarak çalışması ve her çalışmayı aynı sürede tamamlaması önemlidir. Örnek olarak cisim sensorun önünden geçtikten milisaniyeler sonra ışıklandırmanın tetiklenmesi ve yine milisaniyeler sonrasında kameranın görüntü alma için tetiklenmesi verilebilir. Bu işlem her seferinde aynı işlem zamanında

gerçekleşmelidir. Diğer taraftan görüntü işleme birimi ise ham görüntü üzerinde kompleks işlemlerin yapılmasını gerektirir ve bu işlemlerin süresi farklı görüntülerde değişebilmektedir. Bu kompleks işlemleri mikroişlemci gibi sade bir yapının gerçekleştirmesi zordur. Bu sebeple görüntü işleme algoritmalarının üzerinde çalışacağı bilgisayar birimi farklıdır. Ham görüntü işlendikten sonra sonuç bilgisi mikroişlemciye ayırma yapması için gönderilir. Eğer görüntü işleme işlemi cisim ayırma ünitesini geldiği süreden uzun sürerse ayırma başarısız olur. Bu sebeple görüntü işlemenin de gerçek zamana yakın şekilde işlenmesi önemlidir. Şekil 3.3’de çoklu bilgisayar yapısını da kapsayacak örnek bir haberleşme mimarisi verilmiştir.




Şekil 3.3 Genel Haberleşme Mimarisi (Çoklu Bilgisayar)

3.3 Yazılım Mimarisi


Görüntü işlemede gerçek zamanlı çalışan bir sistem geliştirebilmek için seçilecek yazılım mimarisi kritiktir. Birden fazla kameradan gelen görüntüyü aynı anda işleyip ayırma kararı için en kısa sürede sonuç döndüren bir yazılım mimarisine ihtiyaç vardır. İlk olarak tek bilgisayarlı yapının detayları incelenecektir. Birden fazla kameradan aynı anda gelen görüntülerin ardışık işlenmesi işlem süresini çok uzatacağından verimsiz bir yöntem olarak karşımıza çıkar. Paralel işlemler için bilgisayarlardaki çoklu çekirdekli işlemci (Multi-Core Processor) yapısından faydalanılabilir. Bu sayede birden fazla görüntünün

multithread olarak işlendiği bir mimaride görüntü işleme adımları ardışık olarak işlenmeye göre daha hızlı olacaktır. Şekil 3.4'te tek bilgisayarda multithread çalışacak örnek bir mimari verilmiştir. Buradaki yapı üretici (producer) ve tüketici (consumer) problemi olarak tasarlanabilir. Her kamera için görüntü alma iş parçacıkları (thread) kameralardan aldıkları görüntü verisi ile üretici olarak görev yapar. Aldıkları veriyi paylaşılan tampon bellek bölgesinde saklar. Görüntü işleme iş parçacıkları ise paylaşılan tampon bölgesinden ilgili veriyi alır, işler, sonuç oluşturur ve ilgili veriyi paylaşılan bellek'ten çıkarır. İşlenmesi gereken ham kamera görüntülerinin kameradan alınması ve ortak bir bellek bölgesine konulması üreticinin işidir. Bu ortak bellek bölgesinden görüntünün alınıp görüntü işlem adımlarının çalıştırılması ve sonuç üretilmesi ise tüketicinin işidir. Üretici tüketicinin yaptığı işlemde daha fazla sayıda veri (görüntü) üretir ve tüketici buna yetişemez ise istem çalışamaz duruma gelir. Üreticiler ve tüketiciler arasındaki senkronizasyona dikkat edilmesi gerekir. Tüketicinin işlem hızının sadece belli durumlarda yetişemediği ama ortalama olarak yetişebildiği durumları yönetebilmek için kuyruk yapısı olarak tampon bellek kullanılabilir.



Şekil 3.4 Yazılım Mimarisi Tasarımı (Tekli Bilgisayar, Multithread)

Tek bilgisayar ile multithread işlemler her ne kadar hızlanma sağlasa da tamamen paralel şekilde çalışmazlar. Thread yapısını genellikle işletim sistemi yönetir. İşlemci çekirdek sayısı yeterli olmadığı durumlarda veya işletim sistemi başka işlemlere öncelik verdiğinde istenilen işlem hızlarına ulaşılamaz. Tek makinada multithread olarak işleme alternatif olarak birden fazla makinede işlemleri paralelleştirmek çok daha hızlı olacaktır. Şekil 3.5'te çoklu bilgisayar için yayımcı (publisher), abone (subscriber) tabanlı bir mimari örneği sunulmuştur. Bu mimaride her kameradan bir bilgisayar görüntüyü alır ve görüntü işleme adımlarını tamamlar. Çıkan sonucu ise ana bir bilgisayara iletir. Tüm bilgisayarlar ana bilgisayara sonuçları aktardığında ana bilgisayar o nesne ile ilgili kararı verir ve mikroişlemci birimine ayırma için gönderir.



Şekil 3.5 Yazılım Mimarisi Tasarımı (Çoklu Bilgisayar)

Bu bölümde bilgisayarlarla görme tabanlı endüstriyel sistemlerin tasarımı görüntü alma ve yazılım bileşenleri verilmiştir. Görüntü alma bileşenleri için kullanılabilecek ortak alt yapı mimarisi önerilmiştir. Görüntü alma ve işleme yazılım bileşenleri için iki farklı yazılım mimarisi önerilmiştir. Tek bir bilgisayar üzerinde birden fazla işlemci çekirdeğini verimli kullanmak için çoklu iş parçacıklı (multithread) bir model önerilmiştir. Tek bir bilgisayar üzerinde çoklu işlemci çekirdeği tek makinanın işlem kapasitesi ile sınırlıdır. Tek makinanın işlem gücünden daha performanslı bir işlem gerektiğinde farklı bir mimari ihtiyacı doğar. Bunun için yatayda birden fazla bilgisayar ile ölçeklendirmeye uygun bir mimari seçmek gerekir. Bunun için yayımcı-abone modelini kullanan işlemlerin birden fazla makinaya dağıtılabildiği çoklu bilgisayar mimarisi önerilmiştir. Kritik gerçek zamanlı işleme ihtiyacı olan işlerin karşılanabileceği bir sistem bu mimari ile gerçekleştirilebilir.

4. NESNE TESPİTİ VE ARKA PLANDAN AYRIŞTIRILMASI

Kameralarından alınan ham görüntü üzerinde doğrudan hata bulma yöntemlerinin uygulanması ile doğru ve verimli bir sonuç almak çok zordur. Ham görüntü çeşitli ilgi alanlarını içerebilir. İlgili alanlar ve arka planın birbirinden ayrılarak, ilgili alanlar üzerinde detaylı işlemler yapılabilir. Ham görüntü üzerinde ilgili alanlar ayrılmadan hata kontrolünde önemi olmayan gereksiz alanlarında algoritmalara katılması hem hesaplama zamanını hem de doğruluk oranlarını büyük ölçüde olumsuz olarak etkiler. Farklı ilgi alanlarında farklı algoritmaların çalıştırılması da karşılaşılan bir durumdur. Tüm bu nedenlerden dolayı incelenecek bölgenin doğru ve hızlı şekilde arka plandan ayrılması gerekir.

Bölütleme işlemi yapılmak istenen görüntü üzerinde ilgilenilen bölümlerin çıkarılması işlemidir. İlgili alanların arka plandan ayrılır ve sonraki işlem adımları için girdi oluşturur. Görüntü bölütleme, görüntü işlemenin ana dallarından biridir ve birçok görevde önemli bir rol oynar. Literatürde farklı problemlerin çözümü için birçok bölütleme algoritmaları geliştirilmiştir. Geleneksel bölütleme yöntemleri, eşikleme (thresholding), kenar algılama (edge detection), havza dönüşümü (watershed transformation) ve bölge çıkarma (region extraction) veya bunların bir kombinasyonunu temel alır. Standart yöntemler, düşük kontrastlı ve gürültülü görüntülerde doğru sonuçlar sunmaz. Bu bağlamda birçok algoritma geliştirilmiştir. Nesnenin ve arka planın yoğunluk değerleri çok yakın olduğunda istenen bölütleme sonuçlarını elde etmek zordur.

Bir nesnenin düşük kontrastlı bir görüntüden bölümlere ayrılması, görüntü işleme alanında zorlu bir görevdir. Klasik segmentasyon yöntemleri istenen sonuçları vermez. Klasik yöntemler çoğunlukla görüntüleri düşük kontrastlı sınırlar veya kenarlarla bölümlere ayırmada başarısız olur. Bu çalışma ile, uyarlanabilir eşik algoritması ve morfolojik segmentasyona dayalı yeni bir görüntü bölütleme yöntemi önerilmiştir. Önerilen yöntem, gerçek zamanlı olarak düşük kontrastlı görüntüler için yüksek ve hızlı bir sonuç sağlar.

Genel olarak bölütleme yöntemleri 5 ana gruba ayrılabilir. Bunlar

- Eşikleme (Thresholding)
- Kenar Tespiti (Edge Detection)
- Bölge Tabanlı (Region Based)
- Özellik Tabanlı Kümeleme (Feature Based Clustering)
- Model Tabanlı (Model Based)

(Yogamangalam and Karthikeyan 2013)

4.1 İlgili Çalışmalar

Issac vd. (2015) dijital fundus görüntülerinden glokom tespiti için otomatik bir görüntü işleme yöntemi sunar. Optik disk ve kabın segmentasyonuna yönelik yöntemleri, uyarlanabilir eşığe dayanmaktadır. Sabit eşığın kullanıldığı mevcut yöntemlerden farklı olarak, önerilen yöntemin uyarlanabilir doğası, sistemin doğruluğunu artırmaya yardımcı olur ve çeşitli niteliklerde çok çeşitli görüntülere uygulanabilir.

Wang vd. (2013) hünnap yaprağı görüntülerinin arka planını ve ön planını analiz eder. Çevrimiçi bir sistemden rastgele çıkarılan bir yaprak görüntüsündeki yaprakları segmentlere ayırabilen yeni bir uyarlanabilir eşik algoritması öneriyorlar. Bu algoritma, örtüşen laminalar içeren ve yaprak bölgesinin kendisinde eşit olmayan gri tonlamaya sahip karmaşık yaprak görüntülerini bölümlere ayırırken bir avantaja sahiptir. Algoritmaları, hünnap yaprağı görüntülerini gerçek zamanlı video sistemleriyle bölümlere ayırmada uygulanabilir ve etkilidir. Algoritma net, pürüzsüz ve doğru kenar görüntüleri elde edebilir. Algoritmaları, başlangıçta bir tümörü segmentlere ayırmak için kullanılan SVM, havza ve dağınık veri yaklaşımının bir kombinasyonudur.

Foruzan ve Chen (2016) bir doku sınırının yakınındaki bir görüntünün yoğunluk profilinin bir adım/rampa fonksiyonu ile modellendiğinden bahseder. Ancak, düşük kontrastlı görüntülerde, heterojen doku dokularında ve kısmi hacim etkisinin olduğu durumlarda çalışmaz.

Zhang ve Ge (2008), hareketli görüntü dizileri üzerinde arka plan modelinden motive olmuşlardır, düşük kontrastlı sınırlara veya kenarlara sahip görüntüler için ağırlık tabanlı

bir bölütleme yöntemi tanıtılmış ve uygulanmıştır. düşük kontrastlı sınırlar veya kenarlar. Farklı kontrast veya yoğunlukların etkisini azaltmak için, geometrik ve fotometrik efektlerin ticaretini yapan görüntünün her pikseline bir ağırlık fonksiyonu tanımlanır ve uygulanır.

Rahman ve Islam (2013) görüntü bölütleme için havza algoritmasının değiştirilmiş bir versiyonunu önermektedir. Yöntemleri, amacı geleneksel watershed algoritmasının segmentasyon probleminin üstesinden gelmek olan watershed algoritması ile uyarlamalı eşik ve maskeleme işlemine dayanmaktadır. Yöntemleri daha az hesaplama karmaşıklığına sahiptir, bu da onu gerçek zamanlı uygulama için uygun hale getirir.

Mevcut çalışmalar, düşük kontrastlı görüntülerde segmentasyonun zorlu bir problem olduğunu göstermektedir. Çoğu kesin sonuç veremez. Pek çok bilgisayarla görme görevi için doğru ve gerçek zamanlı çalışabilen bir segmentasyon yöntemi arzu edilir. Gerçek zamanlı ve düşük kontrastlı görüntülerle ilgili sorun, önerilen bölütleme yöntemi ile çözülmüştür.

4.2 Segmentasyon Yöntemleri

Görüntü bölütleme, bilgisayarla görme ve görüntü analizinde önemli bir bölümdür. Son yıllarda sanayi, tarım, tıp, askeri ve diğer alanlarda geniş bir uygulama alanına sahiptir. Görüntü bölütleme, görüntüyü birkaç anlamlı, örtüşmeyen bölgeye ayırmak için belirli kriterlere göre benzerliği ifade eder. Görüntü bölütlemenin amacı, orijinal bir görüntüyü homojen bölgelere ayırmaktır. Diğer görüntü işleme yöntemleri için ön işleme aşaması olarak uygulanabilir. Görüntü işleme için görüntü bölütleme yöntemleri için çeşitli yaklaşımlar mevcuttur.

Görüntü işleme uygulamalarının büyümesiyle birlikte görüntü bölütleme, görüntü işlemenin önemli bir parçası haline geldi. Bir görüntüyü segmentlere ayırmanın en basit yöntemi eşiklemedir. Eşikleme yöntemi kullanılarak, bir görüntünün bölütlenmesi, yoğunluk değerleri eşik üzerinde olan tüm piksellerin bir ön plan değerine sabitlenmesiyle yapılır. Kalan pikseller bir arka plan değerine ayarlanır. Bu teknik, gri

tonlamalı görüntülerden ikili görüntüler elde etmek için kullanılabilir. Geleneksel eşikleme teknikleri tüm pikseller için global bir eşik kullanırken, adaptif eşikleme eşik değerini görüntü üzerinde dinamik olarak değiştirir.

Eşikleme algoritması bölütleme için en basit yöntemlerden biridir. Eşikleme, bir eşik değeri seçilerek altındaki ve üstündeki değerlere göre iki seviyeli bir çıktı oluşturmak işlemidir. Bu yöntem ile sadece iki küme oluşur. Belirlenen eşik değerinin altındaki tüm pikseller sıfıra ve üstündeki tüm pikselleri bire dönüştürülür. Sonucunda ikili (binary) bir görüntü oluşur. Bu çalışma, bir görüntünün kontrastına, dokusuna, çözünürlüğüne vb. dayalı olarak ilgili nesneyi doğru çıkarmak için uygun yöntemi seçmek için araştırma sunar.

4.2.1 Global eşikleme

Global eşikleme, eşik değerinden büyük olan piksellerin beyaz olarak ve eşik değerinden küçük veya ona eşit olan piksellerin siyah olarak ayarlanması anlamına gelir. Ya da tersine, eşik değerinden büyük pikseller siyah olarak ayarlanır ve eşik değerinden küçük veya ona eşit pikseller beyaz olarak ayarlanır. İkisi arasındaki fark, ikisinin sunum biçiminde farklı olmasıdır.

Girdi görüntüsünün I , yüksekliğin H ve genişliğin W olduğunu varsayıldığında; $I(r, c)$ I girdisinin, c sütununun, r satırındaki gri piksel değerini temsil eder. $0 \leq r < H$ ve $0 \leq c < W$ global eşikleme işleminden sonra çıktı görüntüsü O olarak ifade edildiğinde ve $O(r, c)$ O 'nun c sütunun, r satırındaki gri değerini denklem (4.1)'de gösterildiği gibi temsil eder (Zuodong and Handong 2019) :

$$O(r, c) = \begin{cases} 255, & I(r, c) > thresh \\ 0, & I(r, c) \leq thresh \end{cases} \text{ veya } O(r, c) = \begin{cases} 0, & I(r, c) > thresh \\ 255, & I(r, c) \leq thresh \end{cases} \quad (4.1)$$

Pikseller seçilen değerden büyük ise 1, küçük ise 0 olarak belirlenir. Sonuçta siyah ve beyazdan oluşan ikili (binary) bir görüntü elde edilir.

Global eşikleme, oldukça hızlı bir yöntem olarak en çok tercih edilen segmentasyon yöntemlerinden biridir. Histogram, iki pik olması durumunda çok iyi sonuçlar gösterir. Küresel eşik tabanlı bölümleme, görüntü üzerindeki uzamsal bilgileri göz ardı eder. Çevresel etkilerden dolayı ilgili nesnelerin yakalanan görüntüler üzerindeki parlaklığı homojen olamaz ve bu da küresel eşik için segmentasyon sürecini zorlaştırır. Global eşiklemenin önemli bir sorunu eşik değerin seçimidir. Manuel olarak optimize edilmiş eşik değeri bile, homojen olmayan kenar frekans geçişleri nedeniyle segmentasyon işlemi için doğru olamaz.

4.2.2 OTSU eşikleme

Bu yöntem, Nobuyuki Otsu ve diğerlerinin adını almıştır (Otsu 1979). Otsu'nun yöntemi, gri tonlamalı bir görüntüyü ikili bir görüntüye dönüştürme yeteneğine sahiptir. Bir görüntünün yerel eşik değerini uyarlamak için bu yöntem çok temel bir yöntem olarak adlandırılabilir. Otsu'nun yöntemi, sınıf içi varyansı en aza indirebilecek eşik değeri arar. Sınıf içi varyans, iki sınıfın ağırlıklı varyans toplamı olarak tanımlanabilir. Sınıf içi varyansı elde etmek için aşağıdaki denklem (4.2) kullanılır.

$$\sigma_w^2 t = \omega_1(t) \sigma_1^2 t + \omega_2(t) \sigma_2^2 t \quad (4.2)$$

$\omega_1(t)$ ağırlıkları, t eşiğiyle ayrılan iki sınıfın olasılıklarını ifade eder. σ_1 ve σ_2 , bu iki sınıfın varyanslarıdır. Otsu'nun yönteminde kullanılan aşağıdaki denklem (4.3, sınıf içi varyansın en aza indirilmesi ve en üst düzeye çıkarılmasının neredeyse benzer olduğunu açıklar.

$$\sigma_b^2 t = \sigma^2 - \sigma_w^2 t = \omega_1(t) \omega_2(t) [\mu_1(t) - \mu_2(t)]^2 \quad (4.3)$$

ω_i , μ_i sınıf ortalamasının sınıf olasılıklarını ifade eder. Bu tür sınıf olasılıkları histogram t yardımıyla ölçülür. Sınıf olasılıkları hesaplamak için aşağıdaki denklem (4.4) kullanılır.

$$\omega_1(t) = \sum_0^t p(i) \quad (4.4)$$

Otsu'nun yöntemindeki sınıf ortalaması şu şekilde tanımlanır (denklem (4.5):

$$\mu_1(t) = \frac{[\sum_0^t p(i) x(i)]}{\omega_1} \quad (4.5)$$

Bu denklemde, $x(i)$, i 'ninci histogram bölmesinin merkezinde yer alan değeri ifade eder. Otsu'nun yöntemi, daha önce tartışılan yöntemi kullanarak μ_2 ve ω_2 'yi de hesaplayabiliyor. Bu iki parametre μ_2 ve ω_2 , t 'den büyük kutular için histogramın sağ tarafını çıkarmak için ölçülür. Bu hesaplamalar yinelemeli olarak gerçekleştirilir ve bu da aşağıda tartışılan etkili bir algoritmaya yol açar.

Adım 1. Her yoğunluk seviyesinin histogramı ve olasılıkları hesaplanır.

Adım 2. Başlangıç değerleri μ_0 ve ω_0 ayarlanır.

Adım 3. Tüm olası eşikler $t=1 \dots$ yoğunluk için bu adımlar tekrarlanır.

Adım 4. Elde edilen sonuç ω_t ve μ_t 'yi güncellemek ve ayrıca $\sigma_b^2 t$ 'yi hesaplamak için kullanılır.

Adım 5. Maksimum eşik değeri elde edilir.

Adım 6. İki maksimum ve bunlara karşılık gelen eşik değerleri hesaplanır ve saklanır.

Adım 7. Son olarak, bu iki eşik değerinin ortalama değeri kullanılarak istenen eşik değeri elde edilir.

Otsu'nun yönteminde, algoritma görüntünün iki piksel sınıfına ayrıldığını varsayıyordu: ön plan ve arka plan. Daha sonra, ilgili sınıflar arası varyansı en aza indirmek için bu iki sınıf ayrıldı ve bu da optimum eşiğin hesaplanmasına yol açtı. Bu yöntem her zaman olasılık yoğunluk fonksiyonundan bağımsızdır. Ancak, bu yöntemle gri düzey değerlerinin bimodal dağılımı varsayılmıştır. Bu varsayım, bu yöntemin ana dezavantajıydı. Ayrıca sınıflar eşit olmadığında eşik değerini belirlemede başarılı değildir (Roy vd. 2014).

4.2.3 Adaptif eşikleme

Bir görüntünün farklı alanlarda farklı aydınlatma koşulları varsa adaptif eşikleme faydalı olabilir. Burada algoritma, etrafındaki küçük bir bölgeye dayalı olarak bir pikselin eşiğini belirler. Böylece, aynı görüntünün farklı bölgeleri için farklı eşikler elde ederiz ve bu da değişen parlamaya sahip görüntüler için daha iyi sonuçlar verir.

Adaptif eşikleme yönteminde, komşu piksellerin aralık, varyans veya yüzeye sığdırma parametreleri gibi bazı yerel istatistiklere dayalı olarak her piksel için bir eşik hesaplanır. Arka plan çıkarma, su akış modeli, piksel değerlerinin ortalama ve standart türevi ve yerel görüntü kontrastı gibi farklı şekillerde yaklaşılabılır. Yerel eşikleme tekniklerinin bazı dezavantajları, bölge boyutuna bağlı, görüntü özelliklerine bağlı ve zaman alıcıdır. Bu nedenle, bazı araştırmacılar hem global hem de yerel eşikleme yöntemlerini uygulayan hibrit bir yaklaşım kullanır ve bazıları morfolojik operatörler kullanır. Niblack (1986), Sauvola vd (1997) yerel varyans tekniğini kullanırken, Bernsen (1986) yerel blok içinde orta kademe değeri kullanır.

Niblack (1986) ve Sauvola vd. (2000) yerel varyans tekniğini kullanır. Bu yöntemlerde eşik, $w \times w$ boyutunda bir pencere içinde yerel ortalama $m(x,y)$ ve standart sapma $\delta(x,y)$ temel alınarak hesaplanır. Sauvola vd. yöntemi, özellikle lekeli ve kötü aydınlatılmış belgeler için Niblack yönteminin geliştirilmiş halidir.

Bu yöntem 1986 yılında Niblack tarafından önerilmiştir. Her pencere için eşik değeri, o pencere içindeki piksellerin ortalama (m) ve standart sapma (σ) değerlerine göre hesaplanır. Eşitlikte (denklem (4.6)) k , Niblack tarafından önerilen -0,2 olarak alınır ve pencere boyutu kullanıcı tarafından önceden belirlenir. Ancak, boş pencerelerde ikileştirme siyah gürültüsü de üretir.

$$T = m + k \times \sigma \quad (4.6)$$

Sauvola Yöntemi: Bu yöntem 1997'de Sauvola ve diğerleri tarafından önerilmiştir. Bu yaklaşım aslında Niblack yönteminden miras alınmıştır. Siyah gürültü probleminin üstesinden başarıyla gelebilir. Eşikleme formülü aşağıdaki denklem (4.7) gibidir:

$$T = m * (1 + k \times (\frac{\sigma}{R - 1})) \quad (4.7)$$

Burada k , [0.2, 0.5] aralığında bir kontrol faktörüdür, R önceden belirlenmiş bir görüntü gri seviye değeridir. Yazar, $k=0.2$ ve $R=125$ önermiştir. Metin ve arka plan arasındaki görüntü kontrastı nispeten küçük olduğunda bu yöntem daha az etkilidir.

Nick Yöntemi: Bu yöntem 2010 yılında Hurshid ve diğerleri tarafından önerilmiştir. Nick yöntemi, Niblack yönteminden geliştirilmiştir. Düşük kontrast sorununu eşik değerini aşağı kaydırarak çözmeye çalıştı. Eşikleme formülü aşağıdaki denklem (4.8) gibidir:

$$T = m + k \times \sqrt{\frac{(\sum P_i^2 - m^2)}{NP}} \quad (4.8)$$

Burada k, [-0.1, -0.2] aralığında bir kontrol faktörüdür, P_i = görüntü pikseli gri değeri ve NP görüntüdeki toplam piksel sayısıdır. $k=-0.1$ olarak önerilmiştir. Nick yönteminin önceki yöntemlere göre en iyi performansı verdiğini iddia etmiştir. Ancak, düşük kontrastlı görüntü sorunu tam çözülemediği.

Adaptif Eşikleme (Adaptive threshold) eşikleme işlemi verilen blok büyüklükleri içinde uygular. Bu sayede görüntü üzerindeki frekans geçişlerini bölgesel olarak belirler. Örnek için çeşitli blok ve alfa değerleri seçilmiştir. Alfa değeri hassasiyeti belirler. Bölütleme işlemi uygulamadan önce smoothing işleminin yapılması istenmeyen gürültülerin bastırılmasını sağlayacaktır.

Görüntüde nesne çıkarımı için homojen olmayan kenar frekans geçişlerinin üstesinden gelmek için adaptif eşikleme (adaptive thresholding) kullanılabilir. Adaptif eşikleme, komşu pikselleri dikkate alarak görüntüdeki tüm pikseller için eşik değerini hesaplar. Mevcut yöntemlere göre çok hızlı ve doğru sonuçlar üretebilir.

Son yıllarda, ikili bölümlendirme ve çok etiketli daha güçlü ve esnek olan derin öğrenme ağlarıyla başarılı bir şekilde modellenmiştir. Dezavantajı olarak modeli eğitmek için zamana, uzmanlığa ve çok miktarda veriye ihtiyaç vardır.

Adaptif eşikleme kullanmanın çeşitli avantajları vardır. Birincisi, geleneksel eşikleme tekniklerinden daha iyi sonuç verir. Yanlış pozitifler (false positives) üretme olasılığı, diğer standart eşikleme yöntemlerinden düşüktür. İkincisi, arka plan gürültüsüne karşı daha az hassastır. Bunun nedeni, eşik maskesinin görüntünün tamamına değil yalnızca yüksek frekans geçişli alanlara uygulanmasıdır. Son olarak, görüntünün yalnızca küçük bir kısmı analiz edildiğinden hesaplama açısından verimlidir. Bu avantajlara rağmen, adaptif eşiklemenin dezavantajları da vardır. Birincisi, algoritmanın parametrelerini

ayarlamak zor olabilir. İkincisi, her zaman iyi sonuç vermeyebilir ve bazen yanlış negatifler (false negatives) üretebilir.

4.2.4 Canny edge detector

Canny (1986) makalesinde kenar algılayıcılarının iki özel performans kriterini optimize etmesi gerektiğini öne sürdü. İlk olarak, kenar algılayıcı iyi bir sinyal-gürültü oranına sahip olmalıdır, böylece görüntü kalitesi düşük olduğunda bile kenarların algılanabilmesi sağlanır. İkinci olarak, kenar algılayıcıları, yüksek derecede konumsal doğruluk gerektiren sonraki görsel süreçleri desteklemek için kenarları doğru bir şekilde lokalize etmelidir. Canny, optimal bir kenar algılayıcısının hem sinyal-gürültü oranını hem de yerleştirmeyi en üst düzeye çıkarması gerektiğini öne sürdü ve bu kriterler için matematiksel ifadeler türetti. Ayrıca, kenar algılayıcısının düzgünlüğünü sınırlamayı gerekli buldu. Ortaya çıkan kısıtlı optimal filtre, bir gauss türevine benzerdi. Bu kriterlere dayanarak, optimal adım kenar algılayıcısının bir gaussian türevine benzer olduğunu iddia etti. Canny, kenar algılama operatörünün performansını yargılamak için üç kriter önerdi: SNR kriteri, yerleştirme kesinlik kriteri ve tek kenar yanıt kriteri ve kenar algılama operatörünü çıkardı.

Geleneksel Canny kenar algılama algoritması, kısa çalışma süresi, nispeten basit hesaplama süreci ve diğer kenar algılama operatörlerinden daha iyi algılama sonuçları nedeniyle yaygın olarak kullanılmaktadır. Adımlar temel olarak aşağıdaki dört adıma ayrılabilir (Li ve Ding 2011):

Adım 1: Görüntüyü bir Gauss fonksiyonu ile yumuşatmaktır. Gauss filtreleme gürültü giderme ve görüntüyü yumuşatmak için kullanılır ve orijinal görüntüden dönüştürülür. σ standart sapmadır ve düzgünlük derecesini kontrol etmek için kullanılır σ küçük olduğunda, konumlandırma kenarı yüksek doğruluktadır, büyük olduğunda, görüntünün aşırı düzgün olmasına, bazı yararlı bilgilerin kaybolmasına ve hesaplama miktarının artmasına neden olabilir. Bu nedenle, yumuşatma parametresi uygun şekilde seçilmelidir (denklem (4.9)).

$$G = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \quad (4.9)$$

Adım 2: Birinci dereceden kısmi türevin sonlu farklar formülü, görüntü gradyanının (yatay G_x ve dikey G_y) yanı sıra azimut açısının genliğini ve yönünü hesaplamak için kullanılır (denklem (4.10)).

$$\theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (4.10)$$

Adım 3: Yalnızca birkaç ince çizgi bırakarak kenar olmayan pikselleri ortadan kaldıran maksimum olmayan bastırma.

Adım 4: Kenar bağlantısı için çift eşik kullanılır ve maksimum olmayan bastırma işlemiyle elde edilen kenarı daha fazla tespit etmek için yüksek eşik düşük eşik seçilir.

Son olarak kenar bağlantısı yapılır. Görüntü kenar konturu, güçlü kenar ile referans olarak birleştirilir. Görüntü kenarının uç noktasına bağlanırken zayıf kenarda devam edilebilecek kenar noktası aranır ve böylece görüntünün tam kenar bilgisi elde edilir.

Geleneksel Canny kenar algılama algoritması, pratik mühendislikte daha yaygın olarak kullanılmasına rağmen, iyileştirilmesi gereken iki yön vardır. İlki, geleneksel algoritmanın görüntünün gradyanını hesaplamak için 2x2 komşu alanın birinci dereceden sınırlı farkını benimsemesidir. Hesaplaması kolaydır, ancak gürültüye karşı daha hassastır. 45° ve 135° yönlerindeki sapmaya katılmadığı için gerçek uç bilgisini kaybetmek kolaydır. İkincisi, geleneksel Canny algoritmasının çift eşiklerinin sabit bir değer ayarlanmasıdır. Çok kenarlı yapıya sahip görüntüler için, geleneksel Canny algoritmasının uyarlanabilirliği ideal değildir ve lokal karakteristik kenar bilgisini kaybetmek kolaydır (Rong vd 2014).

4.2.5 Watershed

Luc Vincent ve Pierre Soille tarafından tanıtılan algoritma, "daldırma" kavramına dayanmaktadır. Bir yüzey olarak kabul edilebilecek gri ölçekli bir I görüntüsünün her bir yerel minimumunun bir deliği vardır ve yüzey suya daldırılmıştır. Daha sonra, en düşük

yoğunluk değerinin minimumundan başlayarak, su kademeli olarak görüntü (yüzey) I'ın farklı toplama havzalarını dolduracaktır. Kavramsal olarak, algoritma daha sonra iki veya daha fazla farklı yerel minimumdan gelen suyun birleşmesi durumundan kaçınmak için bir baraj oluşturur. Bu daldırma işleminin sonunda, her bir yerel minimum, görüntünün (yüzey) havzalarına karşılık gelen barajlarla tamamen çevrelenir.

Watershed dönüşümü (Havza dönüşümü), sahip olduğu birçok avantaj nedeniyle, tıbbi görüntü bölütleme de dahil olmak üzere görüntü işlemenin birçok alanında yaygın olarak kullanılmaktadır. Bu basit, sezgisel bir yöntemdir, hızlıdır ve paralelleştirilebilir ve bir dizi işlemci için neredeyse doğrusal bir hızlanma rapor edilmiştir ve kontrast zayıf olsa bile görüntünün ayrı bölgelerde tam bir bölünmesini sağlar, böylece her türlü kontur birleştirme ihtiyacını ortadan kaldırır. Yüksek çözünürlüklü uzaktan algılama görüntüsünü bölütlemek için bu yöntemi kullanmak uygundur. (Kaur 2014)

Watershed algoritmasının temel üç çeşit gerçekleştirim yöntemi vardır. Bunlar: - Mesafe Dönüşümü Yaklaşımı (Distance Transform Approach), - Gradyan yöntemi (Gradient method), - İşaretçi Kontrollü Yaklaşım (Marker Controlled Approach).

Watershed dönüşümü, çok farklı görüntü bölütleme uygulamaları için yararlı kılan ilginç özelliklere sahiptir. Watershed dönüşümünün aşırı segmentasyon ve gürültüye karşı hassasiyet gibi çeşitli dezavantajları vardır, bu yüzden bunun üstesinden gelmek için işaretçi tabanlı (marker based) watershed tekniğini kullanarak bu sorunların üstesinden gelinmeye çalışılmıştır. Bu teknik, ön plan nesneleri ve arka plan konumlarını işaretler. Görüntünün bölünmesiyle elde edilen sonuçlar, görüntünün kendisinin bilgi içeriğine bağlı olduğundan genellikle çok öznedir. Bu sonuçların değerlendirilmesinde dikkate alınması gereken parametreler görüntüden görüntüye değişir.


4.3 Kovan Açısının Düzeltilmesi

Kovan hareket halinde iken mekanik etkilerden dolayı yalpa, eğilme yaparak zeminle belli bir açıda gelebilmektedir. Kovan arka plandan ayrılarak çıkarıldıktan sonra kovanın daha kolay incelenebilmesi için zemine dik konuma getirilmesi gerekir.

İlk Yöntem ayrılan kovan yüzeyinin içinde kalan alan ve piksellerden faydalanılarak eğimi bulan PCA (Temel Bileşen Analizi) yöntemidir. İkinci yöntem ise en uzun çizgiler üzerinden faydalanılarak uygulanmıştır. Kovan şekli itibariyle yan yüzeylerinde sağ ve solda olmak üzere 2 uzun çizgi çıkması beklenmektedir. Çizgi bulma yöntemlerinden faydalanılarak en uzun 2 çizgi bulunur ve zeminle yaptığı açıdan kovanın ne kadar eğim yaptığı tespit edilebilir.

4.3.1 PCA yöntemi ile eğilme açısının bulunması

PCA çok boyutlu veri kümelerinde kullanılan bir boyut düşürme tekniği. covariance matrisinin eigenvalue'lerini bularak ve veri kümesindeki varyansı maksimize ederek çalışır. PCA yönteminin geometrik yorumuna bakacak olursak, bu yöntemin verilerin çokça fazla değiştiği yönleri yansıttığı gözlemlenir. Bu yönler, en büyük öz değerlere uygun olarak kovaryans matrisinin öz vektörleri ile belirlenmektedir. Öz değerlerin büyüklüğü, öz vektör yönleri boyunca verilerin varyansı ile ilişkilidir. Örnek olarak Şekil 4.1'de iki boyutlu (x_1, x_2) bir veri seti alınır. Veri setinin ortalaması $\bar{x}$ ile temsil edilir. Verilerin dağılımı Şekil 4.1'da gösterilen noktalardır. Burada PCA yöntemi, verilerin hangi yönde (u_1, u_2) en çok değiştiğini yansıtmaktadır (Shokouh 2013).



Şekil 4.1 PCA'nın geometrik yorumu (Shokouh 2013)

Temel bileşenler analizinde, p sayıda değişken içeren bir veri matrisinden yine en çok p sayıda temel bileşen elde edilebilmektedir (denklem (4.11)).

$$Y_1 = a_{11} X_1 + a_{12} X_2 + \dots + a_{1p} X_p$$

$$Y_2 = a_{21} X_1 + a_{22} X_2 + \dots + a_{2p} X_p$$

.

.

.

$$Y_p = a_{p1} X_1 + a_{p2} X_2 + \dots + a_{pp} X_p$$

(4.11)

Burada $Y_1, Y_2, \dots, Y_p$ p sayıdaki temel bileşen ve a_{ij} , i. temel bileşen için j. değişkenin ağırlığını göstermektedir. Temel bileşen ağırlıkları (a_{ij}), aşağıdaki koşulları sağlayacak şekilde hesaplanmaktadır:


1. Birinci temel bileşen en çok, diğer bileşenler ise gittikçe azalan miktarlarda toplam varyansa katkıda bulunurlar.

$$2. a_{i1}^2 + a_{i2}^2 + \dots + a_{ip}^2 = 1 \quad (i=1,2,\dots, p)$$

$$3. a_{i1}^2 a_{j1}^2 + a_{i2}^2 a_{j2}^2 + \dots + a_{ip}^2 a_{jp}^2 = 0 \quad (\text{her } i \neq j \text{ için})$$

Oktay ve Alkan (2010) yukarıda verdikleri tanımlardan sonra temel bileşenler analizini “Görüldüğü gibi, temel bileşenlerin analizinde her bir bileşen analizdeki tüm bileşenlerin doğrusal bir fonksiyonu olarak hesaplanmaktadır. Türetilen temel bileşenler sırasıyla toplam varyansa maksimum katkıda bulunurlar. İkinci koşula göre temel bileşen ağırlıkları kareleri toplamının bir olması gerekmektedir. Bu koşulun sağlanabilmesi için analizdeki tüm değişkenlerin varyanstan arındırılması gerekmektedir. Diğer bir anlatımla orijinal değişkenlerin temel bileşenler analizi öncesi standartlaştırılması gerekmektedir. Zorunlu olan üçüncü koşul yeni değişkenlerin ölçeğini belirlemek için kullanılmaktadır. Çünkü temel bileşen ağırlıklarının ölçeğini değiştirerek varyansı artırmak mümkündür. Temel bileşenler hesaplanırken özdeğerlerin bulunmasından sonra önemli özdeğer sayısına karar vermek çok önemlidir. Bu amaçla birçok yöntem geliştirilmiştir. Bunlardan en basiti, standartlaştırılmış veri matrislerinin kullanılması halinde birden büyük değerli özdeğerin sayısı m sayısını vermektedir veya yaklaşık aynı mantığa dayanan koşulunun sağlandığı en küçük m değeri önemli temel bileşenlerin sayısı olarak alınmaktadır.” şeklinde ifade etmişlerdir.

PCA yöntemi görüntülerde bulunan nesnelerin yönlerini bulmak içinde kullanılabilir. Örnek bir uygulama aşağıda gösterilmiştir.



Şekil 4.2 Kontrast arka planlı örnek görüntülerde PCA ile açı hesaplama
(Anonymous 2013)

Test görüntülerinde nesnelerin arka plan ile zıt renklerle ayrıldığı ve nesnelerin kenarlarının çok düzgün şekilde ayrıştırıldığı görülür. PCA yöntemi bu örnek görüntülerde iyi sonuçlar verir. Kovan görüntüsü üzerinde uygulandığında ise kovan yüzeyi ile arka plan arasında keskin bir geçiş yoktur. Kenarlar girintili çıkıntılı şekilde çıkar.




Şekil 4.3 Kovan örnek görüntüsünde PCA ile açı hesaplama

PCA tekniği ile eğim bulma yöntemi kovan görüntüsünde uygulanmış ve eksenler çizdirilmiştir. Uygulanan PCA yöntemi ile kovanın eğimini bulma tekniği uygun sonuç vermemiştir. Kovan kenarları girintili çıkıntılı olarak arka plandan ayrılabilirdi için iyi sonuçlar vermediği tespit edilmiştir.

4.3.2 En uzun çizgiler ile eğilme açısının bulunması

Literatürde çeşitli çizgi bulma algoritmaları mevcuttur. En çok bilinenleri Hough yöntemidir. Son zamanlarda Hough Transform ile yapılan çizgi bulma algoritmalarına alternatif yöntemler bulunmuştur (Akinlar ve Topal 2011, Grompe ve arkadaşları 2012). Teorik olarak hareketli kovan görüntüsü üzerinde en uzun çizgileri bulan bir algoritma kullanılarak kovan hem arkaplandan ayrıştırabiliriz hem de eğim açısını bulabiliriz. Örnek bir kovan görüntüsünde uygulanmış çizgi algoritması Şekil 4.4’de verilmiştir.




Şekil 4.4 Kovan örnek görüntüsünde çizgi bulma yöntemi uygulanması

Kovan üzerinde sağ ve sol olmak üzere en uzun iki kenar bulunması beklenirken parçalı şekilde çok fazla çizgi oluşmuştur. Mevcut yöntemler geliştirilerek çizgilerin birleştirilmesi ya da belli açıda olanların uzunluğu ile ağırlıklı olarak ortalaması alınabilir. Mevcut hali ile en uzun çizgilerin eğimi bulunarak yapılacak kovan düzeltme işleminden istenilen sonuçlar alınamamıştır.


4.3.3 En küçük dikdörtgen yöntemi ile eğilme açısının bulunması

Bir resimde kapalı alanlarda en küçük dikdörtgeni bulmak için kapalı alanın en küçük ve en büyük x, y değerleri ile hesaplanabileceği düşünülebilir. Fakat bu yöntem yeterli değildir. Şekil 4.5’de örnek görüntüde mavi ile çizilmiş dikdörtgen bu yöntem ile elde edilmiştir. Fakat kırmızı çizgi ile çizilen dikdörtgen daha küçüktür.




Şekil 4.5 En küçük dikdörtgen yöntemi

Kırmızı ile çizilmiş dikdörtgeni elde etmek için convex hull (dışbükey zarf) yöntemi kullanılmalıdır. Convex hull elde edildikten sonra rotating calipers yöntemi ile en küçük dikdörtgen hesaplanabilir.




Şekil 4.6 'de önce convex hull sonrasında rotating calipers yöntemi uygulanarak en küçük dikdörtgen bulunmuştur



Şekil 4.6 Convex hull ve rotating calipers yöntemi

4.4 Kovan Tespiti ve Arka Plan Ayrılması İçin Önerilen Yöntem

Bu bölümde önerilen bölütleme yönteminin adımları detaylı olarak anlatılmaktadır. Yöntemin ana adımları Şekil 4.7'de verilmiştir. Bu bölümde önerilen bölütleme yönteminin adımları detaylı olarak anlatılmaktadır.



Şekil 4.7 Önerilen yöntemin adımları

Ham görüntüler çeşitli nedenlerle arka plan gürültülerini içerir. Smoothing filtresi, görüntüdeki bazı gürültüleri ortadan kaldırır ve kenar algılamının doğruluğunu artırır. Bu nedenlerden dolayı ön işleme adımı olarak smoothing uygulanır. Kenar olmayan gürültülerin bir kısmı ön işleme sonunda elimine edilir.

Adaptif eşikleme, her bölgenin piksel yoğunluklarındaki farklılığa dayalı olarak, istenen ön plan görüntü nesnelerini arka plandan ayırmak için kullanılır. Geleneksel eşikleme operatörü tüm pikseller için global bir eşik kullanırken, Adaptif eşikleme, eşiği görüntü üzerinde dinamik olarak değiştirir. Her piksel konumundaki eşik değeri, komşu piksel yoğunluklarına bağlıdır. Smoothing yapılmış görüntüye Adaptif eşikleme uygulanır. Adaptif eşikleme kullanmanın avantajı, nesnenin aydınlatması homojen olmasa ve düşük kontrastlı olsa bile ilgili nesnenin kenarlarının ortaya çıkarılmasıdır.

Daha sonra, eşiklenmiş görüntüden konturlar çıkarılır. İlgilenilen nesnenin şekli bilinir, bu nedenle kontur özelliklerinden elde edilebilir. Mantıksal değil (logical not) işlemi uygulandıktan sonra morfolojik kapatma (morphological closing) uygulanır. Nesnenin ilgili konturu doldurulur. Morfolojik aşındırma (morphological erode) işleminden sonra nesnenin maskesi elde edilir. Sonuç olarak, ilgili nesne segmentlere ayrılır.


Bu bölümde, düşük kontrastlı ve gürültülü görüntülerde nesne bölütleme yöntemini önermiştir. Önerilen yöntem askeri fişek kovanlarında uygulanmıştır. Elde edilen sonuçlar, önerilen yöntemin nesne bölütlemenin doğruluğunu iyileştirmede yardımcı olduğunu göstermiştir.

5. NESNE YÜZEY HATALARININ BİLGİSAYAR GÖRME TABANLI TESPİTİ

5.1 Gri Düzey Eş Oluşum Matrisleri (GLCM)

Doku, bir desen ya da desenlerin bir bölge üzerinde tekrarlanmasıdır. Bu desenler nitelik bakımından ince, kaba, pürüzsüz, rasgele ya da çizgili gibi değişik özelliklerde olabilirler. Doku özellikleri ikinci dereceden bir istatistik türüdür. Farklı yerlerdeki iki farklı piksel arasındaki gri seviyesi farklılıkları karşılaştırılır. Farklı dokular, doku özellikleri ortaya çıkarılarak bulunabilir. Doku özellikleri, GLCM, birinci dereceden eğim dağılımları, kenar eş oluşum matrisleri gibi çeşitli yollarla bulunabilir.

GLCM ikinci dereceden bileşik durum olasılık yoğunluk fonksiyonunun, $P(i, j | d, \theta)$, tahminine dayanır. Bu matris pikseller arasındaki uzaklık d ve açı θ iken gri seviyesi i 'den gri seviyesi j 'ye geçme olasılığını gösterir. Kare matris kullanılır ve desen özelliklerinin dönme ile değişmediğini garantilemek için genellikle $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° olacak şekilde dört yönde inceleme yapılır. Haralick bu dört yön için bulunan GLCM'den elde edilen özelliklerin ortalamasının alınmasını önermiştir. Uzaklık olarak genellikle $d = 1, 2$ değerleri tercih edilir.



Şekil 5.1 Gri düzey eş oluşum matrisi

Bu matrislerden görüntünün doku karakteristiğini içeren enerji, karışıklık, korelasyon, homojenlik ve entropi olmak üzere 5 adet özellik bulunur.

1. Enerji

$$\sum_{i,j} P_{ij}^2$$

2. Karşıtlık

$$\sum_{i,j} |i-j|^2 P_{ij}$$

3. Korelasyon

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

4. Homojenlik

$$\sum_{i,j} \frac{P_{ij}}{1+|i-j|}$$

5. Entropi

$$-\sum_{i,j} P_{ij} \log P_{ij}$$

Buradaki μ_x , μ_y , σ_x , σ_y değerleri, olasılık yoğunluk fonksiyonu P_{ij} 'nin satırları ve sütunlarının ortalaması ve standart sapmasıdır. GLCM'den elde edilen enerji özelliği görüntüdeki homojenliğin bir ölçüsüdür. Tekdüzelik veya açısız ikinci moment olarak da bilinir. Sabit görüntüler için enerji 1'dir. Karşıtlık özelliği görüntüde bulunan yerel değişimlerin miktarını gösterir. Bir piksel ve komşusu arasındaki yoğunluk zıtlığıdır. Sabit görüntülerde karşıtlık 0'dır. Korelasyon özelliği görüntüdeki gri seviyesi lineer bağımlılıklarının bir ölçüsüdür. Bir piksel ve komşusunun birbiriyle nasıl ilişkili olduğunu gösterir. Korelasyon özelliği birbirleriyle tamamen pozitif ilişkili görüntülerde 1 ve tamamen negatif ilişkili görüntülerde ise -1'dir. Homojenlik özelliği GLCM'deki elemanların dağılımının diyagonal GLCM'deki elemanların dağılımına yakınlığının bir ölçüsüdür. Entropi özelliği ise görüntüde bulunan gri seviyelerinin uzaysal düzensizliğinin düzeyini gösterir (Demirhan ve Güler, 2010).

Huang ve Ye mikro sprey meme ucundaki hataların tespiti için GLCM yönteminden faydalanan bir çalışma yapmışlardır. Geri yayımlı yapay sinir ağları kullanarak bir sınıflandırma yapmışlardır. %90,71 oranında başarı yakaladıklarını iddia etmişlerdir (Huang ve Ye, 2015). Yang ve arkadaşları (2014) TFT (thin-film transistor)'lerin kontrolü için bir yöntem geliştirmişlerdir. GLCM ve ileri beslemeli yapay sinir kullanarak bir algoritma geliştirmişlerdir ve Matlab ile uygulamasını yapmışlardır. %83,3 oranında

bir başarı elde etmişlerdir. Chondronasios ve arkadaşları (2016) alüminyum profiller üzerinde çizik ve kabarcık hatalarını bulmak için görüntü işleme tabanlı bir çözüm önermişlerdir. GLCM ve yapay sinir ağlarından faydalanmışlardır. Çeşitli GLCM özelliklerini kullanarak sonuçları değerlendirmişlerdir. %98,6'lık bir başarı elde ettiklerini iddia etmişlerdir. Hatalı bölgeyi karakterize etmek için GLCM özelliklerini, geometrik özellikleri ve momentleri kullanmışlardır. Sınıflandırma için bir geri yayımlı yapay sinir ağı kullanılmıştır. Geliştirdikleri yöntemleri Matlab ile uygulamaya geçirmişlerdir ve yaptıkları testlerde hata tespiti ve hata sınıflandırmada başarılı sonuçlar almışlardır. Rahejaa ve arkadaşları (2013) kumaş üzerindeki hataları bulmaya yönelik bir çalışma yapmışlardır. Genel olarak bulunan 2 yöntemi karşılaştırmışlardır. Bu yöntemler istatistiksel tabanlı olan GLCM ve dönüşüm bazlı Gabor' dur. GLCM sonucu çıkan istatistikleri hatalı ve hatasız kumaş örnekleri için değerlendirmişlerdir. Gabor filtresinin de farklı çekirdekler için denemişlerdir. Sonuç olarak çalıştıkları problem için GLCM yönteminin Gabor Filtre yaklaşımından daha iyi, daha hızlı ve hesaplaması daha kolay olduğunu savunmuşlardır.

5.2 Dalgacık Dönüşümü (Wavelet Transform)

Bayram vd. (2014) dalgacık dönüşümünü “Spektrum analizi ve zaman serileri metodu sinyal işleme tekniği olarak yaygın olarak kullanılmaktadır. Fourier dönüşümü, frekans içeriği ve spektrum bileşenleri hakkında bilgi sağlayan ve yıllardır bilinen en eski sinyal işleme tekniklerinden biridir. Bu dönüşüm tekniği, sinyali karmaşık üstel formda gösterebilen farklı sinüzoid bileşenlerine ayrıştırmaktadır. Bu nedenle, ani sinyal değişimlerine tepkisiz kalmaktadır. Bu dezavantajı yenmek için, sinyal belirli parçalara ayırarak her bir parçanın Fourier dönüşümünü alan Kısa Süreli Fourier Dönüşümü (KSFD) isimli bir teknik geliştirilmiştir. KSFD’de, fonksiyon, $x(t)$, bir pencere fonksiyonu olan $w(t)$ ile çarpılır ve Fourier dönüşümü hesaplanır. Pencere fonksiyonu τ kadar ötelenir ve Fourier dönüşümü tekrar hesaplanır.

KSFD’nin dezavantajı belirli bir pencere boyutu seçme gerekliliğidir. Bu nedenle sinyalin zaman-frekans uzayı gösterimi bilinmemektedir ve spektrum bileşenlerindeki ani değişim hala gözlenememektedir.


Bu yaklaşıma alternatif olarak sabit olmayan sinyallerin analizinde iyi bir sinyal süreksizlik lokalizasyonu sağlamak için dalgacık dönüşümü yöntemi geliştirilmiştir. Bir sinyale dalgacık dönüşümü uygulanırken, pencere boyutu ani değişiklikleri belirlemek için yüksek frekanslarda kısa, düşük frekanslarda uzun olarak seçilmektedir. Böylelikle frekans uzayında, spektrum bileşenleri ile sinyalin geçici karakteristiğini göstermek mümkün olmaktadır.

Dalgacık dönüşümü, KSFD de olduğu gibi sinyal dalgacık fonksiyonu ile çarpılmaktadır. Dönüşüm zaman-frekans sinyalinin farklı parçaları için ayrı ayrı hesaplanmaktadır. Dalgacık dönüşümünün temel amacı sinyali bir ölçek parametresi ile etiketlenebilen bir takım temel fonksiyonlara ayırmaktır. Böylelikle daha büyük sinyallerin sınırlı bir alanda analizi mümkün hale gelmektedir. Temel fonksiyon özgün ana dalgacık fonksiyonunun genişlemesi, daralması, ötelenmesi ile elde edilir. Diğer bir deyişle dalgacık analizi, ana dalgacık fonksiyonunun ötelenmiş ve ölçeklenmiş versiyonlara bölünmesidir.

Dalgacık analizi, sürekli dalgacık analizi ve ayırık dalgacık analizi olmak üzere iki farklı şekilde gerçekleştirilebilir. Ayırık dalgacık analizi daha kısa zaman alması ve bilgisayar ortamında analizlerin ayırık sinyaller ile yapılabileceğinden tercih edilmektedir. Dalgacık dönüşümünü gerçekleştiren en önemli faktör ayrışmanın seviyesini belirlemektir. Ayrışma seviyesi, orijinal sinyalin örnekleme frekansı ile ayarlanmaktadır. Ayırık dalgacık dönüşümünün temel prensibi, dijital sinyalin zaman ölçekli dijital filtre teknikleri kullanılarak elde edilmesidir.

Ayrık dalgacık dönüşümünde sinyal, aynı anda alçak ve yüksek geçiren iki süzgeçten geçirilmektedir. Bu süzgeçlerin kesim frekansları, sinyalin örnekleme frekansının dörtte biri olarak tasarlanmaktadır. Alçak geçiren süzgecin çıkışı yaklaşım (Y), yüksek geçiren süzgecin çıkışı ise ayrıntı (A) sinyali olarak adlandırılmaktadır. Yaklaşım ve ayrıntı sinyalleri, başlangıçtaki sinyalin yarısı kadar örnek içermekte ve sırasıyla sinyalin alçak ve yüksek frekans bilgisini içermektedir. Elde edilen sinyale tekrar bu süzgeçleme işlemi yapılırsa, başlangıçtaki sinyalin örnek sayısının dörtte biri kadar örnek içeren dört ayrı sinyal elde edilmektedir. Dalgacık paket dönüşümünün ikinci seviyesini oluşturan bu


sinyaller yaklaşımın yaklaşımı (YY), yaklaşımın ayrıntısı (YA), ayrıntının yaklaşımı (AY) ve ayrıntının ayrıntısı (AA) olarak bilinmektedir (Şekil 5.2).” şeklinde özetler.



Şekil 5.2 Bir sinyalin ikinci seviye dalgacık paket ayrışımı (Bayram vd. 2014)

Mohan ve Haripasad seramik fayanslarda yüzey hata kontrolü gerçekleştirmek için dalgacık dönüşümü tabanlı bir metodoloji önermişlerdir. Görüntü işleme ve özellik çıkarma işlemleri Haar Discrete Wavelet Transform (HDWT) yöntemi kullanılarak yapılmıştır. Önerilen metodoloji iki ana aşamadan oluşmaktadır. İlk aşamada referans görüntüsü olarak seçilen yüzeyi hatasız olan bir görüntünün ve test görüntüsü olarak seçilen yüzey kontrolü yapılacak görüntülerin dalgacık dönüşümünün hesaplanması yapılır. İkinci aşamada ise test görüntülerinin hatalı ve hatasız olarak ayrımı yapılabilmesi için öklit uzaklık bağıntısı ile referans görüntüsü arasında 16 adet benzerlik karşılaştırılmıştır. Yapılan testlerin sonucunda önerilen metodolojinin seramik fayansların kontrolünde %98,4 oranında başarımla verdiği sonucuna ulaşılmıştır. Önerilen metodolojiyi farklı fayans hata kontrolü yöntemleri ile karşılaştırmışlardır ve işleme zamanı açısından daha hızlı olduğunu iddia etmişlerdir (Mohan ve Haripasad 2015). Liu ve Yu (2014)'te çalışmalarında nesne yüzeylerindeki hataların optik kızılötesi cut-off filtresi ile otomatik tespitini gerçekleştiren bir çalışma yapmışlardır. Çalışmada karanlık bölge (dark field) ışıklandırma tekniği kullanılarak hatalı bölgelerin görüntü alma bileşenlerin tarafından görünürlüğü artırılmıştır. Algoritmalarında karışık öğrenme metotları yerine stationary wavelets transform algoritmasını kullanmışlardır. Bu sayede

%96 üzeri bir başarı elde edilmiştir. Xue-wu vd. (2011)'deki çalışmalarında parlak metal yüzeylerde hatalarının bulunması üzerine bir çalışma gerçekleştirmişlerdir. Otomatik hata bulma işini 4 aşamada özetlemişlerdir: Görüntü alma, ön işleme, öznelik çıkartma, sınıflandırma. Çalışmada metal yüzeylerdeki hata olmayan gürültüyü azaltmak ve yok etmek için dalgacık dönüşümü yöntemini kullanılmışlardır. Hataların tespiti ve bölütlenmesi için OTSU eşikleme algoritmasını kullanmışlardır. Son aşamada bölütlenmiş görüntüleri spektrum bazında 5 farklı sınıfa ayırmışlardır. Sınıflandırma yapmak için SVM (Support Vector Machine) yönteminden faydalanmışlardır. Geliştirdikleri algoritma yapılan uygulamada 7 farklı tipte hatayı sınıflandırmayı başarmıştır. Dalgacık dönüşümünün gürültü azaltmada başarılı sonuç aldıkları gözlemlenmiştir. Yang vd. (2016) manyetik karolar üzerinde dalgacık dönüşümü kullanarak (Stationary Wavelet Transform - SWT) yeni bir hata bulma yöntemi geliştirmişlerdir. Düzensiz arka planı yok etmek için Sobel filtresi kullanarak ön işlem uygulamışlardır. Dalgacık dönüşümü sonucunda ortaya çıkan alt bantlara alçak geçirgen filtre doğrusal olmayan geliştirme uygulayarak gürültüyü azaltmışlar ve hedef hata çeşitlerini daha belirgin duruma getirmişlerdir (Şekil 5.3). Yapılan simülasyon çalışmalarında %92,86'lık bir doğruluk oranı ve 0.5190 saniye ortalama işlem süresi elde etmişlerdir.



Şekil 5.3 Manyetik karo örnek hata ve tespiti (Yang vd. 2016)

5.3 Hu-Moments ile Hata Bulma

Şengür ve Türkoğlu (2004) hu-moments yöntemini şu şekilde “Momentler, uzun zamandır istatistik teorisinde ve klasik mekanikte kullanılmaktadırlar. İstatistikçiler moment olarak ortalama, varyans, çarpıklık oranı ve kurtosis kullanırlarken, mekanikçiler

momentleri ağırlık merkezi bulmada ve atalet momenti hesaplamada kullanırlar. 1960'ların başında Hu, matematiksel moment teorisinden yedi değişmez moment geliştirdi. Bu yedi moment, ölçeklendirme, döndürme ve dönüşüm işlemleri altında değişmemekte ve karakter tanıma gibi iki boyutlu örüntü tanıma problemlerinin çözümünde gözle görülür başarı sağlamaktadır. Böylece karakter tanıma, nesne tanıma, radar görüntülerinden uçak ve gemi tanıma gibi uygulamalar ortaya çıkmıştır.” özetlemişlerdir.

Klasik mekanikte tanımlanan momentlere benzer olarak iki boyutlu $(p+q)$ dereceli ve $f(x,y)$ dağılımlı bir görüntü için moment şöyle tanımlanır (denklem (5.1);

$$m_{pq} = \iint x^p y^q f(x, y). \partial x. \partial y \quad (5.1)$$

burada $p, q = 0, 1, 2, \dots$ değerlerini alabilir. Bu momentler genelde gürültülere bağlı olarak değişkendirler. Bunun sonucunda merkez momentleri tanımlanmıştır ve aşağıdaki gibi ifade edilir (denklem (5.2);

$$\mu_{pq} = \iint (x - \bar{x})^p (y - \bar{y})^q f(x, y). \partial(x - \bar{x}). \partial(y - \bar{y}) \quad (5.2)$$

Burada $\bar{x}$ şu şekilde tanımlanır (denklem (5.3)

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad \text{ve} \quad \bar{y} = \frac{m_{01}}{m_{00}} \quad (5.3)$$

olarak tanımlanır. Merkez momentleri, dönüşüm altında değişmezlerdir. Bazen momentlerin boyutlara bağlı olarak normalizasyonu istenebilir. Bu işlem μ_{00} moment değeri ile gerçekleştirilebilir. Böylece normalize merkez momenti (denklem (5.4);

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^r} \quad (5.4)$$

olarak tanımlanır. Burada $r = 1 + \frac{p+q}{2}$ dir.

Hu, normalize merkez momentlerini kullanarak yedi adet değişmez moment geliştirmiştir. Hu'nun geliştirdiği momentler şöyledir;

$$\varphi_1 = \eta_{20} + \eta_{02}$$

$$\varphi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}$$

$$\varphi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

$$\varphi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{03} + \eta_{21})^2$$

$$\varphi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

$$\varphi_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})$$

$$\varphi_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ - (\eta_{30} - 3\eta_{12})(\eta_{03} + \eta_{12})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

Bu şekilde kovan yüzeyinde bulunan her hatanın 7 adet özelliği bulunur ve bir hata çeşidi ile eşleştirilir. Bu özellikler bir SVM yapısına girdi olarak verilir. SVM eğitim kümesi ile eğitilir.

5.4 Görüntü İşleme Tabanlı Önerilen Metodoloji

Önerilen algoritma (Tural ve Samet 2019) şu adımları içerir: a) Bilateral filtreleme; b) Sobel filtreleme; c) Eşikleme; ve d) Morfolojik kapama.

a) Bilateral filtre: Gauss bulanıklaştırma, bir görüntüyü yumuşatmanın en basit yöntemidir; her çıkış görüntüsü piksel değeri, giriş görüntüsündeki komşularının ağırlıklı toplamıdır. Çekirdek bileşen, doğrusal kaydırma ile değişmez görüntü filtrelemeye temel işlem olan bir çekirdeğin konvolüsyonudur. Her çıkış pikseli konumunda, lokal ortalama yoğunluğu tahmin eder ve düşük geçişli filtrelemeye karşılık gelir. Gauss konvolüsyonu filtrelenen bir görüntü Paris vd. (2009) tarafından verilmiştir. Denklem (5.5:

$$GC[I]_p = \sum_{q \in S} G_\sigma(\|p - q\|)I_q \quad (5.5)$$

burada $G_\sigma(x)$, 2 boyutlu Gauss çekirdeğini gösterir, I_p , p piksel konumundaki görüntü yoğunluk değeridir, S , uzamsal etki alanı olarak adlandırılan tüm olası görüntü

konumlarının kümesidir, $|\cdot|$ mutlak değerdir ve $\|\cdot\|$ L2 normudur. $G_\sigma(x)$ denklem (5.6) olarak tanımlanır.

$$G_\sigma(x) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (5.6)$$

Gauss filtrelemesi, bitişik konumların yoğunluğunun ağırlıklı bir ortalamasıdır, burada ağırlık, merkez konumuna olan uzamsal mesafe ile azalır p, q pikselinin ağırlığı Gauss $G_\sigma(\|p - q\|)$ ile tanımlanır, burada σ komşuluk boyutunu tanımlayan bir parametredir.

Bilateral filtreleme, Gauss bulanıklaştırmanın geliştirilmiş versiyonudur ve kenarları korurken görüntüleri yumuşatma tekniğidir. İki taraflı filtre ayrıca Gauss konvolusyonuna oldukça benzeyen yakındaki piksellerin ağırlıklı ortalaması olarak da tanımlanır. Aradaki fark, iki taraflı filtrenin, yumuşatma sırasında kenarları korumak için komşularla olan değer farkını dikkate almasıdır. İkili filtrenin ana fikri, bir pikselin başka bir pikseli etkilemesi için yakın bir yerde olması ve benzer bir değere sahip olması gerektiğidir (denklem (5.7)).

$$GC[I]_p = \frac{1}{W_p} \sum_{q \in S} G_{\sigma_s}(\|p - q\|) G_{\sigma_r}(|I_p - I_q|) I_q \quad (5.7)$$

burada normleştirme faktörü W_p , piksel ağırlıklarının toplamının 1.0 olmasını sağlar (denklem (5.8)):

$$W_p = \sum_{q \in S} G_{\sigma_s}(\|p - q\|) G_{\sigma_r}(|I_p - I_q|) \quad (5.8)$$

σ_s ve σ_r parametreleri, görüntü I için filtreleme miktarını belirleyecektir. G_{σ_s} , uzak piksellerin etkisini azaltan bir uzamsal Gauss ağırlığıdır ve G_{σ_r} , yoğunluk değerleri I_p 'den farklı olduğunda piksellerin q etkisini azaltan bir Gauss aralığıdır.

Hata tespiti için yaygın bir yaklaşım, ön işleme adımında bir yumuşatma filtresi uygulamaktır. Bununla birlikte, yumuşatma işlemi, gereksiz gürültüyü ortadan kaldırarak sonucu iyileştirse de, yumuşatma, sorun için özellikle önemli olan bazı ince ayrıntıları da ortadan kaldırır. Önerilen algoritma, bu sorunu çözmek için ikili filtreleme kullanır. İki taraflı filtre, düzgün olmayan dokulu yüzeylerde harika sonuçlar sağlar. Gürültüyü ve homojen olmayan dokuyu bastırırken, kusurları ayırt edilebilir hale getirir. Çift taraflı

filtre, gürültüyü sıkıştırarak ve kusurları netleştirerek bir karikatürleştirici gibi görüntü üzerinde bir etki yaratır.

b) Bilateral filtreden sonra kusurlar tespit edilebilir. Birinci türev kenar dedektörü veya Sobel filtresi, yüzeydeki kusurları tespit etmek için kullanılır. Hesaplaması, yüksek frekansları tespit etmek için oldukça basit ve hızlıdır. Önerilen algoritma, gradyan büyüklüğünü hesaplar. Sobel filtresi genellikle gradyanı hesaplamak için iyi bir yöntem olarak kabul edilir. Sobel operatöründe iki çekirdek kullanılır. Sobel operatörü tarafından elde edilen kenar büyüklüğü, örnek verilerin özelliklerini hesaplamak için kullanılır. Hesaplama aşağıdaki denklemler (5.9 ve (5.10 kullanılarak yapılır Chondronasios vd. (2016).

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} * A, ve \quad (5.9)$$

$$G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix} * A \quad (5.10)$$

burada A orijinal görüntüdür. Gradyan görüntüsü denklem (5.11 olarak hesaplanır:

$$G = \sqrt{G_x^2 + G_y^2} \quad (5.11)$$

c) Eşikleme: Gradyan görüntüsüne global bir eşik uygulanır. Eşik değeri operatör tarafından ayarlanır. Sonuç olarak, kusurlu alanlar beyaz piksellerle gösterilir.

d) Morfolojik Kapanış: Gösterim için bazı yakın kusurlu pikselleri birleştirmek daha iyidir. Bu işlem morfolojik kapatma ile gerçekleştirilebilir.

6. DERİN ÖĞRENME YÖNTEMLERİ İLE YÜZEY HATALARININ TESPİTİ

Yapay görme sistemleri endüstriyel uygulamalarda çok popülerdir. Bu sistemler sayesinde ürünlerin standartları garanti altına alınmakta, doğruluk ve performans artırılmakta, maliyetler düşürülmektedir. Yapay görme sisteminin kullanım alanlarından biri endüstriyel ürünlerin kalite kontrolüdür. Endüstri uygulamalarında üretim sürecinin son aşaması kalite kontroldür.

Makine görme sistemleri, üretim sürecinde kameralar tarafından çekilen görüntüleri gerçek zamanlı olarak işleyerek ürünleri sınıflandırır ve yüzeylerindeki kusurları segmentlere ayırır. Bu yüzden görüntülerin kalitesi çok önemlidir. Doğruluğu etkileyen bir diğer faktör de ürün yüzeyinin özelliğidir. Askeri kovan gibi bazı ürünler metalik, silindirik, homojen olmayan dokuya ve yüksek yansıtıcı yüzeye sahiptir. Metal yüzey, yüksek yansıma katsayısına ve düzgün olmayan dokuya sahiptir. Bu tür doku, gerçek kusurlara benzer rastgele desenler içerir. Bu özellikler, ürünlerin yüzeyindeki gerçek kusurları tek tip olmayan ürün dokusundan ayırt etmeyi zorlaştırır.

Yüzey kalitesini tespit etmek için yapay görme sistemlerinde kullanılmak üzere birçok geleneksel algoritma geliştirilmiştir. Geleneksel yapay görme algoritmaları, yüksek yansıtıcı yüzeylere, rastgele yapılara ve dokulara sahip nesneler için istenen sonuçlara ulaşamadı ve gerçek bir ortamda kullanmak için kusurları tanımlamayı zorlaştırdı. Geleneksel görüntü işleme algoritmalarını kullanarak bazı yüzey kusurlarını ürün yüzey dokusundan ayırt etmek çok zordur. İnsan duyusu bu tür kusurları tespit edebilir. Derin öğrenme, insan duyusu gibi davranmaya başlar ve bu tür kusurları tespit edebilir. Ancak derin öğrenme teknikleri ile ilgili mevcut çalışmalarda elde edilen doğruluk, askeri fişek kovanları gibi yüksek doğrulukta hata tespiti talep edilen sistemler için yeterli değildir. Görüntü işleme teknikleri, ürün dokusundan ayırt edilmesi kolay olduğu gibi yapısal kusurlar üzerinde daha iyi bir performansa sahiptir. Öte yandan, derin öğrenme teknikleri, insan duyusunu taklit eder ve ürün dokusuna benzer çok kusurları tespit ederek daha iyi performans gösterir. Dolayısıyla, derin öğrenme teknikleri ile daha yüksek doğruluğa ulaşılabilceği sonucuna varılabilir.

Ürün dokusunu kusurlu dokudan ayırt etmek zorlu bir problemdir. Daha önceki çalışmalarda, bu problem görüntü işleme (Tural ve Samet 2017) ve derin öğrenme teknikleri (Samet ve Tural 2020) ile çözülmeye çalışılmış ve uygun şekilde %97 ve %96 doğruluk elde edilmiştir. Kusurlu askeri fişek kovanlarının sınıflandırılması için (Samet ve Tural 2020)'de önerilen derin öğrenme tekniği kullanılmıştır. NATO standartlarına göre (MIL-STD-636 1958, MIL-STD-651 1962) askeri fişek kovanlarının sınıflandırma doğruluğu %99'un üzerinde olmalıdır. Kovan yüzeyindeki kusurların segmentasyonu da çok önemlidir. Ancak, mevcut literatürde askeri fişek kovanları kusurlarını segmentlere ayıran herhangi bir çalışma bulunmamaktadır.

Bu çalışmada, doğruluğu artırmak için askeri fişek kovanlarının sınıflandırılması ve yüzeylerindeki kusurların bölümlere ayrılması için metodoloji önerilmiştir. Önerilen metodoloji kapsamında askeri fişek kovanlarının kusurlu olmayan, kusurlu ve etiketli/maskeli görüntü sınıflarına sahip veri setleri oluşturulmuş, askeri fişek kovanlarını sınıflandıracak ve yüzeylerindeki kusurları segmentlere ayıracak derin öğrenme modelleri önerilmiş, gerçekleştirilmiş, Elde edilen sonuçlar Doğruluk (Accuracy), Kesinlik (Precision), Geri Çağırma (Recall), F1-Skoru (F1-Score), Jaccard İndeksi (Jaccard Index, JI) ve Birlik Üzerinden Ortalama Kesişim (Mean Intersection over Union mIoU) metrikler kullanılarak değerlendirilmiştir.

Bu alt bölümde, derin öğrenme teknikleri kullanılarak üniform olmayan dokulara sahip yüzeylerde kusur tespiti, sınıflandırma ve bölütleme ile ilgili mevcut çalışmalar özetlenmiştir.

Samet ve Tural (2020) otomatikleştirilmiş yüzey kontrolü sistemleri için derin öğrenme yaklaşımını önerir. Yaklaşım, aktarım öğrenimi ve veri artırma dahil olmak üzere derin öğrenmede güçlü paradigmaların kullanımıyla başarılı bir sonuca sahiptir. VGG16 modeli kullanılarak %97 doğruluk elde edilmiştir. Sonuçlar, evrişimli sinir ağları (CNN'ler) kullanan makine öğrenimi modellerinin askeri fişek kovanları örneklerinde yüzey hatası tespiti yapabildiğini göstermektedir.

Jiang vd. (2020), X-ışını görüntülerinin dökümüne dayalı kusurları tanımak için zayıf denetimli bir CNN modeli önermektedir. Ayrıca, veri setini genişletmek için bu dikkat haritaları tarafından yönlendirilen yeni bir veri büyütme yöntemi önerilmiştir. Önerilen yöntem kullanılarak %95,5 test doğruluğu ve %96,0 geri çağırma elde edilmiştir.

Würschinger vd. (2020) derin öğrenme modelini ve transfer öğrenme yöntemini bir bilgisayarlı görü sisteminde kullanmak ve kaliteyi artırmak için bir üretim sistemine uygulamak.

Wang vd. (2020), X-ışını görüntülerinde alüminyum alaşımlı döküm kusurlarını tespit etmek için yeni bir derin öğrenme modeli önermektedir. Alüminyum alaşımları üzerinde derin öğrenme kullanarak kusur tespiti yapan bir başka makale de Chen ve arkadaşlarının çalışmasıdır (Chen vd. 2021). Yazarlar, alüminyum alaşımlarının çeşitli kusurlarının otomatik olarak tespit edilmesini sağlamak için bilgisayar vizyonu ve derin öğrenme tekniklerini kullanmayı önermektedir.

Westphal ve Seitz (2021), karmaşık transfer öğrenme kullanarak hata tespiti için CNN tabanlı makine öğrenme algoritmaları önermektedir. Karmaşık transfer öğrenme yöntemleri sunuldu ve %95,8 doğruluk elde edildi.

Wang vd. (2022), CNN'leri kullanan dört aşamalı bir hata tespit modeli önermektedir. İki kameralı otomatik optik kontrol sistemine sahip bir elektronik komponent üretim hattı modellenmiş ve önerilen model yüksek hassasiyet ve hıza ulaşmıştır.

He vd. (2019), sıcak haddelenmiş çeliklerdeki kusurları tespit etmek için CPN adlı yeni bir çerçeve önerdi. Sınıflandırma öncelikli ağ anlamına gelen bu çerçevede, ilk önce görüntüyü sınıflandırmak için kullanılan çok gruplu evrişimli sinir ağı (MG-CNN) adı verilen bir sınıflandırma ağı tanıtıldı. Bu sınıflandırıcının çıktısından, aday kusur bölgelerinin özellik haritaları, kusur tespiti gerçekleştirmek için yolo tabanlı bir kusur dedektörü ağına beslenir. Bu çerçeve, sıcak haddelenmiş çeliklerde ortalama %94'ün üzerinde bir kusur tespit oranı sağladı.

Zhang vd. (2021), gerçek zamanlı olarak karmaşık bir arka plana sahip görüntülerdeki yabancı nesneleri daha doğru bir şekilde segmentlere ayırmak için dikkat mekanizmasını tanıttıkları CNN tabanlı bir ağ sundular. Çalışmalarının sonucu olarak, dikkat mekanizmasının karmaşık görüntülerdeki zengin anlamsal özellikleri yakalama yeteneğini kanıtladılar ve bu da daha doğru bir ağ elde etmelerini sağladı.

CNN kullanarak farklı malzemelerdeki kusurları tespit eden çalışmalar da vardır. Hata tespit çalışmaları cam paneller (Pan vd. 2021), ahşap (Pan vd. 2021) ve kumaş (Seçkin ve Seçkin 2022, Yaşar vd. 2021, Uzen vd. 2021, Zhan vd. 2022, Fouda 2022) üzerindedir.

Mordia ve Verma (2022), yüzey kusurlarının tespiti için görüş sistemine dayalı bazı tekniklerin bir incelemesini sunar. Çelik ürünlerde görsel kusur tespiti ile ilgili görüntü işleme ve makine öğrenimi yöntemlerini içeren 48 çalışma gözden geçirildi.

Başka bir derlemede, Tulbure vd. (2022) nesne algılama modellerinin yapısal ve analitik avantaj ve dezavantajlarını sunar. İncelemede bölge bazlı CNN'ler, YOLO, SSD ve kademeli mimariler değerlendirildi.

Shi ve Chen (2021), toz yatağının katman bazında kusur tespit algoritmasını önermektedir. Hataların sınıflandırılması için CNN uygulanmış ve performansları değerlendirilmiş ve karşılaştırılmıştır. Önerilen algoritma, tek bir görüntüdeki kusurları %99,44 algılama oranıyla 15,67 ms'de ayıklar.

Xu vd. (2021) tünel yüzeylerindeki kusurları tespit etmek ve segmentlere ayırmak için orijinal Mask R-CNN'ye dayalı yeni bir çerçeve önerdi. Bu çerçevede, Mask R-CNN ağının düşük seviyeli özellik çıkarma kabiliyetini geliştirmek için Path Augmentation Feature Pyramid Network (PAFPN) adlı yeni bir modül tanıttılar. Ek olarak, temel ağın segmentasyon sonuçlarını iyileştirmek için ağı bir kenar algılama dalı ile genişlettiler.

Xiao ve Buffiere (2021) çalışmalarında, CT görüntülerinden metallerdeki dahili yorulma çatlaklarının 3 boyutlu şekillerini çıkarmak için orijinal U-Net ve Hessian matris filtresini birleştirdikleri bir görüntü bölütleme yöntemi geliştirdiler.

Du vd. (2022), yüksek semantik bilgi eksikliği olan radyografik görüntülerde alüminyum döküm parçaların kusurlarını segmentlere ayırmak için derin öğrenmeye dayalı bir metodoloji önerdi. Çalışmalarında, Etkileşimli X-ray Ağı (IXNet) adını verdikleri U-Net ve ResNet101 modellerine dayalı yeni bir ağ tanıttılar. Bu ağda, ağın anlamsal bilgileri yakalama yeteneğini geliştirmek için bir tıklama dikkat modülü de kullandılar.

Xu vd. (2022), Deep CNN kullanarak anlamsal bölütleme yöntemine dayalı otomatik bir kaynak hatası tespit sistemi önermektedir. Yang vd. (2022) ve Xu vd. (2022), farklı veri setleri kullanarak Deep CNN'nin yüzey kusur tespiti ve segmentasyonunu sunar.

Kheradmandi ve Mehranfar (2022), kaplama çatlak tespiti için görüntü bölütleme tabanlı teknikler üzerine bir inceleme sunar. İncelemede, çeşitli görüntü segmentasyon algoritmalarının karşılaştırması ve analizi sunulmaktadır.

Son yıllarda hata tespiti, sınıflandırma ve bölütleme üzerine yapılan çalışmaların ağırlıklı olarak derin öğrenme tabanlı olduğu görülmektedir. Derin öğrenme teknikleri ile ilgili mevcut çalışmalar, insan algısı gibi davranmaya başlar ve bu tür kusurları tespit edebilir. Yukarıda görüldüğü gibi, derin öğrenme tekniklerini kullanarak kusurları tespit etmeye, nesneleri sınıflandırmaya ve kusurları segmentlere ayırmaya yönelik birkaç çalışma vardır. Mevcut çalışmalarla ilgili sorun, mevcut derin öğrenme tekniklerinin doğruluğunun, askeri fişek kovanları gibi kritik öneme sahip nesnelerin kontrolü için yeterli olmamasıdır.

Önceden eğitilmiş modellerin çoğu, ImageNet gibi büyük veri kümeleri için özel olarak tasarlanmış karmaşık modellerdir. Bu nedenle, model eğitimi sırasında aşırı uyum ve genelleme yapmama gibi sorunlardan kaçınmak için ince ayar, bu modellerden belirli bir görev ağına bilgi aktarımında kritik bir süreçtir. Tablo 3'te gösterildiği gibi, Xception ve InceptionV3 modelleri hariç, yukarıdaki ince ayar süreçleri, özellikle deneylerimizde beklendiği gibi genellemeyen varsayılan modellerden daha verimli ve göreve özel modeller elde etmemizi sağladı. Özellikle de varsayılan EfficientNet modelleri için bu sonucu gözlemleyebiliriz. İnce ayar, VGGNets modellerinin neredeyse yarısı kadar

parametre sayısını azaltmayı mümkün kılarken, aynı iyi sonuçları veya varsayılan modellerden daha iyi sonuçlar elde etmeyi de mümkün kılmıştır.

Öte yandan, literatürde askeri fişek kovanlarını sınıflandırmak ve kusurları segmentlere ayırmak için derin öğrenme teknikleri ile ilgili dışında bir çalışma bulunmamaktadır. Bu sorunu çözmek için derin öğrenmedeki teknolojik gelişmelerden yararlanılmaktadır.

Bu çalışmada, doğruluğu artırmak için askeri fişek kovanlarının sınıflandırılması ve yüzeylerindeki kusurların derin öğrenme teknikleri kullanılarak bölütlenmesi için bir metodoloji önerilmiştir.


6.1 Derin Konvolüsyonel Sinir Ağları

Derin evrişimli sinir ağları (Derin CNN'ler) son yıllarda büyük başarı kazanmış ve CNN'lerin gelişmesiyle görüntü sınıflandırma, nesne algılama ve görüntü bölütleme gibi birçok bilgisayarlı görü görevlerine başarıyla uygulanmıştır (Shorten ve Khoshgoftaar, 2019).

Mevcut derin öğrenme teknikleri dört kategoriye ayrılabilir: 1) yapısal; 2) istatistiksel; 3) filtre tabanlı; ve 4) model tabanlı yaklaşımlar (Mittal vd. 2019). Bu teknikler, tek tip dokulu, yansıtıcı olmayan yüzeylerde iyi sonuçlar sağlar, ancak çoğu uygulama ve ortam değişkenlerine bağlıdır, ancak kovan yüzeyi gibi tekdüze olmayan dokulu ve oldukça yansıtıcı numuneler için çok etkili değildir.


CNN'ler, görüntü ile ilgili analiz için yaygın olarak uygulanır. CNN'ler normalde üç ana katmandan oluşur (Şekil 6.1): 1) konvolüsyonel katman; 2) Pooling katmanı; ve 3) tam bağlantılı katman. Evrişim katmanı, girişin yerel bölgelerine bir dizi filtre uygular, böylece giriş görüntüsünün özellik haritalarını elde eder. Pooling katmanı, öznitelik boyutunu azaltmak ve fazla sığdırma probleminden kaçınmak için evrişim katmanından sonra uygulanan uzamsal boyutları girerek alt örnekleri alır. Tamamen bağlı katmanlar, normal olarak, sınıf puanlarını hesaplayan CNN'lerin son birkaç katmanını oluşturur. Bir

Derin CNN, normal olarak, dönüşümlü evrişim ve pooling katmanlarından oluşur, ardından tamamen bağlı katmanlar gelir (Ren vd. 2017, Kim vd. 2017).



Şekil 6.1 CNN Yapısı

Kızrak (2017) çalışmasında CNN ağlarını “Sınıflandırma (sınıflandırma), sınıflandırma/lokalize etme (classification/localization), nesne tespiti (object detection) ve resim bölütleme (segmentation) işlemlerine yönelik çalışmalarının neredeyse tamamı CNN algoritması kullanılarak gerçekleştirilmektedir. CNN tüm katmanları birbirine tam bağlantılı olarak tasarlanmış ve her bir evrişimsel filtre öğrenilmesi gereken öznetelikleri oluşturmaktadır. Bu evrişimsel katmalar “pooling” katmaları sayesinde hem boyut hem eğitim süresinde optimizasyonu sağlamaktadır. Bilgisayarlı görü konusunda derin öğrenmenin en kritik noktası AlexNet’tir. Bu yapıda “dropout” ile rastgele bilgilerin ağ yapısından çıkarılması sağlanarak modelin verileri ezberlemesi (overfitting) probleminin önüne geçilmektedir. Bu bir tür regülerizasyon tekniğidir. CNN algoritması eğer elinizde yeterli veri var ise Şekil 6.2 resimde belirtilen görevleri yerine getirebilmektedir.



Şekil 6.2 CNN Örnek Uygulama

VGG, AlexNet'ten sonra sadece katman sayısı artırılarak daha başarılı sonuç elde eden bir ağ yapısı olmuştur. Ancak başarıyı artırmak için, katman sayısını artırmanın tek başına yeterli olunamayacağı; derine giderken genişlemek de gerektiğini GoogLeNet Inception modelleriyle ortaya çıkmıştır. ResNet, Inception modüllerine “Residual” bağlantıları ekleyerek katmanların çıkış performanslarını iyileştirmektedir.

CNN yapısında; Katmanlar derine daha derine gitmektedir. Hesaplama performansı iyileştirilmektedir (ReLU, dropout, batch normalization). Ağ katmanları arasındaki bağlantıların artması ile geriye yayılım algoritması iyileştirilmektedir. Geoffrey Hinton, 80'lerde geri yayılım (backpropagation) algoritmasını popüler etmesiyle tanınmaktadır. Bu algoritma günümüzde derin öğrenme uygulamalarının neredeyse tamamında kullanılmaktadır” olarak özetler.

6.1.1 Sınıflandırma amaçlı derin konvolüsyonel sinir ağları

Bu bölümde askeri fişek kasalarını sınıflandırmak ve yüzeylerindeki kusurları segmentlere ayırmak için önerilen Derin CNN'ler sunulmaktadır. Bu çalışmada askeri fişek kovanları gibi nesnelerin sınıflandırılması için kullanılan modeller şunlardır: 1) VGGNets, 2) ResNets, 3) Inception, 4) Xception, 5) DenseNet ve 6) EfficientNet.

VGGNETs:

VGG ağı, ana katkısı, çok küçük bir evrişim filtreli (3×3) bir mimari kullanırken büyük ölçekli görüntülerin sınıflandırılmasında ağların derinliğinin etkisinin incelenmesi olan derin bir evrişimsel sinir ağıdır (Zisserman ve Simonyan 2014). VGG-16 ve VGG-19, 16 ve 19'un ağırlıklı katman sayısını belirlediği bilinen iki VGG ağ örneğidir. VGG ağları, evrişim, maksimum pooling, aktivasyon ve tam bağlantılı katmanlardan oluşur. VGG16 ve VGG19 modelleri 1000 sınıftan oluşan 14 milyondan fazla görüntü üzerinde eğitildi ve ImageNet veri setinde sırasıyla %90,1 ve %90,0 test doğruluğu elde edildi (Russakovsky vd. 2015).

RESNETS:

ResNets (Residual Networks) (He vd. 2016) bağlantı atlama adı verilen bir teknik kullanır. Ağ boyunca bu bağlantılar, birkaç katmandan eğitim akışını atlar ve doğrudan

çıktıya bağlanır. Bu yaklaşım, ağıdaki katmanların temeldeki eşlemeyi öğrenmek yerine artık eşlemeye uymasını sağlar. Böylece, ilk eşleme $H(x)$ yerine ağ $F(x):=H(x)-x$ 'e uyar ve çıktı olarak $H(x):=F(x)+x$ verir. ResNets yazarları bu mimariyi ImageNet veri kümesinde, VGGNets'ten (Zisserman ve Simonyan 2015) 8 kat daha derin, ancak yine de daha az karmaşık olan 152 katman derinliğiyle değerlendirdi. En bilinen ResNets tabanlı modellerden bazıları, ağıdaki katman sayısını 50, 101, 152'nin belirlediği ResNet50, ResNet101, ResNet152'dir. 2016 yılında ResNets'in yazarları, ResNetV2 olarak adlandırdıkları ResNets'e yeni bir iyileştirme getirdiler (He vd. 2016). Belirgin gelişme, 2D konvolüsyonlardan önce toplu normalleştirme ve ReLU aktivasyonunun eklenmesidir. ResNet50V2, ResNet101V2, ResNet152V2 gibi modeller ilgili modelin ikinci versiyonlarıdır.

INCEPTION:

Derin sinir ağlarının geliştirilmesinde karşılaşılan en büyük sorunlardan biri, ağ derinleştikçe seviyesi yükselebilen aşırı uyumdur. Bu sorunu çözmek için C. Szegedy ve ark. önerilen DCNN mimarisi (Szegedy vd. 2015). Bu mimarinin arkasındaki ana fikir, birden fazla katman kullanmak yerine aynı seviyede farklı boyutlarda birden fazla filtre kullanmaktır. Bu, daha derin bir model yerine paralel katmanlara sahip daha geniş bir modelle sonuçlanır. Bu mimari, evrişimler, ortalama/maksimum pooling, birleştirmeler, bırakmalar ve tam bağlantılı katmanlar içeren simetrik ve asimetrik yapı taşlarından tasarlanmıştır. Bilgisayarla görü literatürüne büyük katkı sağlayan bu mimari birçok kez gözden geçirilmiş ve farklı versiyonları geliştirilmiştir. Bu sürümlerin en iyi bilinenlerinden biri InceptionV3'tür (Szegedy vd. 2016). Bu versiyonda yapılan başlıca iyileştirmeler, büyük filtrelerin daha küçük olanlara çarpanlara ayrılması, asimetrik evrişimlere uzamsal çarpanlara ayrılması, yardımcı sınıflandırıcıların kullanılması ve ızgara boyutunun verimli bir şekilde azaltılmasıdır. 2016 yılında, Inception modelinin geliştiricileri, Inception ve ResNet mimarilerinin (InceptionResNet olarak adlandırılır) birleşiminden kaynaklanan yeni bir model sundukları yeni bir makale (Szegedy vd. 2016) yayınladılar. Inception mimarisinin genişliğinden ve ResNet mimarisinin derinliğinden yararlanan performansı ile bu, görüntü sınıflandırma görevlerine büyük katkı sağlamıştır.

XCEPTION:

Inception'ın ekstrem versiyonunu temsil eden Xception (Chollet 2017), Google'dan F. Chollet tarafından önerilen derin bir evrimsel sinir ağıdır. Inception'dan ilham alan yazar, Inception mimarisindeki inception modülünü derinlemesine ayrılabilir kıvrımlarla değiştirdi. Inception ile aynı sayıda parametreye sahip olan bu mimarinin, ImageNet (InceptionV3 için geliştirilmiştir) gibi veri kümelerinde InceptionV3'ten daha iyi performans gösterdiği kanıtlanmıştır. Bu mimarinin performansı, model parametrelerinin verimli kullanımından kaynaklanmaktadır.

DENSENET:

ResNet mimarisi gibi, DenseNet mimarisi (Huang vd. 2017) de yoğun bloklar kullanır ve bağlantıları atlar. Ancak ResNet'ten farklı olarak, DenseNet'te her katman, önceki tüm katmanlardan ek girdiler alır ve kendi özellik haritalarını sonraki tüm katmanlara iletir. Diğer bir fark, DenseNet'in özellikleri birleştirmek için toplama yerine birleştirme kullanmasıdır. Bu çoklu girişler, DenseNet'in filtre sayısını sınırlamasına izin verir. DenseNet katmanlarında, aktivasyon öncesi toplu normalleştirme, ReLU aktivasyonu, ardından k kanalın çıktı özellik haritaları ile 3×3 evrim ve bitişik yoğun bloklar arasında sırasıyla 1×1 evrim ve 2×2 ortalama pooling kullanılır. DenseNet'in bazı avantajları şunlardır: güçlü gradyan akışı, düşük karmaşıklık özelliklerinin korunması ve hesaplama verimliliği. En bilinen DenseNet modellerinden bazıları DenseNet101, DenseNet121 ve DenseNet169'dur; burada 101, 121 ve 169 modeldeki katman sayısını belirler.

EFFICIENTNET:

EfficientNet (Tan ve Le 2019), evrimli bir sinir ağı mimarisi ve model ölçekleme yöntemidir. Ağın derinlik, genişlik ve çözünürlük boyutlarının isteğe bağlı olarak ölçeklendiği, bileşik ölçekleme yöntemi olarak adlandırılan geleneksel uygulamaların aksine, bu yöntem, bu faktörleri eşit olarak ölçeklendirmek için bir bileşik katsayı ϕ kullanır. Örneğin, α , β , γ , küçük bir ızgara aramasıyla belirlenebilen sabit katsayılardır ve maliyeti 2^ϕ olan bir kaynak kullanmak istiyorsak, ağı derinliğini α^ϕ 'ye, genişliğini β^ϕ 'ya ve çözünürlük (giriş şekli) γ^ϕ olarak. Böyle bir yöntemle duyulan ihtiyaç, görüntü çözünürlüğü ne kadar yüksek olursa, ağı daha geniş bir alıcı alana ve daha ince desenleri

yakalamak için daha fazla özellik haritasına sahip olması için o kadar derin olması gerektiği sezgisiyle haklı çıkar. Yazarlar önce ResNets ve MobileNets mimarilerini ölçeklendirmede yöntemlerinin etkinliğini gösterdiler ve ardından bu çalışmanın ikinci kısmı olarak EfficientNets adlı bir ağ ailesini elde etmek için ölçeklendirdikleri yeni bir temel ağ geliştirdiler. Tüm bu modeller, swish aktivasyonlu tüm sıkıştırma ve uyarma bloklarını kullanan 7 ters çevrilmiş artık bloktan oluşur. Tek farkları, farklı genişlik/derinlik/çözünürlük boyutlarına sahip olmalarını sağlayan parametreleştirme düzeyindedir. EfficientNetB7 (ImageNet'te %84,3 ile en iyi doğruluk) ile SOTA modelleri arasında yer almasını sağlayan önemli sonuçlar elde edilmiştir.

6.1.2 Bölütleme amaçlı derin konvolüsyonel sinir ağları

Kovan yüzey hatalarını bölütleme (segmentasyon) için aşağıdaki Derin Konvolüsyonel Sinir Ağları önerilmiştir: 1) U-Net, 2) ResUnet ve 3) DeepLabv3+.

U-NET:

U-Net, anlamsal segmentasyon için bir mimaridir. U-Net (Ronneberger vd. 2015), tamamen evrimsel ağa dayalı biyomedikal görüntü bölütlemesi için geliştirilmiştir. U-Net, FCN'nin (Long vd. 2015) geliştirilmiş ve geliştirilmiş halidir. Mimari, bağlamı yakalamak için bir sözleşme yolundan ve U-Net'in U şeklinde simetrik bir mimariye sahip olması için hassas lokalizasyon sağlayan simetrik bir genişleyen yoldan oluşur.

RESUNET:

Derin Kalıntı U-Net (Zhang vd. 2018) ResUnet olarak anılır. Zhengxin Zhang ve diğerleri tarafından oluşturulan anlamsal bir segmentasyon kodlayıcı-kod çözücü mimarisidir. İlk olarak, yüksek çözünürlüklü hava fotoğraflarından yolları çıkarmak için uzaktan algılama görüntü analizi alanında kullanılmıştır. Araştırmacılar daha sonra polip segmentasyonu, beyin tümörü segmentasyonu, insan görüntü segmentasyonu ve diğerleri dahil olmak üzere çeşitli başka uygulamalar için kullandılar. ResUnet, daha az parametre ile yüksek performans elde etmek için tasarlanmış tamamen evrimsel bir sinir ağıdır. Mevcut U-Net mimarisi üzerinde bir gelişmedir. Derin kalıcı öğrenme ve U-Net mimarisinin güçlü yanlarını birleştirir. Bu mimari iki avantaj sağlar: 1) artık birim ağın eğitimini


kolaylaştıracaktır; 2) Artık bir birim içindeki ve ağıın düşük ve yüksek seviyeleri arasındaki atlama bağlantıları, çok daha az parametrelili bir sinir ağı tasarlamayı mümkün kılacaktır, ancak anlamsal bölümlenmede karşılaştırılabilir her zamankinden daha iyi performans elde edebilir.

DEEPLABV3+:

DeepLabv3+ (Chen vd. 2018), nesne sınırları boyunca segmentasyon sonuçlarını iyileştirmek için basit ama etkili bir kod çözücü modülü ekleyerek DeepLabv3'ü (Chen vd. 2017) genişletir. Ana ağı orijinal temelinde yeniden değiştirdi. Atrous uzamsal piramit pooling (ASPP) kullanarak çok ölçekli bağlamsal bilgileri kodlayabilirler. Kodlayıcı, çok ölçekli bağlamsal bilgileri işlemek için birden çok ölçekte genişletilmiş evrişim kullanır, kod çözücü modülü ise nesne sınırları boyunca segmentasyon sonuçlarını iyileştirir. Hesaplama karmaşıklığını önemli ölçüde azaltırken önerilen modeli daha hızlı ve daha güçlü hale getiren ayrılabilir evrişim de araştırılmıştır.

6.1.3 Önceden eğitilmiş CNN modellerinin tartışılması

Bilginin temel bir görevden daha özel bir göreve aktarılması, özellikle makine/bilgisayar görme görevlerinde, veri toplamının zor olduğu alanda etkili bir çözüm olmaya devam etmektedir. Etkin bir optimizasyon prosedürü olmasının yanı sıra, sınıflandırma görevinde çok sayıda sınıfa sahip milyonlarca veri noktasında önceden eğitilmiş modellerin kullanılması da sınıflandırmanın iyileştirilmesine olanak tanır. CNN tabanlı modellerin ilk katmanları, kenarlar ve bloblar gibi düşük seviyeli özellikleri öğrenmek için kullanılırken, üst katmanlar, kovan yüzey hataları gibi görüntünün daha soyut ve göreve özgü yönleri olan yüksek seviyeli özellikleri öğrenmek için kullanılır.



Şekil 6.3 Çalışmada uygulanan öğrenme aktarımı

Ancak, Şekil 6.3'de gösterildiği gibi, bilgisayarla görü görevlerinde önceden eğitilmiş modelleri kullanmanın en çok benimsenen yolu, ilk katmanların başlangıç parametrelerini korurken üst katmanları ilgili göreve göre eğitmektir. Bu uygulama, eğitmek için daha az parametreye sahip olmayı sağlar, bu da sinir ağlarının eğitiminde büyük bir sorun olmaya devam eden aşırı takma riskini azaltır.

Şekil 6.3'de görüldüğü gibi, büyük ölçekli bir veri kümesi üzerinde önceden eğitilmiş bir temel ağın (Şekil 6.3 (a)) eğitilmiş ağırlıkları, yeni bir görev için ince ayarlanmış (fine-tuned) ağa ((Şekil 6.3 (b))) tekrar eğitmek için transfer edilmiş. Yeni görev ağında, ilk katman grubu, karşılık gelen katmanlar dondurularak eğitilemez hale getirilir (Donmuş evrişimli katmanlar Şekil 6.3 (b)'de) ve üst katmanlar göreve göre yeniden yapılandırılır (Şekil 6.3 (b)'deki Yeniden eğitilmiş tamamen bağlı katmanlar).

Öznitelik çıkarma ve ince ayar görevleri için de kullanılabilen görüntü sınıflandırma görevinde kullanılan farklı CNN modellerinin ImageNets veri kümesi (Russakovsky vd. 2015, Keras Applications 2022) üzerindeki ayrıntıları ve performansı Çizelge 6.1’de göstermektedir.

Çizelge 6.1 ImageNets veri setinde önceden eğitilmiş Derin CNN modellerinin detayları ve performansı

Models	Sub-models	Size (MB)	Top-1 Accuracy (%)	Top-5 Accuracy (%)	Parameters (M)	References
Xception		88	79.0	94.5	22.9	Chollet 2017
VGG	16	528	71.3	90.1	138.4	Simonyan and Zisserman 2014
	19	549	71.3	90.0	143.7	
RESNET	50	98	74.9	92.1	25.6	He vd. 2016
	101	171	76.4	92.8	44.7	
	152	232	76.6	93.1	60.4	
Inception V3		92	77.9	93.7	23.9	Szegedy vd. 2015
DenseNet	121	33	75.0	92.3	8.1	Huang vd. 2017
	169	57	76.2	93.2	14.3	
	201	80	77.3	93.6	20.2	
EfficientNet	B3	48	81.6	95.7	12.3	Tan and Le 2019
	B7	256	84.3	97.0	66.7	
	V2B3	59	82.0	95.8	14.5	
	V2S	88	83.9	96.7	21.6	
	V2M	220	85.3	97.4	54.4	
	V2L	479	85.7	97.5	119.0	

6.2 Öğrenme Aktarımı (Transfer Learning)

Makine öğrenmesinde en erken aktarılan çalışma, 1993 yılında ayrılabilirliğe dayalı transfer (DBT) algoritmasını formüle eden Lorian Pratt’e atfedilmiştir. 1997 yılında, Machine Learning dergisi, öğrenmeyi aktarmak için ayrılmış özel bir meseleyi yayınladı

ve 1998’de, alan çok-görevli öğrenmeyi, teorik temellerinin daha resmi bir analizi ile birlikte ilerletti. Öğrenmeyi Öğrenme, Pratt ve Sebastian Thrun tarafından düzenlenmiş, konunun 1998 yılında bir gözden geçirmesidir. Öğrenme Aktarımı bilişsel bilimde de uygulandı. Connection Science dergisi, 1996 yılında aktarım yoluyla sinir ağlarının yeniden kullanımı üzerine özel bir konu yayımladı.

Öğrenme Aktarımı, bir problemi çözerken elde edilen bilgiyi saklamak ve daha sonra farklı ama ilgili bir probleme uygulamak üzerine odaklanan makine öğreniminde bir araştırma problemidir. Örneğin, otomobilleri tanımayı öğrenirken kazanılan bilgi, kamyonları tanımaya çalışırken uygulanabilir. Bu alandaki araştırmalar, iki alan arasındaki resmi bağlar sınırlı olmakla birlikte, öğrenmenin aktarımı üzerine psikolojik literatürün uzun tarihi ile bazı ilişkileri taşımaktadır.

Öğrenme Aktarımı, bir görev için eğitilmiş bir modelin, ilgili ikinci bir görevde yeniden tasarlandığı bir makine öğrenmesi tekniğidir. Öğrenme ve alan adı uyarlamasını aktarma, bir ortamda öğrenilenin başka bir ortamda genelleşmeyi iyileştirmek için kullanılmasıyla ilgilidir (Deep Learning 2016).

Öğrenme Aktarımı, ikinci görevi modellerken hızlı ilerleme veya gelişmiş performans sağlayan bir optimizasyondur. Öğrenmeyi transfer etmek, yeni bir görevde öğrenmenin, önceden öğrenilmiş olan ilgili bir görevden bilginin aktarılması yoluyla iyileştirilmesidir. Transfer öğrenmesi, çok görevli öğrenme (multi-tasking learning) ve kavram sapması gibi problemlerle ilgilidir ve yalnızca derin öğrenme için bir çalışma alanı değildir. Bununla birlikte, derin öğrenme modellerini veya derin öğrenme modellerinin eğitildiği büyük ve zorlu veri kümelerini eğitmek için gerekli olan muazzam kaynaklar göz önünde bulundurulduğunda, transfer öğrenimi derin öğrenmede popülerdir.

Öğrenme Aktarımı yöntemleri farklı kriterlere dayanır. En temel iki kriter yeni eğitilecek veri setinin boyutu ve orijinal veri setine benzerliğidir. CNN Sinir Ağlarında öznetelikler ilk katmanlarda daha genel olarak ifade edilirken sonraki katmanlara doğru veriye özgü özneteliklerin arttığı göz önünde bulundurularak 4 farklı senaryo mevcuttur (Tapas 2016, Devikar 2016).

Senaryo 1. Veri benzerliđi çok yüksek ve veri setinin boyutu küçüktür. Bu durumda, veri benzerliđi çok yüksek olduđu için modeli yeniden test etmeye gerek yoktur. Bu aşamada yapılması gereken, çıktı katmanlarını problem tanımına göre özelleştirmek ve deđiştirmektir. Önceden eğitilmiş modeli bir özellik çıkarıcı olarak kullanmaktır.

Senaryo 2. Veri setinin boyutu küçük ve veri benzerliđi çok düşüktür. Bu durumda, önceden eğitilmiş modelin ilk katmanları dondurulur ve çıkış katmanına dođru geriye kalan katmanlar yeniden eğitilir. Çıkış katmanına yakın olan üst katmanlar yeni veri kümesine göre uyarlanır. Daha önce büyük bir veri seti ile eğitilmiş olan başlangıç katmanlarının önceden hesaplanmış halde tutulması ve bu katmanların ağırlıklarının donması ile veri setinin küçük boyutu telafi edilir.

Senaryo 3. Veri setinin boyutu büyük ancak veri benzerliđi çok düşüktür. Bu durumda, büyük veri setine sahip olduğundan model eğitimi başarılı olacaktır. Ancak, sahip olunan veriler önceden belirlenmiş modellerin eğitimi için kullanılan veriler ile karşılaştırıldığında çok farklı olmasından dolayı, önceden belirlenmiş modeller kullanılarak yapılan tahminlerde başarılı olmayacaktır. Bu nedenle, modeli kendi veri kümesine göre yeniden eğitmek en iyi başarılı sonuç veren yöntemdir.

Senaryo 4. Veri setinin boyutları büyük ve veri benzerliđi yüksektir. Bu durum en ideal durumdur. Bu durumda, en başarılı olan model, önceden eğitilmiş olan modeldir. Modelin yapısını ve modelin ilk ağırlıklarını deđiştirmeden korumaktır, modeli kullanmanın en iyi yoludur. Bu model daha sonra önceden eğitilmiş model tarafından hesaplanan ağırlıklar kullanılarak yeniden eğitilebilir. (Kın 2019).


Mevcut veri seti olan kovanlar için incelendiğinde seneryo 2 ile örtüşmektedir.

6.3 Derin Öğrenme Tabanlı Kovan Yüzey Hata Tespiti İçin Önerilen Metodoloji

Askeri fişek kovanlarının sınıflandırılması ve askeri fişek kovanlarının yüzeylerindeki kusurların sınıflandırılması için önerilen metodoloji dört aşamadan oluşmaktadır:

1. Veri kümelerinin oluşturulması;
2. Askeri fişek kovanlarının sınıflandırılması;
3. Askeri fişek kovanlarının yüzeylerindeki kusurların bölümlere ayrılması;
4. Sonuçların deđerlendirilmesi.

Önerilen metodolojinin akış şeması aşağıda gösterilmiştir (Şekil 6.4).



Şekil 6.4 Önerilen metodolojinin akış şeması

Önerilen metodolojinin aşamaları aşağıdaki alt bölümlerde ayrıntılı olarak açıklanmaktadır.

6.3.1 Verisetinin hazırlanması

Askeri fişek kovanı tek tip olmayan dokulu yüzeye sahip metalik, silindirik ve oldukça yansıtıcı bir nesnedir. Mevcut literatürde askeri fişek kovanları sınıflandırmak ve yüzeylerindeki kusurları segmentlere ayırmak için derin öğrenme modelleri için yaygın olarak kullanılan veri kümeleri yoktur. Bu nedenle özel veri setleri oluşturulmalıdır. Aşağıda, bu veri kümesini oluşturmak için bu çalışmada benimsenen ana adımlar verilmiştir.

- 1) Bir makine ile görme sistemi kullanarak silindirik yüzeyden 60 derecelik sektörlerle görüntü alınması. Bu nedenle, her bir kovan yüzeyinden alınan 6 görüntü, üst üste binmeden tüm 360 derecelik yüzeyi kaplamalıdır;
- 2) Alınan görüntülerin ön işleminden geçirilmesi;
- 3) Görüntüleri daha küçük parçalara bölmek;
- 4) Tüm görüntüleri kusurlu ve kusurlu sınıflara ayırarak fişek kovanlarının sınıflandırılması için veri setinin oluşturulması;
- 5) Bir önceki adımda oluşturulan kusurlu sınıftaki görüntülerdeki kusurları etiketleyerek ve maskeleyerek askeri fişek kovanlarının yüzeylerindeki kusurların segmentasyonu için veri setinin oluşturulması;

Böylece, metodolojinin 1. Aşamasında 2 veri seti oluşturulur:

- a) Sınıflandırma için veri seti
- b) Segmentasyon için veri seti.

İlk veri seti, 2. aşamada askeri fişek kovanlarını kusurlu veya kusurlu olarak sınıflandırmak için kullanılacaktır. Öte yandan, ikinci veri seti, askeri fişek kovanlarının yüzeylerindeki kusurları segmentlere ayırmak için 3. aşamada kullanılacaktır.

6.3.2 Fişek kovan görüntülerinin sınıflandırılması

Askeri fişek kovanlarını sınıflandırmak için ana adımlar aşağıdadır.

- 1) Aşama 1'in 4. Adımında oluşturulan kusurlu olmayan ve kusurlu sınıflarla sınıflandırma veri setini kullanmak;
- 2) Bölüm III-A'da sunulan derin öğrenme model(ler)inin seçilmesi;
- 3) Seçilen model(ler)in sırasıyla sınıflandırma veri setinden oluşturulan eğitim ve doğrulama setleri üzerinde eğitilmesi ve doğrulanması;
- 4) Aşama 4'te açıklanan metrikler kullanılarak test setinde eğitilen modellerin değerlendirilmesi;
- 5) Metriklerin elde edilen değerleri uygun ise sınıflandırma aşamasını tamamlayınız. Aksi takdirde, aşağıdaki tekniklerden birini veya birkaçını kullanarak metriklerin değerlerini artırmaya çalışmak:
 - a) Model mimarisinde ve/veya hiperparametrelerde ince ayar yapmak;
 - b) Farklı sinir ağı optimize edicileri kullanarak ağı optimize etmek;
 - c) Veri kümelerine ön işleme ve/veya sonradan işleme uygulamak.

6.3.3 Fişek kovan görüntülerindeki hataların etiketlenmesi

Kusurları segmentlere ayırmanın ana adımları aşağıdadır.

- 1) Aşama 1'in 5. Adımında oluşturulan etiketli/maskelenmiş kusurlarla segmentasyon veri setini kullanmak;
- 2) Bölüm III-B'de sunulan derin öğrenme model(ler)inin seçilmesi;
- 3) Seçilen model(ler)in sırasıyla segmentasyon veri setinden oluşturulan eğitim ve doğrulama setleri üzerinde eğitilmesi ve doğrulanması;

- 4) Aşama 4'te açıklanan metrikler kullanılarak test setinde eğitilen modellerin değerlendirilmesi;
- 5) Metriklerin elde edilen değerleri uygunsa, kusur segmentasyon aşamasını tamamlayın. Aksi takdirde, aşağıdaki tekniklerden birini veya birkaçını kullanarak metriklerin değerlerini artırmaya çalışmak;
 - a) Model mimarisinde ve/veya hiperparametrelerde ince ayar yapmak;
 - b) Farklı sinir ağı optimize edicileri kullanarak ağı optimize etmek;
 - c) Veri kümelerine ön işleme ve/veya sonradan işleme uygulamak.

6.3.4 Sonuçların değerlendirilmesi

Askeri fişek kovanlarının sınıflandırılmasının ve askeri fişek kovanlarının yüzeylerindeki kusurların bölümlendirilmesinin ne kadar başarılı olduğunu belirlemek için çeşitli değerlendirme ölçütleri kullanılmaktadır. Bu metriklerde kullanılan değerler, karışıklık matrisinden elde edilmiştir (Çizelge 6.2).

Çizelge 6.2 Karışıklık matrisi (Confusion matrix)

Confusion Matrix	Estimated Positive	Estimated Negative
True Positive	True Positive (TP)	False Negative (FN)
True Negative	False Positive (FP)	True Negative (TN)

Elde edilen sınıflandırma ve segmentasyon sonuçlarını değerlendirmek için aşağıdaki metrikler kullanılabilir: (1) Doğruluk (Accuracy); (2) Hassasiyet (Precision); (3) Geri çağırma (Recall); (4) F1-Skoru (F1-Score); (5) Jaccard Endeksi (Jaccard Index); (6) Birleşim Üzerinden Ortalama Kesişim (Mean Intersection over Union).

Doğruluk: Doğruluk, modelin genel performansı hakkında bilgi verir. Doğruluk puanı 0 ile 1 arasındadır ve 1'e ne kadar yakınsa modelin başarısı o kadar yüksektir. Sınıf değişkeninin veri kümesinde eşit olarak dağıldığı durumlarda kullanılmalıdır. Eşit olmayan bir şekilde dağıtılmış bir veri kümesinde, model çoğunluk sınıfının değerini tahmin etme eğilimindedir ve bu da yanlış bir yüksek doğruluk sonucu ile sonuçlanır. Bu

nedenle, düzensiz dağılmış veri kümeleri ile kurulan modeli değerlendirmek için doğruluk dışında başka metrikler de dikkate alınmalıdır (denklem (6.1)).

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (6.1)$$

Kesinlik: Kesinlik, kusurlu olmadığı tahmin edilen kovanların kaçının gerçekte kusurlu olmadığını ölçer. Hassasiyet, özellikle FP tahmininin maliyeti yüksek olduğunda kritiktir (denklem (6.2)).

$$Precision = \frac{TP}{(TP + FP)} \quad (6.2)$$

Geri Çağırma: Geri çağırma, kusurlu olduğu tahmin edilen kovanların kaçının gerçekten kusurlu olduğunu ölçer. Geri çağırma, sınıflandırıcıların bütünlüğünün bir ölçüsü olarak düşünülebilir. Geri çağırma, FN tahmininin maliyetinin yüksek olduğu kritik bir ölçümdür. Mümkün olduğunca yüksek olmalıdır (denklem (6.3)).

$$Recall = \frac{TP}{(TP + FN)} \quad (6.3)$$

F1-Skoru: F1-Skoru, kesinlik ve geri çağırma değerlerinin harmonik ortalamasıdır. F1-Score, kesinlik ve geri çağırma arasındaki dengeyi sağlar. F1-Skoru, tüm hata maliyetlerini içerecek bir değerlendirme ölçütü ihtiyacını karşıladığı için önemlidir. Aritmetik ortalama yerine harmonik ortalama kullanılmasının nedeni uç değerlere sahip veri örneklerinin göz ardı edilmesini önlemektir. Özellikle eşit olmayan şekilde dağıtılmış veri kümelerinde doğruluk metriğinden daha iyi bir kılavuzdur (denklem (6.4), (6.5)).

$$F1\ score = \frac{2 \times (Precision \times Recall)}{(Precision + Recall)} \quad (6.4)$$

$$F1\ score = \frac{2 \times TP}{(2 \times TP + FP + FN)} \quad (6.5)$$

Jaccard Endeksi: IoU puanı (Birlik Üzerinden Kesişim) olarak da adlandırılan JI, segmentlere ayrılmış çıktı ile gerçek gerçek arasındaki piksel örtüşme yüzdesini hesaplar (denklem (6.6)).

$$JI\ (or\ IoU) = TP / (TP + FP + FN) \quad (6.6)$$

Birleşim Üzerinden Ortalama Kesişim: Birleşim üzerinden ortalama denklemi aşağıdaki denklem (6.7 ile ifade edilir.

$$mean\ IoU = \frac{1}{K} \sum_{k=1}^K IoU_k \quad (6.7)$$


7. KOVAN YÜZEY HATALARININ TESPİTİ UYGULAMASI

Tez çalışması kapsamında mümkün olan en geniş alanda, en az kurulum/konfigürasyonda, çevre şartlarından en az etkilenen, gerçek zamanlı çalışan sistemlere uygulanabilecek ve hata bulma oranı yüksek bir yöntem geliştirmek hedeflenmiştir.

Bu çalışmanın ilk olarak kovan yüzeyleri üzerinde denenmesi planlanmıştır. Kovan yüzeyi düzensiz bir desene sahiptir ve şekil itibari ile düz değil koniktir. Literatürdeki yapılan çalışmalar incelenerek uygun yöntemler kümesi daraltılmış ve uygun yöntemlerde daha detaylı bir çalışma yapılmıştır.

Kovan yüzeyinin kontrolü için mevcut bir düzenek görüntü alma düzeneği olduğu için test görüntüleri bu görüntüler arasından seçilmiştir. Ham görüntüde (Şekil 7.1) arka plan olduğu için geliştirilen bir kod ile kovan yüzeyi arka plandan ayrılmıştır. Kovan yüzeyi bölümlendikten sonra kovanın yüzeyi çeşitli parçalara ayrılmıştır. Ayrılan parçalardan yüzey incelemesi için çalışmaya en uygun kısım orta yan yüzeydir.

Test verisinin hazırlanması için çalışmalar iki ana problemin üzerindeki yoğunlaşmıştır. Öncelikle hareketli test görüntüleri üzerinde yapılan işlemler ile kovanın arka plandan ayrılıp elde edilmesi ile ilgili yapılan çalışmalardır. Sonrasında ayrıştırılan kovan yüzeyi görüntüsü üzerinde hata bulma yöntemleri üzerinde çalışma yapılmıştır.



Şekil 7.1 İşlenmemiş Kovan Görüntüsü

7.1 Görüntü Alma Bileşenleri

Görüntü alma her ne kadar en temel ve basit bir işlem gibi görünse de kamera düzeneğinden uygun ışık ve ayarlarda görüntü almak çok önemli ve oldukça hassas çalışma isteyen bir konudur. Öncelikle yapılan çalışmalarda kameranın birçok parametresi farklı ışık kaynakları ve şiddetlerinde denenerek bulunmaya çalışılmıştır. Bu parametrelerden en önemlileri objektif hızı (shutter time), kazanç (gain), Gamma ayarlarıdır. Objektif hızı özellikle hareketli görüntülerin alınmasında önemli bir parametredir. Objektif süresi uzun olursa hareket eden cisim bulanık, gölgeli, kuyruklu görünmektedir. Objektif süresi çok kısa olur ise kamera sensörüne yeterli ışık girememekte ve karanlık bir görüntü oluşmaktadır. Yapılan denemeler ile 0.080 ms'nin gölgesiz, iyi sonuçlar verdiği gözlemlenmiştir. Kovanın hızı ortalama 2 m/s olarak hesaplanır ise objektif süresi boyunca 0.16 mm bir kayma olur. Kazanç parametresi genel olarak piksel başına elektron sayısı/piksel başına veri sayısı olarak tanımlanmıştır. Pratikte kazanç arttıkça görüntü daha az ışıktaki daha parlak görüntü elde edilebilir. Fakat kazanç arttıkça resimde istenmeyen bozulmalarda artacaktır. Verdiğimiz ışık kaynağının belirlediğimiz objektif süreleri dahilinde yetersiz olduğu durumlarda kazanç parametresi ile optimum ayarı yaparak daha iyi görüntü elde edilmiştir.

7.2 Görüntü İşleme Yazılımı Bileşenleri

Araştırmada geliştirilen yazılımın temel arayüz işlevleri şunlardır:

- Operatör ekranı ile yazılıma özgü parametreler ayarlanabilmeli
- Birden fazla kameradan alınan görüntüler ekranda gösterilmeli
- Alınan görüntüler işlenip ekranda hatalı/sağlam bilgisi gösterilmeli


Uygulama zaman kritik olduğundan geliştirme için C++ dili seçilmiştir. Arayüz hazırlamak için C++ diline uygun Nokia QT kütüphanesi kullanılmıştır. Kamera üreticisi tarafından sağlanan SDK (yazılım geliştirme kiti) ile kamera üzerinde yazılımsal geliştirmeler yapılmıştır. SDK C++ dili ile uyumludur. Kamera SDK'sı kullanılarak yazılımsal olarak kamera ayarları, tetikleme moduna geçiş, görüntü alma, vb. gibi işlemler yapılmıştır. Satın alınan kamera üzerinde sadece üreticinin sağladığı SDK ile üreticinin sağladığı formatta görüntü alınabilmektedir.

Geliştirilen yazılımda birden fazla kamera görüntüsü olduğu için multithread çalışan bir yazılım mimarisi gerçekleştirilmiştir. Her kamera için bir görüntü alma thread'i oluşturulur. Bu thread'ler her kameradan aldıkları görüntüleri paylaşılan bir bellek bölgesine kaydeder. Her kamera için görüntü işleme thread'leri oluşturulur. Görüntü işleme thread'i paylaşılan bellek bölgesine yazılmış görüntüyü işler ve ekrana gönderir. Bu işlemler sırasında thread'lerin senkronizasyonu çok önemli olmaktadır. Görüntü alma işlemlerinin yüzey için tüm kameralarda aynı anda yapılması gerekmektedir. Multithread geliştirilen bu yazılımda senkronizasyon işlevlerini yerine getirmek için mutex, semafor gibi yapılardan faydalanılmıştır.

7.3 Kovan Yüzeyinin Tespiti ve Ayrıştırılması Uygulaması

7.3.1 Global eşikleme

Bu işlem için kovanın histogramı incelenir. Örnek kovan görüntüsü için çizilen histogram görüntüsü Şekil 7.2'de verilmektedir.



Şekil 7.2 Örnek kovan görüntüsünün histogramı

Yukarıda verilen histogramdan iki tepe değerinin arka plan ve kovan yüzeyi olduğu anlaşılmaktadır. Bu iki tepe arasındaki minimum değere sahip olan piksel değeri eşik değeri olarak seçilmelidir. Histogramdan bu değerin yaklaşık 45'e eşit olduğu

görülmektedir. Bulunan değer (45), bu değerden küçük (40) ve bu değerden büyük (50) değerler için denemeler yapılmıştır.



Şekil 7.3 Örnek değerler için global eşikleme uygulaması

Şekil 7.3 görüldüğü gibi en iyi sonucu bulunan eşik değerine uygun deneme sonucu vermiştir. Farklı ışık ve ortamlarda seçilen değer belirlenmesi ayrı bir problem olarak ele alınmalıdır.

7.3.2 OTSU eşikleme

Görüntüde otomatik olarak histogram verisi üzerinden eşikleme değeri yapan yöntem OTSU denir. OTSU yöntemi global eşikleme ile aynı adımlarla çalışan bir algoritmadır. Fakat OTSU eşik değerinin bulunması işlemini otomatik olarak kendi içinde histogramı kullanarak hesaplar. Örnek kovan görüntüsü için uygulanmış ve eşik değeri için 58 sonucunu vermiştir. Bu değer ile işlem yapıldığında aşağıda verilen sonuçlar elde edilmiştir.









Şekil 7.4 OTSU sonucu ile yakın eşik değerlerinin karşılaştırılması


Otomatik olarak hesaplanan bu eşikleme değerinin kovan yüzeyini doğru olarak bölütleyemediği ve doğru olarak bölütleyebilmek için bir ön adım niteliği taşımadığı görülmektedir.

7.3.3 Canny kenar bulma

Canny kenar bulma algoritması da görüntü işlemede yaygın olarak kullanılan yöntemlerden biridir. Bölütleme yapma amacıyla kullanmak mümkündür. Girdi parametrelerinin doğru belirlenmesi önemlidir. Kovan görüntüsü üzerinde bölütleme için iyi sonuç vermemiştir (Çizelge 7.1 Canny kenar bulma sonuçlar tablosuÇizelge 7.1)

Çizelge 7.1 Canny kenar bulma sonuçlar tablosu

Eşik Değeri Low=10 High=20	Eşik Değeri Low=15 High=30	Eşik Değeri Low=20 High=40
		
Eşik Değeri Low=25 High=50	Eşik Değeri Low=30 High=60	Eşik Değeri Low=35 High=70
		
Eşik Değeri Low=40 High=80	Eşik Değeri Low=45 High=90	Eşik Değeri Low=50 High=100
		




Bu algoritmada girişte uygulanan düşük ve yüksek eşik değerlerinin seçimi Çizelge 7.1’de görüldüğü gibi çok farklı sonuçlar vermektedir. Bu yüzden bu düşük ve yüksek eşik değerlerinin seçilmesi ayrı bir problem olarak ele alınabilir. Değerler düşük seçildiğinde çok fazla detay çıkmakta ve algoritma çalışma zamanı artmaktadır. Değerler yüksek seçildiğinde ise istenilen kovan yüzeyi çıkarma işlemi başarısız olmaktadır.

7.3.4 Watershed

Bu yaklaşım, görüntüdeki gürültü veya diğer düzensizlikler nedeniyle size aşırı bölümlenmiş sonuçlar verir. Bu problemi aşmak için OpenCV’de hangi vadi noktalarının birleştirileceğini ve hangilerinin birleştirilemeyeceğini belirlediğiniz işaretçi tabanlı bir havza algoritması uyguladı. Etkileşimli bir görüntü segmentasyonudur. Yaptığımız şey bildiğimiz nesneye farklı etiketler vermek. Ön plan veya nesne olduğundan emin olduğumuz bölgeyi bir renk (veya yoğunluk) ile, arka plan veya nesne olmadığından emin olduğumuz bölgeyi başka bir renkle ve son olarak hiçbir şeyden emin olmadığımız bölgeyi etiketlenir. Bu noktalar bizim işaretçilerimizdir. Ardından watershed algoritması uygulanır. Ardından işaretçimiz verdiğimiz etiketlerle güncellenecek ve nesnelerin sınırları bulur.

Watershed algoritması region growing yöntemine benzer şekilde çalışır. Fakat bir veya daha fazla başlangıç noktası algoritmaya giriş olarak verilmelidir. Kovan görüntüsünü bölütleme için iyi sonuçlar vermemiştir. Kovan yüzeyi ve arkaplan parlaklık değerleri çok yakın olduğu için tutarlı sonuçlar vermemiştir (Şekil 7.5).




Şekil 7.5 Watershed algoritması sonucu örnek bir bölütleme

7.3.5 Adaptif eşikleme

Adaptif eşikleme yöntemi kullanılarak işlenmemiş kovan görüntüsünde yüzeyin tespiti ve arka plandan ayrıştırılması başarı ile yapılmış ve iyi sonuçlar alınmıştır. Bu yöntemin farklı parametre değerleri ile denenmesi durumunda bile kovan yüzeyini ayırmada iyi sonuçlar verdiği görülmüştür. Blok boyutu ve alfa girdi değişkenlerinin farklı değerleri ile uygulama sonuçları Çizelge 7.2’de verilmiştir. Blok boyutu büyüdükçe kovan kenarının daha kalın sınır bölgesi oluşturduğu görülmüştür. Blok boyut değeri çok büyük seçildiğinde kovan kenar sınır hat bölgesindeki gerekli detaylarında kaybolduğu görülür. Blok boyut değeri çok küçük seçildiğinde ise kovan kenar sınır hat bölgesinin oluşmadığı tespit edilmiştir. Alfa değeri ise arka plandaki gürültüyü kaldırmak için uygun değerde seçilmelidir. Alfa değeri çok düşük seçildiğinde gürültüden dolayı kovayı ayırmak zorlaşır. Çok yüksek seçildiğinde ise kenar sınır hat bölgesini gürültü ile beraber yok etmektedir.

Çizelge 7.2 Adaptif eşikleme sonuçlar tablosu



Blok Boyutu	Alfa 0.9	Alfa 1.5	Alfa 2.1
5x5			
11x11			
17x17			
23x23			
29x29			
35x35			




7.4 Kovan Yüzey Tespiti ve Ayrıştırılması Yöntemlerinin Karşılaştırılması

Hareketli görüntüler farklı bölütleme algoritmaları ve parametreleri ile denemeler yapılmış ve aşağıdaki tabloda verilmiştir. Adaptif eşikleme yönteminin değişebilen parlaklık koşullarında dahi kovan'ın çıkarılması için iyi sonuç verdiği gözlemlenmiştir.

Çizelge 7.3 Bölütleme Algoritmalarının karşılaştırma tablosu




Yöntem	Sonuç
Canny	
Global Threshold	



Yapılan testlerde adaptive eşikleme algoritmasının bu problem için uygun sonuçlar verdiği gözlemlenmiştir. Adaptif eşikleme sonucu bulunan kenarların iç kapalı alanı alınarak kovan yüzeyi çıkartılır.

7.5 En Küçük Dikdörtgen Yöntemi ile Kovan Açı Düzeltme Uygulaması

Yüzeyi çıkarılan kovan şekli en küçük dikdörtgen ile kapsanacak şekilde çevrelenir. Bulunan dikdörtgenin zeminle yaptığı açı bulunur. Hesaplanan bu açı değeri ile görüntü bir miktar çevrilir. Bu şekilde arka plandan ayrılan kovan şekli zemine dik halde elde edilmiş olur (Şekil 7.6). Bu yöntem hem çok hızlıdır hem de başarılı sonuçlar vermiştir. En küçük dikdörtgen yöntemi bir önceki aşamada kullanılan adaptif eşiklemenin sonucunda çıkan maskeyi kullanır.


	
Kovan dış kontur maske	Kovanın arka plandan çıkarılması
	
Kovanı çevreleyen en küçük dikdörtgen	Kovanın zemine dik konuma getirilmesi

Şekil 7.6 En küçük dikdörtgen ile açı düzeltme

7.6 Eşik Değeri ve Morfolojik İşlemlerle Hata Bulma

Morfolojik işlemler kullanılarak örnek bir hata bulma adımları sırasıyla Şekil 7.7, Şekil 7.8, Şekil 7.9, Şekil 7.10, Şekil 7.11, Şekil 7.12 ve Şekil 7.13'te gösterilmiştir. Burada

özellikle sobel filtresi sonucu ortaya çıkan görüntüde seçilecek eşik değeri kritiktir. Bu değer farklı hatalar ve farklı ışıklandırma için değişebilir. Bu yöntemde en kritik ve çözülmesi gereken bir problem olarak eşik değerinin seçilmesi verilebilir.



Şekil 7.7 Orijinal ham görüntü



Şekil 7.8 İlgi alanının çıkarılması



Şekil 7.9 Yan yüzey kısmının ayrılması



Şekil 7.10 Sobel filtresi uygulanması



Şekil 7.11 Eşik değeri uygulanması



Şekil 7.12 Morfolojik kapama işlemi




Şekil 7.13 Küçük boyutlu hataları elenmesi

7.7 GLCM Yönteminin Uygulanması ve Sonuçlarının Değerlendirilmesi

Yüzey hata örneğinin GLCM de uygulanması ve sonuçlarının değerlendirilmesi için örnekler verilmiştir. Mevcut literatür çalışmalarında genel olarak GLCM sonucunda

ıkan parametreler bir sınıflandırma algoritmasında girdi olarak kullanılır. Eđitim ařamasından sonra hatalı hatasız ayırımı yapılır.





řekil 7.14 GLCM rnek grntler ve sonuları

GLCM uygulaması drt ada uygulanır ve sonuların ortalaması alınır. rneđin kare bir resimin GLCM ortalama sonuları, resmin 90° evrilmiř hali ile aynı olacaktır. Sonular (řekil 7.14) incelendiđinde deđerlerin birbirine yakın olduđu grlmektedir fakat kk hataların tespiti iin bu yntemin ok iyi sonular veremeyeceđi grlr. Ayrıca evresel řartlardan ok fazla etkilenebilir.

7.8 Dalgacık Dönüşümü Uygulaması ve Sonuçlarının Değerlendirilmesi

Dalgacık dönüşümünde hata bulmak için farklı yöntemler olmasına rağmen en yaygını deseni ya da gürültüyü ortadan kaldırmaktır. Örnek gürültü azaltmak için kullanılan görüntüler verilmiştir (Şekil 7.15).





Şekil 7.15 Dalgacık dönüşümü örnek görüntüler ve sonuçları


7.9 Bilateral Filtre Temelli Hata Bulma Algoritması Sonuçları

Önişlemler aşamaları sonrasında kovan dış şekli çıkarılıp düzeltildikten sonra hata bulma ile ilgili çalışmalara başlanabilir. Kovan üzerindeki desen (düzensiz gürültü) yok edilebilir ise hata bulma aşaması çok daha kolay olur. Kovan üzerindeki bu deseni kaldırmak için çok farklı yöntemler denenmiştir. Histogram eşitleme, adaptif eşikleme, gauss filtre, average filtre, median filtre, çeşitli gabor çekirdekleri filtresi, tantriggs ışık normalizasyonu, bilateral süzgeç gibi yöntemler denenmiştir. Bilateral süzgeç dışında hiçbir hata tespiti için beklendiği kadar iyi sonuç vermemiştir. Cho ve arkadaşları (2014) yaptıkları çalışmada bilateral süzgeç ile resmin anahatlarını kaybetmeden küçük desenleri elemeyi başarmışlardır. Lin ve arkadaşları (2010) gürültü elemeye bilateral süzgeci kullanmışlardır.

Kovan görüntüsünün kendine has yüzey özelliklerinden ve inceleme zorluklarından dolayı görüntünün kenarlarının bulanıklaşmasını etkili bir şekilde önleyebilen çeşitli

yolları karşılaştırarak, hatalı bölge segmentasyon doğruluğunu iyileştirmek için ikili gürültü giderme filtresi (bilateral süzgeç) kullanılmıştır.

Bilateral süzgeç ile kovan üzerindeki desen ve gürültü büyük ölçüde elenmiş ve hata olabilecek kısımların elde edilmesi başarılmıştır (Şekil 7.16). Fakat kullanılan filtrenin parametreleri çok önemlidir. Seçilen parametreler ile gürültü daha iyi oranlarda azaltılabilirken, hesaplama zamanı artmaktadır. Bu da hesaplama zamanını gerçek zamanlı olamayacak kadar uzatabilmektedir. Bu yüzden seçilen parametrelerin hesaplama zamanına etkisi çok fazladır. Yüksek hesaplama gerektiren bir filtredir. Gerçek zamanlı çalışmasına uygun parametrelerin seçilmesi gereklidir. Gürültü yok edildikten sonra temel sobel ve kenar bulma teknikleri ile hataların yerleri tespit edilebilmiştir.




Şekil 7.16 Örnek Kovan Görüntüsünde Bilateral süzgeç Sonuçları


7.10 Geliştirilen Yazılımın Arayüz Çıktıları

Son olarak geliştirilen metodoloji gerçek bir uygulamaya çevrilmiştir ve kullanıcı arayüzleri hazırlanmıştır. Son kullanıcı arayüzleri C++ ile geliştirilmiş ve cross platform

desteklenmesi için QT kütüphane çatısı kullanılmıştır. Hatalı ve hatasız kovanlar için son kullanıcı arayüz örnekleri Şekil 7.17 ve Şekil 7.18.



Şekil 7.17 Son kullanıcı arayüzü hatalı kovan örneği



Şekil 7.18 Son kullanıcı arayüzü hatasız kovan örneği

8. KOVAN YÜZEY HATALARININ DERİN ÖĞRENME TABANLI TESPİTİ UYGULAMASI

Bu bölümde, askeri fişek kovanları için önerilen metodolojinin uygulama detayları ve sonuçları sunulmaktadır.

8.1 Verisetinin Hazırlanması


Bu makale, askeri fişek kovanlarını sınıflandırmayı ve yüzeylerindeki kusurları segmentlere ayırmayı amaçlamaktadır. Şekil 8.1'te görüldüğü gibi askeri fişek kovanları metalik, silindirik, homojen olmayan dokulu ve yüksek oranda yansıtıcı bir yüzeye sahiptir.




Şekil 8.1 Askeri fişek kovan örnekleri

Askeri fişek kovanlarının (Gainsford 1958) yüzeyindeki korozyon, çizik, çatlak, yarılma, göçük, katlanma, şişkinlik, bükülme ve buruşma gibi kusurları derin öğrenme teknikleri kullanarak tespit etmek, sınıflandırmak ve segmentlere ayırmak için veri setine ihtiyaç vardır. Özel bir prototip makinesi oluşturuldu ve prototip makineden görüntüler toplandı. Aşağıda, veri kümesini oluşturmak için benimsenen ana adımlar verilmiştir.

1) Bir yapay görme sistemi kullanarak, kovan silindirik yüzeyinden 60 derecelik sektörlerle görüntülerin alınması. Bu nedenle, her bir kovan yüzeyinden alınan 6 görüntü, 360 derecelik yüzeyi üst üste binmeden kaplamalıdır (Şekil 4).




(a)



(b)


Şekil 8.2 Kusurlu olmayan (a) ve kusurlu olan (b) silindirik fişek kovanı yüzeyinden 60 derece açı ile alınan görüntüler

2) Yüzey parçalarının çıkarılması. Bu çalışmada fişek kovanlarının sadece yüzey kısmı (bkz. Şekil 4'teki büyük yeşil dikdörtgenler) ele alınmıştır. Böylece her kovan yüzeyinden 6 görüntü elde edilir (Şekil 8.3).




Şekil 8.3 Kusurlu olmayan (a) ve kusurlu olan (b) silindirik fişek kovani gövde yüzeyinin çıkarılması

3) Şekil 5'teki her görüntüyü 3 eşit parçaya bölmek (Şekil 8.4).



Şekil 8.4 Kusurlu olmayan (a) ve kusurlu olan (b) silindirik fişek kovani gövde yüzeylerinin alt parçalara ayrılması


4) Görüntüleri kusurlu ve kusurlu olmayanlarla gruplayarak sınıflandırma için kullanılacak veri kümesinin kusurlu ve kusurlu sınıflarının oluşturulması (Şekil 8.5).



Şekil 8.5 Kusurlu olmayan (a) ve kusurlu olan (b) olarak sınıflandırılmış veriseti

Birçok fişek kovani için 1-4 arasındaki adımlar tekrarlanarak, 750 görüntülü veri kümesinin kusurlu olmayan görüntü sınıfı ve 600 görüntülü veri kümesinin kusurlu görüntü sınıfı elde edilmiştir. Hatalı veri kümesi sınıfı, veri büyütme kullanılarak ve sentetik kusurlar oluşturularak 750 görüntüye çıkarıldı. Bu işlemten sonra 750 kusurlu ve 750 kusurlu görüntü olmak üzere 2 sınıflı dengeli bir veri seti oluşturulmuştur.

5) Bir önceki adımda oluşturulan kusurlu sınıftaki görüntülerdeki kusurları etiketleyerek ve maskeleyerek askeri fişek kovanlarının yüzeylerindeki kusurların segmentasyonu için veri setinin oluşturulması. Etiketli veri kümesindeki görüntülere (maskelere) örnekler Şekil 8.6'de gösterilmektedir.



Şekil 8.6 Kusurlu bölgelerin etiketlenmiş maskeleri

Bu nedenle, 4. adımda sınıflandırma için oluşturulan veri kümesinin kusurlu olmayan ve kusurlu sınıfları, askeri fişek kovanlarını sınıflandırmak için kullanılacaktır. Öte yandan, Adım 4'te oluşturulan hatalı veri kümesi sınıfındaki görüntülerin etiketlenmesi ve maskelenmesi ile elde edilen veri kümesi, kusurları segmentlere ayırmak için kullanılacaktır.

8.2 Fişek Kovanları Verisetinin Sınıflandırılması

Bu bölümde, askeri fişek kovanlarının sınıflandırılmasının uygulama düzeni ve sonuçları sunulmaktadır.

8.2.1 Uygulama düzeneğinin hazırlanması

Bu çalışmada, askeri fişek kovanlarını kusurlu veya kusurlu olarak sınıflandırmak için Çizelge 6.1'de listelenen derin öğrenme modelleri kullanılmıştır. Bu modeller, Tensorflow çerçevesi üzerinde çalışan Keras sinir ağı kitaplığı kullanılarak uygulandı. Modellerin giriş boyutu 128x128x3 olarak ayarlanmış ve veri setindeki görüntüler buna göre yeniden boyutlandırılmıştır. Eğitim/doğrulama/test bölme oranı, eğitim, doğrulama ve test setlerinin orijinal veri setinin genel eğilimlerini korumasına izin veren 60:20:20'ye ayarlandı. Büyük veri kümelerinde önceden eğitilmiş modellerin kullanılması nedeniyle, dönem sayısı (modelin tüm eğitim veri kümesi boyunca tamamladığı tur sayısı) 20'ye ayarlanacak şekilde seçildi, SGD varsayılan iyileştirici (optimizer) olarak 32'lik küme boyutuyla (mini batch-size) kullanıldı. Öğrenme oranı (learning rate) 0,01 olarak ayarlandı. İkili sınıflandırmadaki etkinliği nedeniyle çapraz entropi kaybı fonksiyonu kullanılmıştır. Eğitilen modelleri değerlendirmek için doğruluk (accuracy) metriği seçildi.

8.2.2 Uygulama sonuçları

Deep CNNs modelleri eğitildi ve test veri setindeki doğruluklarına göre karşılaştırıldı (Tablo 3).

Tablo 3'teki Sütun 3 ve 4, sütun 1 ve 2'de listelenen ilk/varsayılan modelleri/alt modelleri kullanan uygulama sonuçlarını gösterir.

Daha verimli ve göreve özel modeller elde etmek için 2 aşamalı performans yükseltme çalışmasına geçildi. İlk aşama, ilk modellerde ince ayar yapmaktır. Tablo 3'teki Sütun 5, 6 ve 7, ince ayar uygulama sonuçlarını göstermektedir. İnce ayar şu şekilde yapıldı:

1. VGGNets'teki dense katman nöronlarının sayısı yarı yarıya azaltıldı;
2. Dropout oranı 0,5'ten 0,2'ye düştü;

3. ResNets, EfficientNets gibi modellerin başında; modelin başında ortalama pooling ve yoğun katmanları kullanan, aşağıdaki gibi bir katman dizisi ile değiştirilmiştir: flatten - dense (2048 nöron) - dropout (0,2 oran) - dense (2048 nöron) - dropout (0,2 oran) - dense (1 nöron). Son katmanın çıktısı, girişin kusurlu olmayan bir fişek kovani olma olasılığına karşılık gelir.

Önceden eğitilmiş modellerin çoğu, ImageNet gibi büyük veri kümeleri için özel olarak tasarlanmış karmaşık modellerdir. Bu nedenle, model eğitimi sırasında aşırı uyum ve genelleme yapmama gibi sorunlardan kaçınmak için ince ayar, bu modellerden belirli bir görev ağına bilgi aktarımında kritik bir süreçtir. Tablo 3'te gösterildiği gibi, Xception ve InceptionV3 modelleri dışında, yukarıdaki ince ayar süreçleri, deneylerimizde beklendiği kadar iyi genellemeyen varsayılan modellerden, özellikle varsayılan modellerden daha verimli ve göreve özel modeller elde etmemizi sağladı. EfficientNet modelleri. İnce ayar, VGGNets modellerinin neredeyse yarısı kadar parametre sayısını azaltmayı mümkün kılarken, aynı iyi sonuçları veya varsayılan modellerden bile daha iyi olmasını sağladı. Model eğitimi sırasında, evrişimli sinir ağı filtrelerinin ağırlıkları, kayıp fonksiyonunu en aza indirmek için en uygun şekilde ayarlanır. Bu ayarın yönü ve büyüklüğü, modeli eğitmek için kullanılan optimize ediciye çok bağlıdır.

Bu fine-tuning etkisi, elde edilen doğruluğa (increase / neutral / decrease) göre yüzde olarak ölçülmüştür (Çizelge 8.1'te sütun 7'ye bakınız). Ardından, her model için en yüksek doğruluğa sahip olan seçildi (3 ve 5 numaralı sütunlarda koyu renkle işaretlenmiş sonuçlara bakın). En iyi sonuç, ilk modelde %11,0'lik bir iyileştirme ile %99,3 doğrulukla ince ayarlı EfficientNetV2S ile elde edildi ve en düşük sonuç, ince ayar ile performansı da %25,6 artırılan ilk EfficientNetV2L (%69,7 doğruluk) ile elde edildi. Doğruluklarına göre Çizelge 8.1 sütun 1'de gösterilen her bir mimari için en yüksek performansa sahip model Çizelge 8.1 sütun 8'de gösterildiği gibi Maksimum Doğruluk (Maximum Accuracy) olarak seçilmiştir.

Çizelge 8.1 Askeri fişek kovanlarının sınıflandırılması uygulama sonuçları

Models	Sub-Models	Accuracy of Initial Models (%)	Number of Parameters of Initial Models (M)	Accuracy of Fine-Tuned Models (%)	Number of Parameters of Fine-Tuned Models (M)	Fine-Tuning effect (%)	Maximum Accuracy
1	2	3	4	5	6	7	8
VGG	16	0.980	65.06	0.987	33.60	+00.7	0.987
	19	0.987	70.37	0.987	38.90	±00.0	0.987
ResNet	50	0.987	23.59	0.990	29.88	+00.3	0.990
	101	0.980	42.66	0.990	48.95	+01.0	0.990
	152	0.983	58.37	0.990	64.67	+00.7	0.990
DenseNet	121	0.980	07.04	0.983	11.24	+00.3	0.983
	169	0.980	12.64	0.987	18.15	+00.7	0.987
	201	0.980	18.32	0.983	24.36	+00.3	0.983
Xception		0.970	20.86	0.963	27.16	- 00.7	0.970
InceptionV3		0.980	21.80	0.970	28.10	- 01.0	0.980
EfficientNet	B3	0.970	10.79	0.983	63.22	+01.3	0.983
	B7	0.907	64.10	0.940	150.09	+03.3	0.940
	V2B3	0.953	12.93	0.993	65.36	+04.0	0.993
	V2S	0.883	20.33	0.993	64.38	+11.0	0.993
	V2M	0.870	53.15	0.963	97.19	+09.3	0.963
	V2L	0.697	117.75	0.953	161.79	+25.6	0.953


Performans iyileştirmenin ikinci aşamasında, VGGNets için ince ayarlanmış (fine-tuned) VGG16, ResNets için ince ayarlanmış ResNet101, DenseNet için ince ayarlanmış DenseNet169, değiştirilmemiş Xception, değiştirilmemiş InceptionV3 ve EfficientNet için ince ayarlanmış EfficientNetV2S'nin seçili modelleri SGD, RMSprop, Adam, Nadam, Adagrad gibi farklı optimize ediciler kullanılarak eğitildi. Elde edilen sonuçlar Çizelge 8.2'te karşılaştırılmıştır. Çizelge 8.2'te görüldüğü gibi, iyileştirilmiş sonuçlar koyu renkle işaretlenmiştir. Bu optimize edici ayarı, ince ayarlanmış VGG16, ince ayarlanmış ResNet101 ve değiştirilmemiş InceptionV3 ve ince ayarlanmış EfficientNetV2S gibi bazı modellerde olumlu bir etkiye sahip olmasa da ince ayar yapılmış DenseNet169 gibi modellerin doğruluğu RMSProp, Adam ve Nadam gibi optimize ediciler ile %100'e ulaştı. Bu sayede performans artışları gözlemlendi.

Çizelge 8.2 Derin CNN'lerin önceden eğitilmiş modellerinde optimize edicilerin performansının değerlendirilmesi

	VGG16	ResNet 101	Dense Net169	Xception	InceptionV3	EfficientNetV2S
Optimizer	Accuracy	Accuracy	Accuracy	Accuracy	Accuracy	Accuracy
SGD	0.987	0.990	0.987	0.970	0.980	0.993
RMSprop	0.987	0.987	1.000	0.900	0.970	0.967
Adam	0.980	0.987	1.000	0.980	0.980	0.987
Nadam	0.980	0.980	1.000	0.980	0.963	0.987
Adagrad	0.983	0.990	0.987	0.887	0.963	0.983

8.2.3 VGG16 modeli ile kovan yüzey hata sınıflandırma örneği


Derin öğrenme girdi veri setini hazırlamak için kovan görüntüleri 300x100 piksele boyutlandırılmıştır. Sonrasında 100x100 3 alt parçaya bölünmüştür. Elde edilen görüntüler hatalı ve hatasız olarak 2 sınıfa ayrılacak şekilde sınıflandırılmıştır. Toplamda yaklaşık 1500 adet veri seti oluşturulmuştur. Elde edilen veri setinin %80'i eğitim için, %10'u doğrulama için, %10'luk bir kısmı ise test için kullanılmıştır. Bunların yanında ezberlemeyi engellemek ve veri setinin boyutunu arttırmak için veri çoğaltma yöntemi de uygulanmıştır.



Şekil 8.7 VGG16 Modeli Mimarisi

Öğrenme Aktarması (Transfer Learning) için VGG16 CNN derin öğrenme modeli seçilmiştir. VGG16 modelinin son 4 katmanındaki ağırlıklar ince ayar (fine-tuning) için


güncellenebilir ayarlanmıştır. Önceki katmaların hepsi sabit olarak kalacak şekilde ayarlanmıştır.



Şekil 8.8 Eğitim sonucu kayıp ve doğruluk grafikleri

Eğitim iterasyonlarında oluşan kayıp ve doğruluk sonuçları EK-1’de verilmiştir.

Python dili ile Keras kütüphanesi ile Tensorflow altyapısı kullanılarak yapılan simülasyon sonucunda kayıp (loss) ve doğruluk (accuracy) grafikleri elde edilmiştir (Şekil 8.8). Model üzerinde test verisi ile yapılan tahminlerde %95 üzeri oranda bir başarımla elde edilmiştir. Sistemin test verileri üzerinde örnek tahminlerden bazıları Şekil 8.9’de verilmiştir.



Şekil 8.9 Test Verisi Tahminleri

Görüntüler alt parçacıklara bölünmüş ve veri çoğaltma (data augmentation) yöntemi ile mevcut veri seti çeşitlendirilmiştir. Öğrenme aktarımı (transfer learning) ve ince ayar (fine-tuning) yöntemlerinden faydalanarak daha önceden eğitilmiş bir modeli (VGG16) kendi veri setimiz için tekrar eğitime işlemi gerçekleştirilmiş ve iyi sonuçlar alınmıştır. Yapılan simülasyon çalışmasında %95 üzerinde bir başarımla elde edilmiştir. Çizelge 8.3’de görüntü işleme ile önerilen yöntem ile karşılaştırmalı sonuçları verilmiştir.

Çizelge 8.3 CNN ve Morfolojik Hata Bulma Karşılaştırması

CNN ile Hata Bulma	Bilateral ve Morfoloji ile Hata Bulma
Süre: yaklaşık 120ms	Süre: yaklaşık: 180ms
Doğruluk: %95 üzeri	Doğruluk: %98 üzeri

8.3 Fişek Kovanlar Yüzey Kusurlarının Segmentasyonu

Bu bölümde, askeri fişek kovanlarının yüzeylerindeki kusurların bölümlendirilmesinin uygulama düzeni ve sonuçları sunulmaktadır. Ayrıca, geliştirilmiş U-Net, ResUnet ve DeepLabv3+ modellerinin uygulama detayları da sunulmaktadır.

8.3.1 Uygulama düzeneğinin hazırlanması

Bu bölümde, Bölüm 8'nin 4. Adımında oluşturulan sınıflandırma için veri setinin kusurlu kovan görüntü sınıfından görüntüler (toplamda 750) etiketlendi ve maskelendi. Sonuç olarak, kusur segmentasyonu için etiketli ve maskeli görüntüler içeren veri seti oluşturulmuştur. Bu veri seti, 70:15:15 oranlarında tren, test ve doğrulama sınıflarına bölünmüştür. Veri seti görüntüleri 128x128 olarak yeniden boyutlandırıldı ve CNN modellerinin girişi buna göre ayarlandı. U-Net (Tan ve Le 2019), ResUnet (Zhang vd. 2018, Zhang vd. 2017) ve DeepLab3+ (Chen vd. 2018), kusur segmentasyonu için kullanılan üç ana CNN modelidir. Tüm modeller, arka uç olarak Tensorflow 2.8 ile Keras API kullanılarak uygulanır. Modellerin eğitimi, doğrulanması ve test edilmesi, 32 GB (27,3 kullanılabılır) RAM'e sahip bir NVIDIA Tesla P100 GPU kullanılarak Google Colab üzerinde yapıldı. Adam optimize edici (Kingma ve Ba 2014), model boyunca geri yayılım sırasında optimal ağırlıkları hesaplamak için varsayılan optimize edici olarak kullanıldı. İkili çapraz entropi kaybı fonksiyonu kullanıldı. Mini-batch boyutu ve öğrenme oranı sırasıyla 32 ve 0.01 olarak ayarlandı. Kayıp fonksiyonu 5 ardışık dönem için bir düşüş kaydetmediğinde, öğrenme oranı 0,1 faktörü ile azalır. Vanishing gradients probleminden kaçınmak için minimum öğrenme 1e-6 olarak ayarlandı. Tüm modelleri 60 dönem için eğittik. Wan vd. (2020) yaptığı uygulamadan esinlenerek eşik 0,50 olarak ayarlandı.

8.3.2 Uygulama sonuçları

Segmentasyon sonuçlarını değerlendirmek için tüm modeller için Union, Jaccard Index (JI) ve F1-Skor (F1-Score) metrikleri üzerinden Ortalama Kesişim (mIoU) kullanıldı. Uygulama sonuçları Çizelge 8.4'te gösterilmiştir. En iyi sonucun mIoU=0.924, JI=0.854, F1-Score=0.921 ile geliştirilmiş U-Net ve ResUnet modelleri ile elde edildiği görülmektedir. Aşağıda bu modellerin iyileştirme detayları yer almaktadır.


Çizelge 8.4 Fişek kovanlarının kusur segmentasyonu uygulama sonuçları

Models/Sub-models		mIoU	JI	F1-Score
Standard U-Net		0.843	0.699	0.823
Improved U-Net		0.924	0.854	0.921
ResUnet		0.924	0.854	0.921
Deeplabv3+	R50 (ImageNet 1k)	0.909	0.825	0.904
	R101 (ImageNet 1k)	0.907	0.822	0.902
	R101 (ours)	0.909	0.825	0.904
	VGG16 (ImageNet 1k)	0.901	0.809	0.894
	VGG16 (ours)	0.906	0.818	0.900
	DenseNet169 (ImageNet 1k)	0.909	0.826	0.904
	DenseNet169 (ours)	0.912	0.831	0.908
	Xception (ImageNet 1k)	0.908	0.823	0.903
	Xception (ours)	0.908	0.822	0.903
	Inceptionv3 (ImageNet 1k)	0.913	0.832	0.908
	Inceptionv3 (ours)	0.913	0.832	0.908
	EfficientNetV2S (ImageNet 1k)	0.914	0.835	0.910
	EfficientNetV2S (ours)	0.915	0.837	0.911

8.3.3 Geliştirilmiş U-NET


Mimarinin genel yapısını korurken, orijinal U-Net modelini sorunumuza uyacak şekilde önemli ölçüde geliştirdik. Mimari girişi 128x128x3 olarak ayarlandı ve özellik haritası çıkarımı için daralma yolu boyunca 4 ardışık kodlama bloğu kullanıldı (Şekil 8.10 Geliştirilmiş U-NET).

Kontraksiyon yolu boyunca alt-örnekleme için, her bloğu adım 2 ile 2x2 max-pooling işlemi takip eder. Öznitelik haritalarının sayısı (kanal sayısı) her bir alt-örnekleme adımında iki katına çıkarılır (Tan ve Lee 2019). Ağı düzenli hale getirmek için farklı oranlarda (0.25, 0.50 ve 0.75) kesintiler uygulandı (Alom vd. 2018). Son kodlayıcı bloğunu, özellik haritası sıkıştırmasını ve bu sıkıştırılmış özellik haritalarının kod çözücüye (expansive path) geçişini sağlayan 256'lık bir özellik haritası boyutuna ve 0,50'lik bir düşme oranına sahip bir darboğaz izledi (Lal vd. 2021). Geniştirilmiş yolda max-pooling işlemleri, özellik haritalarını yukarı örnekleme için 2x2 evrişim devrik işlemleriyle değiştirildi. Daha sonra atlama bağlantıları, kontraksiyon yolunun sık ve derin katmanlarının özellik haritalarını, geniş yol boyunca oluşturulan yüksek seviyeli özelliklerle (anlamsal ve uzamsal bilgi) birleştirmek için kullanıldı.



Şekil 8.10 Geliştirilmiş U-NET

Son katmanda, özellikleri 1 kanalla eşlemek için 1x1'lik bir evrişim gerçekleştirdik, burada her pikselin değeri, ilgili giriş görüntüsündeki kusur bölgelerinin bir parçası olmak için o pikseli temsil eder. Aralıklı ortak değişken kaymasını (Zhou ve Yang 2019) çözmek için ağdaki her evrişim katmanından sonra (aktivasyon fonksiyonundan önce) bir toplu normalleştirme katmanı kullandık ve parametreler $\epsilon=1e-3$, $\beta_{\text{initializer}}=0.01$, $\gamma_{\text{initializer}}=1.0$, $\text{momentum}=0.5$ olarak ayarlandı. Ağdaki evrişimsel filtrelerin ağırlıkları, Xavier'in tek biçimli başlatıcısı ("glorot_uniform başlatıcısı") (Glorot ve Bengio 2010) kullanılarak başlatıldı. Şekil 8.11 standart ((a) ve (b)) ve geliştirilmiş ((c) ve (d)) U-Net mimarilerinin kodlayıcı ve çözücü bloklarını gösterir.



Şekil 8.11 Standart ((a), (b)) ve Geliştirilmiş U-Net ((c) ve (d)) Kodlayıcı/Çözücü Blokları

8.3.4 ResUnet gerçekleştirimi


ResUnet modelini Zhang vd. (2017)'ye göre uygulandı, burada Zhang vd. yol bölgelerinin bölümlendirilmesi için U-Net mimarisini ve kalıcı öğrenmenin (He vd. 2015) güçlü yönlerini birleştirdi. ResUnet ve U-Net'in uygulanması arasındaki temel fark, ResUnet modelindeki artık birimin kodlayıcı ve kod çözücü blokları olarak kullanılmasıdır. Artık birim (residual unit), evrişim, aktivasyon ve toplu normalleştirme katmanlarından ve bu birimin girdi özellik haritalarını çıktısıyla birleştiren bir ekleme katmanından oluşur. Bu birim genel bir form olarak aşağıdaki denklemler (8.1) ve (8.2) olarak gösterilebilir:

$$y_l = h(x_l) + F(x_l, W_l), \quad (8.1)$$

$$x_{l+1} = f(y_l), \quad (8.2)$$

Burada x_l , x_{l+1} ve W_l sırasıyla birinci artık birimin filtrelerinin giriş, çıkış ve ağırlıklarıdır. $F(\cdot)$ artık fonksiyon, $h(x_l)$ kimlik eşleme fonksiyonu $h(x_l) = x_l$ ve $f(y_l)$

aktivasyon fonksiyonudur. Tıpkı U-Net ağ uygulamasında olduğu gibi, ResUnet ağındaki evrişimsel filtrelerin ağırlıkları da Glorot ve Bengio'nun (2010) tek biçimli başlatıcısıyla başlatıldı. Şekil 8.12, ResUnet mimarisinde kodlayıcı ve kod çözücü blokları olarak kullanılan artık birimleri göstermektedir.




Şekil 8.12 Geliştirilmiş ResUnet'in Kodlayıcı/Kod Çözücü Blokları

Çizelge 8.4 Fişek kovanlarının kusur segmentasyonu uygulama sonuçları'te genel olarak, sınıflandırma görevi sırasında veri setimizde önceden eğitilmiş ağırlıkları kullandığımız DeepLabv3+ mimarisine dayalı modellerin, ImageNet önceden eğitilmiş ağırlıkların kullanıldığı modellerden daha iyi performans gösterdiği gözlemlenebilir. Bu modeller arasında Deeplabv3+ EfficientNetV2S (güncellenmiş) en iyi performansı mIoU=0.915,

JI=0.837, F1-Score=0.911 metrik sonuçlarıyla gösterdi. Aşağıda bu modelin iyileştirme detayı bulunmaktadır.

8.3.5 DeepLabv3+ gerçekleştirimi

DeepLabv3+, orijinal belgede (Chen vd. 2018) olduğu gibi aynı ASPP (Atrous Spatial Pyramid Pooling) mimarisi kullanılarak sırasıyla 1, 6, 12, 18 genişleme oranları ve 256'lık bir özellik kanal boyutu ile uygulandı. Sınıflandırma bölümünde geliştirilen en verimli modellerin eğitilmiş ağırlıklarından faydalanmak için, Şekil 8.13'da gösterildiği gibi DeepLabv3+ uygulamasında omurga ağları (özellik çıkarıcı ağlar) olarak Çizelge 8.1'teki modelleri (ve ResNet-50 modeli) kullandık.



Şekil 8.13 DeepLabv3+ Mimarisi

Omurga ağlarında önceden eğitilmiş iki ağırlık kullanıldı: (1) ImageNet önceden eğitilmiş ağırlıklar ve (2) kovan veri seti için önceden eğitilmiş ağırlıklar. U-Net ve ResUnet

modelleri arasında daha spesifik bir karşılaştırma için Precision ve Recall kullanıldı. Çizelge 8.5, kusurlu kovan yüzeylerinin segmentasyonu için bu çalışmada kullanılan geliştirilmiş U-Net ve ResUnet modellerinin karşılaştırmalı sonuçlarını göstermektedir.


Çizelge 8.5 Geliştirilmiş U-Net ve ResUnet modelleri arasında karşılaştırma

Model	F1-score	Precision	Recall
Geliştirilmiş U-Net	0.921	0.916	0.927
ResUnet	0.921	0.921	0.922

FP (False Positive) tahmininin maliyeti yüksek ise ResUnet modeli, aksi takdirde FN (False Negative) tahmininin maliyeti yüksek ise U-Net modeli kullanılmalıdır.

Şekil 8.14, segmentasyon için veri setlerinin test setindeki sonuçları vermektedir. Şekil 8.14, Çizelge 8.4'te listelenen Derin CNN modelleri kullanılarak bölümlere ayrılmış beş adet hatalı askeri fişek kovanı örneğini göstermektedir. Sonuçların iyi bir görsel olarak anlaşılmasını sağlamak için kusurlu bölgelerin ana hatları kırmızı kutularla belirtilmiştir. Şekil 13'te görülebileceği gibi, standart U-Net modeli hariç, diğer tüm modeller basit kusur yüzeylerini iyi bir şekilde segmentlere ayırabilir (bkz. Şekil 8.14'teki Örnek 1 ve 2), özellikle geliştirilmiş U-Net ve ResUnet Bölgeleri yüksek hassasiyetle segmentlere ayıran modeller. Örnek 3'te, geliştirilmiş U-Net, ResUnet ve EfficientNetV2S (güncellenmiş) modellerinin daha az görünür kusurların segmentasyonunda en verimli modeller olduğunu görebiliriz (Çizelge 8.4 sonuçlarına göre). Segmentasyon verilerinin etiketlenmesi piksel bazında olduğundan, segmentasyonu mükemmel bir şekilde gerçekleştirmek zordur. Dolayısıyla etiketleme sonucunda bazı piksellerin gözden kaçtığı görülebilir. Çalışmalar sonucunda, geliştirilmiş U-Net ve ResUnet modellerimizin bu kusurları (etiketleme aşamasında gözden kaçan) çok yüksek bir hassasiyetle (Örnek 4'te gösterildiği gibi) segmentlere ayırabildiği gözlemlenebilir. Çizelge 8.5'da bildirildiği gibi ResUnet, hassaslık açısından geliştirilmiş U-Net modelinden daha iyi performans gösterirken, ikincisi en yüksek hatırlamaya sahiptir. Bu nitel karşılaştırma, ResUnet'in askeri fişek kovanı kusurlu yüzeyini diğer tüm modellerden daha yüksek bir hassasiyetle ve ayrıca bazı kusurlu piksellerin gözden kaçırıldığı maskeyi öngördüğü Örnek 5'te gösterilmektedir. Bazı karmaşık örneklerde, önceden eğitilmiş ağırlıklarımızla başlatılan modellerin daha iyi performansı, ImageNet'te önceden eğitilmiş ağırlıklarla başlatılan

modellerin (Şekil 8.14 Example 3 g-h, q-r çiftleri ve Example 4 i-j, k-l çiftleri) üzerinde fark edilebilir.



Şekil 8.14 Hata segmentasyonu için test setinde elde edilen sonuçlardan örnekler. (a) Girdi görüntüsü; (b) Maske (Zemin Gerçeği); (c) Standart U-Net; (d) İyileştirilmiş U-Net; (e) ResUnet; (f) DeepLabv3+ (ResNet-50-I1k); (g) DeepLabv3+ (ResNet-101-I1k); (h) DeepLabv3+ (ResNet-101-I1k)

Güncellenmiş); (i) DeepLabv3+ (VGG-16-I1k); (j) DeepLabv3+ (VGG-16-Güncellenmiş); (k) DeepLabv3+ (DenseNet-169-I1k); (l) DeepLabv3+ (DenseNet-169-Güncellenmiş); (m) DeepLabv3+ (Xception-I1k); (n) DeepLabv3+ (Xception-Güncellenmiş); (o) DeepLabv3+ (InceptionV3-I1k); (p) DeepLabv3+ (InceptionV3-Güncellenmiş); (q) DeepLabv3+ (EfficientNetV2S-I1k); (r) DeepLabv3+ (EfficientNetV2S-Güncellenmiş)

8.4 Bulgular ve Tartışma

Düşük doğruluk, düşük performans ve yüksek maliyet, endüstriyel ürünlerin, özellikle fişek kovanları gibi askeri ürünlerin manuel kalite kontrolünün dezavantajlarıdır. Bu dezavantajlara çözüm bulmak için yapay görme sistemlerini kullanan otomatik kalite kontrol yaygın olarak kullanılmaktadır. Bu sistemler, üretim sürecinde kameralar vasıtasıyla nesnelerin yüzeylerinden görüntüleri gerçek zamanlı olarak alır. Bu nedenle, kusur tespitinin uygun doğruluğunu elde etmek için görüntülerin kalitesi çok önemlidir. Doğruluğu etkileyen bir diğer faktör de ürün yüzeyinin homojen olmayan dokusudur. Ürünün düzgün olmayan dokusunu kusurlu dokudan ayırt etmek zorlu bir problemdir. Bu soruna çözüm getirmek için, doğruluğu artırmak için askeri fişek kovanlarının sınıflandırılması ve yüzeylerindeki kusurların düzgün olmayan doku ile bölümlere ayrılması için metodoloji önerildi. Önerilen metodoloji kapsamında veri seti oluşturulmuş, sınıflandırma ve segmentasyon için derin öğrenme modelleri geliştirilmiş ve uygulanmıştır. Samet ve Tural'ın (2020) çalışmalarında ifade ettiği gibi mevcut görüntü işleme teknikleri ve derin öğrenme modelleri uygulanarak (VGG16) askeri fişek kovanlarda sırasıyla %96 ve %97 oranlarında doğruluklar elde edilmiştir. Hatanın istenmediği kritik ürün kontrollerinde bu oranların üstünde bir başarı ve doğruluk beklenmektedir. Bu çalışmada, mevcut literatürde erişilebilen doğruluk oranları mevcut modellerin parametreleri değiştirilerek ve modeller üzerinde değişiklik yapılarak artırılmıştır. Önerilen metodoloji sayesinde sınıflandırma için DenseNet169 modeli ile askeri fişek kovanlarının sınıflandırma doğruluğu %100'e artırılmıştır. Kusurlu bölgelerin segmentasyonu için kullanılan mevcut U-Net ve ResUnet modelleri üzerinde yapılan geliştirme ve değişiklikler ile F1-Skor doğruluğu %92,1'e çıkarıldığı gözlemlenmiştir. Yapılan çalışmada sınıflandırma ve segmentasyon işlemleri ardarda uygulanarak yüzey kontrolünde yüksek başarı elde edilmiştir.

Bu çalışmanın ana bulgusu, derin öğrenme tekniklerinin, askeri fişek kovan yüzeyindeki kusurların sınıflandırılması ve segmentasyonu için gerekli NATO standartlarına ulaşma potansiyeline sahip olmasıdır. Elde edilen sonuçlardan ulaşılan diğer bir bulgu ise, konvansiyonel görüntü işleme teknikleri ile yüzey dokusundan ayırt etmenin çok zorlayıcı olduğu ancak insan yetisi ile bulunabilecek kusur çeşitlerinde, kusurların derin öğrenme teknikleri ile yüksek doğruluk oranlarında tespitinin mümkün olduğunun kanıtlanmasıdır.



9. SONUÇ

Bilgisayar ile görme algoritmaları birçok alanda yaygın olarak kullanılmaktadır ve kullanım alanları hızla yaygınlaşmaya devam etmektedir. Bu kullanım alanlarından biri de endüstriyel olarak üretilen ürünlerin yüzey hatalarının tespiti. Endüstride kullanılan kalite kontrol sistemlerinde bilgisayar ile görme algoritmaları önemli bir yer almaktadır. Otomatik kalite kontrol sistemleri, kusurlu ürünleri tespit etmek ve kusurlu ürünleri ayırmak için kullanılır. Farklı kontrol yöntemleri olmasına rağmen yoğun olarak kullanılan yöntem göz ile görülebilen yüzey kusurlarının incelenmesi ile yapılır. İnsan gözü ile yapılan kontroller, makinalar ile yapılan kontrollere göre birçok dezavantajı barındırmasına rağmen endüstride ağırlıklı olarak kullanılmaya devam etmektedir. Çünkü nesne yüzey hatalarının incelenmesi ve tespitinin sofistike problemleri içinde barındırır. İnsan karar verme yetisi bu noktada çoğu bilgisayarla görme tabanlı sistemlere göre daha iyi biçimde çalışmaktadır. Bilgisayarla görme sistemleri kusurların yüzey dokusundan çok zor ayrıştığı durumlarda karar vermekte zorlanmaktadır.

Çalışmada kapsamında endüstriyel uygulamalarda nesne yüzey hatalarının bilgisayarla görme tabanlı tespiti için tüm alt bileşenleri içeren donanım ve yazılım mimarisi oluşturulmuştur. Kovan yüzeylerinin hata tespiti için başka çalışmalarda da kullanılabilecek bir veri seti oluşturulmuştur. Kameralardan alınan ham görüntüler üzerinde segmentasyon işlemleri yapılarak kovan yüzeyini yüksek doğruluk ve yüksek işlem hızı ile tespit eden yöntem önerilmiştir. Segmente edilen kovan yüzey maskesi kolay işlenebilmesi için gerekli düzeltme açısı hesaplanıp dik konuma getirilmiştir ve kovan gövde yüzey bölgesi çıkartılmıştır. Kovan gövde yüzey bölgesi üzerinde kusurlarını tespit eden görüntü işleme algoritmaları önerilmiştir. Doku yüzeyi ile ayrılması zor hataların tespiti için ise insan beynini taklit eden derin öğrenme yöntemleri geliştirilmiş ve standart modeller üzerinde geliştirmeler yapılarak katkı sağlanmıştır.

Çalışmada derin öğrenme modellerinde önerilen metodoloji ile askeri fişek kovanlarının kusurlu/kusursuz sınıflandırması ve kusurların segmentasyonunda doğruluk oranları mevcut modellere göre artırılmıştır. Yüzey hata bulma teknikleri ile ilgili literatürde geçen yöntemler daha detaylı olarak incelenmiş ve simülasyonları gerçekleştirilmiştir.

Deney düzeneđi üzerinde alınan hareketli görüntülerde kovan yüzeyinin ayrıştırılması, kovan eğiklik açısının düzeltilmesi ve yüzey de hata bulma ile ilgili çalışmalar yapılmıştır. Bilateral süzgecin kovan yüzeyinde hataları belirginleştirme ve hata olmayan yüzey deseninin ayrıştırılmasında iyi sonuçlar verdiği gözlemlenmiştir. Hesaplama zamanı olarak gerçek zamanlı çalışmaya uygun bir filtre olduğu gözlemlenmiştir.

Kovan veriseti üzerinde geliştirilen görüntü işleme ve evrişimsel sinir ağıları (VGG16) kullanılarak sırasıyla %97 ve %96 oranlarında başarımlar elde edilmiştir. Daha sonra DenseNet169 modeli geliştirilerek kovanların sınıflandırma doğruluđu %100'e çıkartılmıştır. Hata segmentasyonunda ise iyileştirilen U-Net ve ResUnet ile %92,1 oranında F1-Skoruna erişilmiştir.

Bu çalışmanın temel bulgusu, endüstriyel uygulamalarda nesne yüzey hatalarının bilgisayarla görme tabanlı tespiti için insan gözü ile yapılan kontrollerden daha güvenli ve daha doğru olacak sistem ve metodolojilerin geliştirilmesidir. Hem sınıflandırma hem de bölütleme için ileriki çalışmalarda referans olabilecek bir veri seti oluşturulmuştur.

KAYNAKLAR

- Anonymous. 2013. Web Sitesi: <https://robospace.wordpress.com/2013/10/09/object-orientation-principal-component-analysis-opencv>, Erişim Tarihi: 15.11.2022.
- Alom, M., Hasan, M., Yakopcic, C., Taha, T., and Asari, V. 2018. Recurrent Residual Convolutional Neural Network based on U-Net (R2U-Net) for Medical Image Segmentation. CVPR, 2018
- Asha, V., Bhajantri, N.U. and Nagabhushan, P. 2011. Automatic Detection Of Texture Defects Using Texture-Periodicity And Gabor Wavelets. In International Conference on Information Processing 2011 Aug 5 (pp. 548-553). Springer, Berlin, Heidelberg.
- Bayram, S., Kaplan, K., Kuncan, M. and Ertunç, H.M., 2014. The Effect Of Bearings Faults To Coefficients Obtained By Using Wavelet Transform. IEEE 978-1-4799-4874-1.
- Bernsen, J. 1986. Dynamic Thresholding of Gray-Level Images. Proc. 8th Int. Conf. on Pattern Recognition, Paris, pp. 1251–1255.
- Campos, M., Martins, T., Ferreira, M., & Santos, C. 2008. Detection of defects in automotive metal components through computer vision. In 2008 IEEE International Symposium on Industrial Electronics (pp. 860-865).
- Canny, J. 1986. A Computational Approach to Edge Detection. IEEE Trans. on Pattern Analysis and Machine Intelligence, 8(6), pp. 679-698.
- Cavdarli, M., and Seke, E. 2010. Measuring Roughness on Wood Surfaces for Detection of Defects Using Multi-Frame Imaging. INISTA 2010 International Symposium on Innovations in Intelligent Systems and Applications, June 2010, Kayseri.
- Chen, K., Zeng, Z., and Yang J. 2021. A deep region-based pyramid neural network for automatic detection and multi-classification of various surface defects of aluminum alloys. Journal of Building Engineering, 43, 102523.
- Chen, L.C., Papandreou, G., Schroff, F., and Adam, H. 2017. Rethinking Atrous Convolution for Semantic Image Segmentation. arXiv:1706.05587.
- Chen, L.C., Zhu, Y., Papandreou, G., Schroff, F., and Adam, H. 2018. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. European Conference on Computer Vision (2018): 833-851
- Chen, Y., Zhang, X. and Zhang, J., 2013. Quick Detection of Defects In Armor Plate Images By Complexity. Journal of Multimedia, 8(6), p.685.

- Choi, J. and Kim, C. 2012. Unsupervised Detection of Surface Defects: A Two-Step Approach. 9th IEEE International Conference on Image Processing, Pages 1037 – 1040, Sept. 30.
- Chollet, F. 2016. Xception: Deep Learning with Depthwise Separable Convolutions. CVPR, 2016.
- Chondronasios, A., Popov, I. and Jordanov, I., 2016. Feature Selection For Surface Defect Classification Of Extruded Aluminum Profiles. *Int J Adv Manuf Technol*, 83:33–41.
- Çıklaçandır, F. G. Y., Utku, S. and Özdemir, H. 2021. Fabric Defect Classification Using Combination of Deep Learning and Machine Learning. *Journal of Artificial Intelligence and Data Science (JAIDA)*, 1(1), 22-27.
- Demirhan, A. ve Güler, İ., 2010. Özörgütlemeli Harita Ağları Ve Gri Düzey Eş Oluşum Matrisleri İle Görüntü Bölütleme. *Gazi Üniv. Müh. Mim. Fak. Der. Cilt* 25, No 2.
- Devikar P. (2016). Transfer Learning for Image Classification Of Various Dog Breeds. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, vol.5, no.12.
- Dietterich, T. G., Pratt, L., and Thrun, S. 1997. Special issue on inductive transfer. *Machine Learning*, 28(1).
- Du, W., Shen, H., Zhang, G., Yao, X. and Fu, J. 2022. Interactive defect segmentation in X-Ray images based on deep learning. *Expert Systems with Applications*, 198, 116692.
- Farooq, A., Smith M., Smith, L. and Midha S. 2005. Dynamic Photometric Stereo for on Line Quality Control of Ceramic Tiles. *Computers in Industry*, Vol. 56, No. 8-9; pp. 918-934.
- Fathi, A. and Eskandari, A. R. 2013. Defect Detection of Tiles Based on High Frequency Distortion. *International Journal of Electrical and Computer Engineering (IJECE)*, Vol. 3, No. 4; August, pp. 483-491.
- Feng, T., Zou, L., Yan, J., Shi, W., Liu, Y., Fan, C. and Deng, D., 2016. Real-Time Fabric Defect Detection Using Accelerated Small-Scale Over-Completed Dictionary of Sparse Coding. *International Journal of Advanced Robotic Systems*, 13(1), p.1.
- Foruzan, A.H., Chen, Y. 2016. Improved segmentation of low-contrast lesions using sigmoid edge model, *International Journal of Computer Assisted Radiology and Surgery*. Vol.11, No.7, pp.1267-1283.

- Fouda, Y. M. 2022. Integral images-based approach for fabric defect detection. *Optics & Laser Technology*, 147, 107608.
- Frayman, Y., Zheng, H. and Nahavandi, S., 2004. Machine Vision System for Automatic Inspection of Surface Defects in Aluminum Die Casting. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, Vol.10 No.3.
- Glorot, X., and Bengio, Y. 2010. Understanding the difficulty of training deep feedforward neural networks. *Proc. 13th Int. Conf. Artif. Intell. Statist*, pp. 249–256.
- Goodfellow, I., Bengio, Y., and Courville, A. 2016. *Deep Learning*. MIT press.
- He, D., Xu, K. and Zhou, P. 2019. Defect detection of hot rolled steels with a new object detection framework called classification priority network. *Computers & Industrial Engineering*, 128, 290-297.
- He, K., Zhang, X., Ren, S. and Sun, J. 2016. Identity Mappings in Deep Residual Networks. *CVPR*, 2016.
- He, K., Zhang, X., Ren, S. and Sun, J. 2015. Deep Residual Learning for Image Recognition. *CVPR*, 2015.
- Huang, K., and Ye, Y., 2015. A Novel Machine Vision System for the Inspection of Micro-Spray Nozzle. *Sensors* ISSN 1424-8220.
- Huang, G., Liu, Z., Maaten, L. and Weinberger, K. 2016. Densely Connected Convolutional Networks. *CVPR*, 2016.
- Issac, A., Sarathi, M.P. and Dutta, M.K. 2015. An adaptive threshold based image processing technique for improved glaucoma detection and classification. *Computer Methods and Programs in Biomedicine*, Vol.122, No.2, pp.229-244.
- İnik, Ö. ve Ülker E. 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri", *Gaziosmanpasa Journal Of Scientific Research*, Gbad, 85-104.
- Jahanbin, S., Bovik, A.C., Pérez, E. and Nair, D., 2009, September. Automatic Inspection of Textured Surfaces By Support Vector Machines. In *Optical Inspection and Metrology for Non-Optics Industries* (Vol. 7432, p. 74320A). International Society for Optics and Photonics.
- Jia, H., Murphey, Y. L., Shi, J. and Chang, T. 2004. An Intelligent Real-Time Vision System for Surface Defect Detection. *Proceedings of the 17th International Conference on Pattern Recognition*, 239 – 242.

- Jiang, L., Wang Y., Tang, Z., Miao, Y., and Chen, S. 2021. Casting defect detection in X-ray images using convolutional neural networks and attention-guided data augmentation. *Measurement*
- Jijina K. P., Sreeja S. S. and Vinod P. R. 2013. Real Time Detection and Classification of Metal Defects Using Image Processing. *International Research Journal of Computer Science Engineering and Applications*, Vol 2 Issue 4 April, ISSN 2319-8672.
- Kaur, A. 2014. "Image Segmentation Using Watershed Transform". *International Journal of Soft Computing and Engineering (IJDCE)*, ISSN: 2231-2307, Volume-4, Issue-1, March 2014.
- Kheradmandi, N. and Mehranfar, V. 2022. A critical review and comparative study on image segmentation-based techniques for pavement crack detection. *Construction and Building Materials*, 321.
- Khurshid, K., Siddiqi, I., Faure, C., Vincent, N. 2010. Comparison of Niblack inspired Binarization methods for ancient documents. In: 16th International conference on Document Recognition and Retrieval. SPIE, USA.
- Kın, Z. B. 2019. Türk İşaret Dili Alfabesinin Derin Öğrenme Yöntemi ile Sınıflandırılması. Başkent Üniversitesi, Fen Bilimleri Enstitüsü. Yüksek Lisans Tezi.
- Kızrak., M.A. 2017. Yapay Zekada Büyük Yenilik: Kapsül Ağları (Capsule Networks). <http://dergi.bmo.org.tr>.
- Kim, S., Kim, W. Noh, Y. K., and Park, F. C. 2017. Transfer learning for automated optical inspection. *International Joint Conference on Neural Networks (IJCNN)*, (2017), IEEE, 2517-2524.
- Kingma D. and Ba, J. 2014. Adam: A Method for Stochastic Optimization. *Machine Learning*, 2014.
- Krizhevsky, A., I. Sutskever and G. Hinton. 2012. ImageNet Classification with Deep Convolutional Neural Networks. In *NIPS'2012*. 23, 24, 27, 100, 200, 371, 456, 460.
- Lal, S., Das, D., Alabhya, K., Kanfode, A., Kumar, A., and Kini, J. 2021. NucleiSegNet: Robust deep learning architecture for the nuclei segmentation of liver cancer histopathology images. *Computers in Biology and Medicine*, Volume 128.
- Latif-Amet, A., Ertüzün, A. and Erçil, A. 2000. An Efficient Method for Texture Defect Detection: Sub-Band Domain Co-Occurrence Matrices. *Image and Vision Computing* 18; 543- 553.

- Li, J., Ding, S. 2011. A Research on Improved Canny Edge Detection Algorithm. In: Zhang, J. (eds) Applied Informatics and Communication. ICAIC 2011. Communications in Computer and Information Science, vol 228. Springer, Berlin, Heidelberg.
- Li, Q. and Ren S., 2012. A Real-Time Visual Inspection System for Discrete Surface Defects of Rail Heads. IEEE Transactions on Instrumentation and Measurement, Vol. 61, No. 8, August 2012.
- Li, P., Jiao, Y., Jing, J. and Li, J., 2013. The High-speed Fabric Defect Detection Algorithm Based on the Image Layered Model. Journal of Fiber Bioengineering and Informatics, 161-173.
- Liu, Y. and Yu, F. 2014. Automatic Inspection System of Surface Defects on Optical IR-CUT Filter Based on Machine Vision, Elsevier, 55, 243-257.
- Long, J., Shelhamer, E., and Darrell, T. 2014. Fully Convolutional Networks for Semantic Segmentation. CVPR, 2014.
- McCulloch, W. S. and W. Pitts. 1943. A Logical Calculus of The Ideas Immanent in Nervous Activity. The Bulletin of Mathematical Biophysics 5(4): 115–133
- Michaeli, W. and Berdel, K., 2011. Inspection of Textured Plastics Surfaces. Optical Engineering Volume 50, Issue 2, February 04, 2011.
- MIL-STD-636. 1958. Military Standard: Visual inspection standards for small arms ammunition through caliber 0.50. Department of Defense, United States of America.
- MIL-STD-651. 1962. Military Standard: Visual inspection standards for 20mm ammunition and components, Department of Defense. United States of America
- Mittal, S., Chopra, C., Trivedi, A. and Chanak, P. 2019 .Defect segmentation in surfaces using deep learning. International Conference on Issues and Challenges in Intelligent Computing Techniques (ICICT), 1, 1-6.
- Mohan, V. and Haripasad. 2015. Ceramic tile's inspection using HaarDiscrete Wavelet Transform and Euclidean Distance. International Journal of Advanced Research Trends in Engineering and Technology (IJARTET), 2015, Vol. II, Special Issue I. 150-154.
- Mordia, R. and Verma, A. K. 2022. Visual techniques for defects detection in steel products: A comparative study. Engineering Failure Analysis, 134, 106047.

- Mosorov, V. and Tomczak, L. 2014. Image Texture Defect Detection Method Using Fuzzy C-Means Clustering for Visual Inspection Systems. *Arabian Journal for Science and Engineering*, 39(4), pp.3013-3022.
- Niblack, W. 1986. *An Introduction to Digital Image Processing*. Prentice-Hall, Englewood Cliffs, NJ, 1986, pp. 115–116.
- Oktay, E. and Alkan, Ö. 2010. Temel Bileşenler Analizi Yöntemiyle Toplu Taşıma Araçlarından Memnuniyeti Etkileyen Faktörlerin Belirlenmesi: Erzurum İli Örneği. 11. Ekonometri ve İstatistik Sempozyumu, At Sakarya, 811-826.
- Otsu, N. 1979. A Threshold Selection Method from Gray-level Histograms. *IEEE Trans. Systems, Man, and Cybernetics*, vol. 9, Issue. 1, pp. 62–66.
- Pan, L., Rogulin, R., Kondrashev, S. 2021. Artificial neural network for defect detection in CT images of wood. *Computers and Electronics in Agriculture*, 187, 106312.
- Pan, Z., Yang, J., Wang, X., Wang, F., Azim, I., Wang, C. 2021. Image-based surface scratch detection on architectural glass panels using deep learning approach. *Construction and Building Materials*, 282, 122717.
- Patel, B., and Bhaidasna, H. 2016. Survey on different methods for Defect Detection. *International Research Journal of Engineering and Technology (IRJET)*, Volume: 03, Issue:02, Page:1217-1220, February 2016.
- Paris, S., Kornprobst, P., Tumblin, J., Durand, F. 2009. Bilateral filtering: Theory and applications. *Foundations and Trends in Computer Graphics and Vision*, 4 (1), 1–73.
- Perng, D., Liu, H. and Chang, C. 2011. *Automated SMD LED Inspection Using Machine Vision*. Int J Adv Manuf Technol, Springer-Verlag London Limited, 2011.
- Pratt, L. Y. 1993. Discriminability-Based Transfer Between Neural Networks. In *Advances in Neural Information Processing Systems* (pp. 204-211).
- Rahejaa, J.L., Kumar S. and Chaudharyc, A., 2013. Fabric defect detection based on GLCM and Gabor filter: A comparison. *Optik* 124 (2013) 6469–6474.
- Rahman, H., and Islam, R. 2013. Segmentation of color image using adaptive thresholding and masking with watershed algorithm. *International Conference on Informatics, Electronics & Vision (ICIEV)*, 2013, pp.1-6.
- Ralló, M., Millán, M.S. and Escofet, J., 2009. Unsupervised Novelty Detection Using Gabor Filters for Defect Segmentation in Textures. *JOSA A*, 26(9), pp.1967-1976.

- Ren, R., Hung, T., and Tan, K. C. 2017. A generic deep-learning-based approach for automated surface inspection. *IEEE Transactions on Cybernetics*, 48(3), 929-940.
- Rong, W., Li, Z., Zhang W., and Sun, L. 2014. An improved Canny edge detection algorithm. *IEEE International Conference on Mechatronics and Automation*, pp. 577-582, doi: 10.1109/ICMA.2014.6885761.
- Ronneberger, O., Fischer P., and Brox, T. 2015. U-net: Convolutional Networks for Biomedical Image Segmentation. *MICCAI*, 2015 (pp. 234-241). Springer, Cham.
- Roy, P., Dutta, S., Dey, N., Dey, G., Chakraborty S., and Ray, R. 2014. Adaptive thresholding: A comparative study. *International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT)*, 2014, pp. 1182-1186.
- Russakovsky, O., Deng, J., Su, H. Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein M., et al. 2015. ImageNet Large Scale Visual Recognition Challenge. *CVPR*, 2015.
- Samet, R. and Tural, S., 2020. Deep Learning Based Defect Detection of Metallic Surfaces. In *Seventh International Conference on Control and Optimization with Industrial Applications* (pp. 362-364).
- Sauvola, J., Seppanen, T., Haapakoski, S., Pietikainen, M. 1997. Adaptive Document Binarization. In: *Fourth International Conference Document Analysis and Recognition (ICDAR)*, Ulm, Germany.
- Sauvola, J., and Pietikainen, M. 2000. Adaptive Document Image Binarization. *Pattern Recognition* 33(2), pp. 225–236.
- Seçkin, A. Ç., and Seçkin, M. 2022. Detection of fabric defects with intertwined frame vector feature extraction. *Alexandria Engineering Journal*, 61(4), 2887-2898.
- Şengür, A., and Türkoğlu, İ. 2004. Değişmez Momentlerle Türkçe Karakter Tanım. *Doğu Anadolu Bölgesi Araştırmaları*.
- Shi, B. and Chen, Z. 2021. A layer-wise multi-defect detection system for powder bed monitoring: Lighting strategy for imaging, adaptive segmentation and classification. *Materials & Design*, 210, 110035.
- Shokouh, G.S. 2013. Gerçek Zamanlı Sayısal Görüntü İşleme ve Örüntü Tanıma Tekniklerinin Araştırılması ve Uygulanması. *Ankara Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*.

- Shorten, C., and Khoshgoftaar, T. M., 2019. A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60.
- Sun, T.H., Tseng, C.C. and Chen, M.S., 2010. Electric Contacts Inspection Using Machine Vision. *Image and Vision Computing*, 28(6), pp.890-901.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke V., and Rabinovich, A. 2014. Going Deeper with Convolutions. *CVPR*, 2014.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens J. and Wojna, Z. 2015. Rethinking the Inception Architecture for Computer Vision. *CVPR*, 2015.
- Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. 2016. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *CVPR*, 2016.
- Tan, M. and Le, Q. 2019. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *CVPR*, 2019.
- Tapas, A. 2016. Transfer Learning for Image Classification and Plant Phenotyping. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, vol. 5, no.11.
- Timm, F., and Barth, E. 2011. Non-Parametric Texture Defect Detection Using Weibull Features. *Image Processing: Machine Vision Applications IV*, volume 7877. *Proceedings of SPIE. SPIE-IS&T*. San Francisco, USA.
- Tulbure, A. A., Tulbure, A.A. and Dulf, E.H. 2022. A review on modern defect detection models using DCNNs – Deep convolutional neural networks. *Journal of Advanced Research*, 35, 33-48.
- Tural, S. and Samet, R. 2019. Automated Defect Detection on Surface of Military Cartridges. *Journal of Modern Technology and Engineering*, 4(3), 178-189.
- Tural, S. and Samet, R., Aydin, S., and Traore, M. 2022. Deep Learning Based Classification of Military Cartridge Cases and Defect Segmentation. *IEEE Access*, vol. 10, pp. 74961-74976. doi: 10.1109/ACCESS.2022.3191328.
- Uzen, H., Turkoglu, M. and Hanbay, D. 2021. Texture defect classification with multiple pooling and filter ensemble based on deep neural network. *Expert Systems with Applications*, 175, 114838.
- Wan, T., Zhao, L., Feng, H., Li, D., Tong, C., and Qin, Z. 2020. Robust nuclei segmentation in histopathology using ASPPU-Net and boundary refinement. *Neurocomputing*, Volume 408, 2020, pp. 144-156

- Wang, J., He, J., Han, Y., Ouyang, C., and Li, D. 2013. An adaptive thresholding algorithm of field leaf image. *Computers and Electronics in Agriculture*, Vol.96, pp.23-39.
- Wang, K., Fan-Jiang, H., Lee, Y. 2022. A multiple-stage defect detection model by convolutional neural network. *Computers & Industrial Engineering*, 168, 108096.
- Wang, Y., Hu, C., Chen, K., and Yin, Z., 2020. Self-attention guided model for defect detection of aluminium alloy casting on X-ray image. *Computers & Electrical Engineering*, 88, 106821.
- Westphal, E. and Seitz, H. 2021. A machine learning method for defect detection and visualization in selective laser sintering based on convolutional neural networks. *Additive Manufacturing*, 41, 101965.
- Würschinger, H., Mühlbauer, M., Winter, M., Engelbrecht, M., and Hanenkamp, N. 2020. Implementation and potentials of a machine vision system in a series production using deep learning and low-cost hardware. *Procedia CIRP*, 90, 611-616.
- Xiao, C. and Buffiere, J.Y. 2021. Neural network segmentation methods for fatigue crack images obtained with X-ray tomography. *Engineering Fracture Mechanics*, 2021, 252.
- Xie, X. and Mirmehdi, M., 2005, August. Texture Exemplars for Defect Detection on Random Textures. In *International Conference on Pattern Recognition and Image Analysis* (pp. 404-413). Springer, Berlin, Heidelberg.
- Xie, X., 2008. A Review of Recent Advances in Surface Defect Detection Using Texture Analysis Techniques. *Electronic Letters on Computer Vision and Image Analysis* 7(3):1-22.
- Xu, H., Yan, Z.H., Ji, B.W., Huang, P.F., Cheng, J.P., Wu, X.D. 2022. Defect detection in welding radiographic images based on semantic segmentation methods. *Measurement*, 188, 110569.
- Xu, R., Hao, R. and Huang, B. 2022. Efficient surface defect detection using self-supervised learning strategy and segmentation network. *Advanced Engineering Informatics*, 52, 101566.
- Xu, Y., Li, D., Xie, Q., Wu, Q. and Wang, J. 2021. Automatic defect detection and segmentation of tunnel surface using modified Mask R-CNN. *Measurement*, 178, 109316.

- Xue-Wu, Z., Yan-Qiong, D., Yan-Yun, L., Ai-Ye, S. and Rui-Yu, L., 2011. A Vision Inspection System For The Surface Defects Of Strongly Reflected Metal Based On Multi-Class SVM. *Expert Systems with Applications Elsevier*, 38(5), 5930–5939.
- Yang, C., Liu, P., Yin, G., Jiang, H. and Li, X., 2016. Defect Detection in Magnetic Tile Images Based on Stationary Wavelet Transform. *NDT&E International* 83 (2016) 78–87.
- Yang, L., Fan, J., Huo, B., Li, E. and Liu, Y. 2022. A nondestructive automatic defect detection method with pixelwise segmentation. *Knowledge-Based Systems*, 242, 108338.
- Yang, S.W, Lin, C.S, Lin, S.K. and Chiang, H.T., 2014. Automatic Defect Recognition of TFT Array Process Using Gray Level Co-Occurrence Matrix. *Optik* 125, 2671–2676.
- Yıldırım Ö., Uçar A., Baloğlu U. B. 2018. Recognition of Real-World Texture Images Under Challenging Conditions with Deep Learning. *Akıllı Sistemler ve Uygulamaları Dergisi*, Cilt: 1, Sayı: 1, Sayfa 122-126.
- Yogamangalam, R. and Karthikeyan, B., 2013. Segmentation techniques comparison in image processing. *International Journal of Engineering and Technology (IJET)*, 5(1), pp.307-313.
- Zhang, Y. and Ge, L. 2008. New approach to low contrast image segmentation, *Bioinformatics and Biomedical Engineering. ICBBE*, 2008, pp.2369-2372.
- Zhan, Z., Zhou, J. and Xu, B. 2022. Fabric defect classification using prototypical network of few-shot learning algorithm. *Computers in Industry*, 138, 103628.
- Zhang, K., Wang, W., Lv, Z., Fan, Y., and Song, Y. 2021. Computer vision detection of foreign objects in coal processing using attention CNN. *Engineering Applications of Artificial Intelligence*, 102, 104242.
- Zhang, Z., Liu, Q., and Wang. 2017. Road Extraction by Deep Residual U-Net. *CVPR*, 2017.
- Zhang, Z., Liu, Q., and Wang, Y. 2018. Road Extraction by Deep Residual U-Net. *IEEE Geoscience and Remote Sensing Letters*, vol. 15, no. 5, pp.749–753.
- Zhou, X., and Yang, G. 2019. Normalization in Training U-Net for 2D Biomedical Semantic Segmentation. *CVPR*, 2019.
- Zisserman, A., and Simonyan, K. 2014. Very Deep Convolutional Networks for Large-Scale Image Recognition. *CVPR*, 2014.

Zuodong N., and Handong L. 2019. Research and analysis of threshold segmentation algorithms in image processing. IOP Conf. Series: Journal of Physics: Conf. Series 1237. IOP Publishing doi:10.1088/1742-6596/1237/2/022122



EK 1 Eğitim İterasyonlarında Oluşan Kayıp ve Doğruluk Değerleri

```
Epoch 1/40
75/75 [=====] - 269s 4s/step - loss: 0.7449 - acc:
0.5371 - val_loss: 0.5899 - val_acc: 0.9400
Epoch 2/40
75/75 [=====] - 9s 125ms/step - loss: 0.6463 - acc:
0.6279 - val_loss: 0.5253 - val_acc: 0.9400
Epoch 3/40
75/75 [=====] - 10s 131ms/step - loss: 0.5792 - acc:
0.6963 - val_loss: 0.4678 - val_acc: 0.9467
Epoch 4/40
75/75 [=====] - 10s 132ms/step - loss: 0.5322 - acc:
0.7417 - val_loss: 0.4189 - val_acc: 0.9467
Epoch 5/40
75/75 [=====] - 10s 132ms/step - loss: 0.4829 - acc:
0.7829 - val_loss: 0.3764 - val_acc: 0.9533
Epoch 6/40
75/75 [=====] - 10s 137ms/step - loss: 0.4370 - acc:
0.8217 - val_loss: 0.3385 - val_acc: 0.9600
Epoch 7/40
75/75 [=====] - 10s 133ms/step - loss: 0.3999 - acc:
0.8425 - val_loss: 0.3030 - val_acc: 0.9467
Epoch 8/40
75/75 [=====] - 10s 131ms/step - loss: 0.3534 - acc:
0.8767 - val_loss: 0.2721 - val_acc: 0.9600
Epoch 9/40
75/75 [=====] - 10s 130ms/step - loss: 0.3142 - acc:
0.9021 - val_loss: 0.2444 - val_acc: 0.9667
Epoch 10/40
75/75 [=====] - 10s 131ms/step - loss: 0.2913 - acc:
0.9146 - val_loss: 0.2206 - val_acc: 0.9667
Epoch 11/40
75/75 [=====] - 10s 131ms/step - loss: 0.2776 - acc:
0.9221 - val_loss: 0.1980 - val_acc: 0.9667
Epoch 12/40
75/75 [=====] - 10s 130ms/step - loss: 0.2424 - acc:
0.9350 - val_loss: 0.1803 - val_acc: 0.9667
Epoch 13/40
75/75 [=====] - 10s 130ms/step - loss: 0.2355 - acc:
0.9342 - val_loss: 0.1663 - val_acc: 0.9733
Epoch 14/40
75/75 [=====] - 10s 129ms/step - loss: 0.2183 - acc:
0.9450 - val_loss: 0.1542 - val_acc: 0.9733
Epoch 15/40
75/75 [=====] - 10s 131ms/step - loss: 0.1985 - acc:
0.9471 - val_loss: 0.1417 - val_acc: 0.9667
Epoch 16/40
75/75 [=====] - 10s 131ms/step - loss: 0.1985 - acc:
0.9483 - val_loss: 0.1317 - val_acc: 0.9733
Epoch 17/40
75/75 [=====] - 10s 131ms/step - loss: 0.1784 - acc:
0.9521 - val_loss: 0.1237 - val_acc: 0.9733
Epoch 18/40
75/75 [=====] - 10s 130ms/step - loss: 0.1645 - acc:
0.9621 - val_loss: 0.1154 - val_acc: 0.9733
Epoch 19/40
75/75 [=====] - 10s 130ms/step - loss: 0.1629 - acc:
0.9513 - val_loss: 0.1092 - val_acc: 0.9800
Epoch 20/40
75/75 [=====] - 10s 130ms/step - loss: 0.1556 - acc:
0.9571 - val_loss: 0.1029 - val_acc: 0.9800
Epoch 21/40
```

```

75/75 [=====] - 10s 129ms/step - loss: 0.1432 - acc:
0.9671 - val_loss: 0.0975 - val_acc: 0.9800
Epoch 22/40
75/75 [=====] - 10s 128ms/step - loss: 0.1353 - acc:
0.9658 - val_loss: 0.0933 - val_acc: 0.9800
Epoch 23/40
75/75 [=====] - 10s 131ms/step - loss: 0.1370 - acc:
0.9600 - val_loss: 0.0879 - val_acc: 0.9800
Epoch 24/40
75/75 [=====] - 10s 130ms/step - loss: 0.1287 - acc:
0.9679 - val_loss: 0.0839 - val_acc: 0.9800
Epoch 25/40
75/75 [=====] - 10s 130ms/step - loss: 0.1274 - acc:
0.9658 - val_loss: 0.0808 - val_acc: 0.9800
Epoch 26/40
75/75 [=====] - 10s 129ms/step - loss: 0.1225 - acc:
0.9679 - val_loss: 0.0768 - val_acc: 0.9800
Epoch 27/40
75/75 [=====] - 10s 129ms/step - loss: 0.1153 - acc:
0.9704 - val_loss: 0.0741 - val_acc: 0.9800
Epoch 28/40
75/75 [=====] - 10s 129ms/step - loss: 0.1168 - acc:
0.9692 - val_loss: 0.0726 - val_acc: 0.9867
Epoch 29/40
75/75 [=====] - 10s 128ms/step - loss: 0.1113 - acc:
0.9675 - val_loss: 0.0690 - val_acc: 0.9867
Epoch 30/40
75/75 [=====] - 10s 128ms/step - loss: 0.1008 - acc:
0.9758 - val_loss: 0.0652 - val_acc: 0.9800
Epoch 31/40
75/75 [=====] - 10s 128ms/step - loss: 0.1111 - acc:
0.9679 - val_loss: 0.0642 - val_acc: 0.9867
Epoch 32/40
75/75 [=====] - 10s 130ms/step - loss: 0.1068 - acc:
0.9700 - val_loss: 0.0611 - val_acc: 0.9867
Epoch 33/40
75/75 [=====] - 10s 127ms/step - loss: 0.1034 - acc:
0.9712 - val_loss: 0.0589 - val_acc: 0.9867
Epoch 34/40
75/75 [=====] - 10s 127ms/step - loss: 0.0981 - acc:
0.9750 - val_loss: 0.0575 - val_acc: 0.9867
Epoch 35/40
75/75 [=====] - 10s 127ms/step - loss: 0.0965 - acc:
0.9696 - val_loss: 0.0550 - val_acc: 0.9867
Epoch 36/40
75/75 [=====] - 10s 129ms/step - loss: 0.1022 - acc:
0.9708 - val_loss: 0.0537 - val_acc: 0.9867
Epoch 37/40
75/75 [=====] - 10s 128ms/step - loss: 0.0929 - acc:
0.9742 - val_loss: 0.0518 - val_acc: 0.9867
Epoch 38/40
75/75 [=====] - 10s 133ms/step - loss: 0.0898 - acc:
0.9762 - val_loss: 0.0509 - val_acc: 0.9933
Epoch 39/40
75/75 [=====] - 10s 129ms/step - loss: 0.1016 - acc:
0.9696 - val_loss: 0.0504 - val_acc: 0.9933
Epoch 40/40
75/75 [=====] - 10s 129ms/step - loss: 0.0920 - acc:
0.9750 - val_loss: 0.0480 - val_acc: 0.9933

```