

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİBRİT OPTİK GÖRÜNTÜLEME SİSTEMİ İLE TESPİT EDİLEN SERAMİK
YÜZEY KUSURLARININ GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME
TEKNİKLERİYLE ANALİZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DUYGU DEMİRCAN

NİSAN 2025

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİBRİT OPTİK GÖRÜNTÜLEME SİSTEMİ İLE TESPİT EDİLEN SERAMİK
YÜZEY KUSURLARININ GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME
TEKNİKLERİYLE ANALİZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Duygu DEMİRCAN

DANIŞMAN : Doç. Dr. Gülhan USTABAŞ KAYA
İKİNCİ DANIŞMAN : Doç. Dr. Rukiye UZUN ARSLAN

ZONGULDAK
Nisan 2025

KABUL:

Duygu DEMİRCAN tarafından hazırlanan “Hibrit Optik Görüntüleme Sistemi ile Tespit Edilen Seramik Yüzey Kusurlarının Görüntü İşleme ve Derin Öğrenme Teknikleriyle Analizi” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir. 24/04/2025

Danışman: Doç. Dr. Gülhan USTABAŞ KAYA

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

Üye: Prof. Dr. Ozan ARTUN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

Üye: Doç. Dr. Kenan ÖZEL

Ankara Üniversitesi, Gama Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Alternatif Enerji Kaynakları Teknolojisi Programı

ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

..../..../2025

Prof. Dr. Fikret GÖLGELEYEN
Fen Bilimleri Enstitüsü Müdürü



“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Duygu DEMİRCAN

ÖZET

Yüksek Lisans Tezi

HİBRİT OPTİK GÖRÜNTÜLEME SİSTEMİ İLE TESPİT EDİLEN SERAMİK YÜZEY KUSURLARININ GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME TEKNİKLERİYLE ANALİZİ

Duygu DEMİRCAN

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Gülhan USTABAŞ KAYA

İkinci Danışman: Doç. Dr. Rukiye UZUN ARSLAN

Nisan 2025, 161 sayfa

Bu çalışmanın amacı, seramik ve porselen gibi yapıya sahip malzemelerdeki görünür ve görünmez kusurların hassas bir şekilde tespit edilmesi ve üretim süreçlerinin daha verimli hale getirilmesi için hibrit optik görüntüleme sistemi (HOGS) kullanarak, temassız ölçüm yapabilen yüksek çözünürlüklü hibrit bir sistem geliştirmektir. Bu amaç doğrultusunda, Yanal kesme sayısal holografik mikroskopisi (YKSHM) ve mikroskopik saçak projeksiyon profilometrisi (MSPP) yöntemlerinin birleştirildiği HOGS sistemi ile kaydedilen hologramlardan bilginin geri elde edilebilmesi için faz bilgisi kullanılmıştır. Faz bilgisi çıkartmak için ise literatürde sıklıkla kullanılan sürekli dalgacık dönüşümü (mexican hat, morlet), Fourier ve Hilbert dönüşüm teknikleri tercih edilmiştir. Buna ek olarak başarılı sonuç veren Hilbert dönüşümünün başarımını daha da arttırabilmek için çeşitli kenar belirleme teknikleri; Canny, Prewitt, Sobel uygulanmıştır. Nihai olarak görüntülerdeki kusuru en belirgin hale getiren Hilbert+Sobel

ÖZET (devam ediyor)

teknîği derin öğrenme öğrenme tabanlı ResNet-50 modelinde çeşitli düzenlemeler yapılarak kusursuz seramiklerden ayırt edilmesi için sınıflandırılmıştır. Bu sınıflandırmada yapılan görüntü işleme metodlarının sınıflandırma başarımına etkisine değinebilmek amacı ile HOGS kullanılarak elde edilen optik görüntülerin ham haline de Resnet-50 mimarisi uygulanmış ve sonuçlar karşılaştırmalı olarak sunulmuştur. Bu çalışma, seramik üretiminde kalite kontrol sürecinde zaman ve maliyetin azaltılmasına katkı sağlamayı, aynı zamanda uzaktan algılama ile insan gözünden daha hassas ve doğru sonuçlar elde edilmesini amaçlamaktadır. Günümüzde kullanılan çeşitli uzaktan algılama yöntemlerine göre bu yaklaşım, hem maliyeti düşürmekte hem de seramik yüzeyine zarar vermeden hızlı bir kalite kontrolü sunmaktadır. Bu çalışma günümüzde inşaat, elektrik-elektronik, tıp, sanat, savunma sanayi ve mühendislik uygulamaları gibi birçok sektörde faaliyet gösteren seramik ve porselen endüstrisinde üreticilerin karşılaştığı yüzey kusur tespitinde yaşanan zorlukların üstesinden gelmesinde katkı sağlayacaktır. Yapılan tez, birden çok yaklaşımı bir araya getirip hibrit bir sistem sunduğundan bu alanda öncü çalışmalardan olmuştur.

Anahtar Kelimeler: Seramik, Kalite, Yüzey Kusurları, HOGS, Hologram Görüntüsü, Dalgacık Dönüşümü, Kenar Belirleme, Derin Öğrenme.

Bilim Kodu: 608.06.00

ABSTRACT

M. Sc. Thesis

ANALYSIS OF CERAMIC SURFACE DEFECTS DETECTED WITH HYBRID OPTICAL IMAGING SYSTEM USING IMAGE PROCESSING AND DEEP LEARNING TECHNIQUES

Duygu DEMİRCAN

Zonguldak Bülent Ecevit University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Thesis Advisor: Assoc. Prof. Dr. Gülhan USTABAS KAYA

Co-Advisor: Assoc. Prof. Dr. Rukiye UZUN ARSLAN

April 2025, 161 pages

The aim of this study is to develop a high-resolution hybrid system capable of non-contact measurement using a Hybrid Optical Imaging Sensor (HOGS) to precisely detect visible and invisible defects in materials with ceramic and porcelain-like structures and to improve the efficiency of production processes. For this purpose, phase information was used to retrieve data from the holograms recorded with the HOGS system, which combines Lateral Shearing Digital Holographic Microscopy (LSDHM) and Microscopic Fringe Projection Profilometry (MFPP) methods. In order to extract the phase information, commonly used techniques in the literature such as Continuous Wavelet Transform (Mexican Hat, Morlet), Fourier Transform, and Hilbert Transform were preferred. In addition, to further improve the performance of the successful Hilbert Transform, various edge detection techniques including Canny, Prewitt, and Sobel were applied. Finally, the Hilbert+Sobel technique, which made the defect most distinguishable in the images, was used for classification with a deep learning-based ResNet-

ABSTRACT (continued)

50 model that was modified accordingly to distinguish defective ceramics from flawless ones. In order to evaluate the impact of the applied image processing methods on classification performance, the raw optical images obtained with HOGS were also classified using the ResNet-50 architecture, and the results were presented comparatively. This study aims to contribute to the reduction of time and cost in the quality control process in ceramic production, while also providing more precise and accurate results than the human eye through remote sensing. Compared to various remote sensing methods used today, this approach offers both cost-effectiveness and fast quality control without damaging the ceramic surface. This study is expected to help overcome the difficulties encountered in surface defect detection in the ceramic and porcelain industry, which operates in many sectors such as construction, electrical-electronics, medicine, art, defense industry, and engineering applications. As the thesis brings together multiple approaches to offer a hybrid system, it has become one of the pioneering works in this field.

Keywords: Ceramic, Quality, Surface Defects, HOGS, Hologram Image, Wavelet Transform, Edge Detection, Deep Learning.

Science Code: 608.06.00

TEŞEKKÜR

Yüksek lisans tez çalışmam süresince akademik danışmanlığımı üstlenen Doç. Dr. Gülhan USTABAŞ KAYA ve Doç. Dr. Rukiye UZUN ARSLAN' a yönlendirme ve destekleri için teşekkür ederim.

Çeşitli kusur yüzeylerini içerisinde barındıran seramik malzeme temini ile bu makalenin deneysel çalışmalarına katkıda bulunan " ISV Saniter Seramik Sanayi A.Ş." ye ve Elektrik-Elektronik Mühendisi Furkan POKER'e katkılarından dolayı teşekkür ederim.

Bu süreçte manevi desteğini her zaman hissettiren yakın çevreme ve daima yanımda olan, sabrı, emeği ve sevgisiyle, desteğini her zaman hissettiren anneme özel olarak teşekkür ederim.



İÇİNDEKİLER

	<u>Sayfa</u>
KABUL:.....	ii
ÖZET.....	iii
ABSTRACT.....	v
TEŞEKKÜR.....	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ.....	xvii
SİMGELER VE KISALTMALAR DİZİNİ.....	xix
 BÖLÜM 1 GİRİŞ.....	 1
 BÖLÜM 2 SERAMİK VE ÜRETİM SÜREÇLERİ.....	 13
2.1 SERAMİK MALZEMESİ VE KULLANIM ALANLARI.....	13
2.2 SERAMİK ÜRETİM SÜREÇLERİ.....	14
2.3 SERAMİK ÜRETİMİNDE ORTAYA ÇIKABİLECEK KUSURLAR.....	15
2.4 SERAMİK YÜZEYLERDE KUSURLARI BELİRLEME YÖNTEMLERİ.....	18
 BÖLÜM 3 TEMEL BİLGİLER.....	 21
3.1 ELEKTROMANYETİK DALGA EŞİTLİKLERİNDE IŞIĞIN ÖNEMİ.....	21
3.2 IŞIKTA GİRİŞİM OLAYLARI VE IŞIĞIN KIRINIMINDA FRESNEL YAKLAŞIMI.....	24
3.3 HOLOGRAFİ VE İNTERFEROMETRİ.....	28
 BÖLÜM 4 HİBRİT OPTİK GÖRÜNTÜLEME SİSTEMİNİN YAPISI VE HOLOGRAM GÖRÜNTÜLERİNİN ELDE EDİLMESİ.....	 31
4.1 HİBRİT OPTİK GÖRÜNTÜLEME SİSTEMİ (HOGS).....	31

İÇİNDEKİLER (devam ediyor)

Sayfa

4.2 HOLOGRAMLARDAN GÖRÜNTÜNÜN GERİ ELDE EDİLMESİ (YENİDEN YAPILANDIRMA).....	38
4.2.1 Fourier Dönüşüm Metodu (FDM)	39
4.2.2 Hilbert Dönüşümü (HD)	41
4.2.3 Dalgacık Dönüşümü (DD)	44
 BÖLÜM 5 FAZ DÖNÜŞÜMÜ BAŞARIMINI ARTTIRMAK İÇİN KENAR BELİRLEME TEKNİKLERİNİN UYGULANMASI	 49
 5.1 CANNY OPERATÖRÜ.....	 50
5.2 PREWITT OPERATÖRÜ	51
5.3 SOBEL OPERATÖRÜ	52
 BÖLÜM 6 DERİN ÖĞRENME	 55
 6.1 ESA MİMARİSİ.....	 56
6.1.1 Giriş Katmanı (GK)	57
6.1.2 Konvolüsyon Katmanı (KK).....	57
6.1.3 Düzleştirilmiş Doğrusal Birim Katmanı (Rectified Linear Units Layer (ReLU)) ...	58
6.1.4 Havuzlama Katmanı (HK)	59
6.1.5 Tam Bağlantılı Katman (TBK)	60
6.1.6 Drop Out Katmanı.....	61
6.1.7 Sınıflandırma Katmanı (SK)	62
6.1.8 Yumuşatma Katmanı (YK).....	62
6.1.9 Normalizasyon Katmanı (NK).....	63
6.2 PERFORMANS DEĞERLENDİRME KRİTERLERİ	63
6.3 HATA ÖLÇÜM KRİTERLERİ	65
6.4 DERİN ÖĞRENME MODELLERİNDE ALGORİTMA BAŞARIMINI ETKİLEYEN PARAMETRELER.....	 66
6.4.1 Batch Boyutu.....	66
6.4.2 Eğitim Turu (Epoch-Epok) Sayısı	67

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
6.4.3 Optimizasyon	68
6.4.4. Öğrenme Oranı	70
6.4.5 Düzenleştirme	71
6.4.6 Aktivasyon Fonksiyonları	72
6.5 RESNET AĞI	74
6.6 KULLANILAN DERİN ÖĞRENME KÜTÜPHANELERİ	76
6.6.1 TensorFlow.....	76
6.6.2 Keras	77
6.6.3 Torch	78
6.6.4 PyTorch	78
 BÖLÜM 7 HOGS İLE TESPİT EDİLEN SERAMİK YÜZEY KUSURLARININ YENİDEN YAPILANDIRMA YÖNTEMLERİ İLE GERİ ELDE EDİLMESİ	 79
 7.1 SERAMİK YÜZEY LEKESİ	 79
7.2 SERAMİK YÜZEY DALGALANMALARI	84
7.2.1 Rötüş Kusuruna Ait Elde Edilen Sonuçlar	85
7.2.2 Çatlak Kusuru için Sonuçlar	98
7.2.3 Toplama Kusuru için Sonuçlar	111
 BÖLÜM 8 HILBERT DÖNÜŞÜMÜ TEKNİĞİNİN ÇEŞİTLİ KENAR BELİRLEME YÖNTEMLERİ İLE BİRLİKTE UYGULANMASI.....	 123
 BÖLÜM 9 HOGS SİSTEMİ İLE ELDE EDİLEN KUSURLARIN DERİN ÖĞRENME TABANLI RESNET-50 ALGORİTMASI İLE SINIFLANDIRILMASI	 129
 9.1 HOGS ELDE EDİLEN GÖRSELLERİN SINIFLANDIRILMASI (I. MODEL)	 132
9.2 YENİDEN YAPILANDIRILMIŞ (HD+Sobel) GÖRSELLERİN SINIFLANDIRILMASI (II. Model)	 137

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
BÖLÜM 10 SONUÇLAR VE TARTIŞMA	145
KAYNAKLAR	149
ÖZGEÇMİŞ	161



ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 2.1 Seramik Üretim Süreci.....	14
Şekil 3.1 Koordinat Düzlemlerini Gösteren Şematik Gösterim.	26
Şekil 3.2 Işığın Elektromanyetik Dalga Gösterimi	28
Şekil 3.3 Fotoğrafik ve Holografik Görüntüleme Aşamaları	29
Şekil 3.4 İnterferometri Sisteminin Şematik Gösterimi	30
Şekil 4.1 Hibrit Optik Görüntüleme Sistemi.	31
Şekil 4.2 YKSHM kolunda Lazer Işınının Obje Yüzeyine Kadar İzlediği Yol.....	32
Şekil 4.3 Hologram Elde Edilme Süreci a) Modifiye Edilmiş YKSHM ile Hologram Oluşturma Aşamaları c) Elde Edilen Hologram Görseli.	34
Şekil 4.4 YKSHM Sisteminde Kullanılan MSPP Kolu.....	36
Şekil 4.5 HOGS Sistemi ile Kaydedilen Hologramlar a) Kusursuz Seramik Yüzeyin Referans Hologramı b) Çatlak Seramik Yüzeyin Hologramı c) Hava Yüzey Kusurlu Hologram d) Rötüş Yüzey Kusurlu Hologram e) Toplama Yüzey Kusurlu Hologram.	38
Şekil 4.6 MD Gösterimi.	46
Şekil 4.7 Mexican Hat Dalgacığı Gösterimi.	47
Şekil 5.1 Yaygın Kullanıma Sahip Kenar Çeşitleri.	50
Şekil 6.1 Yapay Zeka Yöntemlerinin Temsili Gösterimi.....	56
Şekil 6.2 ESA'ların farklı katmanlarda nesne ile ilgili oluşturduğu farklı temsiller.	57
Şekil 6.3 Konvolüsyon Katmanı	58
Şekil 6.4 Havuzlama Katmanı.....	60
Şekil 6.5 Tam Bağlantı Katmanı	61
Şekil 6.6 Derin Öğrenme Modelleri (A) Ezberleme Yapmış Derin Öğrenme Modeli (B) Ezberleme Katmanı Kullanılmış Derin Öğrenme Modeli.....	61
Şekil 6.7 Softmax Fonksiyonu	62
Şekil 6.8 Gradyan Azaltma Yöntemlerinin Gelişim Sürecini Gösteren Harita	69
Şekil 6.9 Modele Ait Blok Diyagramı.	74
Şekil 6.10 ReLU Blok Yapısı	74
Şekil 6.11 ResNet-50 Mimarisi ilk 34 Katman	75
Şekil 6.12 Tensorflow Mimarisi Katmanları.	77

ŞEKİLLER DİZİNİ (devam ediyor)

No	Sayfa
Şekil 7.1 Seramik Yüzeyler a) Referans Yüzey b) Hava Kusuru Bulunan Kusurlu Yüzey.	80
Şekil 7.2 Referans Yüzeyin Hologramı.....	81
Şekil 7.3 En Parlak Piksel Yaklaşımından Elde Edilen Sonuçlar A) Hava Kusuru Bulunan Hologramlar B) FDM ile Geri Elde Edilen Faz Görüntüleri C) En Parlak Piksel Bölge Belirleme Yaklaşımı ile İşaretlenmiş Alanlar.	82
Şekil 7.4 Rötüş Kusuru Bulunan Yüzeye Ait Seramik Görseli.	85
Şekil 7.5 Rötüş Kusuru Hologramları A) Referans Yüzeye Ait Hologram B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzey Arasındaki Fark Alınarak FDM Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.....	86
Şekil 7.6 Rötüş Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak HD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.....	87
Şekil 7.7 Rötüş Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MHDD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.....	88
Şekil 7.8 Rötüş Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MDD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.....	89
Şekil 7.9 30° – 30° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.	90
Şekil 7.10 30° – 30° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen B) MHDD ile Elde Edilen.	91
Şekil 7.11 60° – 60° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.....	92
Şekil 7.12 60° – 60° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen B) MHDD ile Elde Edilen.	93
Şekil 7.13 90° – 90° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.....	94
Şekil 7.14 90° – 90° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen B) MHDD ile Elde Edilen.	95
Şekil 7.15 Çatlak Kusuru Bulunan Yüzeye Ait Seramik Görseli.....	99
Şekil 7.16 Çatlak Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak FDM Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.	100
Şekil 7.17 Çatlak Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak HD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.	101

ŞEKİLLER DİZİNİ (devam ediyor)

No	Sayfa
Şekil 7.18 30° – 30° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM Kullanılarak Elde Edilen B) HD Kullanılarak Elde Edilen.....	102
Şekil 7.19 60° – 60° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM Kullanılarak Elde Edilen B) HD Kullanılarak Elde Edilen.....	103
Şekil 7.20 90° – 90° elevation-azimuth açılarınd a elde edilen 3B yüzey profilleri a) FDM kullanılarak elde edilen b) HD kullanılarak elde edilen.....	104
Şekil 7.21 Çatlak Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MHDD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.	105
Şekil 7.22 Çatlak Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MDD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.	106
Şekil 7.23 30° – 30° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD Kullanılarak Elde Edilen Yüzey Profili B) MHDD Kullanılarak Elde Edilen Yüzey Profili.....	107
Şekil 7.24 60° – 60° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD Kullanılarak Elde Edilen Yüzey Profili B) MHDD Kullanılarak Elde Edilen Yüzey Profili.....	108
Şekil 7.25 90° – 90° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD Kullanılarak Elde Edilen Yüzey Profili B) MHDD Kullanılarak Elde Edilen Yüzey Profili.....	109
Şekil 7.26 Toplama Kusuru Bulunan Yüzeye Ait Seramik Görseli.	111
Şekil 7.27 Toplama Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak FDM Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.	112
Şekil 7.28 Toplama Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak HD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.	113
Şekil 7.29 Toplama Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MHDD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.	114
Şekil 7.30 Toplama Kusuru Hologramları A) Referans Yüzeye Ait Hologram B) Kusurlu Yüzeye Ait Hologram C) Referans ve Kusurlu Yüzey Arasındaki Fark Alınarak MDD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.	115
Şekil 7.31 Toplama Kusuruna Ait 30° – 30° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.....	116
Şekil 7.32 Toplama kusuruna ait 60° – 60° elevation-azimuth açılarınd a elde edilen 3B yüzey profilleri a) FDM ile elde edilen b) HD ile elde edilen.	117

ŞEKİLLER DİZİNİ (devam ediyor)

No	Sayfa
Şekil 7.33 Toplama Kusuruna Ait $90^\circ - 90^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.	118
Şekil 7.34 Toplama Kusuruna Ait $30^\circ - 30^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen Yüzey Profili B) MHDD ile Elde Edilen Yüzey Profili.	119
Şekil 7.35 Toplama Kusuruna Ait $60^\circ - 60^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen Yüzey Profili B) MHDD ile Elde Edilen Yüzey Profili.	120
Şekil 7.36 Toplama Kusuruna Ait $90^\circ - 90^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen Yüzey Profili B) MHDD ile Elde Edilen Yüzey Profili.	121
Şekil 8.1 Rötüş Kusuru İçin Elde Edilen Görüntüler A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak HD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü D) HD Kullanılarak Elde Edilen 3B Yüzey Profili.....	124
Şekil 8.2 Canny Operatörü ile Elde Edilen Görüntüler A) HD+Canny ile Elde Edilen Fark Hologramı B) Fark Görüntüsünün 3B Yüzey Profili.....	124
Şekil 8.3 Prewitt Operatörü ile Elde Edilen Görüntüler A) HD +Prewitt ile Elde Edilen Fark Hologramı B) Fark Görüntüsünün 3B Yüzey Profili.	125
Şekil 8.4 Sobel Operatörü ile Elde Edilen Görüntüler A) HD+Sobel ile Elde Edilen Fark Hologramı B) Fark Görüntüsünün 3B Yüzey Profili.....	125
Şekil 9.1 Derin Öğrenme Sürecine Kullanılan Modelin Yapısı.	130
Şekil 9.2 HOGS ile Elde Edilen Görsellerin Sınıflandırılmasına Ait ROC Eğrisi.....	135
Şekil 9.3 I. Model Uygulanan Seramik Görsellerin Sınıflandırılmasına Ait Karmaşıklık Matrisi.....	136
Şekil 9.4 I. Model ile Elde Edilen Eğitim ve Doğrulama Kaybı ile Eğitim ve Doğrulama Doğruluğu Grafikleri.	137
Şekil 9.5 II. Modele Ait Elde Edilen ROC Eğrisi.	141
Şekil 9.6 II. Model Uygulanan Seramik Görsellerin Sınıflandırılmasına Ait Karmaşıklık Matrisi.....	142
Şekil 9.7 II. Model ile Elde Edilen Eğitim ve Doğrulama Kaybı ile Eğitim ve Doğrulama Doğruluğu Grafikleri.	143

ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 2.1 Seramik Yüzeylerinde Oluşan Olası Yüzey Kusurları.....	17
Çizelge 2.2. Seramik Kusurlarını Belirlemede Literatürde Kullanılan Yöntemlerin Kıyaslanması.....	18
Çizelge 6.1 Karmaşıklık Matrisi.....	64
Çizelge 6.2 Model Değerlendirme Kriterleri.....	65
Çizelge 6.3 Farklı Gradyan Azaltma Tekniklerinin Özelliklerinin Karşılaştırılması	69
Çizelge 6.4 Aktivasyon Fonksiyonları	73
Çizelge 6.5 DÖ Algoritmaları	76
Çizelge 7.1 Rötüş kusurlu fark görsellerinin 3B faz görüntülerinin maksimum ve ortalama piksel nokta sayısı	97
Çizelge 7.2 Rötüş kusurlu fark görsellerinin 3B faz görüntülerinin beyaz ve siyah pikselleri arasındaki fark	97
Çizelge 7.3 Rötüş kusurlu fark görsellerinin 3B faz görüntülerinin Z - eksen genlik değerleri.....	98
Çizelge 7.4 Çatlak kusuru için elde edilen fark görsellerinin 3B faz görüntülerinin maksimum ve ortalama piksel nokta sayısı	110
Çizelge 7.5 Çatlak kusurlu fark görsellerinin 3B faz görüntülerinin beyaz ve siyah pikselleri arasındaki fark	110
Çizelge 7.6 Çatlak kusurlu fark görsellerinin 3B faz görüntülerinin Z - eksen genlik değerleri.....	111
Çizelge 7.7 Toplama kusuru için elde edilen fark görsellerinin 3B faz görüntülerine ait maksimum ve ortalama piksel nokta sayısı.....	122
Çizelge 7.8 Toplama kusurlu fark görsellerinin 3B faz görüntülerine ait beyaz ve siyah pikselleri arasındaki fark	122
Çizelge 7.9 Toplama kusurlu fark görsellerinin 3B faz görüntülerine ait Z - eksen genlik değerleri.....	122
Çizelge 8.1 HD ve kenar belirleme tekniklerinin birlikte kullanımı ile elde edilen siyah ve beyaz piksel değerleri	126
Çizelge 8.2 3-Boyutlu yüzey profillerinden elde edilen Z-eksen genlik değerleri	127
Çizelge 9.1 Derin Öğrenme Sürecinde Kullanılan Kütüphaneler ve Kullanım Amaçları	130

ÇİZELGELER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
Çizelge 9.2 Veri Ön İşleme Parametreleri	131
Çizelge 9.3 Eğitim Hiperparametreleri	131
Çizelge 9.4 Hiper Parametre Değerleri	132
Çizelge 9.5 I. Model Performans Metrikleri	133
Çizelge 9.6 I. Model Kullanıldığında Test Verisi Üzerindeki Performans Değerlendirmesi .	135
Çizelge 9.7 I. Model Uygulanan Seramik Görsellerin Sınıflandırmasına Ait Karmaşıklık Matrisi	136
Çizelge 9.8 II. Model Performans Metrikleri.	138
Çizelge 9.9 II. Model Kullanıldığında Test Verisi Üzerindeki Performans Değerlendirmesi.	141
Çizelge 9.10 II. Model Uygulanan Seramik Görsellerin Sınıflandırmasına Ait Karmaşıklık Matrisi.....	142

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

I	Işık şiddeti
E	Elektrik alan şiddeti
ϵ_0	Elektiriksel geçirgenlik (vakum)
c	Işık hızı
A	Genlik
λ	Dalga boyu
k	Dalga sayısı
φ	Faz farkı
Ψ	Dalga fonksiyonu
x, y, z	Koordinat düzlemleri
r	Uzaklık
n	Kırılma indisi
θ	Açı
Λ	Saçak aralığı
v	Hız
ω	Açısal frekans
μ	Mikron / geçirgenlik
σ	Standart sapma / iletkenlik
ρ	Yoğunluk
$u(x)$	Giriş düzlemindeki dalga fonksiyonu
$U(x,y)$	Kırınım düzlemindeki kompleks dalga fonksiyonu
$A(x)$	Genlik fonksiyonu
$\Phi(x)$	Faz fonksiyonu
$H(x)$	Hilbert dönüşüm çekirdeği

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

j	Sanal birim ($j^2 = -1$)
f_s	Taşıyıcı frekans
$W(x)$	Dalgacık fonksiyonu
$\angle$	Faz açısı operatörü
R_1, R_2	Referans ışınları
O_1, O_2	Obje ışınları
Δ	Fark
z	Derinlik yönü
$g(x,y)$	Giriş görüntüsü
∇	Görüntü gradyanı
G_x, G_y	Gradyan bileşenleri
$ G $	Gradyan büyüklüğü
σ_g	Gauss filtresi standart sapması
T	Eşik değeri
$S(x, y)$	Kusur fark görüntüsü
$\hat{y}_i$	i. örneğin tahmini
y_i	i. örneğin gerçek değeri
y_{ij}	j. sınıfa aitlik (etiket)
p_{ij}	j. sınıfa ait tahmin olasılığı
α_t	Focal loss sınıf ağırlığı
γ	Focal loss odaklanma parametresi
η	Öğrenme oranı
ε	Sayısal kararlılık sabiti
w, b	Ağırlıklar ve bias
$\hat{m}, \hat{v}$	Adam optimizasyon moment tahminleri
C	Sınıf sayısı
N	Örnek sayısı
L	Kayıp fonksiyonu
f	Frekans (dalga frekansı)
d	Uzaklık, açıklık boyutu (optik açıklık)

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

t	Zaman (özellikle diferansiyel faz analizinde)
b	Bias değeri (nöron ağı denklemlerinde)
$\text{Re}\{ \}, \text{Im}\{ \}$	Gerçek ve sanal bileşenler

KISALTMALAR

AUC	: ROC Eğrisi Altında Kalan Alan
AE	: Akustik Emisyon
Adam	: Uyarlanabilir Moment Tahmini
AFD	: Ayırık Fourier Dönüşümü
API	: Uygulama Programlama Arayüzü
BCE	: Binary Crossentropy
BT	: Bilgisayarlı Tomografi
CCE	: Categorical Crossentropy
CCD	: Şarj Bağlantılı Cihaz
CMOS	: Metal Oksit Yarıiletken
CPU	: Merkezi İşlem Birimi
DC	: Doğru Akım
DD	: Dalgacık Dönüşümü
DFP	: Dijital Saçak Projeksiyonu
DFD	: Bulanıklık Temelli Derinlik
DHM	: Sayısal Holografik Mikroskopisi
DIA	: Derin İnanç Ağları
DN	: Doğru Negatif
DOF	: Alan Derinliği
DP	: Doğru Pozitif
DPO	: Doğru Pozitif Oranı
DÖ	: Derin Öğrenme
ESA	: Evrişimsel Sinir Ağı
EGA	: Etkili Girişim Alanı

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

FD	: Fourier Dönüşümü
FDM	: Fourier Dönüşümü Metodu
FL	: Focal Loss
FTP	: Fourier Dönüşüm Profilometrisi
GPU	: Grafik İşlemci Birimi
GK	: Giriş Katmanı
HD	: Hilbert Dönüşümü
HDM	: Hilbert Dönüşümü Metodu
HK	: Havuzlama Katmanı
HL	: Hinge Loss
HOGS	: Hibrit Optik Görüntüleme Sistemi
KBM	: Kısıtlı Boltzmann Makineleri
KCP	: Kesme Cam Plakası
KL	: Kullback-Leibler Divergence
KK	: Konvolüsyon Katmanı
LCD	: Sıvı Kristal Ekran
LCoS	: Sıvı Kristalli Silikon
MCC	: Matthews Korelasyon Katsayısı
MD	: Morlet Dalgacığı
MDD	: Morlet Dalgacık Dönüşümü
MHDD	: Mexican Hat Dalgacık Dönüşümü
MHD	: Mexican Hat Dalgacığı
MFPP	: Mikroskopik Saçak Projeksiyon Profilometrisi
MSPP	: Mikroskopik Saçak Projeksiyon Profilometrisi
NK	: Normalizasyon Katmanı
PFP	: Faz Kaydırmalı Öngörülen Saçak Profilometrisi
PreLU	: Parametrik ReLU
PSP	: Faz Kaydırmalı Profilometri
ReLU	: Düzleştirilmiş Doğrusal Birim
RNN	: Yinelemeli Sinir Ağları

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

ROC	: Alıcı Operatör Karakteristiği Eğrisi
SDD	: Sürekli Dalgacık Dönüşümü
SGD	: Stokastik Gradyan İnişi
SK	: Sınıflandırma Katmanı
SLP	: Yapılandırılmış Işık Projeksiyonu
SCCE	: Sparse Categorical Crossentropy
TBK	: Tam Bağlantılı Katman
UET	: Ultrason Uyarımlı Termografi
UT	: Ultrasonik Test
YPO	: Yanlış Pozitif Oranı
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları
YK	: Yumuşatma Katmanı
YKSHM	: Yanal Kesme Sayısal Holografik Mikroskopi
YN	: Yanlış Negatif
2B	: 2 Boyutlu
3B	: 3 Boyutlu



BÖLÜM 1

GİRİŞ

Seramik, ilk çağlardan itibaren günlük yaşamın temel gereçlerinden biri olarak varlığını sürdürmüş ve insanlık tarihi boyunca önemini koruyan bir malzeme olmuştur. Çömlek yapımı gibi geleneksel yöntemlerle başlayan seramik üretimi, sanayi ve teknolojinin gelişimiyle birlikte çeşitlenerek ürün yelpazesini genişletmiştir. Türkiye'de bu evrim, 1950'lerdeki sanayileşme sürecinde seramik sektöründeki üretim faaliyetlerinin canlanmasıyla somutlaşmış; 1980'lerde ise teknolojik ilerlemeler sayesinde sektör hem büyüme hızını artırmış hem de üretim kapasitesini önemli ölçüde genişletmiştir [1]. Ancak tüm bu gelişmelere karşın, günümüzde seramik ve porselen endüstrisinde üreticilerin karşılaştığı başlıca zorluklardan biri, malzeme yüzeyinde oluşabilecek kusurların erken aşamada tespiti [2]. Bu tür kusurlar hem ekonomik kayıplara hem de üretim verimliliğinin düşmesine neden olmakta olup, seri üretim öncesinde tespit edilmeleri büyük önem taşımaktadır.

Seramik ürünlerdeki yüzey kusurları genellikle temaslı ve temassız yöntemler aracılığıyla tespit edilmektedir. Temaslı test yöntemleri, malzemenin yapısal bütünlüğünü olumsuz etkileyerek dayanımını azaltma riski taşımaktadır. Yüksek çözünürlüklü temassız test yöntemleri ise ayrıntılı veri sağlayabilmelerine rağmen, yüksek donanım maliyetleri nedeniyle endüstriyel ölçekte yaygın olarak kullanılmamaktadır. Öte yandan, manuel görsel denetim (test) yöntemleri, operatöre bağlı subjektif değerlendirmelerden kaynaklanan düşük doğruluk ve sınırlı tekrarlanabilirlik gibi dezavantajlar barındırmaktadır. Bu durum, manuel yöntemlerinin tercih edilme oranını önemli ölçüde azaltmaktadır. Ayrıca, uzun süreli çıplak gözle yapılan muayenelerde, operatör yorgunluğu ve dikkatsizliği gibi faktörler mikro boyuttaki çatlak, kırık ve yüzey dalgalanmalarının tespitinde düşük başarımlara ve hatalı değerlendirmelere yol açabilmektedir. Bu nedenle, seri üretim öncesinde kalite-kontrol süreçlerini optimize etmek ya da yalnızca yüzey kusurlarını tespit etmek amacıyla, uygulama kolaylığı ve düşük maliyet avantajı sunan temassız test yöntemleri giderek daha fazla tercih edilmektedir. Bu yöntemler, kusurları hızlı ve etkili bir şekilde saptayarak düzeltme süreçlerinin daha verimli bir şekilde

yürütülmesine olanak tanımaktadır. Günümüzde, yüzeyle fiziksel temas gerektirmeyen ve malzeme bütünlüğünü hızlı bir şekilde tarayabilen çeşitli temassız test yöntemleri geliştirilmiştir. Bu kapsamda, Wang ve arkadaşları, kavisli kompozit materyallerin yüzeylerinde oluşan katman ayrılması gibi kusurların tespitinde Ultrasonik Test (UT) yönteminden yararlanmışlardır. Çalışmada, ikiz robot teknolojisi ile entegre edilen UT sistemi sayesinde yüksek doğrulukta kusur tespiti sağlanmıştır [3,4]. Ancak, UT tabanlı yöntemlerin performansı ideal laboratuvar koşullarında yüksek olmakla birlikte, endüstriyel ortamlarda çeşitli sınırlamalarla karşılaşmaktadır. Özellikle ham seramiklerin taşınması sırasındaki titreşimler, ortamdaki toz birikimi, kurutma sonrası yüzey sıcaklık değişimleri, nem içeriği ve yüzey pürüzlülüğü gibi faktörler, ölçümlerin kararlılığını ve tekrarlanabilirliğini olumsuz etkilemektedir [5].

UT yönteminin endüstriyel uygulamalardaki sınırlılıkları, alternatif temassız yöntemlerine duyulan gereksinimi açıkça ortaya koymaktadır. Bu bağlamda, radyografi yöntemi; malzemelerin manyetik özelliklerinden bağımsız çalışma prensibi sayesinde hem ferromanyetik hem de non-ferromanyetik malzemelerin analizinde etkili bir çözüm sunmaktadır. X-ışını veya gama (γ) ışınlarının malzeme içindeki soğurulma farklılıklarına dayanan bu yöntem, malzemenin iç yapısını tahribatsız bir şekilde görüntülemenin yanı sıra, (malzemedeki) kalınlık farklılıklarını yüksek hassasiyetle tespit edebilmektedir. Ayrıca, yüzeydeki yapısal değişimlerin ve yüzey altı kusurların güvenilir bir şekilde belirlenmesine olanak tanımaktadır [6]. Ancak, radyografi yönteminin çözünürlük limiti, malzeme kalınlığının yaklaşık %2'si düzeyindedir. İnce çatlakların tespit edilebilmesi için, ışın demetinin kusur düzlemine paralel olarak yönlendirilmesi gerekmektedir [7]. Bu durum, özellikle küçük veya derin kusurların tespitinde operatör becerisine olan bağımlılığı artırmaktadır.

Radyografi yönteminin çözünürlük limiti ve operatör bağımlılığı, endüstriyel uygulamalarda çeşitli zorluklara neden olmakta ve yöntemin genel verimliliğini sınırlamaktadır. Bu sınırlamaları aşmak için geliştirilen termal görüntüleme yöntemleri, malzeme yüzeyindeki ısı dağılım anomalilerini kızılötesi kameralarla tespit ederek yapısal haritalama sağlamaktadır. Özellikle aktif termografi yönteminde, harici uyartımla (elektromanyetik radyasyon veya ultrason) başlatılan ısı transferi sayesinde kusurlar daha hassas şekilde belirlenebilmektedir. Bu süreçteki ısı dinamikleri, malzemenin termal iletkenlik, yayılım, yoğunluk ve nem gibi özelliklerinden etkilenmektedir [8].

Bu tekniklerden ultrason uyarımlı termografi (UET), vibro-termografinin önemli bir alt kategorisini oluşturmaktadır. Bu yöntemde, malzeme içine uygulanan ultrasonik enerji, yapısal kusurların bulunduğu bölgelerde sürtünme ve diğer mekanik etkileşimler yoluyla termal enerjiye dönüşmektedir. Oluşan lokal sıcaklık değişimleri kızılötesi görüntüleme sistemleriyle kaydedilerek yüzey altı hasar analizi gerçekleştirilmektedir [9]. Milisaniyeler içinde gerçekleşen bu sıcaklık değişimleri, kızılötesi kamera tarafından parlak bir kızılötesi ışık kaynağı şeklinde görüntülenmektedir. Görüntüde, parlak alanlar ısı anomali bölgelerini temsil ederken, arka plan nispeten karanlık kalmaktadır [10]. Diğer termografi yöntemlerinden farklı olarak fiziksel temas gerektiren UET, yüksek doğruluk sağlamakla birlikte, test yüzeyinde aşınmaya yol açabilmektedir.

Literatürde, termografi dışında malzeme kusurlarının tespiti için birçok alternatif yöntem bulunmaktadır. Bu yöntemlerden biri, Sun ve arkadaşları'nın çalışmasında öne çıkan akustik emisyon (AE) tabanlı yaklaşımdır. Söz konusu çalışmada, AE sinyalleriyle boru malzemesindeki mikro çatlaklar arasındaki ilişkiyi analiz edilmiştir. Sun ve arkadaşları, yaptıkları analizlerle malzemedeki kusurların etkin biçimde tespit edilebilmesi için basınç ile yüksek frekanslı ses dalgalarının eşzamanlı uygulanması gerektiğini ortaya koymuşlardır [11].

Tahribatsız muayene teknikleri kapsamında AE dışında yaygın olarak kullanılan bir diğer yöntem, sıvı (boya) penetrant yöntemidir. Bu yöntemde, kılcal etki ile malzeme yüzeyindeki kırık ve çatlaklara nüfuz eden özel bir sıvı (penetrant) aracılığıyla kusurlar tespit edilmektedir. Ekonomik olması ve geniş bir malzeme yelpazesine uygulanabilmesi nedeniyle endüstride sıkça tercih edilen bu yöntem, özellikle manyetik olmayan malzemelerdeki (alüminyum, paslanmaz çelik, titanyum, seramik, plastik vb.) yüzeysel kusurların tespitinde etkilidir. Ancak, yalnızca yüzey kusurlarını belirleyebilmesi, gözeneksiz malzemelerde yüzey altı hataları tespit edememesi ve kalıntı bırakma riski gibi sınırlamaları bulunmaktadır [5,12].

Buna karşın optik kameralı video ölçüm yöntemleri, temas gerektirmeyen bir yaklaşımla yüksek hassasiyetli ölçümler sunarak sıvı penetrant yöntemine kıyasla daha kapsamlı bir analiz imkanı sağlamaktadır. Bu yöntemlerin en önemli avantajı, yalnızca yüzeysel kusurları değil aynı zamanda boyutsal toleransları ve geometrik uygunlukları da değerlendirebilmesidir. Malzemelerin iki (2B) veya üç (3B) boyutlu analizlerini gerçekleştirebilen bu sistemler, özellikle kalite kontrol süreçleri, üretim optimizasyonu ve hata tespiti olmak üzere üç temel alanda önemli bir rol üstlenmektedir. Yöntemde yüksek çözünürlüklü optik kameralar

sayesinde, insan gözüyle tespit edilemeyen mikro düzeydeki yüzey kusurları, çatlaklar ve şekil bozuklukları kolaylıkla belirlenebilmektedir. Ayrıca, bu sistemler ürünlerin boyut ve geometrik özelliklerini hassas bir şekilde ölçerek üretim toleranslarına uygunluğunu objektif olarak değerlendirebilmektedir. Temassız çalışma prensibi, bu yöntemi özellikle kırılğan veya hassas yüzeyli malzemeler için ideal kılmaktadır. Malzemelere zarar vermeden gerçekleştirilen hızlı ölçümler, üretim verimliliğini artırırken aynı zamanda maliyetleri de düşürmektedir [13]. Buna karşın, yöntemin mikro boyuttaki kusurları tespit etmedeki sınırlılığı, optik mikroskopi tabanlı yöntemlere olan ihtiyacı ortaya çıkarmaktadır. Optik mikroskop tabanlı yüzey görüntüleme teknikleri zaman içinde önemli evrimler geçirerek gelişmiş ve farklı ihtiyaçlara yönelik çözümler sunar hâle gelmiştir. Günümüzde kullanılan görüntüleme sistemleri genellikle ya küçük hacimlerin yüksek çözünürlükte incelenmesine ya da büyük hacimlerin düşük çözünürlükle analizine imkân tanımaktadır. Bu durum, her iki gereksinimi bir arada karşılayabilecek bütüncül bir yöntem olan ihtiyacı doğurmaktadır. Yüzey görüntüleme mikroskobu ise bu boşluğu doldurarak söz konusu ihtiyaca etkili bir yanıt sunmaktadır [14].

Bu tür sistemlerin yaygınlaşmasıyla birlikte, ölçüm süreçlerinde otomasyon ve üç boyutlu analiz ihtiyacı giderek artmaktadır. Bu ihtiyaca yönelik olarak geliştirilen otomatik ölçüm yöntemleri, temaslı ve temassız olmak üzere iki ana kategori altında sınıflandırılmaktadır. Temaslı yöntemler, fiziksel temas gerektirmesi nedeniyle özellikle hassas malzemelerde hasar riski oluşturabilmekte ve bu durum ölçüm doğruluğunu olumsuz etkileyebilmektedir. Bu sınırlamalar nedeniyle, endüstriyel uygulamalarda temassız yöntemler giderek daha fazla tercih edilmektedir. Bu alandaki yenilikçi çalışmalardan biri olarak Netsu ve arkadaşları, yüzey analizinde holografik interferometriyi grafik işlemcilerle entegre ederek önemli bir ilerleme kaydetmişlerdir. Ancak geliştirdikleri bu yöntem, aynalar, ışın ayırıcılar ve mercekler gibi çoklu optik bileşenler içermesi nedeniyle karmaşık bir yapı sergilemektedir [15]. Holografik interferometrinin bu karmaşıklığına alternatif olarak, Falk ve arkadaşları daha basit bir temassız optik ölçüm yöntemi olan dijital görüntü korelasyonunu (DIC) kullanmışlardır. Bununla birlikte, DIC yöntemi de birden fazla işlem adımı gerektirmesi ve korelasyonun yalnızca belirli noktalarda sağlanabilmesi gibi bazı kısıtlamalar taşımaktadır [16]. Bu tür sınırlamaları aşmak amacıyla, Tsenev ve arkadaşları malzeme deformasyonunu ölçmek için parametrik test yöntemini geliştirmişlerdir. Ancak bu yöntemde bileşenlere doğrudan çekme kuvveti uygulanması, malzemenin zarar görme riskini beraberinde getirmektedir [15,17].

Tüm bu sınırlamalar göz önünde bulundurulduğunda, özellikle hassas yapılara zarar vermeden uygulanabilecek alternatif ölçüm yöntemlerine olan ihtiyaç giderek artmaktadır. Bu doğrultuda, mikro elektromekanik bileşenlerin 3B şekil ölçümüne dayalı temassız yöntemler, son yıllarda çeşitli uygulama alanlarında yaygın olarak kullanılmaya başlanmıştır [18,19]. Fotogrametri yapısal ışık projeksiyonu ve optik metroloji gibi yöntemler, bu alanda sıklıkla kullanılan teknikler arasında yer almaktadır [20]. Bu temassız ölçüm yöntemleri, yalnızca mikro yapıların analiziyle sınırlı kalmamakta, aynı zamanda farklı malzeme yüzeylerinin değerlendirilmesinde de etkili çözümler sunmaktadır. Özellikle seramik ve porselen malzemelerdeki yüzey kusurlarının tespitinde, geleneksel yöntemlerin karşılaştığı zorluklar nedeniyle, optik metroloji temelli yaklaşımlar giderek daha fazla tercih edilmektedir [21].

Optik metroloji yöntemleri, temassız ölçüm kabiliyetleri ve yüksek çözünürlük avantajlarının yanı sıra, gelişmiş tam alan görüntüleme sensörleri ve güçlü ışık kaynaklarıyla donatılmaları sayesinde yüzey profilometrisi alanında önemli bir yere sahiptir. Özellikle 3B şekil ölçümüne yönelik olarak geliştirilen optik interferometri [22,23], dijital saçak projeksiyonu (Digital Fringe Projection, DFP) [24,25], çok adımlı faz kaydırma teknikleri [26] ve stereo görüş sistemleri [15,27] literatürde öne çıkan başlıca optik yöntemler arasında yer almaktadır. Bu tekniklerden biri olan DFP, mikro yapı yüzeylerin saçak desenlerini taramak amacıyla projeksiyon sistemi ile birlikte çalışan bir şarj bağlantılı cihaz (Charge-Coupled Device, CCD) kamera kullanmaktadır. Bu yöntemde, yüzeye yansıtılan sinüzoidal saçak desenleri yüzey geometrisine bağlı olarak modülasyona uğramakta ve bu modülasyon aracılığıyla derinlik bilgisi kodlanmaktadır. Ardışık faz kaydırma algoritmaları sayesinde faz değerleri yüksek hassasiyetle tahmin edilebilmekte; böylece elde edilen faz bilgileri kullanılarak yüzeyin üç boyutlu geometrisi yüksek doğrulukla yeniden yapılandırılabilir. Bu doğruluk ve çözünürlük avantajlarını daha da ileriye taşımak amacıyla Yin ve arkadaşları, kamera-projektör düzeneği ile uzun çalışma mesafesine sahip mercekleri bir araya getiren yenilikçi bir saçak projeksiyon tabanlı 3B mikroskopi sistemi geliştirmiştir. Geliştirilen sistemde iki temel yenilik bulunmaktadır. Bunlardan birincisi, geniş alan derinliği (Depth of Field, DOF) elde etmek amacıyla Scheimpflug prensibinin uygulanmasıdır. İkincisi ise, kantitatif ölçümlerde yüksek hassasiyet sağlamak için x-y-z doğrusal hareketlerin yanı sıra döndürme ve eğme kabiliyetine sahip beş eksenli motorlu bir tablanın sisteme entegre edilmesidir. Bu iki yenilik, sistemin hem derinlik çözünürlüğünü hem de ölçüm esnekliğini artırarak, karmaşık yüzey topografilerinin hassas ve güvenilir bir şekilde analiz edilmesine olanak tanımaktadır. Ancak, sistemde kullanılan optik ve mekanik bileşenlerin yerleşim ayarlarının doğru bir şekilde yapılması

durumunda yüksek çözünürlüklü görüntüleme sağlanamamaktadır [25]. Öte yandan, Liu ve arkadaşları mikrofiber ve metrik vidalar gibi küçük nesnelerin 3B görüntülenmesi için bulanıklık temelli derinlik (Depth from Defocus, DFD) tahminine dayalı bir mikroskop sistemi önermişlerdir. Önerilen sistem, yüksek çözünürlükte görüntüleme imkânı sunmasına rağmen, yüzey geometrisinin daha hassas bir biçimde yeniden yapılandırılabilmesi için faz kaydırma algoritmalarıyla elde edilen faz bilgisine ihtiyaç duymaktadır. Faz bilgisindeki süreksizliklerin giderilmesi ve doğru faz haritasının elde edilebilmesi amacıyla ise, bir dizi sinüzoidal saçak deseni kullanılması gerekmektedir [24]. Söz konusu süreçte, her biri belirli bir faz farkıyla kaydırılmış çok sayıda sinüzoidal saçak deseninin analizine dayanan çok adımlı faz kaydırma yöntemleri yaygın olarak tercih edilmektedir. Bu yöntemler, faz süreksizliklerini ortadan kaldırarak yüksek hassasiyetli faz haritalarının oluşturulmasında oldukça etkili sonuçlar sunmaktadır. Ancak, çok sayıda görüntü alınmasını gerektirmesi nedeniyle, bu tür yaklaşımlar yüksek hızlı ölçümler ve gerçek zamanlı görüntüleme uygulamaları için uygun değildir. Bu nedenle, dinamik durumdaki malzemelerin görüntülenmesinde ölçüm süresini azaltmak amacıyla stereo görüş ve optik interferometri gibi alternatif yöntemlerden yararlanılmaktadır [15].

Literatürde, malzemelerin 3B mikro yapıları yüzeylerinin temassız olarak görüntülenmesinde yapılandırılmış ışık projeksiyonu (Spatial Light Projection, SLP) gibi alternatif yöntemler de etkin bir şekilde kullanılmaktadır. Bu yöntemler arasında SLP yöntemi, kompakt kurulum boyutu ve kolay uygulanabilirlik avantajlarının yanı sıra, yüzey bilgisini kodlayarak verimli şekilde aktarması ve geniş bir ölçüm aralığı sunmasıyla öne çıkmaktadır [28]. Ayrıca, SLP yöntemi holografik interferometriyle elde edilen saçak desenlerinin analizinde faz ölçüm sistemleriyle birlikte de kullanılabilir. SLP tabanlı faz ölçüm sistemlerinde, hedef yüzeyin 3B bilgisi kamera ve projektör yardımıyla elde edilmektedir. Bu süreçte kaydedilen hologramlardan (girişim desenlerinden) yeniden yapılandırma yoluyla çıkarılan sinüzoidal saçakların faz bilgisi ise, malzemenin yüzey özelliklerini yansıtmaktadır. Elde edilen bu faz bilgisi, aynı zamanda yüzeydeki kusurların yüksekliğinin belirlenmesine de olanak tanımaktadır. SLP uygulamasında faz ölçüm yöntemi olarak genellikle faz kaydırmalı profilometri (Phase Shifting Profilometry, PSP) ve Fourier dönüşüm profilometrisi (Fourier Transform Profilometry, FTP) kullanılmaktadır. Ancak bu yöntemlerin her biri, doğru faz bilgisine ulaşılabilmesi için birden fazla saçak görüntüsüne ihtiyaç duymaktadır [29,30]. Ayrıca bu yöntemler geniş gradyanlara uygun yüzeyi ölçmemekte ve renk eşitsizliklerine karşı da duyarsız kalmaktadır. Bu sınırlamaları aşmak amacıyla, son yıllarda üç boyutlu hacimsel mikro

yapılı yüzeylerin görüntülenmesinde mikroskobik saçak projeksiyon profilometrisi (Microscopic Fringe Projection Profilometry, MFPP) yöntemi ön plana çıkmaktadır. Ancak bu yöntemde, sıvı kristalli silikon (Liquid Crystal on Silicon, LCoS), Ronchi ızgaraları, çeşitli ek mercekler ve optik bileşenler gibi karmaşık konfigürasyonlara ihtiyaç duyulmaktadır. Bununla birlikte, ölçüm yalnızca yükseklik aralığı oldukça kısa olan mikro ölçekli hedeflerle sınırlı kalmaktadır. Bu sınırlamaların üstesinden gelmek amacıyla, Proll ve çalışma arkadaşları, yansıtıcı ferroelektrik LCoS ekran tabanlı bir projeksiyon sistemi kullanarak girişim desenlerini oluşturmuş ve faz bilgisini, çoklu faz kaydırmalı saçak desenlerine dayalı bir faz kaydırma algoritması ile elde etmişlerdir [31]. Öte yandan, Li ve arkadaşları, küçük boyutlu ve yüksek kalınlığa sahip malzemelerin, karmaşık faz-derinlik dönüşüm süreçlerine ihtiyaç duyulmaksızın görselleştirilebilmesi için yeni bir telesentrik faz kaydırmalı öngörülen saçak profilometrisi (Predicted Fringe Profilometry, PFP) yöntemi önermiştir. Önerilen sistemde projeksiyonu için sıvı kristal ekran (liquid crystal display- LCD) tabanlı bir projektör kullanılmıştır [15,32].

Yukarıda belirtilen çalışmaların ortaya koyduğu üzere, 3B algılama sistemlerinde; temas gerektirmeyen, yüksek hız ve çözünürlükte ölçüm kabiliyeti sunan, bununla birlikte algoritmik esneklik ve yazılım tabanlı iyileştirmelere açık bir mimariye sahip çözümlerin gerekliliği öne çıkmaktadır. Özellikle seramik yüzey kusurlarının erken aşamada tespit edilmesi ve görselleştirilmesi süreçlerinde, 2B görüntüleme yöntemlerinin yetersiz kalması, 3B yöntemlerin ise yüksek maliyet ve karmaşık kurulum gereksinimleri nedeniyle endüstriyel uygulamalarda tercih edilmediği gözlemlenmektedir. Literatürdeki mevcut çözümlerin çoğunlukla temas temelli çalışma prensibi veya yüzey hazırlık işlemleri (boyama, kaplama vb.) gerektirmesi, seramik malzemelerde ikincil hasar riskini artırarak bu sistemlerin endüstriyel benimsenmesini önemli ölçüde kısıtlamaktadır. Bu nedenle, tahribatsız çalışabilen, düşük maliyetli ve yüksek verimlilikte 3B görüntüleme teknolojilerinin geliştirilmesine yönelik akademik ve endüstriyel araştırmaların önemi giderek artmaktadır.

Son yıllarda yapılan çalışmalar, yüzey kusurlarının doğru tespiti ve kalite kontrol süreçlerinin geliştirilmesi bağlamında optik mikroskopi ve yüzey profilometri sistemlerinin birlikte kullanımının önemli avantajlar sağladığını ortaya koymaktadır. Bu bağlamda Ustabaş Kaya'nın geliştirdiği hibrit optik görüntüleme sistemi (HOGS), yanal kesme-sayısal holografi tekniği (YKSHM) ile mikroskopik saçak projeksiyonlu profilometrinin (MSPP) sinerjistik birleşimine dayanmaktadır [15]. Bu hibrit sistem, mikro ölçekli yüzey kusurlarının yüksek hassasiyetle

tespit edilmesinde kayda değer başarı göstermiştir. Önerilen sistemin etkinliği, özellikle elektronik endüstrisinde kritik öneme sahip baskılı devre kartlarında (Printed Circuit Board, PCB) yapılan testlerle kanıtlanmıştır. HOGS, hem üretim sürecinden kaynaklanan hem de elektriksel akımın neden olduğu termal stresler sonucu oluşan mikro boyuttaki kusurların görselleştirilmesinde etkili sonuçlar vermiştir [15,33]. Aynı zamanda, yapı malzemeleri alanında mikro/nano ölçekli köpük beton yapılarıdaki hava kabarcıklarının karakterizasyonu gibi farklı uygulamalarda da başarıyla kullanılmıştır [33]. Bu bulgular, hibrit sistemlerin geleneksel yöntemlerin sınırlamalarını aşmada ve endüstriyel uygulamalarda yeni olanaklar sunmada ne kadar etkili olabileceğini göstermektedir.

Holografik sistemler, yüzeye ait bilgilerin yeniden yapılandırma yoluyla 3B olarak elde edilebilmesi sayesinde geleneksel yöntemlere kıyasla önemli avantajlar sunmaktadır. Bu süreçte faz bilgisi, numunenin derinlik yapısını yansıttığı için kritik öneme sahiptir. HOGS sistemi ile bu bilgiye erişmek mümkün olsa da, faz çıkarımında kullanılan sinyal işleme teknikleri sistemin başarımını doğrudan etkilemektedir.

Bu doğrultuda, faz bilgisinin güvenilir şekilde çıkarılabilmesi için kullanılan sinyal işleme yöntemlerinin özellikleri büyük önem taşımaktadır. Sinyallerin enerji içeriğini analiz etmek amacıyla geleneksel olarak Fourier dönüşümü (FD) kullanılmakta ve böylece veriler frekans alanına taşınmaktadır. Ancak bu yöntem, sinyalin zaman ve frekans bilgilerini aynı anda sunamamakta; yalnızca biri hakkında bilgi sağlamaktadır. Bu sınırlamayı aşmak üzere geliştirilen dalgacık dönüşümü (wavelet transform, DD), sinyalin zaman-frekans düzleminde analiz edilmesine olanak tanımaktadır. Ancak bu yöntemde, önceden tanımlanmış temel fonksiyonların orijinal sinyalle konvolüsyon işlemine tabi tutulması, belirli sınırlamalara yol açabilmektedir. Her iki yöntemde de sinyallerin ayrıştırılmasında periyodik yapılar kullanılmaktadır [34]. Öte yandan Hilbert dönüşümü (HD), bir sinyalin fazını 90 derece kaydırarak analitik temsili oluşturarak matematiksel bir işlem olarak tanımlanmaktadır. Bu dönüşüm, özellikle sinyalin anlık faz ve genlik bilgisinin çıkarılmasında kullanılmaktadır. Ayrık sinyaller üzerinde uygulandığında, genellikle hızlı FD yöntemiyle gerçekleştirilmektedir. Bu süreçte, sinyalin frekans bileşenleri analiz edilerek negatif frekanslar bastırılmakta ve pozitif frekanslar uygun şekilde ölçeklendirilmektedir. Ardından, ters FD uygulanarak sinyalin gerçek ve sanal bileşenlerden oluşan kompleks bir formu elde edilmektedir. Bu kompleks yapı, sinyalin faz bilgisinin çıkarılmasına olanak sağlamaktadır. Gerçek görüntüler veya geniş bantlı sinyaller genellikle birden fazla bileşene sahip olduğundan, HD uygulanmadan önce bu sinyallerin

uygun şekilde ayrıştırılması gerekmektedir. Böylece, anlık faz ve genlik bilgilerinin doğru ve güvenilir bir şekilde hesaplanması sağlanmaktadır [35].

Bu tür sinyal işleme yaklaşımlarının pratik uygulama alanlarından biri de sayısal holografik mikroskopi sistemleridir. Tek bir pozlamayla eksiksiz 3B veriyi yakalayabilme yeteneği sayesinde bu sistemler, yalnızca yüksek görüntüleme verimliliği sağlamakla kalmayıp, aynı zamanda gerçek zamanlı uygulamalarda da performansı önemli ölçüde artırmaktadır. Ayrıca, çözünürlük ve görüntü kalitesinin iyileştirilmesi, gürültü giderme ve kenar doğrulama gibi işlemler için çeşitli sinyal işleme tekniklerinin entegrasyonuna olanak tanıyarak sistemin genel başarımını daha da geliştirmektedir [36-38].

Bu bağlamda, kenar tespiti işlemi de görüntü analizinde kritik bir rol oynamaktadır. Kenar tespiti, bir görüntüdeki keskin süreksizliklerin belirlenmesi ve konumlandırılması süreci olup; görsel algılama, nesne tanıma ve tıbbi görüntüleme gibi birçok alanda yaygın şekilde kullanılmaktadır. Bu amaçla başlıca iki yöntem öne çıkmaktadır: gradyan tabanlı ve Laplace tabanlı operatörler. Gradyan tabanlı yöntemler arasında özellikle Sobel, Prewitt ve Canny operatörleri dikkat çekmektedir. Sobel ve Prewitt operatörleri, kenarları birinci türev bilgisine dayanarak tespit ederken; Canny operatörü, kenar belirlemede gürültü azaltma, çift eşikleme ve kenar izleme gibi çok aşamalı bir süreç kullanmaktadır. Kenar tespitinin temel amacı, görüntüdeki şekil, yansıtıcılık ve geçirgenlik gibi özellikler hakkında bilgi edinmek ve yanlış pozitifleri en aza indirerek mümkün olan en doğru sonuçları elde etmektir [39].

Diğer taraftan, malzemelerdeki yüzey kusurlarının erken aşamada tespit edilmesi için yalnızca yüzey üzerindeki bozulmaların bulunması yeterli değildir; kusurun konumunun belirlenmesi ve türünün sınıflandırılması da üretim süreçlerinin kalitesi açısından büyük önem taşımaktadır. Bu doğrultuda, derin öğrenme (DÖ) teknikleri, otomatik özellik çıkarımı ve yüksek doğruluk oranları sayesinde yüzey analizi başta olmak üzere birçok alanda etkili bir şekilde kullanılmaktadır. Çok katmanlı yapay sinir ağları (YSA) ile çalışan DÖ algoritmaları; görüntü ve ses tanıma, robotik uygulamalar, uzaktan algılama, genetik analizler ve tıbbi teşhis gibi farklı alanlarda yaygın olarak uygulanmaktadır [15, 40–42]. YSA yönelik ilk model, McCulloch ve Pitts (1943) tarafından geliştirilmiş olsa da, doğrusal olmayan problemlerde yetersiz kalması nedeniyle bu alana olan ilgi bir dönem azalmıştır [43]. 1980'li yıllarda geri yayılım algoritmasıyla birlikte paralel dağıtık yapılar önerilmiş ve bu gelişmeler DÖ temelini oluşturmuştur [44]. DÖ'nin yaygınlık kazanmasında en önemli dönüm noktalarından biri, 2012

yılında düzenlenen ImageNet yarışmasında Evrişimsel Sinir Ağı (ESA) tabanlı bir modelin birinci olmasıyla yaşanmıştır [45, 46]. Bu başarı, büyük veri kümelerinin işlenebilir hâle gelmesiyle birlikte derin öğrenme algoritmalarının performansını önemli ölçüde artırmıştır. Günümüzde bu algoritmalar, yalnızca akademik çalışmalarda değil, aynı zamanda otomasyon sistemleri gibi günlük yaşam uygulamalarında da etkin biçimde kullanılmaktadır [47].

DÖ yönelik katkılardan biri de Krizhevsky ve Hinton tarafından gerçekleştirilmiştir. Bu çalışmada, doğal görüntülerin çok katmanlı modellerle nasıl eğitilebileceği ele alınmış ve milyonlarca renkli görüntü içeren büyük veri kümeleri kullanılmıştır [48]. Daha önce benzer yöntemler denenmiş olsa da pratikte yeterli başarı sağlanamamıştır. Krizhevsky ve Hinton, özellikle Kısıtlı Boltzmann Makineleri (KBM) ve Derin İnanç Ağları (DİA) üzerine odaklanarak, bu yapıların görüntü sınıflandırma problemleri için daha etkili olduğunu ortaya koymuştur [49].

Tüm bu çalışmalar detaylı olarak incelendiğinde, gerçek zamanlı çalışabilen, yüksek kaliteli görüntü sağlayan, yüzey kusurlarını hassasiyetle tespit edebilen ve aynı zamanda sınıflandırma yapabilen bir optik görüntüleme sisteminin, özellikle seramik yüzey denetimi için literatürde bulunmadığı görülmektedir. Bu tez çalışması, mevcut yöntemlerde tespit edilen eksikliklerin giderilmesi ve bu ihtiyaçlara yanıt verebilecek hibrit bir sistemin geliştirilmesi amacıyla gerçekleştirilmiştir.

Bu tez çalışması üç temel aşamadan oluşan kapsamlı bir metodoloji sunmaktadır:

İlk aşamada seramik ve porselen malzeme yüzeylerindeki kusurların hassas bir şekilde tespit edilmesi ve üretim süreçlerinin daha verimli hâle getirilmesi amacıyla hibrit optik görüntüleme sisteminin (HOGS) kullanılması önerilmektedir. Temassız ölçüm kabiliyetine sahip HOGS, Yanal Kesme Sayısal Holografik Mikroskopi (YKSHM) sisteminin, Mikroskobik Saçak Projeksiyon Profilometrisi (MSPP) ile entegrasyonu sonucunda oluşturulmuştur [15, 33]. Daha önce baskılı devre kartları üzerindeki mikro boyutlu kusurların tespitinde başarıyla kullanılan bu sistem, sunduğu avantajlar doğrultusunda seramik ve porselen yüzey kusurlarının belirlenmesine yönelik olarak ilk kez önerilmektedir.

Çalışmanın ikinci aşamasında, kaydedilen hologramlardan faz bilgisi elde edebilmek amacıyla çeşitli faz dönüşüm yöntemleri (Mexican Hat, Morlet, Fourier ve Hilbert) ile kenar belirleme

teknikleri (Canny, Prewitt, Sobel) birlikte uygulanmıştır. Bu yöntemlerin bireysel ve hibrit olarak kullanım senaryoları karşılaştırılmış; her bir kombinasyonun başarımları düzeyleri değerlendirilerek analitik olarak tartışılmıştır.

Üçüncü aşamada ise, yüzey kusurlarının sınıflandırılması için derin öğrenme algoritmalarından faydalanılmıştır. Bu kapsamda, HOGS ile elde edilen görüntüler üzerinde uygulanan faz dönüşüm ve kenar belirleme teknikleri sonucunda oluşturulan görseller, ResNet-50 mimarisi temelinde geliştirilen derin öğrenme modeli aracılığıyla sınıflandırılmıştır. Bu sınıflandırma sürecinde, seramik yüzeylerine ait kusurlu ve kusursuz sınıflar belirlenmiş ve her bir senaryoya ait başarı oranları hesaplanmıştır. Böylece, seramik üretiminin aktif olarak sürdürüğü endüstriyel ortamlarda, çok sayıda seramik yüzey görüntüsünün yazılımsal olarak hızlı ve doğru biçimde analiz edilerek kusur tespiti yapılması amaçlanmıştır.



BÖLÜM 2

SERAMİK VE ÜRETİM SÜREÇLERİ

2.1 SERAMİK MALZEMESİ VE KULLANIM ALANLARI

Seramik, metalik bileşenler içermeyen inorganik malzemelerin toz formuna getirilip şekillendirilmesinin ardından sinterleme işlemiyle üretilen ve yüksek mekanik dayanım sunan malzemeler sınıfını tanımlayan genel bir terimdir. Tarihsel olarak insanlık tarafından kullanılan en eski yapay malzemelerden biri olan seramik, günümüzde de çeşitli alanlardaki kullanımını sürdürerek önemini korumaktadır.

Mikroyapısal özelliklerine göre seramik malzemeler, gözenekli ve yoğun (kompakt) yapılı olmak üzere iki ana grupta sınıflandırılmaktadır. Gözenekli seramiklerde, kullanılan kilin pişirilme sıcaklığı, malzemenin kullanım esnasında maruz kalacağı çalışma sıcaklığının altında tutulur. Bu durum, tam sinterleşmenin gerçekleşmesini engelleyerek malzemenin gözenekli bir yapıda kalmasına neden olur. Gözenekli seramikler, yapı seramikleri (çanak çömlek, tuğla, kiremit ve seramik borular) ve ince seramikler (sağlık gereçleri, yer ve duvar karosu, sofa ve süs eşyaları) olmak üzere iki temel gruba ayrılır. Bu tür seramikler, yüksek ısı yalıtım özelliklerine sahip olmalarının yanı sıra sırlama işlemiyle su emme özellikleri azaltılabilmektedir. Ancak, bu malzemelerin sertliği düşüktür ve yüzeyleri genellikle pürüzlüdür. Buna karşın yoğun yapılı seramikler, yüksek sıcaklıkta sinterlenerek gözenekliliği minimize edilmiş ve dolayısıyla su geçirmez özellik kazanmış malzemelerdir. Uygulama alanlarına bağlı olarak biyoseramikler, nükleer seramikler, mekanik seramikler ve fonksiyonel seramikler olmak üzere çeşitli alt kategorilere ayrılmaktadır. Bu gruplardan fonksiyonel seramikler; elektriksel, manyetik, optik ve kimyasal özellikleri sayesinde elektrik sigortaları ve şalterler gibi elektriğin etkin biçimde kullanıldığı uygulamalarda yaygın olarak tercih edilmektedir. Elektronik alanlarda ise manyetik ve dielektrik özelliklere sahip seramik malzemeler ön plana çıkmaktadır. Refrakter seramikler, yüksek sıcaklığa dayanıklılık gerektiren uygulamalarda kullanılırken, biyoseramikler tıbbi alanda diş protezleri ve implantlar

gibi medikal ürünlerde kullanım bulmaktadır. Nükleer seramikler, radyasyon absorpsiyonu sağlamaları ve nükleer yakıt sistemlerinde kullanılmaları nedeniyle önem arz etmektedir. Mekanik seramikler, aşınma direnci yüksek malzemeler olarak motor gövdeleri ve uzay araçlarında karşılaşılan yüksek sıcaklık ve sürtünme problemlerine karşı koruyucu kılıf görevi görmektedir. Filtre seramikleri ise filtrasyon amaçlı uygulamalarda kullanılmaktadır. Sonuç olarak, seramik malzemeler; su geçirmezlik, kimyasal direnç, yüzey özellikleri (parlak veya mat) ve mekanik dayanımlarıyla çeşitli endüstriyel ve teknolojik uygulamalarda vazgeçilmez bir rol oynamaktadır [50,51].

2.2 SERAMİK ÜRETİM SÜREÇLERİ

Seramik malzemelerin üretimi, belirli aşamaları içeren sistematik bir süreç gerektirmektedir. Şekil 2.1’de sunulan akış şeması, bu sürecin temel adımlarını özetlemektedir.



Şekil 2.1 Seramik Üretim Süreci.

Seramik üretim sürecinin ilk ve en kritik aşaması, hammaddenin hazırlanmasıdır. Bu aşamada, kullanılacak kil türünün belirlenmesi büyük önem taşımaktadır, çünkü her kilin kimyasal bileşimi, plastisitesi ve pişme davranışı gibi özellikleri farklılık göstermektedir. Bu bağlamda özelliklerine göre öğütülmüş seramik ve hammaddeler, değirmenlerde boyutlarına göre ayrıştırılmakta ve uygun şekilde birleştirilmektedir. Ayrıştırılan hammaddeler, homojen bir yapı elde edilecek şekilde karıştırılarak hava kabarcıklarından arındırılmakta; bu sayede şekillendirme aşamasında oluşabilecek çatlakların önüne geçilmektedir. Homojenlik sağlandıktan sonra malzeme, prosesin gerekliliklerine göre kuru ya da yaş olarak öğütülmektedir. Son aşamada ise öğütülen karışımlar havuzlarda dinlendirilerek şekillendirme işlemine hazır hale getirilmektedir.

Üretim sürecinin ikinci aşamasını şekillendirme işlemi oluşturmaktadır. Bu süreçte, havuzlarda dinlendirilen çamur, %25–30 oranında su içerecek şekilde döküm çamuru ya da sıvı kil formuna getirilerek hazırlanmaktadır. Hazırlanan bu karışım, alçı kalıplara dökülmekte ve ardından bir

ya da birkaç gün süren kurutma işlemine tabi tutulmaktadır. Kurutma aşaması, mikro çatlakların ve yapısal deformasyonların oluşmasını engellemek açısından büyük önem taşımaktadır. Aynı zamanda bu işlem, çamurun nem oranını düşürerek, pişirme aşamasında meydana gelebilecek patlamaların önüne geçilmesini sağlamaktadır. Şekillendirme işleminin son aşamasında ise, belirli bir basınç altında – yaklaşık 3000 ton – pres uygulanarak kalıpların son hâli oluşturulmaktadır.

Üçüncü aşamada sırlama işlemi gerçekleştirilmektedir. Ancak bu adımdan önce, malzemenin dayanıklılığını artırmak amacıyla “ilk pişirme” olarak adlandırılan bir ön işlem uygulanmaktadır. Sırlama işlemi, seramiğin hem mekanik dayanımını hem de yüzey kalitesini artırmayı hedeflemektedir. Bu bağlamda, estetik özellikleri geliştirmek ve farklı renk ile dokular elde etmek amacıyla yüzeyler, ana bileşeni frit olan camsı bir tabaka olan sır (glaze) ile kaplanmaktadır. Sırlı yüzeyler, hem su geçirmezlik özelliği sunmakta hem de parlak, cam benzeri bir görünüm kazandırmaktadır.

Sırlama işleminin ardından, üretim sürecinin dördüncü ve son aşamasını pişirme işlemi oluşturmaktadır. Bu aşamada, seramik parçalar yüksek sıcaklıkta ısıtılarak, taneler arasındaki gözenekler azaltılmakta ve böylece malzemenin yoğunluğu ile mekanik mukavemeti artırılmaktadır. Yaklaşık 50 dakika süren bu pişirme işlemi, 1250 °C civarındaki sıcaklıklarda gerçekleştirilmekte olup, malzemenin erime sıcaklığının altında tutulmasına özen gösterilmektedir. Böylece, seramiğin nihai fiziksel ve yapısal özellikleri kazanması sağlanmaktadır [52].

2.3 SERAMİK ÜRETİMİNDE ORTAYA ÇIKABİLECEK KUSURLAR

Seramik üretiminde kurutma aşaması, çeşitli üretim kusurlarının oluşmasına neden olabilmektedir. Bu kusurların önemli bir kısmı doğrudan kurutma sürecinin kendisinden kaynaklanmaktadır. Şekillendirme işlemini takiben gelen kurutma aşaması, seramik malzemenin nihai özellikleri üzerinde belirleyici bir rol oynamaktadır. Şekillendirme sırasında malzemeye plastiklik kazandırmak amacıyla belirli oranlarda su eklenmekte, kurutma işlemiyle bu suyun sistemden uzaklaştırılması sağlanmaktadır. Ancak, suyun boşaldığı bölgelerde meydana gelen açıklıklar, pişirme aşamasında çatlak oluşumuna zemin hazırlayabilmektedir.

Öte yandan, kurutma işlemi, üretim sürecindeki diğer aşamalara kıyasla daha uzun bir zaman dilimi gerektirmektedir. Bu işlem açık havada doğal yollarla gerçekleştirilebileceği gibi, endüstriyel kurutma fırınları aracılığıyla da yapılabilmektedir. Kurutma süresi, kullanılan şekillendirme yöntemine ve ürün tipine bağlı olarak önemli farklılıklar gösterebilmektedir. Örneğin, kuru yöntemle şekillendirilen seramiklerde kurutma süresi dakikalarla sınırlı kalırken, yaş yöntemle üretilenlerde bu süre saatlere kadar uzayabilmektedir. Bununla birlikte, kurutma sıcaklığı da elde edilmek istenen ürünün türüne göre değişkenlik göstermektedir. Örneğin, kaplama malzemelerinin üretiminde nem oranı %0,3'e düşürülerek 150–200 °C sıcaklık aralığında sıcak hava püskürtülmesi uygulanmaktadır. Sağlık gereçlerinde ise nem oranı %1'e indirilmekte ve kurutma işlemi 60–80 °C sıcaklık aralığında gerçekleştirilmektedir. Kurutma işleminin etkinliği, kurutucularda yer alan fanlar yardımıyla sıcak havanın homojen biçimde dağıtılmasıyla artırılmakta ve bu sayede kurutma süreci dengeli bir şekilde tamamlanmaktadır [53].

Seramik üretim sürecinde, sırlama aşamasında da çatlak, kırık gibi çeşitli yüzey kusurları meydana gelebilmektedir. Genellikle iki temel pişirme işlemi arasında yer alan sırlama aşaması, seramik üretiminin kritik adımlarından biri olarak kabul edilmektedir. Bu aşama, "bisküvi pişirme" (bisque firing) adı verilen ilk pişirme işleminden geçmiş olan seramik ürünlere uygulanmakta ve ardından gerçekleştirilen "sır pişirme" (glaze firing) işlemiyle tamamlanmaktadır. Ancak sırlama sırasında meydana gelen hatalar, seramiklerin hem estetik hem de işlevsel özelliklerini olumsuz etkileyebilmektedir. Örneğin, hızlı kurutma veya soğutma, sırın kalın ya da düzensiz uygulanması, fırın sıcaklığının optimal aralıkların dışında olması gibi faktörler, sır yüzeyinde çatlama ve kırılmalara yol açabilmektedir. Bu nedenle, sırlama hatalarının en aza indirilebilmesi için hazırlık ve uygulama aşamalarında titizlikle hareket edilmesi büyük önem taşımaktadır. Süreç boyunca gösterilecek özen, yüksek kalitede ve kusursuz ürünlerin elde edilmesini mümkün kılmaktadır [54].

Seramik malzemelerin seri üretiminden önce, olası kusurların tespit edilmesi gerekmektedir. Ancak, bu tespit işlemleri sırasında yüzeye düşen ışığın etkisi, görüntüleme sistemlerinin doğru karar vermesini zorlaştırabilmektedir. Dış ortam ışığından kaynaklanan değişiklikler, algılayıcı sistemlerin sabit bir görüntü elde etmesini engelleyerek, hatalı değerlendirmelere neden olabilmektedir. Benzer şekilde, elle yapılan muayenelerde de, gözlemcilerin yorumlarında farklılıklar ortaya çıkabilmektedir. Özellikle hareket halindeki yüzeylerin incelenmesi esnasında, ortamda bulunan gürültü, gözlemcinin yorgunluğu veya stres gibi psikolojik

etkenler, algı yetisini olumsuz etkileyerek değerlendirme sürecinin doğruluğunu azaltabilmektedir. Bu nedenle, seramik ürünlerin paketlenme öncesinde görsel olarak değerlendirilip kalite kontrolünden geçirilmesi kritik öneme sahiptir. Ancak insan gözüyle yapılan denetimlerde, genellikle yalnızca 2 mm'den büyük ve belirgin renkteki kusurlar tespit edilebilmektedir. Daha küçük ya da renk tonu farklılıkları içeren yüzey kusurlarının belirlenmesi ise oldukça zordur. Bu tür kusurların detaylı şekilde ortaya konulabilmesi, yalnızca görüntü işleme tekniklerinin kullanıldığı bilgisayar destekli sistemlerle mümkün olabilmektedir. Bu sistemler sayesinde, daha güvenilir ve nesnel bir kalite kontrol süreci yürütülmekte; tespit edilen kusurlar sınıflandırılarak, ürünler uygun kategorilere ayrılmakta ve buna göre paketlenme işlemleri gerçekleştirilmektedir [55].

Seramik sektöründe kalite-kontrol ve üretim süreçlerine otomasyonun dahil edilmesi, verimliliği önemli ölçüde arttırmaktadır. Ayrıca zaman tasarrufu da sağlamaktadır. Otomasyon sistemleri, seramik malzemelerin kalite kontrolünde kullanılarak ürün üzerindeki kusurların tespit edilmesini sağlamaktadır ve bu kusurlar doğrultusunda bu malzemeler kalite seviyelerine göre ayrılabilirler [55,56].

Seramik sektöründe kalite kontrol ve üretim süreçlerine otomasyonun entegre edilmesi, yalnızca verimliliği artırmakla kalmamakta, aynı zamanda önemli ölçüde zaman tasarrufu da sağlamaktadır. Otomasyon sistemleri, yüzey kusurlarının doğru biçimde tespit edilmesini mümkün kılmakta ve bu kusurlar doğrultusunda ürünlerin belirli kalite sınıflarına ayrılmasını sağlamaktadır [55,56].

Yukarıda açıklanan kusurlar dikkate alınarak, seramik malzemelerin yüzeylerinde gözlemlenebilecek olası hatalar Çizelge 2.1'de sunulmaktadır.

Çizelge 2.1 Seramik Yüzeylerinde Oluşan Olası Yüzey Kusurları.

Kusur İsimleri	Kusur Kategorisi	Kusur Ölçüsü
Hava	Yüzey Lekesi	1 mm
Rötuş	Yüzey Dalgalanması	Yüzeye yayılan kusur
Çatlak	Yüzey Lekesi + Yüzey Dalgalanması	1 mm-2 mm
Toplama	Yüzey Lekesi + Yüzey Dalgalanması	2 mm
Blister	Yüzey Lekesi + Yüzey Dalgalanması	1 mm-2 mm
Leke	Yüzey Lekesi	1mm

Bu tez çalışmasında, HOGS sistemi aracılığıyla hava, rötuş, çatlak ve toplama gibi yüzey kusurlarının görüntülenmesi amaçlanmaktadır. Leke kusurunun hava kusuruyla, blister kusurunun ise çatlak kusuruyla benzer özellikler göstermesi nedeniyle, bu çalışmada ilgili kusurlar ayrıntılı olarak incelenecek ve aralarındaki benzerlikler ile farklılıklar karşılaştırmalı olarak analiz edilecektir.

2.4 SERAMİK YÜZEYLERDE KUSURLARI BELİRLEME YÖNTEMLERİ

Seramik yüzeylerde oluşabilecek kusurlar, farklı prensiplere dayanan çeşitli yöntemler aracılığıyla tespit edilebilmektedir. Bu yöntemler; görsel denetim (manuel kontrol), ultrasonik testler, X-ışını ve bilgisayarlı tomografi (BT) taramaları, termal görüntüleme (termografi), akustik emisyon testi, floresan boya penetrant testi ile optik ve kamera sistemleri olmak üzere sınıflandırılmaktadır. Her bir yöntemin belirli avantajları ve sınırlılıkları bulunmakta olup, uygulama alanına ve kusur türüne göre tercih edilmektedir.

Çizelge 2.2’de, seramik yüzey kusurlarının tespiti için yaygın olarak kullanılan bu yöntemler ve her bir yönteme ilişkin temel kısıtlamalar özetlenmiştir.

Çizelge 2.2 Seramik Kusurlarını Belirlemede Literatürde Kullanılan Yöntemlerin Kıyaslanması.

Teknik	Ölçüm Kabiliyetleri	Sınırlandırmalar
Görsel Muayene	Makroskopik yüzey kusurları	Küçük kusurların tespit edilmesi zordur. Malzeme yüzeyi hakkında kesin yargıya varılamaz, görecelidir.
Ultrasonik Testler	Yüzey altı kusurları	Ses iletimi iyi olmadığında tespit doğruluğu düşmektedir.
X-Ray ve BT Tarama	Yüzey altı kusurları	Malzeme kalınlığı % 2 olduğu durumlarda kullanılabilir. Diğer durumlarda sonuç vermez. Kusur tespiti için malzeme yüzeyinin gözenekli olması gerekmektedir. Tek tip yazılımla çalışan cihazlardır.
Termal Görüntüleme (Termografi)	Yüzey altı kusurları	Isı transferi için mekanik temas içermektedir. Numunede bozulmalara sebep olabilmektedir.
Akustik Emisyon Testi	Tüm yapı analizi	Yorumlanması zor ve pahalı ekipmanlara ihtiyaç duyulmaktadır.
Floresan Boya Penetrant Testi	Yüzey Kusurları	Boya malzemesi numunede tahribata yol açabilmektedir. Yüzey altı kusurları incelenememektedir.
Optik Kamera Sistemleri	Mikro Yüzey Kusurları	2 boyutlu ve 3 boyutlu yüzey kusurlarını inceleyen görüntüleme sistemleri vardır 3 boyutlu olanlar daha kapsamlı bir inceleme imkanı sunmaktadır. Kullanılan teknoloji ve ekipman ile sistem daha hassas hale getirebilmektedir ve maliyet düşürülebilmektedir.

Çizelge 2.2’de sunulan karşılaştırmalı analizler doğrultusunda, bu çalışmanın temel hedefleri kapsamında seramik yüzeylerde gözlemlenen mikro boyuttaki çatlak, leke, çizik gibi lokal kusurlar ile yüzey dalgalanmaları gibi geometrik süreksizliklerin karakterizasyonunda optik ve kamera tabanlı görüntüleme sistemlerinin, geleneksel yöntemlere (örn. kontakt profilometre, elektron mikroskobu) kıyasla daha avantajlı olduğu tespit edilmiştir. Bu nedenle çalışmada, mikro ölçekli yüzey kusurlarının yüksek doğrulukla tespiti ve karakterizasyonu için yüksek çözünürlüklü görüntüleme kapasitesine sahip, mikrometre seviyesinde hassasiyet sunan ve 3B yüzey topografyasını çıkarabilen HOGS tercih edilmiştir.





BÖLÜM 3

TEMEL BİLGİLER

Bu bölümde, HOGS'nin temelini oluşturan optik bileşenler hakkında bilgi verilecektir. Seramik yüzey kusurlarının görüntülenmesi için kullanılacak HOGS, sayısal holografi tekniğine dayanmaktadır. Holografinin temeli ise ışığın dalga yapısına ve dalgaların girişim ve kırınım özelliklerine bağlıdır. Bu nedenle bu bölümde ilk olarak ışığın dalga yapısı daha sonra da ve dalgaların girişim ve kırınım özellikleri anlatılacaktır.

3.1 ELEKTROMANYETİK DALGA EŞİTLİKLERİNDE IŞIĞIN ÖNEMİ

Holografi, ışığın dalga karakteristiğine dayanan girişim ve kırınım olaylarını temel alan bir tekniktir. Eş fazlı (koherent, uyumlu) iki ışık dalgasının üst üste binmesiyle girişim olayı meydana gelmektedir [57,58]. Bu girişim sonucunda oluşan desen ise hologram olarak adlandırılmaktadır. Hologramın oluşum mekanizmasının anlaşılabilmesi için öncelikle ışığın elektromanyetik dalga yapısının incelenmesi gerekmektedir. Bu bağlamda, elektromanyetik dalgaların enerji yoğunluğunun kavranması, holografi sürecinde etkili olan temel fiziksel ilkelerin anlaşılması açısından büyük önem taşımaktadır.

Elektromanyetik alan yoğunluğu (şiddeti), birim zaman başına belirli bir alanda toplanan enerji yoğunluğu şeklinde tanımlanmaktadır. Maxwell denklemlerine göre bu şiddet, Eşitlik 3.1 ile ifade edilmektedir [58,59].

$$I = \varepsilon_0 c E^2 \quad (3.1)$$

Burada I elektromanyetik alan şiddetini, E elektrik alan şiddetini, ε_0 serbest uzayın elektriksel geçirgenliğini, c ($c=299792458\text{m/s}$) ise ışığın boşluktaki hızını temsil etmektedir. Denklemden de açıkça görüldüğü üzere, elektromanyetik alan yoğunluğu, elektrik alanın karesi ile doğru

orantılı ($I \approx E^2$) olarak değişmektedir. Bu ilişki, ışığın elektromanyetik dalga yapısına dayanmaktadır.

Işık, elektromanyetik bir dalga olarak, uzayda zamanla değişen elektrik ve manyetik alanların birleşimi şeklinde tanımlanmaktadır [58,60]. Bu dalgaların önemli bir özelliği, birbirleriyle etkileşime girebilmeleridir. İki ışık dalgasının girişim yapabilmesi, elektrik ve manyetik alan vektörlerinin bir araya gelerek üst üste binebilmesi sayesinde gerçekleşmektedir [58,61]. Girişim, birden fazla sinüzoidal dalganın aynı anda yayılması sonucu, belirli bir noktada ve anda ortaya çıkan toplam elektrik alanının, bu dalgaların ayrı ayrı oluşturduğu alanların vektörel toplamı olarak tanımlanmasıyla açıklanmaktadır.

Işık, elektromanyetik bir dalga olarak ele alındığında, uzayda zamanla değişen elektrik ve manyetik alanların birleşimi şeklinde tanımlanmaktadır [58,60]. Bu dalgaların temel özelliklerinden biri, birbirleriyle etkileşime girebilmeleridir. İki ışık dalgasının girişim yapabilmesi, söz konusu alan vektörlerinin süperpozisyon ilkesi doğrultusunda bir araya gelebilmesi sayesinde mümkün olmaktadır [58,61]. Üst üste binme prensibine dayanan girişim, iki veya daha fazla sinüzoidal dalganın aynı anda hareket etmesiyle, belirli bir yer ve zamanda oluşan toplam elektrik alan olarak tanımlanmaktadır. Bu toplam alan, her bir dalganın oluşturduğu elektrik alanların vektörel toplamına karşılık gelmektedir [58,62].

Girişimle oluşan bu elektromanyetik dalga, hem elektrik hem de manyetik alan bileşenlerini içermekte olup, Maxwell'in dalga denklemleri kapsamında Eşitlik 3.2 ile matematiksel olarak tanımlanmaktadır [58,59]:

$$\nabla^2(\vec{E}, \vec{H}) = \frac{1}{c^2} \frac{\partial^2}{\partial t^2}(\vec{E}, \vec{H}) \quad (3.2)$$

Burada $\vec{E}$ ve $\vec{H}$ parametreleri sırası ile elektrik ve manyetik alan vektörlerini, t ise zamansal koordinatı ifade etmektedir [63,64].

Diğer taraftan optikte, manyetik alan vektörleri genellikle ihmal edildiğinden, elektromanyetik dalgalar çoğunlukla Eşitlik 3.3'te verilen sinüzoidal formda basitleştirilerek tanımlanmaktadır [58,62,65]:

$$E(z, t) = E_0 \cos(\omega t - kz + \theta) \quad (3.3)$$

t anında z noktasındaki elektrik alanı gösteren bu ifadede; θ faz sabitini, k dalga sayısını, ω açısal frekansı, E_0 ise dalganın genliğini temsil etmektedir. Burada dalga sayısı k ile dalga boyu λ arasındaki ilişki Eşitlik 3.4'teki gibi ifade edilmektedir [64]:

$$k = \frac{2\pi}{\lambda} \quad (3.4)$$

Dalgalar, polarizasyon etkisiyle dikey, yatay ya da herhangi bir doğrultuda yayılabilmektedir. Elektrik alan vektörünün belirli bir yönde salınım göstermesi, polarizasyon olarak tanımlanmaktadır. Örneğin, z yönünde yayılan doğrusal polarize tek renkli (monokromatik) bir dalganın skaler denklemi ise Eşitlik 3.5'te verilmiştir [64,66,67]:

$$\frac{\partial^2 E}{\partial z^2} - \frac{1}{c^2} \frac{\partial^2 E}{\partial t^2} = 0 \quad (3.5)$$

Burada ($-kz + \theta$) ifadesi, dalganın z noktasındaki fazını göstermektedir. Harmonik bir dalgayı ifade etmek için faz değerlerinin üstel olarak verilmesi gerekmektedir. Bu bağlamda, eşitlikte yer alan cosinüs terimi, Euler formülü kullanılarak aşağıdaki biçimde yeniden ifade edilebilmektedir [64,68]:

$$\cos \theta = \frac{1}{2}(e^{i\theta} + e^{-i\theta}) \quad (3.6)$$

Bu doğrultuda, harmonik dalga ifadesi en basit haliyle Eşitlik 3.7'de sunulmaktadır.

$$E(z, t) = \frac{1}{2} E_0 e^{i(\omega t - kz + \theta)} \quad (3.7)$$

Diğer yandan, bir dalgada aynı fazda bulunan noktaların oluşturduğu yüzey, yayılma ortamında bir dalga cephesini tanımlar. Bu yüzey, genel olarak düzlem dalga veya küresel dalga biçiminde sınıflandırılmaktadır [57,64].

Düzlem dalga, dalganın yayılma yönüne dik tüm yüzeylerde fazın sabit olduğu durumlarda ortaya çıkmaktadır. Bir düzlem dalganın $t = 0$ anında en basit haliyle verilen tanımı Eşitlik 3.8’de sunulmaktadır [64,66]:

$$E(r) = E_0 e^{i(k \cdot r + \theta)} \quad (3.8)$$

Burada k ve r sırasıyla düzlem dalga ve uzay vektörlerini temsil etmektedir. Bu vektörlerin 3B uzaydaki gösterimleri ise sırasıyla $k = (k_x, k_y, k_z)$ ve $r = (x, y, z)$ şeklindedir.

Dalga cephesini tanımlayan bir diğer dalga türü ise küresel dalgadır. Düzlem dalga kartezyen koordinat sistemiyle, küresel dalga ise koordinat sistemi ile temsil edilmektedir. Bunun nedeni, dalga cephesinin her noktasından dalganın eşit hızla küresel olarak yayılması ve bu yüzeydeki tüm noktalarda fazın sabit kabul edilmesidir [69].

Küresel simetrinin geçerli olduğu durumlarda, küresel dalga θ ve ψ açılarına bağımlı değildir ve bu nedenle denklemi Eşitlik 3.9’da olduğu gibi ifade edilebilmektedir [58].

$$E(r, t) = \frac{E_0}{r} e^{i(\omega t - kr + \phi)} \quad (3.9)$$

Eşitlikten de görüldüğü üzere, küresel dalgada genlik değeri, $\frac{1}{r}$ kadar azalmaktadır. Dolayısıyla düzlem dalgada E_0 olan genlik, küresel dalgada $\frac{E_0}{r}$ olarak ifade edilmektedir. Bu durum, iki dalga cephesi arasında $\frac{1}{r}$ kadar bir fark olduğunu göstermektedir.

3.2 IŞIKTA GİRİŞİM OLAYLARI VE IŞIĞIN KIRINIMINDA FRESNEL YAKLAŞIMI

Girişim olgusu, ışığın dalga doğasını ortaya koyan temel fiziksel olaylardan biridir ve klasik olarak Young’ın çift yarık deneyi ile açıklanmaktadır [58,70]. Bu deneyde, akkor bir ışık kaynağından çıkan ışınlar önce tek bir dar yarıktan geçirilerek paralelleştirilmekte, ardından yaklaşık 1 mm aralıkla yerleştirilmiş iki dar yarıktan geçirilerek faz uyumu sağlanmaktadır. Böylece iki yarık, aynı faza sahip ve birbiriyle tutarlı (koherent) iki noktasal ışık kaynağı gibi davranmaktadır. Bu düzenek sayesinde, her iki yarıktan çıkan ışık dalgaları üst üste binerek ekran (perde) üzerinde girişim desenleri oluşturmaktadır. Aydınlık ve karanlık şeritler şeklinde

gözlemlenen bu desenler, sırasıyla yapıcı ve yıkıcı girişim bölgelerini temsil etmektedir. Yol farkının dalga boyunun tam katı olduğu durumlarda yapıcı girişim (aydınlık şeritler), yarım katı olduğu durumlarda ise yıkıcı girişim (karanlık şeritler) meydana gelmektedir [70]. Girişim desenlerinin oluşumu, dalga denkleminin doğrusal yapısından kaynaklanmaktadır; çünkü bu yapı, iki dalganın süperpozisyonunun da bu denklemi sağlamasına olanak tanımaktadır. Bu durumu matematiksel olarak ifade eden denklem, Eşitlik 3.10'da verilmektedir.

$$\vec{E}(\vec{r}, t) = \sum_i \vec{E}_i(\vec{r}, t) \quad i = 1, 2, \dots \quad (3.10)$$

Bu çerçevede, eşit frekanslara ve dalga boylarına sahip, aynı polarizasyon yönündeki iki tek renkli dalgaya ait karmaşık genlikler sırasıyla Eşitlik 3.11 ve Eşitlik 3.12'de verilmektedir.

$$E_1(x, y, z) = E_{01} \exp(i\varphi_1) \quad (3.11)$$

$$E_2(x, y, z) = E_{02} \exp(i\varphi_2) \quad (3.12)$$

Benzer şekilde, iki veya daha fazla sinüs dalgasının bir arada hareket etmesiyle, belirli bir noktada ve zamanda oluşan toplam elektrik alan, karmaşık genlik olarak ifade edilmektedir. Ortaya çıkan bu toplam genlik, bireysel genliklerin cebirsel toplamı ile elde edilmekte olup, ilgili ifade Eşitlik 3.13'te sunulmaktadır [58,59,65]:

$$E_0^2 = E_{01}^2 + E_{02}^2 + 2E_{01}E_{02} \cos(\varphi_2 - \varphi_1) \quad (3.13)$$

Elektromanyetik alan şiddeti (I), E^2 ile doğru orantılı ($I \approx E^2$) olduğundan, toplam elektrik alanını ışığın şiddeti olarak Eşitlik 3.14'teki gibi ifade edilebilmektedir [58,59]:


$$I = |E_1 + E_2|^2 = (E_1 + E_2)(E_1 + E_2)^* = I_1 + I_2 + 2\sqrt{I_1 I_2} \cos \Delta\varphi \quad (3.14)$$

Burada I_1 ve I_2 sırasıyla her iki dalgaya ait şiddetleri temsil ederken, iki dalga arasındaki faz farkı $\Delta\varphi$ olarak tanımlanmaktadır. Faz farkı Eşitlik 3.15'teki gibi ifade edilmektedir:

$$\Delta\varphi = \varphi_2 - \varphi_1 \quad (3.15)$$

Dalga özelliği gösteren her türlü fiziksel olgu (ışık ve radyo dalgaları gibi), girişim deseni oluşturma potansiyeline sahiptir. Bu bağlamda, faz uyumu yüksek ve spektral saflığı fazla olan bir ışık kaynağı olan lazer, girişim desenlerinin oluşturulmasında son derece etkili bir araçtır. Nitekim, günümüzde bilinen hologramların üretimi ancak lazerin icadıyla mümkün olabilmektedir. Lazerle kaydedilen hologramların yeniden görüntülenmesi ise temelde kırınım ve girişim gibi ışığın dalga karakterine dayanmaktadır [58,64].

Işığın dalga niteliğini daha açık biçimde ortaya koymak amacıyla, girişim olgusuna ek olarak kırınım olayının da ele alınması gerekmektedir. Işık, bir engele rastladığında bu engelin kenarlarında veya dar açıklıklarda bükülerek farklı yönlere sapmaktadır [62,65]. Kırınım olgusu, Huygens ilkesi çerçevesinde nitel olarak açıklanmaktadır. Bu ilkeye göre, bir dalga cephesinin her noktası, ikincil küresel dalgaların kaynağı olarak kabul edilmektedir. Herhangi bir noktadaki dalga alanı ise bu ikincil dalgaların birbirleriyle girişim yapması sonucu oluşmaktadır [71].



Şekil 3.1 Koordinat Düzlemlerini Gösteren Şematik Gösterim [71].

Kırınım olgusunu sayısal olarak açıklamak amacıyla Fresnel-Kirchhoff integrali kullanılmaktadır. Şekil 3.1, Fresnel kırınımında kullanılan düzlemleri şematik olarak göstermektedir. Bu şekilde yer alan kaynak, açıklık (görüntü) ve kırınım düzlemleri sırasıyla (ξ, η) , (x, y) ve (ξ', η') koordinatları ile tanımlanmaktadır. İlgili tüm düzlemler birbirine paralel olup, kaynak düzlemi düzlem dalga ile aydınlatılmaktadır. Kaynak ile görüntü düzlemi arasındaki mesafe z ile ifade edilmekte olup, bu mesafenin büyüklüğüne bağlı olarak kırınım olgusu yakın alan (Fresnel) ve uzak alan (Fraunhofer) kırınımı olarak sınıflandırılmaktadır. Kırınım düzleminde oluşan kırınım deseninin matematiksek olarak Eşitlik 3.16'da gibi ifade edilmektedir:

$$\Gamma(\xi', \eta') = \frac{i}{\lambda} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} A(x, y) \frac{\exp\left(-i\frac{2\pi}{\lambda}\rho'\right)}{\rho'} Q dx dy \quad (3.16)$$

(ξ, η) koordinatlarına sahip kaynak düzleminde, S noktasında konumlanan ışık kaynağı küresel dalgalar yaymaktadır. Açıklık (görüntü) düzlemindeki dalga alanı $A(x, y)$ ile gösterilmekte olup, bu terim dalganın karmaşık genliğini ifade etmektedir. Huygens prensibi çerçevesinde, başlangıçta (x, y) konumunda yalnızca tek bir deliğe sahip opak bir açıklık varsayılmaktadır. Bu açıklıktaki delik, ikincil dalgaların kaynağı olarak işlev görmektedir. Kırınım düzleminde (ξ', η') koordinatlarındaki alan dağılımı, hem açıklığın giriş tarafında tanımlanan $A(x, y)$ alan dağılımı ile (x, y) konumundan yayılan ikincil küresel dalganın genliği olan $\frac{\exp\left(-i\frac{2\pi}{\lambda}\rho'\right)}{\rho'}$ ifadeyle orantılıdır. Burada ρ' değeri açıklık düzlemindeki (x, y) ile kırınım düzlemindeki (ξ', η') noktası arasındaki mesafe olup, Eşitlik 3.17'deki gibi ifade edilmektedir.

$$\rho' = \sqrt{(x - \xi')^2 + (y - \eta')^2 + d^2} \quad (3.17)$$


Huygens ilkesi, bir dalga cephesinin her noktasını ikincil küresel dalgalar üreten bir kaynak olarak ele almaktadır. Ancak bu model, dalgaların hem ileri hem de geri yönde yayıldığını öngörürken, gerçekte gözlemlenen dalga ilerlemesi yalnızca ileri yönde gerçekleşmektedir. Bu sorunu gidermek amacıyla, Fresnel-Kirchhoff kırınım kuramında Eşitlik 3.18 ile tanımlanan eğim faktörü (Q) eklenmiştir. Bu faktör, yalnızca ileri yönde yayılan bileşenlerin dikkate alınmasını sağlayarak matematiksel modelin fiziksel gerçekliğe daha uygun hâle getirilmesini mümkün kılmaktadır.

$$Q = \frac{1}{2}(\cos\theta + \cos\theta') \quad (3.18)$$

Yukarıda açıklanan girişim ve kırınım olguları arasındaki temel fark, oluşum mekanizmalarına dayanmaktadır. Girişim, eş fazlı iki veya daha fazla ışık dalgasının üst üste binmesi sonucu oluşan yapıcı ya da yıkıcı girişim bölgelerinde gözlemlenen yoğunluk değişimlerini ifade etmektedir. Buna karşılık kırınım, ışığın bir engel ya da dar bir açıklıktan geçerken, bu fiziksel sınırların kenarlarında bükülmesi sonucu oluşan ve karakteristik geometrik desenler sergileyen dalga yayılımını tanımlamaktadır.

3.3 HOLOGRAFİ VE İNTERFEROMETRİ


Elektromanyetik dalga özelliği gösteren ışık, birbirine dik düzlemlerde salınım yapan elektrik ve manyetik alan bileşenlerinden oluşmaktadır. Bu dalga yapısı, ışığın yalnızca genlik bilgisini değil, aynı zamanda faz bilgisini de taşımasını sağlamaktadır. Görüntüleme sistemlerinde bir nesnenin tam olarak kaydedilebilmesi için, ışığın taşıdığı bu iki temel bilginin (genlik ve faz) birlikte kaydedilmesi gerekmektedir [72]. Bu gereksinim, holografî tekniğinin önemini ortaya koymaktadır. Geleneksel görüntüleme yöntemlerinden önemli ölçüde farklılaşan holografî, hem ışık şiddetini (genlik) hem de dalga cephelerinin uzamsal dağılımını (faz) eşzamanlı olarak kaydedebilen hologram adı verilen özel kayıt ortamlarını kullanmaktadır. Holografî tekniğinin altında yatan fiziksel ilkelerin daha iyi anlaşılabilmesi adına, ışığın elektromanyetik dalga yapısı Şekil 3.2’de görselleştirilmiştir.



Şekil 3.2 Işığın Elektromanyetik Dalga Gösterimi [72].

Elektromanyetik dalga teorisi çerçevesinde, ışık yoğunluğu matematiksel olarak dalga genliğinin karesiyle orantılı biçimde ifade edilmektedir. Geleneksel fotografik yöntemler, ışığın yalnızca yoğunluk bilgisini kaydederek bu bilgiyi 2B bir düzleme (film yüzeyi veya dijital dedektör) aktarmaktadır. Günümüz dijital görüntüleme sistemleri dahi, temelde yalnızca dalga şiddetini algılayabilecek hassasiyette tasarlandıklarından, nesneden gelen dalga ile referans dalga arasındaki kritik faz farkı bilgisini kaydedememektedir. Bu temel eksiklik, 3B uzamsal bilginin elde edilmesini engelleyen temel faktördür. 3B görüntülemenin gerçekleştirilebilmesi için, nesnenin farklı noktalarından gelen ışık dalgalarının kayıt düzlemine ulaşma sürelerindeki farkların (faz bilgisinin) mutlaka korunması gerekmektedir. Bu gereksinim, holografik kayıt tekniğinin temel prensibini oluşturmaktadır. Holografik sistemlerde, nesneden yansıyan ışık dalgası ile frekans ve faz bakımından tamamen uyumlu (koherent) bir referans dalgası kullanılarak, bu iki dalganın girişim deseni kaydedilmektedir. Oluşan bu girişim deseni, hem

yoğunluk hem de faz bilgisini bünyesinde barındıran kompleks bir yapı sergilemektedir. Holografinin temel avantajı, geleneksel yöntemlerin aksine nesnenin optik görüntüsünü değil, kendisinden yayılan dalga cephelerinin tam bir kaydını sunmasıdır. Bu nedenle hologramlar (girişim desenleri) incelendiğinde, çıplak gözle herhangi bir nesne görüntüsü algılanamaz. Orijinal dalga cephelerinin yeniden oluşturulabilmesi için, kayıt ortamının orijinal referans dalga ile yeniden aydınlatılması gereklidir. Bu süreç, holografik görüntülemenin temel çalışma prensibini oluşturmaktadır. Fotografik ve holografik görüntüleme teknikleri arasındaki temel farklılıkların daha net anlaşılabilmesi amacıyla, Şekil 3.3'te detaylı bir karşılaştırmalı şematik gösterim sunulmuştur. Bu şema, iki teknik arasındaki temel prensip farklılıklarını ve holografinin üç boyutlu görüntülemeye sağladığı avantajları görsel olarak ortaya koymaktadır.




Şekil 3.3 Fotografik ve Holografik Görüntüleme Aşamaları [72].

Holografik teknikler, 3B sinyallerin (görüntü, ses) kaydedilmesine olanak tanımakta ve sıkıştırılmış verilerin geri kazanımı sırasında herhangi bir veri kaybı yaşanmamasını sağlamaktadır. Bu özellik, veri depolama birimlerinin kapasite verimliliğini önemli ölçüde artırmaktadır [69]. Sayısal holografî, klasik holografide olduğu gibi referans ışınının fazına olan bağımlılığı korumaktadır. Ancak, klasik holografide insan gözü tarafından algılanabilen 3B yapı, sayısal ortamda (örneğin monitör ekranında) doğrudan hacimsel bilgi sunamamaktadır.

Buna karşın, faz bilgisinin hesaplanabilir oluşu, sayısal holografıyı interferometrik uygulamalar açısından değerli kılmaktadır [73].

İnterferometri tekniği ise, ışığın yayılım karakteristiklerini dalga boyu temelli analiz eden bir tekniktir. Bu yöntemde, aynı faza sahip iki koherent dalga ayrıştırılarak tekrar birleştirilmekte ve bu süreçte oluşan girişim desenleri holografik interferometrinin temelini oluşturmaktadır. Holografik interferometri, mikrometre-altı düzeyde deformasyon analizi [57], kırılma indisi ölçümleri ve yüksek çözünürlüklü mikroskopik görüntüleme gibi çeşitli uygulama alanlarına sahiptir [74,75]. Özellikle hücre ve doku gibi biyolojik sistemlerin faz kontrast görüntülemesinde vazgeçilmez bir yöntem olarak öne çıkmaktadır [73]. Şekil 3.4'te, temel bir interferometri sisteminin şematik yapısı sunulmaktadır.



Şekil 3.4 İnterferometri Sisteminin Şematik Gösterimi [73].


Bu şekilde gösterildiği üzere objeden gelen obje dalgası A_S ile referans dalgaının A_R girişim yapması ile bir kayıt ortamı oluşmaktadır. Bu oramın kırılma indisi n ile gösterilmektedir. Girişim deseni, dalga boyu (λ) ile θ geliş açısına bağlı olan bir periyottan oluşmaktadır. Bu periyot ise $\Lambda = \frac{\lambda}{2 \sin \theta}$ ile gösterilmektedir.

BÖLÜM 4

HİBRİT OPTİK GÖRÜNTÜLEME SİSTEMİNİN YAPISI VE HOLOGRAM GÖRÜNTÜLERİNİN ELDE EDİLMESİ


4.1 HİBRİT OPTİK GÖRÜNTÜLEME SİSTEMİ (HOGS)

Şekil 4.1’de bu tez çalışması kapsamında hologram görüntülerini elde etmek için kullanılan HOGS sunulmuştur. Bu sistem temelde iki ana kolun birleşiminden oluşmaktadır. Kırmızı daire ile gösterilen ve lazerden gelen ışının cismi aydınlattığı kol “Yanal Kesme Sayısal Holografik Mikroskobi” (YKSHM) olarak ifade edilirken, sarı daire ile işaretlenen kol “Mikroskobik Saçak Projeksiyon Profilometrisi” (MSPP) kolu olarak tanımlanmaktadır [15, 33].



Şekil 4.1 Hibritle Optik Görüntüleme Sistemi.

YKSHM kolunda, seramik örneğiyle ilgili bilgilerin kaydedileceği girişim desenini (GD) - hologram- veren holografik kayıt ortamı oluşturulmuştur. Şekil 4.2’de YKSHM koluna ait optik elemanların görüntüsü ayrıntılı bir şekilde sunulmuştur.



Şekil 4.2 YKSHM kolunda Lazer Işınının Obje Yüzeyine Kadar İzlediği Yol.


Eksen üstü veya ortak yol konfigürasyonuna dayalı geleneksel sayısal holografik mikroskopi (DHM) sistemleri, eksen dışı konfigürasyonlara kıyasla daha yüksek zamansal kararlılık sunmaktadır. Ancak bu avantajına karşın, holografik görüntülerde kırılmamış (doğrusal) ışığın üst üste binmesiyle ortaya çıkan istenmeyen ikiz görüntü (twin image) problemi, tek bir hologramdan faz bilgisinin doğru şekilde yeniden yapılandırılmasını güçleştirmektedir. Bu örtüşme problemini ortadan kaldırmanın etkili yollarından biri, ışın bölücü (beam splitter) gibi optik elemanların sisteme entegre edilmesidir. Ayrıca, geleneksel sistemlerde hologram kaydında maksimum modülasyon derinliğini sağlamak amacıyla kullanılan ızgaranın açısıl konumunun hassas biçimde kontrol edilmesi sayesinde, hem ışın şiddeti dengelenmekte hem de yüksek frekanslı benek gürültüsü azaltılabilmektedir. Örtüşme problemini ortadan kaldırmanın bir başka yolu ise modifiye edilmiş, Şekil 4.2’de sunulan YKSHM kullanmaktır [76]. Bu sistemde, geleneksel holografik sistemlerden farklı olarak hologram üretimi için kurulum açısından daha kolay, mekanik olarak daha sağlam ve zamansal olarak daha kararlı bir yapıya sahip olan kesme cam plakası (KCP) kullanılmaktadır. Ayrıca bu sistemde, KCP’den çıkan ışık dalgası ikinci bir mercek aracılığıyla hizalanmakta ve böylece hizalama hatalarından kaynaklanan ikiz görüntü (twin image) problemi büyük ölçüde ortadan kaldırılmaktadır. Bunun yanı sıra, sistemde oluşan benek gürültüsünün şiddeti de minimum düzeye indirilebilmektedir [41].

Holografik sistemlerde girişim deseni oluşturmak için en temel şartlardan bir tanesi eş fazlı ışık kaynağının kullanılmasıdır. Bu amaç doğrultusunda, gerçekleştirilen çalışmada ışık kaynağı olarak 442 nanometre (nm) dalga boyuna ve 200 miliWatt (mW) çıkış gücüne sahip Helyum Kadmiyum (He–Cd) lazer kullanılmıştır. Lazer kaynağından çıkan ışığın dağılmasını önlemek için ilk olarak paralelleştirilmesi gerekmektedir. Bu işlem 100 mm odak uzaklığına sahip bir konveks mercek (Mercek 1) kullanılarak gerçekleştirilmiştir. Parallelleştirilen ışını kesme plakasına yönlendirmek için ise Şekil 4.2’de görüldüğü gibi yaklaşık 45^0 açıyla monte edilmiş olan ayna kullanılmıştır [15, 33]. Aynadan 45^0 açıyla yansıyan ışın daha sonra KCP üzerine düşürülmektedir. Bu sistemde holografik kayıt ortamı (girişim deseni) yaratmak için gerekli olan iki ışık dalgası, KCP’nin yapısında bulunan ön ve arka yüzeyler aracılığı ile meydana getirilmektedir. Bu yüzeyler ışığı iki kola ayırarak tekrar birleştirmektedir. Ön ve arka yüzeylerdeki bilgilerin kullanılması ile elde edilen girişim deseni matematiksel olarak Eşitlik 4.1’de sunulmuştur.

$$\begin{aligned}
 I(x,y) &= |O_F(x,y) + O_B(x,y)|^2 \\
 &= |(O_1(x,y) + R_1(x,y)) + (O_2(x,y) + R_2(x,y))|^2 \\
 &= [|O_1|^2 + |R_1|^2] + [|O_2|^2 + |R_2|^2] + [(R_1 + R_2)(O_1^* + O_2^*)] \\
 &\quad + (O_1 + O_2)(R_1^* + R_2^*) + [O_1^*O_2 + O_2^*O_1] + [R_1^*R_2 + R_2^*R_1]
 \end{aligned} \tag{4.1}$$

Burada KCP'nin ön ve arka yüzeylerinden yansıyan nesne ışınları sırasıyla O_F ve O_B olarak tanımlanmaktadır. O_F ve O_B içerisinde hem nesneye ait bilgileri içeren alanları hem de nesneye ait bilgi içermeyen alanları bulundurmaktadır. Nesne bilgilerini içeren alanlar sırasıyla O_1 ve O_2 olarak adlandırılırken, nesne verisi olmayan bilgileri içeren alanlar R_1 ve R_2 olarak ifade edilmektedir. Holografik sistemlerin yapısından kaynaklı meydana gelen gerçek ve sanal görüntülerden oluşan ikiz görüntüler ve DC (direct current-doğru akım) kaymaya ait tanımlar eşitlikteki birinci ve ikinci köşeli parantezlerde yer almaktadır. Şekil 4.3(a)’da bu tanımlar açık mavi kısımlar ile gösterilmiştir. Şekil 4.3(a)’da koyu mavi ile gösterilen alan ise üst üste bindirilmiş istenmeyen görüntüleri temsil etmektedir. DC kayması ve sanal görüntü gibi istenmeyen bileşenler, YKSHM sisteminde kullanılan kendi kendine referans veren konfigürasyonun doğal bir sonucu olarak kaçınılmaz biçimde ortaya çıkmaktadır. Bu nedenle, istenmeyen kopya görüntülerin üst üste bindiği ikiz görüntüler, yeniden oluşturulan görüntülerden ayıklanamadığı için görüntü kalitesini düşürmektedir [41]. Yeniden yapılandırma işlemi gerçekleştirilirken bozulmamış gerçek bir görüntüye ulaşmak için O_1 , O_2 , R_1 ve R_2

parametrelerinin karmaşık eşlenikleri kullanılmaktadır. Uzaysal olarak değişen bu karmaşık eşlenik ifadeler sırasıyla O_1^* , R_1^* , O_2^* ve R_2^* olarak tanımlanmaktadır.



Şekil 4.3 Hologram Elde Edilme Süreci a) Modifiye Edilmiş YKSHM ile Hologram Oluşturma Aşamaları c) Elde Edilen Hologram Görseli.

Bu tez çalışması kapsamında kurulan YKSHM sisteminde 100m odak uzaklığına sahip mercekle kullanılmıştır. İkinci merceğin açısı kontrol edilerek ışın iki alana bölünmektedir. Bu alanlara yarım nesne ışın ve yarım referans ışın alanları adı verilmektedir. Diğer taraftan, KCP'nin ön yüzeyinden yansıyan alanda nesne bilgisi olan ve olmayan iki alan bulunmaktadır. Nesne bilgilerinin bulunduğu bu kısım Şekil 4.3 (b1)'de O_1 ile gösterilmektedir. Dairenin sağ yarım küresindeki bu alan yarım nesne ışın alanı olarak tanımlanmaktadır. Aynı şekilde dairenin sol yarım küresinde de nesne bilgilerinin bulunmadığı ve (R_1) ile gösterilen kısım bulunmaktadır. Öte yandan KCP'nin arka yüzeyinden yansıyan bölgede de iki bölge bulunmaktadır. Çemberin sol yarım küresinde (R_2) ile gösterilen kısım nesne bilgisini içermekte olup, yarım referans ışın alanını oluşturmaktadır. Aynı şekilde dairenin sağ yarım küresinde de nesne bilgilerinin bulunduğu bölge bulunmakta ve (O_2) ile gösterilmektedir. Şekil 4.3(b2) ve (b3)'de bahsedilen bu bölgeler açıkça gösterilmektedir.

Geleneksel YKSHM sistemlerinden farklı olarak hedef nesne, ikinci mercek (Şekil 4.2'de Mercek-2 olarak tanımlanmıştır) kullanılarak optik eksenin yan taraflarında konumlandırılmıştır. Açının ayarlanması ile yapılan konumlandırma sayesinde örtüşme probleminin ortadan kaldırılması amaçlanmaktadır. Yani kaydedilen nesne optik eksene değil de optik eksenin kenarına kaydırılmaktadır. Şekil 4.3 b(2) ve b(3), ikinci merceğin açısını ayarlayarak hedef nesnenin optik eksenin kenarına nasıl kaydığını göstermektedir. Eşitlik

4.2’de yarım nesne ışını (R_1) ve yarım referans ışınından (O_2) oluşan hologram düzleminde meydana gelen girişim deseninin yoğunluğu matematiksel verilmiştir [41,77].

$$I(x, y) = |O_1(x, y) + R_2(x, y)|^2 = |O_1|^2 + |R_2|^2 + O_1^* R_2 + O_1 R_2^* \quad (4.2)$$

Mercek-2 sisteme eklendikten sonra hedef nesnenin farklı açılara göre konumu Şekil 4.3 (b2) ve (b3)'de sunulmaktadır. KCP ve ikinci merceğin hafif açısal dönüşleriyle alt bölümlere ayrılmış ışının yoğunluğu kontrol edilebilmektedir. Böylece maksimum modülasyon derinliği elde edilmekte ve yüksek frekanslı benek gürültüsü ortadan kaldırılmaktadır. Görüldüğü gibi hedeflenen nesne hologram alanının etkin girişim alanı (EGA) olarak adlandırılan tarafına kaydırılmıştır. İki kesikli nesne kirişi arasında yinelenen görüntüler olmaksızın oluşan anlamlı girişim deseni olarak adlandırılan EGA, Şekil 4.3 (b3)'de kırmızı daire ile gösterilmektedir. Bu alan yeniden yapılandırılma işlemi için kullanılmaktadır. EGA'da, büyütülmüş numunelerin boyutu yanal kesmeden daha küçük olduğundan, numuneler ikinci kopya yanal kesme ile örtüşmemektedir [41].

HOGS sisteminde YKSHM ile oluşturulan holografik kayıt ortamına görüntülenecek nesne yerleştirilmektedir. Nesneye ait yüzey bilgisini içeren holografik deseni görüntüleyebilmek ve yüzey profili çıkartabilmek için MSPP sistemi YKSHM ile birleştirilmiştir. Bu tez çalışmasında MSPP kolu ile oluşturulan hologramları görüntülemek için tamamlayıcı metal oksit yarı iletken (Complementary metal oxide semiconductor -CMOS) kamera kullanılmıştır. CMOS'un iki piksel aralığındaki mesafesi ve çözünürlüğü sırasıyla $14 \mu\text{m} \times 14 \mu\text{m}$ ve 512×512 'dir. Bir saniyede görüntü alma hızı ise 50 fps (frame per second)'dir. CMOS ile hologramlar kaydedilmeden önce MSPP kolunda holografik desen 6X büyütme oranı ile büyütülmektedir. Daha sonra ise odaklama işlemi ile kontrast bir görüntü elde edilmesi sağlanmıştır. Bu işlemleri gerçekleştirmek için Şekil 4.1’de de görüldüğü gibi CMOS kameranin önüne sırası ile yakınlaştırma merceği ve mikroskopik objektif (MO) yerleştirilmiştir. MSPP kolunda bulunan kamera ve komponentleri Şekil 4.4’te gösterilmiştir.



Şekil 4.4 YKSHM Sisteminde Kullanılan MSPP Kolu.

Sistemde kontrast bir görüntü yakalamak için gerekli olan odak ayarı, kamera lensinin nesneye olan mesafesi MO 'nun büyütme oranı, CMOS'un odak uzaklığı, görüntülenecek alanın boyutu ve belirlenen uygun kamera piksel boyutu kullanılarak hesaplanmıştır. Bir başka deyişle, HOGS sisteminin çözünürlüğü; kullanılan kameranın özellikleri ve odaklama merceği gibi hesaplama parametrelerinin analizi yoluyla değerlendirilmektedir. Bu çalışmada girişim deseni, Optronis CamRecord CMOS kamera (CR600x2 serisi) kullanılarak kaydedilmiştir. Kameranın tüm özelliklerine bakıldığında en yüksek ışık hassasiyetine saniyede 500 kare (fps) kayıt yaparak 1280×1024 piksel tam çözünürlüğe ulaşılmıştır. CMOS'un tam çözünürlüğü, daha düşük yenileme hızı kullanılarak X ve Y piksel olarak da ayarlanabilmektedir Eşitlik 4.3 ve Eşitlik 4.4, sistemin çözünürlüğünü veren odak uzaklığının ve sensör boyutunun matematiksel ifadelerini göstermektedir [78].

$$Odak\ Uzaklığı\ [mm] = \frac{A}{1 + \frac{B}{Sensör\ Boyutu\ [mm]}} \quad (4.3)$$

$$Sensör\ Boyutu\ [mm] = 0,014x\sqrt{X^2 + Y^2} \quad (4.4)$$

Eşitlik 4.3'te A kamera merceği ile holografik kayıt ekranı arasındaki mesafeyi, B kaydedilen nesnenin boyutunu göstermektedir. Denklem 4.4'te sunulan sensör boyutu, kullanılan kameranın yatay ve dikey piksel sayıları olan X ve Y parametrelerine bağlı olarak değişmektedir. Bu parametreler, sensörün çözünürlüğünü belirleyerek sistemin uzamsal çözünürlüğünü doğrudan etkilemektedir. Bu çalışmada X ve Y pikselleri 50 fps ile 512×512 azaltılmış sensör çözünürlüğünde yapılandırılmıştır.


MSPP ile kaydedilen holografik görüntüler kaydedildikten sonra bir arayüz vasıtası ile bilgisayara aktarılmaktadır. Ancak holografik görüntülerden yüzey bilgilerini 3B olarak geri elde etmek için faz bilgilerinin çıkartılması gerekmektedir. Bu çalışmada kullanılan faz bilgisi bulma yöntemleri bir sonraki bölümde ayrıntılı olarak açıklanacaktır. Diğer taraftan, MSPP gibi projeksiyon sistemlerinde, kaydedilen hologramlarda sabit noktaların faz değerlerindeki değişimi hesaplamak gerekmektedir. Bu bağlamda, saçak deformasyonu olarak da adlandırılan faz sapmalarının matematiksel modelleme ile yükseklik değerlerine dönüştürülmesi beklenmektedir [79,80]. Bu deformasyonu matematiksel olarak ifade etmek için MSPP parametreleri kullanılarak Eşitlik 4.5'te ifade edilmiştir [33].

$$I(x, y) = 2I_0(x, y) \left\{ 1 + \cos \left(2\pi \left[\frac{x \cos(\alpha)}{f_p} + \varphi(x, y) \right] \right) \right\} \quad (4.5)$$

Burada, MSPP kolu ile YKSHM tarafından oluşturulan holografik kayıt ortamı arasındaki açı α olarak tanımlanmaktadır. Hologramların saçak aralığı f_p olarak ifade edilmektedir. Holografik kayıt yapılan malzemelerin yüzey profilleri birbirinden farklı olduğu için bu yüzeylerdeki yükseklik bilgilerinin değişimini hesaplamak gerekmektedir [33]. Hologramlardan elde edilen faz bilgisi ile yükseklik bilgisi arasındaki ilişkiyi kurmak için Eşitlik 4.6 kullanılmaktadır [33].

$$h = f_p \frac{\varphi(x, y) \sin(\beta)}{2\pi \sin(\alpha)} \quad (4.6)$$

Burada yükseklik bilgisi h olarak ifade edilmektedir. MSPP kolu ile görüntülenen holografik alan arasındaki açı β olarak verilmektedir. Yükseklik bilgisi içeren faz görüntüleri 2B olarak elde edilmektedir. Bu 2B görüntüler sarılı faz görüntüleri olarak tanımlanmaktadır [33]. Örnek seramik yüzey kusurlarının önerilen sistem ile görüntülenmesi ile kaydedilen hologramlar Şekil 4.5'te sunulmuştur.



Şekil 4.5 HOGS Sistemi ile Kaydedilen Hologramlar a) Kusursuz Seramik Yüzeyin Referans Hologramı b) Çatlak Seramik Yüzeyin Hologramı c) Hava Yüzey Kusurlu Hologram d) Rötüş Yüzey Kusurlu Hologram e) Toplama Yüzey Kusurlu Hologram.

4.2 HOLOGRAMLARDAN GÖRÜNTÜNÜN GERİ ELDE EDİLMESİ (YENİDEN YAPILANDIRMA)

Holografik sistemlerde yeniden yapılandırma süreci, hologramları frekans bileşenlerine ayırarak, bu bileşenleri çeşitli fonksiyonlar/algoritmalar ile ortaya çıkarma işlemi olarak adlandırılmaktadır. Yeniden yapılandırma sürecinde görüntülenen nesneye ait 3B bilgiyi çıkartmak için genlik ve faz bilgileri kullanılmaktadır. Hologram oluşturmak için frekans bakımından uyumlu, eş fazlı iki dalganın girişimi gereklidir. Bu girişim esnasında oluşan kompleks dalganın şiddeti sadece her bir dalganın ayrı ayrı şiddetlerine bağlı değildir. Çünkü genlik bilgisinde görüntülenen nesneye ait derinlik bilgisini vermemektedir. Derinlik bilgisini veren bu iki dalganın aralarında oluşan faz farkıdır. Bu nedenle gerçekleştirilen çalışmada

yeniden yapılandırma süreci hologramlardan geri elde edilen faz bilgilerinin çıkartılması ile yapılmıştır.

Faz farkı kullanılarak elde edilen 2B görüntüden, yüzeyin derinliği (z-boyutu) hakkında bilgi çıkarılabilmektedir. Faz farkları, görüntüdeki her bir pikselin ne kadar ışık geciktirdiği veya hızlandırdığı gösterilmekte olup, bu farklılıkların yüzeydeki yükseklik farklarına karşılık geldiği bilinmektedir. Örneğin, ışığın bir malzemedan geçerken faz kayması yaşadığı ve bu kaymaların, malzemenin kalınlık veya yoğunluk değişiklikleriyle ilişkili olduğu gözlemlenmektedir. Bu faz kaymaları, 3B bir derinlik haritası oluşturulmasında kullanılmaktadır. Faz dönüşümünden elde edilen bilgilerle, her pikselin x-y düzlemindeki konumuna karşılık gelen yükseklik (z) değerlerini içeren bir yükseklik haritası çıkarılmaktadır. Böylece, görüntü yatay düzlemle birlikte dikey eksen de bilgi taşıyan bir profilometri haritasına dönüştürülmektedir. Burada yükseklik bilgisi birimsiz olup, hologram üzerinden faz dönüşümü yapılarak z eksen genlik değeri elde edilmektedir.

Bu çalışma kapsamında kullanılan faz çıkartma metodları aşağıda sunulmuştur:

4.2.1 Fourier Dönüşüm Metodu (FDM)

FD, sinyale ait anlamlı bilgilerin elde edilebilmesi amacıyla, zaman domenindeki bir sinyalin frekans domenine dönüştürülmesi için kullanılmaktadır [81,82]. Bir başka deyişle, bu yöntemde uzamsal domen üzerindeki piksellere ait özellikler, frekans bölgesine aktarılmakta ve böylece görüntüye ilişkin yapısal bilgiler çıkarılabilmektedir. Bu dönüşüm sonucunda hem faz hem de frekans spektrumları elde edilebilmektedir. Geleneksel yöntemlerde sinyallerden bilgi çıkarımı yapılabilmesi için genellikle ötelenme ve ölçekleme gibi ön işleme adımlarına ihtiyaç duyulmaktadır. Oysa FD, bu işlem basamaklarını ortadan kaldırarak daha doğrudan ve etkili bir analiz imkânı sunmaktadır. Ayrıca, frekans domenindeki yerel ve bölgesel piksellere ait özelliklerin çıkarımı için yalnızca FD'nin uygulanması yeterli olmaktadır.

Bu dönüşüm, görüntüleri sinüs ve kosinüs bileşenlerine ayıran klasik bir görüntü işleme aracıdır. Fourier dönüşümü ile elde edilen çıktı, görüntünün frekans (Fourier) domenindeki temsilini sunarken; giriş verisi, uzamsal domen üzerindeki eşdeğer görüntüdür. Fourier domenindeki her bir piksel, uzamsal domendeki görüntüde bulunan belirli bir frekans bileşenine karşılık gelmektedir. Bir görüntünün uzamsal domende tam olarak tanımlanabilmesi

için yeterli sayıda frekans bileşenini içeren örneklenmiş bir dönüşüm gereklidir. Bu amaçla, Ayırık Fourier Dönüşümü (AFD), sınırlı sayıda örnek üzerinden Fourier dönüşümünün uygulanmasını sağlayarak, dijital görüntü işleme alanında yaygın biçimde kullanılmaktadır [82].

AFD, sürekli bir sinyalin veya görüntünün ayırık örneklerini alarak bu verileri frekans bileşenlerine dönüştüren bir yöntemdir. Görüntülerde, her bir pikselin değeri, görüntünün uzamsal (spatial) alanındaki bir noktayı temsil etmektedir. AFD, bu uzamsal veriyi frekans alanına dönüştürerek, görüntünün hangi frekans bileşenlerine sahip olduğunu analiz etmeye yaramaktadır. Görüntüler genellikle ayırık piksel değerleri ile temsil edilmektedir. AFD, bu tür veriler üzerinde çalışmak için tasarlanmıştır. AFD ile üretilen görüntü, uzamsal görüntüyle aynı boyuttadır ve bu sayede giriş boyutu parametrelerini değiştirmeden bir ağ eğitilebilmektedir.

$M \times N$ piksel boyutunda bir görüntü için AFD, uzamsal koordinatları x ve y olan $f(x, y)$ ile tanımlanmaktadır.

$$F(\xi, \eta) = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} f(x, y) e^{-i2\pi(\frac{\xi x}{M} + \frac{\eta y}{N})} \quad (4.7)$$

Eşitlik 4.1’de verilen ξ ve η sırasıyla $[0, 1, 2, \dots, M-1]$ ve $[0, 1, 2, \dots, N-1]$ aralığındadır. $i^2 = -1$ ise karmaşık sanal sayıdır. AFD’nin özelliklerinden biri, orijinal görüntü $f(x, y)$ ’nin $F(\xi, \eta)$ ’ye ters AFD uygulayarak elde edilebilmesidir. Bu ters dönüşüm Eşitlik 4.8’deki gibi tanımlanmaktadır.

$$f(x, y) = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(\xi, \eta) e^{j2\pi(\frac{\xi x}{M} + \frac{\eta y}{N})} \quad (4.8)$$

AFD sonucunda elde edilen görüntüde, sıfır frekans bileşeni (DC bileşeni) varsayılan olarak sol üst köşede yer almaktadır. Bu bileşeni spektrumun merkezine taşımak amacıyla, AFD çıktısı hem u hem de v yönlerinde sırasıyla $M/2$ ve $N/2$ kadar kaydırılmaktadır. Eşitlik 4.8 ve Eşitlik 4.9’te tanımlanan özellikler kullanılarak $(f(x, y) \leftrightarrow F(u, v))$ dönüşüm çifti aracılığıyla, orijinal görüntü $f(x, y)$ üzerine FD uygulandığında bu kaydırma işlemi gerçekleştirilebilmektedir (Bakınız Eşitlik 4.10)

$$f(x, y)e^{j2\pi(\frac{\xi_0 x}{M} + \frac{\eta_0 y}{N})} \leftrightarrow F(\xi - \xi_0, \eta - \eta_0) \quad (4.8)$$

$$F(x - x_0, y - y_0) \leftrightarrow F(\xi, \eta)e^{-j2\pi(\frac{\xi_0 x_0}{M} + \frac{\eta_0 y_0}{N})} \quad (4.9)$$

$$f(x, y)(-1)^{(x+y)} \leftrightarrow F(\xi - M/2, \eta - N/2) \quad (4.10)$$

Eşitlik 4.5 tanımlanan FD ve kaydırma işlemi sayesinde, spektrumun DC bileşeni olan $F(0,0)$ noktası $(\xi_0, \eta_0) = (M/2, N/2)$ konumuna taşınmaktadır. Bu işlem, düşük frekans bileşenlerinin spektrumun merkezine yerleştirilmesini sağlamaktadır.

FD, reel değerli bir fonksiyonun kompleks değerli dönüşümüdür. Bu bağlamda, $F(\xi, \eta)$, Eşitlik 4.11'deki gibi gerçel bileşen (R) ve sanal bileşen (I) olmak üzere iki ayrı kısımdan oluşacak şekilde yeniden yazılabilmektedir.

$$F(\xi, \eta) = R(\xi, \eta) + iI(\xi, \eta) \quad (4.11)$$

Genlik spektrumu ise Eşitlik 4.12'deki gibi verilmektedir.

$$F_m(\xi, \eta) = 20 \times \log(\sqrt{R^2(\xi, \eta) + I^2(\xi, \eta)}) \quad (4.12)$$

Eşitlik 4.12'de tanımlanan ifadede $f(x, y)$ girdi görüntüsünün uzamsal (spatial) alandaki temsili olarak ifade edilmekte olup, buna karşılık gelen $F_m(\xi, \eta)$ ise AFD ile elde edilen genlik spektrum görüntüsünü temsil etmektedir. Bu ifade, uzamsal alan ile frekans alanı arasındaki dönüşüm ilişkisini ortaya koymaktadır [83].

4.2.2 Hilbert Dönüşümü (HD)

İlk olarak David Hilbert tarafından literatüre kazandırılan Hilbert dönüşümü, aerodinamikten yoğun madde fiziğine, optikten saçak desen analizine ve çeşitli mühendislik problemlerine kadar geniş bir uygulama alanına sahiptir [84]. Özellikle optik alanında, görüntülerin yeniden elde edilmesi süreçlerinde faz çıkarımı amacıyla sıklıkla tercih edilen yöntemlerden biri olarak öne çıkmaktadır. [15,33]. Matematiksel olarak, gerçek değerli bir sinyali karmaşık bir formda

temsil eden bir çıktı sinyaline dönüştüren doğrusal bir operatör olarak tanımlanmaktadır. Bu dönüşüm, Fourier spektrumlarında bulunan simetrik faz bileşenlerinin ortadan kaldırılması yoluyla gerçekleştirilmekte olup, sinyalin analitik temsiline olanak sağlamaktadır.

HD, gerçek değerli bir sinyal için Cauchy integrali aracılığıyla tanımlanmakta olup, bu tanım Eşitlik 4.8’de verilmektedir. Burada kullanılan Cauchy integrali, klasik tanımının bir uzantısı niteliğinde olup, başa eklenen P sembolü ile gösterilen Cauchy ana değerini (principal value) içermektedir. Söz konusu integralde, entegrasyon sınırları sonlu veya sonsuz aralıklarda tanımlanabilmektedir.

$$Hf(x) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{f(y)dy}{x-y}, \quad her \ x \in \mathbb{R} \quad (4.13)$$

Burada tek değişkenli bir fonksiyon olan f , x noktasında değerlendirilmekte olup bu nedenle $f(x)$ biçiminde ifade edilmektedir. Öte yandan, $Hf(x)$ gösterimi, aynı noktada HD uygulanmış fonksiyonun değerini temsil etmektedir.

Bu dönüşüm ifadesi, bir çekirdek (kernel) fonksiyonu içermekte olup, söz konusu fonksiyonun tanımı Eşitlik 4.14’te verilmektedir. Bahsi geçen eşitlikte, $x = y$ durumunda fonksiyon tekil bir yapıya sahip olmakta ve bu nedenle tekil bir kernel fonksiyonu olarak değerlendirilmektedir.

$$k(x, y) = \frac{1}{\pi(x-y)} \quad (4.14)$$

HD ifadesi, Cauchy’nin ana değer integral kavramı dikkate alınarak Eşitlik 4.15’te verilmiştir [84].

$$I(x, a) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{\sin as \ ds}{x-s} \quad (4.15)$$

Burada a ile verilen ifade bir sabittir. Eşitlik 4.15’in diferansiyel denklemi ise Eşitlik 4.16 ile verilmektedir.

$$\frac{d^2 I}{dx^2} + a^2 I = 0 \quad (4.16)$$

Eşitlik 4.15 ve Eşitlik 4.16 birlikte ele alındığında Eşitlik 4.17’de verilen denkleme ulaşılmaktadır.

$$I(x, a) = \alpha \cos ax + \beta \sin ax \quad (4.17)$$

Burada α ve β keyfi sabitlerdir. $x = 0$ olduğu durumlarda Eşitlik 4.18’de sunulan ifade ortaya çıkmaktadır.

$$\frac{1}{\pi} \int_{-\infty}^{\infty} \frac{\sin as \, ds}{s} = \text{sign}(a) \quad (4.18)$$

$\text{sign}(a)$ değeri ise Eşitlik 4.19’teki gibi tanımlanmaktadır.

$$\text{sign}(a) = \begin{cases} 1, & a > 0 \\ 0, & a = 0 \\ -1, & a < 0 \end{cases} \quad (4.19)$$

Eşitlik 4.19’dan $\alpha = -\text{sign}(a)$ elde edilmektedir. Ayrıca, $I(x, a) = -I(-x, -a)$ olduğu için $\beta = 0$ bulunmaktadır [84].

Tüm bu bulgular ışığında x ekseninde taşıyıcı frekans (m) olduğu durumlarda girişim desenine ait matematiksel ifadeyi HD ile yazmak mümkündür. (Bakınız Eşitlik 4.20).

$$H(x, y) = I_0(x, y) [1 + \cos(mx + \varphi(x, y))] \quad (4.20)$$

Eşitlik 4.20 ile ifade edilen sinyalin toplam enerjisinin korunabilmesi için $H(x)$ ’ in sadece pozitif bileşenleri kullanılmalıdır. Bu bağlamda negatif bileşenlerin sinyalden çıkartılması gerekmektedir. Diğer taraftan, pozitif bileşenlere ait frekans değerleri 2 ile çarpılarak spektrumdaki değerler arttırılmaktadır. Gerçek değerli sinyalin filtrelenmesi ile de spektrumda sadece pozitif frekans değerleri kullanılmaktadır. Filtreme işlemi ile DC terimi frekans düzleminde sıfırlanmaktadır. Sonuçta Eşitlik 4.15’te verilen ifadenin HD’ ne ulaşılmaktadır. Elde edilen HD denklemi Eşitlik 4.21’ de verilmiştir.

$$H_{YS}(x) = H(x) + i H_{GDS}(x) \quad (4.21)$$

Burada tanımlanan $H_{GDS}(x)$, (x, y) düzleminde ifade edildiğinde Eşitlik 4.22'ye ulaşılmaktadır.

$$H_{GDS}(x, y) = \frac{1}{i} \int_{-\infty}^{\infty} H_1(f) \text{sign}(f) \exp(-i2\pi fx) df \quad (4.22)$$

Eşitlik 4.22 kullanılarak sinyale ait faz bilgisini çıkartmak mümkündür. Faz bilgisi ifade Eşitlik 4.23'te verilmiştir [15,33].

$$\varphi(x, y) = \tan^{-1} \left(\frac{\text{Im} H_{GDS}(x, y)}{\text{Re} H_{GDS}(x, y)} \right) \quad (4.23)$$

4.2.3 Dalgacık Dönüşümü (DD)

Holografik sistemlerde, hologramlardan nesneye ait bilginin çıkartılması için gerekli olan faz çıkartım işlemi çok çeşitli sinyal işleme metodları ile gerçekleştirilebilmektedir. Başlık 4.2.2'de bahsedildiği gibi bu dönüşümler arasında kullanılan en yaygın kullanılan metodlardan bir tanesi FD iken diğeri HD'dir. HD ile çıkartılan faz bilgilerinde lokal değişimler ile ani farklılıklar görüntülenebilmektedir [85]. FD'de ise periyodik tekrar eden yapılan veya desenlerin ayrımı frekans analizi ile gerçekleştirilmektedir [86,87]. Bu iki yöntemin temeli FD esaslıdır. Ancak Fourier analizi yapılırken sinyallerin domenler arasındaki geçişi (zaman domeninden frekans domenine) esnasında zamana ait bilgiler kaybolmaktadır. Sinyalin zaman içerisinde değişmeyen bir karakteristiğe sahip olduğu durumlarda kayıp önemsenmeyebilir. Ancak sinyaller genellikle ani değişimler, eğim, kırılma gibi önemli değerler içerebilmektedir. Bu tür özellikler ise sinyalin kritik parçalarını oluşturma potansiyeline sahiptir ve Fourier analizi bu unsurları tespit etmede yetersiz kalmaktadır [88,89].

Dalgacık dönüşümü (DD), geçmişte FD'nün uygulandığı ve bazı durumlarda yetersiz kaldığı veri analizlerinde başarılı sonuçlar sağlamaktadır. Özellikle, değişken ya da düzensiz küçük ayrıntılara sahip işaretler ve görüntüler, klasik FD'ne kıyasla dalgacıklar kullanılarak daha etkili bir şekilde analiz edilebilmektedir. Bir başka deyişle, bu yöntem yüzey yapılarını çoklu çözünürlükte inceleyerek zaman-frekans düzleminde daha esnek ve ayrıntılı bir değerlendirme yapma olanağı sunmaktadır [90,91]. DD, ses ve işitsel sinyal işleme, görüntü ve video işleme,

haberleşme, jeofizik, ekonomi ve tıp gibi alanlarda, bir boyutlu ve iki boyutlu sinyal işleme uygulamalarında yaygın olarak kullanılmaktadır [92].

Holografik sistemlerde çoklu çözünürlük sağlamak için saçak yapılarındaki (holografik desen) faz bilgisi DD kullanılarak bulunabilmektedir. DD'nün temelinde yatan sürekli dalgacık dönüşümü (SDD) ile yüksek/düşük zaman ve frekans çözünürlüklerine göre frekans ayarlaması yapılabilmektedir [93]. SDD ile bir sinyal, SDD'nin sahip olduğu ana fonksiyonlar sayesinde küçük salınımlara/dalgalanmalara ayrıştırılabilmektedir. Yani, ana dalgacıklarının ölçeklendirilmesi ve kaydırılması ile sinyalin zaman-frekans gösterimi yapılabilmektedir [91]. Durağan olmayan sinyalleri analiz etmek için kullanabilmesi, hologramlardan farklı değerlere sahip faz bilgisinin çıkarımında avantaj sağlamaktadır. Ancak, frekans ayarı yaparak holografik desenlerden faz bilgisini çıkartabilmek için ilk aşamada uygulanacak dalgacık türünün belirlenmesi gerekmektedir.

Bu tez çalışması kapsamında SDD ile faz bilgisi çıkartmak için literatürde yaygın olarak kullanılan dalgacık türlerinden Morlet Dalgacık dönüşümü (MDD) ve Mexican hat Dalgacık dönüşümleri (MHDD) tercih edilmiştir.

SDD'yi kullanarak holografik desenlerdeki her bir satıra ait şiddet yoğunluğu Eşitlik 4.24 ile verilmektedir.

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} I(t) \psi_{a,b}^* \left(\frac{t-b}{a} \right) dt \quad (4.24)$$

Burada, ana fonksiyona ait ana dalgacık ψ ile ifade edilmektedir. Bu ana dalgacık a kadar ölçeklendirilmekte, b kadar da dönüştürülmektedir. Yeniden yapılandırma süreçlerinde a ve b parametrelerinin aldığı değer önem kazanmaktadır. Ayrıca bu eşitlikte yer alan $\psi_{a,b}^* \left(\frac{t-b}{a} \right)$ ifadesi MDD için kullanılan dalgacığın karmaşık eşleniğini vermektedir.


Morlet dalgacığı (MD), Gaussian'ın sinüs dalgaları ile modüle edilmiştir. Bu dalga aynı zamanda zaman- frekans dönüşümünde etkili olan bir düzlem dalgadır. Eşitlik 4.25'de MD'ye ait fonksiyonu tanımlamaktadır.

$$\psi(\omega) = \exp(-2\pi^2(v - v_0)^2) \quad (4.25)$$

Bu ifadede yer alan ω ve v_0 sırasıyla açısal frekans ve sabit değer olarak tanımlanmaktadır. Bu dönüşümde frekans çözünürlüğü ise β parametresi ile dengelenmektedir. Eşitlik 4.26'da verilen fonksiyon β parametresini içerisinde barındıran MD'nin gerçel (gerçek) değerini matematiksel olarak tanımlamaktadır [91].

$$\psi_r(t) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{\beta^2 t^2}{2}\right) \cos(2\pi v_0 t) \quad (4.26)$$

Bu eşitlikte görüldüğü gibi MD, frekans bölgesinde yer alan sağ ve sol bölgelerde üssel azalmayı göstermektedir. Bu azalan sinyal bir kosinüs sinyalidir. Morlet dalgacığının osilasyon sayısı ω açısal frekansı ile belirlenmektedir. Şekil 4.6'da örnek bir Morlet dalgacık gösterimi sunulmuştur [94]. Bu örnek şekilde t , zaman aralığını verirken, -1 ile 1 arasında 1000 örnek ile oluşturulduğunu göstermektedir. MD'yi meydana getiren gerçel ve sanal bileşenler, zaman biriminin çevrilmesi ile oluşmaktadır. Aynı zamanda MD'nin sahip olduğu ana dalgacığın ölçeklenmesi gerekmektedir.



Şekil 4.6 MD Gösterimi.

Bu çalışmada SDD ile faz çıkartma işlemi yaparken, kullanılan ikinci dalgacık türü Mexican hat dalgacığıdır (MHD). Bu dalgacığı elde etmek için 2 boyutlu Gaussian'a laplasyen operatörü uygulanmaktadır. Laplasyen operatörünün uygulanması ile şapka şeklinde dalgacıklar meydana gelmektedir. Bu nedenle bu dalgacık, Meksika Şapkası Dalgacık Ailesi olarak adlandırılmaktadır. Fourier uzayında MHD Eşitlik 4.27'de verilen denklem ile ifade edilmektedir [95].

$$\psi_n(k) = \frac{k^{2n} e^{-\frac{k^2}{2}}}{2^n n!} \quad (4.27)$$

Gerçek uzayda bu ifade Eşitlik 4.28'deki gibi tekrar yazılabilmektedir.

$$\psi_n(x) = \frac{(-1)^n}{2^n n!} \Delta^n \varphi(x) \quad (4.28)$$


Burada 2B Gaussian ifadesi $\varphi(x)$ ile elde edilmektedir ve Eşitlik 4.29'teki gibi tanımlanmaktadır.

$$\varphi(x) = \frac{e^{-x^2/2}}{\sqrt{2\pi}} \quad (4.29)$$

Genel ifade ile ölçeklendirme ve kaydırma parametrelerini içerisinde barındıran MHD'yi tanımlamak mümkündür. Eşitlik 4.30'da s ve a 'nın gösterildiği fonksiyon yer almaktadır.

$$\phi(t, a, s) = \frac{\left(\frac{(t-a)}{s}\right)^2 - 1 \cdot \exp\left(-0.5 \cdot \left(\frac{(t-a)}{s}\right)^2\right)}{\sqrt{2\pi} \cdot s^3} \quad (4.30)$$

Şekil 4.7'de $a = (1,0,1)$ iken elde edilen Mexican Hat Dalgacığına ait grafik sunulmaktadır [96,97].



Şekil 4.7 Mexican Hat Dalgacığı Gösterimi.



BÖLÜM 5


FAZ DÖNÜŞÜMÜ BAŞARIMINI ARTTIRMAK İÇİN KENAR BELİRLEME TEKNİKLERİNİN UYGULANMASI

Bu tez çalışmasında, kusurlu ve kusursuz seramik örneklerinden HOGS tekniğiyle elde edilen hologram görüntüleri karşılaştırılmıştır. Görüntüler arasındaki farklılıkları analiz edebilmek amacıyla, öncelikle çeşitli faz dönüşüm yöntemleri uygulanmıştır. Ancak görüntülerin daha ayrıntılı ve anlamlı biçimde değerlendirilebilmesi için yalnızca faz bilgisi yeterli olmadığından, kenar belirleme teknikleri de sürece dâhil edilmiştir. Bu kapsamda, faz dönüşümünün performansını artırmak amacıyla kenar tespitiyle bütünleşik hibrit bir yöntem geliştirilmiştir. Sonuç olarak, hem yalnızca faz dönüşümüne dayalı hem de kenar belirleme ile desteklenen yöntemlerin çıktıları yazılımsal olarak 3B yüzey profilleri şeklinde görselleştirilmiş ve karşılaştırmalı olarak sunulmuştur.

Görüntülerin etkin bir şekilde analiz edilebilmesi için, öncelikle kenar bilgilerinin doğru bir biçimde tespit edilmesi gerekmektedir. Kenar tespiti, yalnızca görüntüdeki belirgin geçişleri ortaya çıkarmakla kalmaz, aynı zamanda görüntünün yapısal olarak anlamlı bölgelere ayrılmasına olanak tanıyarak sonraki analiz aşamaları için sağlam bir temel oluşturmaktadır. Bu bağlamda, kenar bilgisi; görüntüdeki sınırların belirlenmesini, bölgesel ayrımların yapılmasını ve şekilsel özelliklerin ortaya çıkarılmasını mümkün kılmaktadır. Kenarlar, görüntü içerisindeki parlaklık değişimlerinin ani ve belirgin olduğu bölgeler olarak tanımlanmakta olup, görüntü özelliklerinin analizi ve sınıflandırılması süreçlerinde de kritik bir rol üstlenmektedir. Literatürde yaygın biçimde kabul gören beş temel kenar türü-basamak, rampa, iç bükey, dış bükey ve sütun kenarları- Şekil 5.1’de görsel olarak sunulmaktadır [98].

Şekil 5.1(a) ve Şekil 5.1(b)’de sunulan çatı türü kenarlar, görüntüde parlaklık değerlerinin düzenli bir şekilde artması ya da azalması durumunda ortaya çıkmakta olup, bu kenarların oluşumunda genellikle sınır bilgisi yerine, yüzeyde ışık kaynağına bağlı olarak meydana gelen yansıma farklılıkları etkili olmaktadır. Şekil 5.1(c)’de gösterilen rampa kenar, parlaklık

geçişinin ani olmadığı ve birkaç piksel boyunca kademeli olarak gerçekleştiği durumları temsil etmektedir. Bu türün aksine, Şekil 5.1(d)'de sunulan basamak kenar, görüntüdeki bir bölgenin çevresine kıyasla daha parlak ya da daha karanlık olması durumunda ortaya çıkan ani geçişleri ifade etmektedir. Basamak kenar yapısının bir türevi olarak değerlendirilebilecek kolon kenarlar ise, ters işaretli iki basamak kenarın çok kısa bir mesafede yer almasıyla oluşmakta olup, bu tür bir geçişin örneği Şekil 5.1(e)'de sunulmaktadır. Öte yandan, ideal ve belirgin kenar yapılarına ek olarak, özellikle düşük kaliteli ya da bozulmuş görüntülerde, yapısal olarak sınıflandırılması güç ve kenar belirleme algoritmaları açısından ek zorluklar barındıran gürültülü kenarlarla da karşılaşılabilir [98].



Şekil 5.1 Yaygın Kullanıma Sahip Kenar Çeşitleri.

Bu farklı kenar türlerinin doğru biçimde tespit edilmesi ve görüntü analizine entegre edilebilmesi amacıyla, literatürde çeşitli kenar belirleme yöntemleri geliştirilmiştir. Bu yöntemler; kullandıkları filtreleme yaklaşımları ve eşikleme stratejileri sayesinde, farklı kenar yapılarını algılamada önemli avantajlar sağlamaktadır.

5.1 CANNY OPERATÖRÜ

Canny kenar tespit yöntemi, görüntü işleme alanında yerel maksimum eğim değerlerini tespit ederek kenar çıkarma işlemini gerçekleştiren etkili bir yaklaşımdır. Bu yöntem, kenarların belirlenmesi için Gauss filtresinin türevine dayalı bir eğim hesaplama tekniği kullanmaktadır. İki aşamalı bir eşikleme mekanizması içeren Canny operatörü, yüksek ve düşük eşik değerleri vasıtasıyla güçlü ve zayıf kenarları ayırt etmektedir. Özellikle, zayıf kenarların sonuç görüntüsünde korunabilmesi için güçlü kenarlarla bağlantılı olması gerekmektedir; bu durum,

yalnızca anlamlı kenar yapılarının tespit edilmesini sağlayarak yanlış pozitif oranını minimize etmektedir [99–101].

Canny tarafından geliştirilen bu algoritma, çok aşamalı bir işlem sürecine sahiptir. İlk aşamada, görüntü üzerinde Gauss konvolüsyonu uygulanarak gürültü azaltma ve yumuşatma işlemi gerçekleştirilir. Sonrasında, yoğunluk süreksizliklerinin belirlenmesi amacıyla iki boyutlu birinci türev operatörü kullanılarak eğim büyüklüğü ve yönü hesaplanır [102]. Gauss filtresinin matematiksel ifadesi ise Eşitlik 5.1’de verildiği üzere modellenmektedir.

$$g(m, n) = G_{\sigma}(m, n) * f(m, n) \quad (5.1)$$

Burada G_{σ} varyansı σ^2 olan bir Gauss fonksiyonu temsil ederken, $*$ sembolü konvolüsyon operatörünü ifade etmektedir. m ve n , görüntüdeki bir pikselin satır ve sütun konumlarını belirtmek amacıyla kullanılmaktadır. $f(m, n)$ ise (m, n) koordinatındaki pikselin çevresindeki yerel komşuluğu tanımlamaktadır [101]. G_{σ} ’nın matematiksel olarak açık ifadesi Eşitlik 5.2’deki gibi verilmektedir.

$$G_{\sigma} = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{m^2+n^2}{2\sigma^2}\right) \quad (5.2)$$

Bu doğrultuda, belirli bir gradyan operatörü (örneğin Sobel) kullanılarak, $g(m, n)$ ifadesi Eşitlik 5.3’te verilen denklem aracılığıyla hesaplanmaktadır.

$$g_{m,n}(m, n) = \sqrt{(g_m(m, n) \cdot N_{IC})^2 + (g_n(m, n) \cdot N_{IC})^2} \quad (5.3)$$

Burada, N_{IC} görüntü komşuluğunu, $g_{m,n}(m, n)$, tahmin edilen gradyanların birleşik sonucunu ifade etmektedir.

5.2 PREWITT OPERATÖRÜ

Prewitt operatörü, 1970 yılında J.M.S. Prewitt tarafından geliştirilen temel bir kenar tespit yöntemidir. Yapısal olarak Sobel operatörüyle benzerlik göstermekle birlikte, kullanılan filtre yapıları açısından bazı önemli farklılıklar içermektedir. Prewitt operatörü, görüntüdeki her bir

noktanın türev değerlerinin hesaplanması için iki ayrı filtre kullanımını gerektirmektedir ki bu özelliğiyle tek filtre kullanan diğer operatörlerden ayrışmaktadır.

Prewitt yönteminin uygulanmasında, 3×3 boyutlarında tasarlanmış iki farklı konvolüsyon çekirdeği kullanılmaktadır. Bu çekirdekler, sırasıyla x ve y yönlerindeki yoğunluk değişimlerini ölçerek kenar piksellerinin belirlenmesine olanak sağlamaktadır. Operatörün matematiksel temelini oluşturan ve türev hesaplamalarında kullanılan formüller, Eşitlik 5.4 ve Eşitlik 5.5'te detaylı olarak sunulmuştur [103].

$$P_x = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad (5.4)$$

$$P_y = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad (5.5)$$

Burada eşitliklerde verilen P_x ve P_y filtreleri, sırasıyla yatay ve dikey gradyan bileşenlerini temsil etmekte olup, toplam gradyan büyüklüğünün hesaplanmasında birlikte kullanılmaktadır. Toplam gradyanın matematiksel ifadesi ise Eşitlik 5.6'da sunulmaktadır [102].

$$P_P = \sqrt{(P_x \cdot N_{IP})^2 + (P_y \cdot N_{IP})^2} \quad (5.6)$$

Burada, N_{IP} , 3×3 boyutlarında tanımlanmış bir görüntü komşuluğunu temsil etmekte olup, merkez pikselin çevresindeki yerel bölgeyi ifade etmektedir.

5.3 SOBEL OPERATÖRÜ

Sobel operatörü, 1970 yılında Sobel tarafından geliştirilen ve kenar tespiti amacıyla kullanılan gradyan tabanlı bir yöntemdir. Bu yöntem, maske merkezine daha yakın konumda bulunan piksellere daha yüksek ağırlık vererek kenar belirleme sürecinde yerel yapıları daha etkili biçimde vurgulamaktadır [104]. Sobel operatörü, gradyan büyüklüğünün maksimum olduğu bölgeleri esas alarak kenarları belirlemekte ve bu doğrultuda görüntüdeki kenar piksellerini

tespit etmektedir [105]. Yöntem, kenar algılama sürecinde 3×3 boyutlarında iki konvolüsyon çekirdeği (kernel) kullanmakta olup, gradyan tabanlı bir operatör olarak sınıflandırılmaktadır.

Sobel operatörü, 2B uzaysal gradyan bileşenlerinin tahminine dayanmakta ve genellikle gri tonlamalı görüntüler üzerinde uygulanmaktadır. Bu operatör, her bir piksel konumunda yaklaşık mutlak gradyan büyüklüğünü hesaplamak için x ve y yönlerine ait iki ayrı 3×3 konvolüsyon maskesi kullanılmaktadır. Bu maskeler, görüntü üzerinde kayan bir pencere mantığıyla uygulanmakta; her adımda küçük bir piksel grubu işlenerek kenarların tespiti sağlanmaktadır. Maske, satır boyunca yatay olarak kaydırıldıktan sonra bir alt satıra geçerek işleme devam etmektedir. Ancak, kullanılan 3×3 konvolüsyon maskesi nedeniyle görüntünün kenarlarında (ilk ve son satır ile sütunlarda) bulunan pikseller işleme dâhil edilememektedir. Bu durum, kenar bölgelerinde bilgi kaybına yol açabilmekte olup, kenar tespiti açısından dikkate alınması gereken önemli bir sınırlamadır.

Diğer kenar algılama operatörleriyle karşılaştırıldığında, Sobel operatörünün iki temel avantajı öne çıkmaktadır. Birincisi, ortalama faktörünün entegre edilmesi sayesinde, görüntüdeki rastgele gürültülerin bastırılmasına katkı sağlayarak yumuşatma etkisi oluşturmaktadır. İkincisi ise, türev hesaplamalarının iki ardışık satır veya sütun boyunca gerçekleştirilmesiyle, kenarın her iki tarafındaki piksellerin daha fazla vurgulanmasına olanak tanınmasıdır. Bu durum, kenarların daha kalın ve belirgin biçimde görünmesini sağlamaktadır [106].

Ayrıca, Sobel operatörü, türev hesaplamalarından önce görüntüde yumuşatma işlemi gerçekleştirerek kenar vurgusunu artırmaktadır. Özellikle x yönündeki kısmi türevin hesaplanmasından önce uygulanan bu yumuşatma işlemi, Eşitlik 5.7’de sunulan filtre aracılığıyla gerçekleştirilmektedir [102].

$$h_x = \begin{bmatrix} 1 & 1 \\ 2 & 2 \\ 1 & 1 \end{bmatrix} \quad (5.7)$$

Türev yaklaşımı ile görüntü yumuşatma işlemlerinde kullanılan filtrelerin her ikisinin de doğrusal nitelikte olması, bu iki işlemin, x yönü için Eşitlik 5.8’de verilen matris formunda birleştirilmesine olanak sağlamaktadır [102]. $h_{Sobel,x}$ filtresi, x yönündeki türevi yaklaşık olarak hesaplamak için kullanılmaktadır.

$$h_{Sobel,x} = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (5.8)$$

Benzer şekilde, y yönündeki kısmi türevi hesaplayan filtre Eşitlik 5.9'da gösterilmiştir [102].

$h_{Sobel,y}$ filtresi, y yönündeki türevi yaklaşık olarak hesaplamak için kullanılmaktadır.

$$h_{Sobel,y} = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (5.9)$$

Bu doğrultuda, gradyan yaklaşımlarından elde edilen sonuçlar, gradyan büyüklüğünü hesaplamak amacıyla Eşitlik 5.10'da verilen formül aracılığıyla birleştirilebilmektedir [102].

$$h_{Sobel} = \sqrt{(h_{Sobel,x} \cdot N_{IS})^2 + (h_{Sobel,y} \cdot N_{IS})^2} \quad (5.10)$$

Burada h_{Sobel} gradyan yaklaşımlarının birleşik sonucunu temsil ederken, $N_{IS} 3 \times 3$ boyutlarında tanımlanmış bir görüntü komşuluğunu ifade etmektedir.

BÖLÜM 6

DERİN ÖĞRENME


Derin öğrenme (DÖ), yapay sinir ağlarının (YSA) çok katmanlı mimarilerle geliştirilmiş bir biçimidir. YSA'lar, biyolojik sinir hücrelerinden esinlenerek tasarlanmış yapay yapılar olup, görüntü işleme, sinyal analizi, sınıflandırma ve tanı gibi birçok alanda kullanılmaktadır. Derin öğrenme ise, bu temel yapının katman sayısının artırılmasıyla daha karmaşık örüntüleri öğrenebilen gelişmiş bir modelleme yaklaşımıdır. Verilerin çok katmanlı soyut temsillerini otomatik olarak öğrenebilmesi, bu yöntemin çeşitli öğrenme görevlerinde yüksek performans sergilemesini sağlamaktadır. Bu genel yapının temsili bir gösterimi Şekil 6.1'de sunulmuştur.

DÖ modelleri, tipik olarak girdi katmanı, konvolüsyonel katmanlar (kenar ve özellik tespiti için), havuzlama katmanları (boyutsallık azaltma), aktivasyon fonksiyonları (ReLU, Softmax) ve tam bağlantılı katmanlardan oluşan hiyerarşik bir yapı sergilemektedir. Bu katmanlarda gerçekleştirilen işlemler, çok sayıda matris hesaplaması ve parametre güncellemesini içermektedir. Bu işlem yoğunluğu, büyük veri hacimlerinin işlenmesini gerektirmekte ve yüksek hesaplama gücüne sahip sistemlere olan ihtiyacı artırmaktadır. Daha fazla veri ile genellikle daha yüksek başarı elde edilebilse de, bu durum aynı zamanda eğitim süresinin uzamasına ve daha fazla hesaplama kaynağına ihtiyaç duyulmasına yol açmaktadır. Bu nedenle, grafik işlemcilerin (GPU – Graphics Processing Unit) paralel işlem yeteneklerinden yararlanılarak model eğitimi süreci önemli ölçüde hızlandırılabilir [107-109].

Bu genel çerçeve doğrultusunda, bu bölümde öncelikle derin öğrenme mimarilerinden biri olan Evrimsel Sinir Ağları (ESA) ayrıntılı olarak ele alınmış; ardından ESA mimarisine ait katman yapısı, performans değerlendirme metrikleri, hata ölçüm kriterleri ve algoritma başarımını etkileyen parametreler detaylı biçimde incelenmiştir.

Elde edilen kuramsal bilgiler ışığında, tez kapsamında kusurlu ve kusursuz seramik yüzeylerin sınıflandırılmasına yönelik olarak ResNet50 algoritması kullanılmış; model performansı,

hologram yüzeylerinden elde edilen görüntüler ile yapılandırılmış veriler üzerinde karşılaştırmalı olarak değerlendirilmiştir [110,111].




Şekil 6.1 Yapay Zeka Yöntemlerinin Temsili Gösterimi [110, 111].

6.1 ESA MİMARİSİ

Evrimsel Sinir Ağları (ESA), DÖ alanında temel mimari yapılardan biri olarak kabul edilmektedir. ESA mimarisi genellikle ardışık olarak düzenlenmiş çok katmanlı bir yapıdan oluşmakta olup, bu katmanlar temel olarak öznetelik çıkarımı ve sınıflandırma işlevlerini yerine getirmektedir. İlk aşamada, konvolüsyonel katmanlar ve havuzlama (pooling) katmanları bulunmaktadır. Konvolüsyonel katmanlar, giriş verisindeki yerel örüntüleri tespit etmekte ve bu örüntülerden öznetelik haritaları oluşturmaktadır. Bu katmanları izleyen havuzlama katmanları ise boyutsal indirgeme yaparak hem hesaplama karmaşıklığını azaltmakta hem de modelin öteleme ve deformasyonlara karşı direncini artırmaktadır. Ardından gelen tam bağlantılı (fully connected) katmanlar, önceki katmanlardan çıkarılan yüksek seviyeli öznetelikleri birleştirerek sınıflandırma görevine hazır hale getirmektedir. Çıkış katmanı aracılığıyla da sınıflandırma işlemi gerçekleştirilmekte ve modelin tahminleri üretilmektedir. ESA'ların eğitim sürecinde, çıkış katmanında hesaplanan hata değeri geriye yayılım (backpropagation) algoritmasıyla ağ boyunca iletilmekte; ardından, ağırlıklar uygun bir optimizasyon algoritması (örneğin, stokastik gradyan inişi) yardımıyla güncellenerek modelin performansı artırılmaktadır. Başlangıçta görüntü sınıflandırma problemleri için geliştirilen ESA'lar, günümüzde ses tanıma, doğal dil işleme ve tıbbi görüntü analizi gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. ESA'ların başarısı, özellikle verilerdeki hiyerarşik örüntüleri otomatik olarak öğrenebilme yeteneğinden kaynaklanmaktadır. Örneğin, bir görüntü sınıflandırma görevinde ESA'lar, alt seviyede piksellerden kenar ve doku bilgilerini, orta

seviyede nesne parçalarını ve üst seviyede ise bütünsel nesne temsillerini öğrenerek etkili bir sınıflandırma gerçekleştirebilmektedir. Bu özellikleri sayesinde ESA'lar, DÖ uygulamalarının vazgeçilmez bir bileşeni haline gelmiştir [112]. Şekil 6.2'de bu yapının temsili gösterimi sunulmaktadır.



Şekil 6.2 ESA'ların farklı katmanlarda nesne ile ilgili oluşturduğu farklı temsiller [112,113].


6.1.1 Giriş Katmanı (GK)

ESA mimarisinin ilk bileşeni giriş katmanıdır. Bu katmanda, veri setindeki örnekler ham halleriyle ağı aktarılmaktadır. Giriş verisinin boyutu, model başarımı üzerinde doğrudan etkili olup, uygun şekilde belirlenmesi gerekmektedir. Özellikle görüntü boyutunun büyük olması durumunda bellek kullanımı, eğitim süresi ve test başına düşen işlem süresi artış gösterebilir; buna karşın, bu durum ağı doğruluğunu artırma potansiyeli taşımaktadır. Öte yandan, düşük boyutlu görüntüler bellek gereksinimini azaltarak eğitim süresini kısaltabilmektedir. Ancak bu durum, ağı derinliğini sınırlayarak performans kaybına yol açabilmektedir. Bu nedenle, görüntü analizine yönelik DÖ modellerinde, ağı derinliği, donanımsal hesaplama maliyeti ve hedeflenen doğruluk düzeyi göz önünde bulundurularak uygun bir giriş boyutunun seçilmesi kritik öneme sahiptir [112].

6.1.2 Konvolüsyon Katmanı (KK)

Konvolüsyon Katmanı (KK), DÖ mimarisinde temel işlevsel katmanlardan biridir. Geleneksel YSA'da öznitelik çıkarımı genellikle kullanıcı tarafından manuel olarak gerçekleştirilirken, konvolüsyonel sinir ağları gibi DÖ modellerinde bu işlem otomatik olarak gerçekleştirilmektedir. KK'da önceden tanımlanmış filtre (çekirdek) matrisleri aracılığıyla giriş verisindeki anlamlı öznitelikler çıkarılmaktadır. Bu süreç sonucunda, giriş verisinden daha küçük boyutlara sahip ancak anlam bakımından yoğun bir öznitelik haritası elde edilmektedir [114]. Şekil 6.3 ve Denklem 6.1'de gösterildiği gibi, $[i, j]$ boyutunda bir K matrisi, $(x + i - 1)$,

$(y + j - 1)$ boyutundaki I matrisi üzerinde gezdirilerek, $[x, y]$ boyutunda yeni bir $I * K$ matrisi oluşturulmaktadır [115].



Şekil 6.3 Konvolüsyon Katmanı [115].

$$(I * K)_{xy} = \sum_{i=1}^h \sum_{j=1}^w K_{ij} \cdot I_{x+i-1, y+j-1} \quad (6.1)$$

Şekil 6.3' den de görüldüğü üzere, ağız eğitimi ve elde edilen performans, görüntü üzerinde uygulanan tarama matrisine doğrudan bağlıdır. Kullanılan matrisin boyutlarının çok büyük olması ya da yüksek değerlere sahip elemanlar içermesi durumunda, eğitim süreci önemli ölçüde uzayabilmekte; ayrıca bu durum, sayısal kararsızlıklar nedeniyle hata oluşma riskini de artırabilmektedir [116].

6.1.3 Düzleştirilmiş Doğrusal Birim Katmanı (Rectified Linear Units Layer (ReLU))

ESA'da konvolüsyon katmanından sonra aktivasyon işlemi yapılmaktadır. Aktivasyon ya da aktifleştirme katmanı olarak adlandırılan bu basamakta, aktivasyon işlemini gerçekleştirmek için aktivasyon fonksiyonları kullanılmaktadır. Sigmoid, hiperbolik tanjant, sinüs, step, eşik değer fonksiyonları yaygın olarak kullanılan aktivasyon fonksiyonları arasında yer almaktadır [107].

KK'da gerçekleştirilen matematiksel işlemler sonucunda elde edilen çıktı, başlangıçta doğrusal bir yapıya sahiptir. Ancak, bu yapıya uygulanan aktivasyon katmanı aracılığıyla ağ doğrusal olmayan bir forma dönüştürülmekte ve bu sayede daha karmaşık örüntülerin öğrenilmesi

sağlanmaktadır. Bu yapı, öğrenme sürecini hızlandırmakla birlikte ağıın ifade gücünü de artırmaktadır. Söz konusu öğrenme sürecine ilişkin matematiksel ifade Eşitlik 6.2’de sunulmaktadır [112].

$$\text{conv}(I, K)_{xy} = \sigma\left(b + \sum_{i=1}^h \sum_{j=1}^w \sum_{k=1}^d K_{ij} \cdot I_{x+i-1, y+j-1, k}\right) \quad (6.2)$$


Eşitlik 6.2’de, Eşitlik 6.1’den farklı olarak d ifadesi yer almaktadır. Bu d değeri görüntünün boyutlarını ifade etmektedir. b değeri ise bias olarak tanımlanmaktadır ve isteğe bağlı olarak kullanılmaktadır. Ayrıca, σ terimi, aktivasyon fonksiyonunu olarak adlandırılmaktadır. Aktivasyon katmanı, konvolüsyon katmanından elde edilen negatif değerlerin pozitif değere dönüştürülmesi için kullanılmaktadır [112].

6.1.4 Havuzlama Katmanı (HK)

Havuzlama katmanı, verilerin daha küçük boyutlara indirgenmesini sağlayarak ağıın hesaplama yükünü azaltan ve işlem verimliliğini artıran önemli bir bileşendir. Genellikle aktivasyon katmanından sonra yer alan bu katman, yalnızca veri boyutunu küçültmekle kalmaz; aynı zamanda modelin öteleme ve küçük yapısal bozulmalara karşı daha dayanıklı hale gelmesine katkı sağlamaktadır. Ancak, bu işlem belirli düzeyde bilgi kaybına yol açabileceğinden, önemsiz ya da düşük öneme sahip verilerin elenmesi hedeflenirken, anlamlı bilgilerin korunması büyük önem taşımaktadır [117].

Havuzlama işlemi, modelin genel performansına iki temel açıdan katkı sağlamaktadır. Birincisi, sonraki katmanlara iletilen veri miktarının azalması hesaplama maliyetini düşürmekte ve eğitimi hızlandırmaktadır. İkincisi ise, gereksiz verilerin elimine edilmesi modelin aşırı öğrenme (overfitting) riskini azaltarak genelleme yeteneğini artırmaktadır. Bu katmanda veri küçültme amacıyla kullanılan farklı matris türleri Şekil 6.4’te gösterilmektedir. En yüksek, en düşük ve ortalama değerleri esas alan matrisler sırasıyla max pooling, min pooling ve average pooling yöntemleriyle ifade edilmektedir. Kare biçimine getirilen bu matrisler, aktivasyon katmanından elde edilen öznitelik haritaları üzerinde kaydırılarak yeni veri matrisleri oluşturmaktadır. Literatürde max pooling yöntemi, diğerlerine kıyasla daha iyi sonuçlar vermesi nedeniyle daha yaygın olarak tercih edilmektedir. Bununla birlikte, HK tüm ESA

mimarilerinde zorunlu bir bileşen değildir; bazı mimari tasarımlarda bu katmana yer verilmemekte ve işlem akışı doğrudan bir sonraki katmana aktarılmaktadır [115].




Şekil 6.4 Havuzlama Katmanı [115].

6.1.5 Tam Bağlantılı Katman (TBK)

Havuzlama veya alt örnekleme katmanının ardından gelen tam bağlantılı katman, önceki katmandan gelen veriye bağlı olarak işlem gerçekleştirmektedir. Şekil 6.5'te de gösterildiği üzere, bu katman; kendisinden önceki katmandaki tüm nöronlarla tam bağlantı kuran yapıyla öne çıkmaktadır. Bu aşamada, nesnenin hangi sınıfa ait olduğunun belirlenebilmesi için öne çıkan özniteliklerin ilgili sınıflarla olan ilişkileri analiz edilmektedir. Tam bağlantılı katman, yüksek seviyeli öznitelikler ile sınıf etiketleri arasındaki ilişki derecesine göre karar sürecini yönlendirmektedir. Bu bağlamda, nöronlardaki ağırlık değerleri incelenerek, verinin ait olduğu sınıf tahmin edilmektedir.


Bu katmandan elde edilen veriler, tek boyutlu bir vektör hâline getirilerek sonuç (çıkış) katmanına iletilmektedir. Örneğin, $16 \times 16 \times 100$ boyutuna sahip bir veri, 2048×1 boyutunda bir vektöre dönüştürüldüğünde, 25600×2048 boyutlarında bir ağırlık matrisi oluşturulmakta ve 2048 nöronun her biri 25.600 nöronla tam bağlantı kurmaktadır [107,115].



Şekil 6.5 Tam Bağlantı Katmanı [115].

6.1.6 Drop Out Katmanı


Büyük veri ile eğitilen derin öğrenme modellerinde, ağız eğitim verisini ezberlemesi (overfitting) yaygın bir problemdir. Bu sorunun önüne geçebilmek için, eğitim sürecinde bazı nöronların etkisinin geçici olarak devre dışı bırakılması amaçlanır. Bu işlemi gerçekleştiren yapı dropout katmanı olarak adlandırılmaktadır. ESA'dan farklı olarak bazı DÖ mimarilerinde, modelin genelleme yeteneğini artırmak amacıyla rastgele seçilen düğümler (nöronlar) eğitim sırasında devre dışı bırakılmaktadır. Böylece ağız belirli örüntüleri ezberlemesi engellenerek daha sağlam ve genellenebilir bir öğrenme elde edilmektedir. Bununla birlikte, bu yaklaşım öğrenme süresini bir miktar uzatabilmektedir [112,115]. Şekil 6.6'da, drop out katmanı içeren ve içermeyen iki farklı model mimarisi örnek olarak sunulmuştur.



Şekil 6.6 Derin Öğrenme Modelleri (A) Ezberleme Yapmış Derin Öğrenme Modeli (B) Ezberleme Katmanı Kullanılmış Derin Öğrenme Modeli [115].

6.1.7 Sınıflandırma Katmanı (SK)

Sınıflandırma katmanı (SK), TBK'dan sonra gelen ve DÖ mimarilerinde sınıflandırma görevini yerine getiren son katmandır. Bu katmanın çıkış boyutu, sınıflandırılacak sınıf sayısı kadar nöron içerecek şekilde belirlenmektedir. Örneğin, model 15 farklı nesneyi sınıflandıracak şekilde tasarlanmışsa, sınıflandırma katmanının çıkışında 15 nöron yer almaktadır. TBK'nın çıkış boyutunun 4096 olarak belirlendiği bir yapıda, SK ile TBK arasındaki bağlantılar için 4096×15 boyutunda bir ağırlık matrisi oluşturulmaktadır. Bu katmanda farklı sınıflandırıcılar kullanılabilmekle birlikte, genellikle softmax sınıflandırıcısı yüksek doğruluk oranları nedeniyle tercih edilmektedir. Şekil 6.7'de softmax fonksiyonunun grafiği sunulmaktadır. Burada sınıflandırma işlemi sırasında, her sınıf için 0 ile 1 arasında bir olasılık değeri üretilmekte ve bu değerlerin toplamı 1 olacak şekilde normalize edilmektedir. Çıkışlardan değeri 1'e en yakın olan nöron, modelin tahmin ettiği sınıfı temsil etmektedir [112].



Şekil 6.7 Softmax Fonksiyonu [111,118].

6.1.8 Yumuşatma Katmanı (YK)

Yumuşatma (softmax) katmanı, sınıflandırma problemlerinde çıktı katmanı olarak işlev görmektedir. Bu katman, kendisinden önceki tam bağlı katmandan aldığı çıktı değerlerini kullanarak her sınıf için normalize edilmiş olasılık değerleri üretmektedir. Bu olasılıklar, giriş verisinin ilgili sınıflara ait olma ihtimalini temsil etmekte olup, toplamaları bire eşit olacak şekilde hesaplanmaktadır. Eğitim sürecinde, modelin tahminleri ile gerçek etiketler arasındaki fark, çoğunlukla çapraz entropi kayıp fonksiyonu (cross-entropy loss) ile ölçülmektedir. Bu, modelin daha doğru sınıflandırmalar yapması için parametrelerin güncellenmesini sağlamaktadır [107].

6.1.9 Normalizasyon Katmanı (NK)

Normalizasyon katmanları, derin sinir ağlarının eğitimi sırasında, ağıın öğrenme sürecini hızlandırmak ve kararlılığını artırmak amacıyla kullanılmaktadır. Bu katmanlar, genellikle ReLU gibi aktivasyon fonksiyonlarından sonra uygulanmakta ve gizli katmanlardaki aktivasyonların belirli bir dağılımda kalmasını sağlamaktadır. Böylece, her katmandaki girişlerin çok büyük ya da çok küçük değerlere ulaşması engellenmektedir. Normalizasyon, modelin daha hızlı ve dengeli öğrenmesine yardımcı olurken, aynı zamanda eğitim süresini de kısaltmaktadır. Özellikle batch normalization gibi yöntemler, ağıın performansını artırmakta ve aşırı uyum riskini azaltmaktadır. Verilerin belirli bir aralıkta tutulması, hem eğitim sürecinin verimliliğini artırmakta hem de modelin genel doğruluk oranını iyileştirmektedir [107].

6.2 PERFORMANS DEĞERLENDİRME KRİTERLERİ

Sınıflandırma modellerinin başarısı, tahmin edilen sınıf etiketleri ile gerçek sınıf etiketleri arasındaki ilişkiye göre değerlendirilmektedir. Gerçek sınıf değeri pozitif olan bir verinin pozitif olarak sınıflandırılması doğru pozitif (DP) olarak adlandırılırken, negatif olarak sınıflandırılması yanlış negatif (YN) olarak tanımlanmaktadır. Diğer taraftan, gerçek sınıf değeri negatif olan bir verinin negatif olarak sınıflandırılması doğru negatif (DN) ve pozitif olarak sınıflandırılması yanlış pozitif (YP) olarak adlandırılmaktadır. Karmaşıklık matrisindeki bu değerler kullanılarak çeşitli performans ölçütleri hesaplanabilmektedir. Doğruluk, duyarlılık, özgüllük, keskinlik ve F1 skoru gibi metrikler en çok tercih edilen performans metrikleridir [119]. Bunlara ek olarak, ikili sınıflandırma problemlerinde veri dengesizliği söz konusu olduğunda, Matthews Korelasyon Katsayısı (MCC) da hesaplanmaktadır. Bu performans ölçütlerine ait matematiksel ifadeler sırasıyla Eşitlik 6.3-6.8'de sunulmuştur [120,121].

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \times 100 \quad (6.3)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \times 100 \quad (6.4)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \times 100 \quad (6.5)$$

$$Kesinlik = \frac{DP}{DP+YP} \times 100 \quad (6.6)$$

$$F1 \text{ skor} = 2 \times \frac{Duyarluluk \times Kesinlik}{Duyarluluk + Kesinlik} \quad (6.7)$$

$$MCC = \frac{DP \times DN - YP \times YN}{\sqrt{(DP+YP)(DP+YN)(DN+YP)(DN+YN)}} \quad (6.8)$$

Bahsi geçen parametreler, veri setinden elde edilen özelliklerin model performansı üzerindeki etkisinin değerlendirilmesine olanak tanımaktadır. Sınıflandırma algoritmalarının doğruluk düzeyini ölçmede en yaygın yöntemlerden biri karmaşıklık matrisidir (Confusion Matrix) [115]. Bu bağlamda, tez kapsamında elde edilen sınıflandırma sonuçlarının başarısı, karmaşıklık matrisi aracılığıyla analiz edilmiştir. Modelin çıktısının "KUSURLU" veya "KUSURSUZ" şeklinde ikili bir karar olması nedeniyle, 2x2 boyutunda bir matris oluşturulmuş ve bu matris Çizelge 6.1'de sunulmuştur.

Çizelge 6.1 Karmaşıklık Matrisi.

		Gerçek Sınıf	
		Pozitif	Negatif
Tahmin Edilen Sınıf	Pozitif	DP (Doğru Pozitif)	YN (Yanlış Negatif)
	Negatif	YP (Yanlış Pozitif)	DN (Doğru Negatif)

Modelin performansını değerlendirmek amacıyla kullanılan dört temel sınıflandırma durumu bulunmaktadır. Gerçek sınıfın kusurlu seramik olduğu ve modelin de bunu doğru şekilde kusurlu olarak tahmin ettiği durumlar doğru pozitif (DP), gerçek sınıfın kusursuz seramik olduğu ve modelin de bunu doğru şekilde kusursuz olarak tahmin ettiği durumlar ise doğru negatif (DN) olarak tanımlanır. Bunun yanında, gerçek sınıf kusurlu seramik olmasına rağmen modelin bunu kusursuz olarak tahmin etmesi yanlış negatif (YN), gerçek sınıf kusursuz olmasına rağmen modelin bunu kusurlu olarak tahmin etmesi ise yanlış pozitif (YP) olarak adlandırılmaktadır. Bu dört temel durumdan yola çıkarak oluşturulan değerlendirme kriterleri Çizelge 6.2'de sunulmuştur.

Çizelge 6.2 Model Değerlendirme Kriterleri.

Değerlendirme Kriteri	Açıklama	Formül
Doğruluk Oranı	Oluşturulan modelin hedef sınıfları tahmin başarısı.	$\frac{(DP + DN)}{N}$
Kesinlik (Precision)	Oluşturulan modelde sonucun ne kadar doğru olduğunu gösterir.	$\frac{DP}{(DP + YP)}$
Duyarlılık (Recall)	Oluşturulan modelde doğru örnekleri bulma yeteneğini gösterir.	$\frac{DP}{(DP + YN)}$
Özgüllük (Specificity)	Modelin negatif sınıfları doğru bir şekilde tanımlayabilme yeteneğini gösterir.	$\frac{DN}{(DN + YP)}$
MCC (Matthews Correlation Coefficient)	Sınıflandırma performansını pozitif ve negatif sınıflar arasındaki dengeyi de dikkate alarak ölçen bir metriktir. -1 ile +1 arasında değer alır.	$\frac{(DP \times DN) - (YP \times YN)}{\sqrt{(DP + YP) \times (DP + YN) \times (DN + YP) \times (DN + YN)}}$
F1-Skore (F1 Score)	Kesinlik ve duyarlılığın harmonik ortalamasıdır.	$\frac{2 \times (Kesinlik \times Duyarlılık)}{(Kesinlik + Duyarlılık)}$

6.3 HATA ÖLÇÜM KRİTERLERİ

DÖ tabanlı modellerinde, üretilen çıktıların hedeflenen değerlere olan yakınlığı, model başarımının değerlendirilmesinde temel bir ölçüt olarak kabul edilmektedir. Beklenen çıktılar ile modelin hesapladığı değerler arasındaki fark, modelin sınıflandırma doğruluğundan ne derece sapma gösterdiğini ortaya koymaktadır. Hata hesaplamasına geçilmeden önce, çıktı katmanında elde edilen değerlerin uygun şekilde normalleştirilmesi gerekmektedir. Bu işlemin ardından, normalleştirilmiş çıktılar belirlenen hata hesaplama fonksiyonuna yönlendirilerek modelin performansı nicel olarak değerlendirilmektedir. Bu bağlamda, ikili sınıflandırma problemlerinde yaygın olarak sigmoid aktivasyon fonksiyonu, çok sınıflı sınıflandırma problemlerinde ise softmax fonksiyonu tercih edilmektedir [122]. Hata (maliyet) fonksiyonu olarak ise Categorical Crossentropy (CCE), Sparse Categorical Crossentropy (SCCE), Binary Crossentropy (BCE), Focal Loss (FL), Kullback-Leibler Divergence (KL), Hinge Loss (HL) gibi yöntemlerden biri tercih edilebilmektedir [123].

6.4 DERİN ÖĞRENME MODELLERİNDE ALGORİTMA BAŞARIMINI ETKİLEYEN PARAMETRELER

6.4.1 Batch Boyutu

Bir sinir ağının görüntüleri doğru şekilde sınıflandırabilmesi için çeşitli hiperparametrelerin uygun şekilde ayarlanması gerekmektedir. Eğitim süreci başlamadan önce belirlenmesi gereken temel hiperparametrelerden biri, gradyan tahmini sırasında kullanılacak veri miktarını belirleyen batch boyutudur. Literatürde, batch boyutunun model performansı üzerindeki etkisini inceleyen çalışmalar, küçük ve büyük batch boyutlarının doğruluk oranı ile yakınsama süreci açısından farklı avantajlar ve sınırlılıklar sunduğunu ortaya koymaktadır. Küçük batch boyutları genellikle daha hızlı yakınsama sağlayabilmekte; ancak öğrenme sürecinde yüksek varyansa neden olarak model üzerinde düzenleyici bir etki yaratabilmektedir. Buna karşın, büyük batch boyutlarının daha düşük hata oranları ile daha optimal çözümlere ulaşma potansiyeline sahip olduğu, ancak yakınsama sürecinin daha yavaş gerçekleşebileceği bildirilmektedir. Ayrıca, küçük batch boyutları ile stabil bir öğrenme elde edebilmek için genellikle daha düşük bir öğrenme oranına ihtiyaç duyulduğu ortaya koyulmuştur [124,125].

Batch boyutunun derin öğrenme modellerinin performansı üzerindeki etkisini sistematik olarak inceleyen Radiuk [126], bu parametrenin Konvolüsyonel Sinir Ağları (Convolutional Neural Networks, CNN) üzerindeki etkilerini MNIST ve CIFAR-10 veri setleri aracılığıyla deneysel olarak analiz etmiştir. Çalışmada, farklı *batch* boyutlarının modelin öğrenme dinamikleri ve nihai performansı üzerindeki etkilerinin kapsamlı biçimde ortaya konulması hedeflenmiştir. Çalışmada, 16'dan 1024'e kadar 2'nin kuvvetleri şeklinde artan batch boyutlarının yanı sıra 50, 100, 150, 200 ve 250 gibi ara değerler de test edilerek geniş bir parametre aralığı incelenmiştir. Deneylerde MNIST veri seti için LeNet mimarisi, CIFAR-10 veri seti içinse beş katmanlı özel bir CNN yapısı kullanılmıştır. Her iki modelde de optimizasyon için Stokastik Gradyan İnişi (Stochastic Gradient Descent, SGD) algoritması tercih edilmiş olup, öğrenme oranları sırasıyla 0.001 ve 0.0001 olarak belirlenmiştir. Elde edilen sonuçlar, batch boyutunun model performansı üzerinde istatistiksel olarak anlamlı bir etkiye sahip olduğunu ortaya koymuştur. Deneysel bulgular, özellikle 1024 gibi büyük batch boyutlarının daha yüksek sınıflandırma doğruluğu sağladığını, buna karşılık 16 gibi küçük batch boyutlarının ise nispeten düşük performans gösterdiğini kanıtlamıştır. Bu sonuçlar, büyük batch boyutlarının gradyan tahminlerindeki varyansı azaltarak optimizasyon sürecini daha kararlı hâle getirdiğini doğrulamaktadır [126].

Benzer şekilde, Bengio 32'lik batch boyutunun çoğu durumda uygun bir varsayılan değer olarak kullanılabileceğini belirtmiştir [127]. Büyük batch boyutlarının hesaplama sürecini hızlandırabileceğini ve yakınsama için gerekli güncelleme sayısını azaltabileceğini ifade eden çalışmada, batch boyutunun doğruluk oranından ziyade öğrenme sürecinin yakınsama davranışı üzerinde daha belirgin etkiler gösterebileceği vurgulanmıştır [125]. Masters ve Luschi [128] de momentumun etkisini hariç tutmak amacıyla SGD optimizasyon yöntemi ile AlexNet [46] ve ResNet [129] mimarileri üzerinde 2'den 211'e kadar farklı batch boyutlarının etkisini ele almışlardır. Üç farklı veri seti üzerinde gerçekleştirilen analizlerde, en yüksek başarımın 2 ila 32 arasındaki batch boyutlarında elde edildiği ve küçük batch boyutlarının büyük batch boyutlarına göre daha dayanıklı olduğu ortaya konulmuştur [125].

Sonuç olarak, batch boyutu seçimi, veri setinin özellikleri, model karmaşıklığı ve hesaplama kaynakları gibi faktörler dikkate alınarak yapılması gereken stratejik bir karardır.

6.4.2 Eğitim Turu (Epoch-Epok) Sayısı

Eğitim turu (Epoch-Epok) sayısı, bir öğrenme algoritmasının eğitim veri seti üzerinde kaç kez çalıştırılacağını belirleyen temel hiper parametrelerden biridir. Eğitim sürecinde önemli bir rol oynayan bu parametre, fonksiyonun performansını doğrudan etkileyebilmektedir. Epok, tüm eğitim verisinin sinir ağına sunulması ve bu süreçte ağı ağırlıkları ile yanlışlıklarının güncellenmesini ifade etmektedir. Eğitim verileri modele bireysel olarak veya belirli batch boyutlarında aktarılabilmektedir [130].

Modelin etkili biçimde öğrenebilmesi için epok sayısının uygun şekilde belirlenmesi gerekmektedir. Epok sayısının yetersiz olması durumunda model öğrenmeyi tamamlayamazken, aşırı yüksek epok sayıları, eğitim verisine fazlasıyla uyum sağlanmasına ve dolayısıyla aşırı öğrenme (overfitting) problemine yol açabilmektedir. Bu durumda modelin yeni veriler üzerindeki genelleme kapasitesi zayıflamakta ve test performansı düşebilmektedir [131].

Bir epok süresince model, eğitim veri setindeki tüm örnekleri en az bir kez işleyerek parametrelerini güncelleştirmektedir. Epok, bir veya daha fazla *batch*'ten oluşacak şekilde yapılandırılabilir. Eğitim süreci boyunca dış döngü epok sayısını kontrol ederken, iç döngü belirlenen *batch* boyutuna göre verileri işlemektedir [131].

Genellikle epok sayısı, model hatası yeterince minimize edilene kadar yüksek tutulmaktadır. Uygulamalarda bu parametre 10, 100, 500 veya 1000 gibi çeşitli değerlerde ayarlanabilmektedir. Epok sayısının model üzerindeki etkilerini değerlendirmek amacıyla, öğrenme eğrileri sıkça kullanılmaktadır. Bu grafiklerde yatay eksen epok sayısı, dikey eksen ise model hatası veya performans metriği yer almakta olup; öğrenmenin yetersiz, aşırı ya da dengeli olup olmadığını analiz etmekte önemli bir araç olarak kullanılmaktadır [131].

6.4.3 Optimizasyon

Öğrenme tabanlı modellerde, parametrelerin doğru biçimde güncellenmesi öğrenme sürecinin başarısı açısından kritik bir rol oynamaktadır. YSA'da bu güncellemeler, her bir örneğin model tarafından işlenmesinden sonra elde edilen hataya bağlı olarak gerçekleştirilmektedir. Bu amaçla en yaygın kullanılan yöntemlerden biri Geri Yayılım (Backpropagation) algoritmasıdır [112]. Söz konusu algoritma, sinir ağındaki her bir ağırlığın toplam hata üzerindeki etkisini belirleyerek, bu ağırlıkların uygun şekilde güncellenmesini sağlamaktadır. Bu süreçte genellikle gradyan tabanlı optimizasyon tekniklerinden yararlanılmaktadır [122].


Gradyan temelli yaklaşımların yaygın kullanımıyla birlikte, DÖ modellerinde öğrenme sürecini daha etkili hâle getirmek amacıyla çeşitli stratejiler geliştirilmiştir. Bu stratejiler arasında, ağ mimarisinin derinleştirilmesi, hiperparametre optimizasyonu, gelişmiş veri temsili tekniklerinin uygulanması ve uygun optimizasyon algoritmalarının seçimi yer almaktadır. Ancak, DÖ modelleri için evrensel olarak kabul görmüş sabit bir tasarım kılavuzu bulunmamaktadır. Optimizasyon algoritmalarının temel amacı, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkı minimize eden bir hedef fonksiyonunu (genellikle kayıp fonksiyonu) en aza indirmektir. Bu süreç; sınıflandırma, regresyon veya kümeleme gibi farklı görevlerde, en uygun mimari ve öğrenme parametrelerinin belirlenmesini içermektedir.

Literatürde yapılan çalışmalara bakıldığında birçok optimizasyon algoritmasının kullanıldığı görülmektedir. Bu algoritmaların büyük bir kısmı gradyan inişi yöntemine dayanmaktadır. Gradyan inişi teknikleri, özellikle hata geri yayılımı yöntemi ile birlikte kullanılarak, ağırlıkların güncelleyerek hata oranını düşürmeyi amaçlamaktadır. DÖ temelli uygulamalarda en yaygın kullanılan optimizasyon algoritmalarından biri Uyarlanabilir Moment Tahmini (Adam) algoritmasıdır [132,133].

Bu doğrultuda, yalnızca derin öğrenme modellerinde değil, genel makine öğrenmesi uygulamalarında da yaygın olarak kullanılan altı temel gradyan tabanlı optimizasyon algoritması bulunmaktadır: Stokastik Gradyan Azaltma (SGD), Momentum, Adagrad, RMSProp (Kök Ortalama Kare İlerleme), Adadelta ve Adam. Bu algoritmaların temel özellikleri Çizelge 6.3'te karşılaştırmalı olarak sunulmakta; tarihsel gelişim süreçleri ise Şekil 6.8'de görselleştirilmektedir [133,134].

Çizelge 6.3 Farklı Gradyan Azaltma Tekniklerinin Özelliklerinin Karşılaştırılması [133,134].

Yöntem	Tarih	Öğrenme Katsayısı	Eğim
SGD	1951	+	+
Momentum	1964		+
AdaGrad	2011	+	
RMSprop	2012	+	
Adadelta	2012	+	
Adam	2014	+	+



Şekil 6.8 Gradyan Azaltma Yöntemlerinin Gelişim Sürecini Gösteren Harita [134].

Adam optimizasyon algoritması, literatürde yaygın olarak kullanılan ve gradyan temelli optimizasyon yöntemlerinden biri olup, Momentum ve RMSProp tekniklerinin avantajlarını birleştirerek geliştirilmiştir. Bu algoritma, Momentum yönteminde kullanılan moment bileşeni ile RMSProp yöntemindeki adaptif öğrenme oranı yaklaşımını bir araya getirerek daha dengeli ve verimli bir öğrenme süreci sunmaktadır [134–140]. Adam algoritmasına ait güncelleme kuralları ve matematiksel ifadeler sırasıyla Eşitlik 6.9–6.13’de sunulmaktadır.

$$w_{t+1} = w_t - \frac{a}{\sqrt{\hat{S}_t + \epsilon}} \cdot \hat{V}_t \quad (6.9)$$

$$\widehat{V}_t = \frac{V_t}{1-\beta_1^t} \quad (6.10)$$

$$\widehat{S}_t = \frac{S_t}{1-\beta_2^t} \quad (6.11)$$

$$V_t = \beta_1 V_{t-1} + (1 - \beta_1) \frac{\partial L}{\partial w_t} \quad (6.12)$$

$$S_t = \beta_2 S_{t-1} + (1 - \beta_2) \left(\frac{\partial L}{\partial w_t} \right)^2 \quad (6.13)$$

Burada, başlangıç değerleri olarak S ve V için 0, a için 0.001, β_1 için 0.9, β_2 için 0.999 ve ϵ için 10^{-8} seçilmiştir [134-140]. Yukarıda verilen denklemlerde, w_t , t . iterasyondaki ağırlık parametresini, a ise öğrenme oranını vermektedir. Bu oran modelin ne kadar büyük adımlarla güncelleneceğini belirlemektedir. Bununla birlikte, V_t , gradyanın üstel hareketli ortalamasını (momentum bileşeni), S_t , gradyanın karesinin üstel hareketli ortalamasını (RMSProp bileşeni), $\widehat{V}_t$, V_t değerinin bias düzeltilmiş halini, $\widehat{S}_t$ ise S_t değerinin bias düzeltilmiş halini ifade etmektedir. β_1 , β_2 , ϵ ise sırasıyla momentum terimi için üstel ağırlık katsayısı, RMSProp terimi için üstel ağırlık katsayısı ve sayısal kararlılığı sağlamak için küçük bir değer olarak tanımlanmaktadır. $\frac{\partial L}{\partial w_t}$ ise kayıp fonksiyonunun w_t ağırlığına göre türevini (gradyan değeri) ifade etmektedir.

6.4.4. Öğrenme Oranı

Geri yayılım algoritması, sunduğu esneklik ve sağlamlık sayesinde sinir ağlarının eğitimi ve sınıflandırma süreçlerinde yaygın olarak kullanılmaktadır. Çeşitli gerçek dünya problemlerinde başarıyla uygulanmış olan bu algoritma, modelin hata oranını azaltarak daha doğru tahminler üretilmesini mümkün kılmaktadır [141]. Algoritma kapsamında, her yinelemede hata gradyanı hesaplanmakta ve buna bağlı olarak ağ ağırlıkları güncellenmektedir. Ağırlık güncellemelerinin büyüklüğü, öğrenme oranı ile çarpılarak belirlenmekte olup bu oran, öğrenme sürecinin hızı ve doğruluğu açısından kritik bir rol oynamaktadır.

Düşük öğrenme oranı, ağırlık güncellemelerinin yavaş ilerlemesine neden olarak öğrenme sürecini uzatabilirken; yüksek bir öğrenme oranı daha hızlı güncellemeler sağlayarak hata fonksiyonundaki

düşüşü hızlandırabilir. Ancak, öğrenme oranının çok yüksek olması durumunda model, hata fonksiyonunun minimum noktasına düzenli şekilde yakınsamak yerine, bu noktayı atlayarak istikrarsız bir öğrenme süreci sergileyebilir. Buna karşılık, çok düşük değerler seçildiğinde modelin global minimuma ulaşması uzun sürebilir ve bu da eğitim sürecini verimsiz hâle getirebilir [142-144]. Bu bağlamda, öğrenme oranı modelin hata minimizasyonu performansını doğrudan etkileyen temel bir hiper parametre olarak öne çıkmaktadır.

Geri yayılım algoritması, gradyan inişi yöntemiyle hata fonksiyonunu minimize etmeye yönelik olarak, her iterasyonda küçük adımlarla aşağı yönlü ilerleme sağlamaktadır. Bu süreçte iyi tanımlanmış bir eğitim ve doğrulama protokolünün varlığı, modelin genelleme performansı açısından büyük önem taşımaktadır. Söz konusu protokol, denetimli öğrenme çerçevesinde uygulanmakta olup, özellikle büyük ölçekli veri kümeleriyle çalışırken öğrenme oranının doğru biçimde belirlenmemesi, modelin genelleme kapasitesini olumsuz etkileyebilmektedir [143].

Ayrıca, ağ yapısında aşırı sayıda nöronun bulunması ya da hesaplama yükünün giriş vektörünün boyutunu aşması durumunda benzer öğrenme problemleri ortaya çıkabilmektedir. Eğitim verisinin miktarı da modelin performansını etkileyen bir diğer önemli unsurdur; aşırı veri kullanımı bazı durumlarda genelleme kapasitesini artırırken, bazı durumlarda ise modelin aşırı öğrenme eğilimi göstermesine yol açabilmektedir [142].

6.4.5 Düzenleştirme

DÖ temelli modellerinde aşırı problemini önlemek amacıyla çeşitli düzenleştirme teknikleri yaygın olarak kullanılmaktadır. Bunlar arasında en etkili yöntemler L1/L2 norm tabanlı düzenleştirme ve dropout (seyreltme) teknikleridir. L1 düzenleştirme (Lasso), ağırlık vektörlerinin mutlak değerlerinin toplamını kayıp fonksiyonuna ekleyerek seyrek çözümler üretme eğilimindedir. L2 düzenleştirme (Ridge) ise ağırlık vektörlerinin karelerinin toplamını kullanmakta ve parametreleri daha küçük değerlere çekerek yumuşak bir sınırlama sağlamaktadır. Her iki yöntemde de λ düzenleştirme katsayısı, model karmaşıklığı ile veri uyumu arasındaki dengeyi kontrol etmektedir. Uygun λ değerinin seçimi kritik öneme sahiptir, çok yüksek değerler modelin basit kalmasına (underfitting), çok düşük değerler ise aşırı öğrenmeye (overfitting) yol açabilmektedir [122].

Dropout tekniđi ise daha radikal bir yaklaşıml sunarak, eğitim sırasında her iterasyonda rastgele seçilen nöronları geçici olarak devre dışı bırakmaktadır. Bu yöntem, modelin belirli nöronlara aşırı bağımlılık geliştirmesini engelleyerek daha sağlam özellikler öğrenmesini sağlamaktadır. Dropout uygulanan nöronlar, hem ileri yayılım hem de geri yayılım aşamalarında hesaba katılmaz, böylece model farklı alt ağ kombinasyonları öğrenebilmektedir [145]. Deneysel sonuçlar, dropout'un özellikle büyük ölçekli derin ağlarda genelleme performansını önemli ölçüde iyileştirdiğini göstermektedir [122]. Bu düzenleme teknikleri, tek başlarına veya kombinasyon halinde kullanılarak derin öğrenme modellerinin genelleme yeteneğini artırmada etkili bir şekilde uygulanabilmektedir.

6.4.6 Aktivasyon Fonksiyonları

Sinir ağı mimarilerinde, doğrusal matris işlemleri sonucu oluşan yapıların doğrusal olmayan bir forma dönüştürülmesi, modelin karmaşık ilişkileri öğrenebilmesi açısından kritik öneme sahiptir. Bu dönüşüm, aktivasyon fonksiyonları aracılığıyla gerçekleştirilmekte ve öğrenme sürecinin temel bileşenlerinden biri olarak değerlendirilmektedir [112]. Aktivasyon fonksiyonları yalnızca doğrusal olmayanlık kazandırmakla kalmaz, aynı zamanda ağ bileşenlerinin türevlenebilirliğini artırarak optimizasyon sürecini kolaylaştırır. Hesaplama hızını artırmak ve öğrenme sürecini verimli hâle getirmek amacıyla, türevi kolay alınabilen fonksiyonların tercih edilmesi büyük önem taşımaktadır. Literatürde yaygın olarak kullanılan aktivasyon fonksiyonlarına ilişkin bilgiler Çizelge 6.4'te sunulmaktadır [122].

Kullanılan aktivasyon fonksiyonları, öğrenme sürecinde modelin performansını doğrudan etkileyen avantaj ve sınırlılıklara sahiptir. Bu fonksiyonlardan Sigmoid, özellikle sınıflandırma problemlerinde yaygın olarak tercih edilmekte olup, girdileri 0 ile 1 aralığına dönüştürmektedir. Ancak, derin yapılarla birlikte kullanıldığında türev değerlerinin sıfıra yaklaşmasına neden olan kaybolan gradyan (vanishing gradient) problemine yol açabilmektedir. Diğer yandan, tanjant hiperbolik (tanh) fonksiyonu çıktıları -1 ile 1 aralığında üretmek sıfır merkezli bir dağılım sağlamaktadır. Bu özelliđi, gradyanların daha dengeli yayılmasına katkı sunmakta ve optimizasyon sürecini kısmen kolaylaştırmaktadır. Bununla birlikte, bu fonksiyon da derin ağlarda kaybolan gradyan sorununu tam olarak ortadan kaldıramamaktadır.


Bu sınırlamaların üstesinden gelmek amacıyla geliştirilen Düzleştirilmiş Doğrusal Birim (Rectified Linear Unit, ReLU) fonksiyonu, negatif girişleri sıfıra eşitleyip pozitif girişleri doğrudan geçirerek hesaplama açısından verimli bir yapı sunar. Ayrıca, kaybolan gradyan problemine karşı görece daha dayanıklı olmasıyla dikkat çeker. Ancak ReLU, negatif girişleri tamamen sıfırlaması nedeniyle bazı nöronların kalıcı olarak devre dışı kalmasına yol açan ölü ReLU problemine neden olabilmektedir. Bu duruma çözüm olarak önerilen Leaky ReLU fonksiyonunda, negatif değerler için sabit ve küçük bir eğim tanımlanarak bu değerlerin tamamen sıfırlanması önlenmektedir. Negatif eğimin sabit değil, öğrenilebilir bir parametre olarak modellenmesi durumunda ise fonksiyon Parametrik ReLU (PReLU) adını almaktadır [122,146,147].

Çizelge 6.4 Aktivasyon Fonksiyonları

	Fonksiyon Türü	Matematiksel ifade	Fonksiyon Grafiği
1	Sigmoid	$y = \frac{1}{1 + e^{-Net}}$	Sigmoid Fonksiyonunun Grafiği: Çıktı (y) 0.0 ile 1.0 arasında, Net Girdi (x) -10.0 ile 10.0 arasında değişir. Fonksiyon, -10.0'da 0.0'a yakın, 0.0'da 0.5'e, 10.0'da 1.0'a yaklaşır.
2	Tanjant Hiperbolik	$y = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}}$	tanh Fonksiyonunun Grafiği: Çıktı (y) -1.00 ile 1.00 arasında, Net Girdi (x) -10.0 ile 10.0 arasında değişir. Fonksiyon, -10.0'da -1.00'a yakın, 0.0'da 0.0'a, 10.0'da 1.00'a yaklaşır.
3	ReLU	$y = \max(0, Net)$	ReLU Fonksiyonunun Grafiği: Çıktı (y) 0 ile 10 arasında, Net Girdi (x) -10.0 ile 10.0 arasında değişir. Fonksiyon, -10.0'dan 0.0'a kadar 0'dır, 0.0'dan itibaren 1:1 oranında artar.
4	Leaky-ReLU	$y = \begin{cases} Net, & \text{eğer } Net > 0 \\ \alpha \cdot Net, & \text{eğer } Net \leq 0 \end{cases}$	Leaky ReLU Fonksiyonunun Grafiği: Çıktı (y) -2 ile 10 arasında, Net Girdi (x) -10.0 ile 10.0 arasında değişir. Fonksiyon, -10.0'da -2'dir, 0.0'da 0'a, 10.0'da 10'a ulaşır.


6.5 RESNET AĞI

ResNet, ESA mimarisine çeşitli iyileştirmeler getirilerek geliştirilmiş bir DÖ modelidir. Bu model, artık bağlantılar (skip connections) mekanizması sayesinde geleneksel ESA'lara göre çok daha derin yapıların kararlı biçimde eğitilmesini sağlamakta, gradyan kaybı (vanishing gradient) gibi optimizasyon problemlerini minimize etmekte ve parametre verimliliğini artırarak daha yüksek sınıflandırma doğruluğu elde edilmesine katkıda bulunmaktadır. Şekil 6.9'da, örnek bir ResNet mimarisine ait blok diyagram sunulmaktadır [47].




Şekil 6.9 Modele Ait Blok Diyagramı.

Microsoft tarafından geliştirilen bu mimari, doğrusal bir katman ve iki ReLU aktivasyon fonksiyonundan oluşan, kalıntı bilgisi (residual value) beslemesiyle çalışan özel bir modül olan residual block yapısını temel almaktadır. Bu yapı, öğrenme sürecinin hem daha hızlı hem de daha verimli gerçekleşmesini hedeflemektedir [129]. Şekil 6.10'da söz konusu modülün yapısı ayrıntılı olarak gösterilmektedir [148-149].



Şekil 6.10 ReLU Blok Yapısı [149,150].

Bu bloklarda, giriş verisi (x) konvolüsyon dizisinden (ReLU) geçirilerek bir çıktı ($F(x)$) elde edilmekte ve bu çıktı, orijinal girişle toplanarak blok çıkışı ($H(x) = F(x) + x$) oluşturulmaktadır [112]. Elde edilen bu değer, sonraki katmana giriş olarak iletilmekte, böylece modelin eğitimi daha etkin bir şekilde gerçekleşmektedir. Ağın daha kararlı çalışmasını sağlamak amacıyla batch normalization uygulanmakta; bu düzenleyici mekanizma, gradyan kaybı probleminin önüne geçerek modelin istikrarlı bir şekilde öğrenmesini desteklemektedir. Aynı zamanda, eğitim süresinin kısalmasına ve genel performansın artmasına katkıda bulunmaktadır. Son sınıflandırma katmanından önce uygulanan küresel ortalama havuzlama işlemiyle, önceki katmandaki özellik haritalarının ortalama çıktısı hesaplanmakta ve veri boyutu azaltılarak model, sınıflandırma aşamasına daha uygun hâle getirilmektedir [47]. Literatürde 50 katmanlı yapısıyla bilinen ResNet-50 mimarisi, yardımcı katmanlar ve bileşenlerle birlikte toplamda 177 katmandan oluşan derin bir ağ yapısına sahiptir [104,126]. Bu yapının ilk 34 katmanına ait mimari detaylar Şekil 6.11’de sunulmaktadır [129,150].



Şekil 6.11 ResNet-50 Mimarisi ilk 34 Katman [129,150].

ResNet-50, 2015 yılında düzenlenen ILSVRC ImageNet yarışmasında %3.6'lık hata oranı ile birincilik elde etmiş ve bu başarısıyla o dönemdeki görsel sınıflandırma sistemleri arasında en yüksek doğruluk seviyelerinden birine ulaşmıştır [150]. Görsel tanıma görevlerinde yaygın olarak kabul edilen referans hata oranlarının %5 ila %10 arasında değiştiği göz önünde bulundurulduğunda, elde edilen sonuç modelin üstün sınıflandırma performansını ortaya koymaktadır. Ayrıca, önceki derin öğrenme mimarilerine kıyasla daha fazla katman içeren ResNet, mimari derinlik açısından birçok yapıyı geride bırakmıştır [151]. Bu bağlamda,

ResNet-50'nin yanı sıra farklı DÖ algoritmalarına ait geliştirilme yılları, parametre sayıları ve hata oranlarına ilişkin karşılaştırmalı veriler Çizelge 6.5'te sunulmaktadır [150].

Çizelge 6.5 DÖ Algoritmaları [150].

Derin Öğrenme Algoritması	Yıl	Geliştirici	Hata Oranı	Parametre Sayısı
LeNet	1998	Yann LeCun ve ark.	-	60 bin
AlexNet	2012	Alex Krizhevsky, Geoffrey Hinton, Ilya Sutskever	%15.3	60 Mil.
ZFNet	2013	Matthew Zeiler ve Rob Fergus	%14.8	62 Mil.
GoogleNet	2014	Google	%6.67	4 Mil.
VGG Net	2014	Simonyan, Zisserman	%7.3	138 Mil.
ResNet	2015	Kaiming He	%3.6	60 Mil (Yaklaşık)

6.6 KULLANILAN DERİN ÖĞRENME KÜTÜPHANELERİ


Günümüzde DÖ uygulamalarının geliştirilmesinde TensorFlow, PyTorch, Keras gibi açık kaynaklı kütüphaneler yaygın olarak kullanılmaktadır. Bu kütüphaneler, karmaşık sinir ağı modellerinin tasarımı ve eğitimi süreçlerini büyük ölçüde kolaylaştırmaktadır. Ancak uygulamada, veri ön işleme, model optimizasyonu ve sonuçların görselleştirilmesi gibi farklı aşamalarda çeşitli uzmanlık alanlarına hitap eden birden fazla kütüphanenin entegre bir şekilde kullanılması gerekmektedir [111,152]. Bu yaklaşım, her bir kütüphanenin güçlü yönlerinden maksimum düzeyde faydalanmayı mümkün kılmakta ve projelerin verimliliğini artırmaktadır.

6.6.1 TensorFlow

TensorFlow, DÖ uygulamalarının geliştirilmesine yönelik kapsamlı ve esnek bir yazılım altyapısı sunan açık kaynaklı bir kütüphanedir [111]. Google Brain ekibi tarafından geliştirilen TensorFlow, farklı programlama dilleri, donanım platformları ve çalışma ortamlarında çalışabilme esnekliğine sahiptir. Yapısal olarak veri akış grafikleri temelinde tasarlanmış olup, hesaplamalar bu grafikler üzerinden gerçekleştirilmektedir. Bu sayede düğüm durumları izlenebilir, güncellenebilir ve dallanma ya da döngü kontrolü içeren veri akışı hesaplamaları uygulanabilmektedir [153].

Kütüphane; otomatik türev hesaplama, parametre paylaşımı ve paralel yürütme gibi özellikleriyle farklı DÖ mimarilerini desteklemektedir. Veri akış grafiği modelinin paralel

olarak çalıştırılabilmesi, çoklu hesaplama kaynaklarının etkin kullanımına olanak tanımakta ve bu durum performans artışı sağlamaktadır [111]. Ayrıca, düşük donanım kapasitelerine sahip cihazlarda kullanılmak üzere optimize edilmiş bir çıkarım sürümü geliştirilmiş olup, mobil ve Nesnelerin İnterneti (Internet of Things, IoT) uygulamaları için verimli çözümler sunmaktadır. TensorFlow'un Google ve Amazon gibi bulut tabanlı platformlarla uyumlu çalışması sayesinde, modellerin oluşturulması, eğitilmesi ve test edilmesi bulut ortamlarında da gerçekleştirilebilmektedir. TensorFlow'un mimari katmanlarına ilişkin şematik gösterim Şekil 6.12'de sunulmaktadır.



Şekil 6.12 Tensorflow Mimarisi Katmanları.

6.6.2 Keras

Keras, Python programlama dili ile geliştirilmiş, DÖ modellerinin tasarımı, eğitimi ve testinde kullanılan yüksek seviyeli bir kütüphanedir [154]. Kullanıcı dostu yapısı ve sadeleştirilmiş araçları sayesinde, DÖ temelli uygulamalarının geliştirilmesini kolaylaştırmaktadır. TensorFlow ve Theano gibi altyapılar üzerinde çalışarak, üst düzey bir uygulama programlama arayüzü (Application Programming Interface, API) sunmakta ve DÖ modellerini daha erişilebilir hâle getirmektedir. Kod değişikliği gerektirmeksizin hem merkezi işlem birimi (Central Processing Unit, CPU) hem de GPU üzerinde çalışabilmesi, Keras'a önemli bir esneklik kazandırmaktadır. Ayrıca, hızlı prototipleme süreçlerini destekleyen kapsamlı API'lerin yanı sıra, ESA, yinelemeli sinir ağları (Recurrent Neural Network, RNN) ve bu yapıların birleşimine yönelik önceden tanımlı bileşenler de kütüphane bünyesinde sunulmaktadır [111].

6.6.3 Torch

Torch, derin öğrenme ve makine öğrenimi algoritmalarına destek sağlayan bir hesaplama kütüphanesidir. Hem CPU hem de GPU üzerinde çalışabilme yeteneğine sahip olan bu kütüphane, Facebook, Twitter ve Google gibi önde gelen teknoloji şirketleri tarafından desteklenmiştir. Konuşma ve görüntü işleme, video analizi, denetimli ve denetimsiz öğrenme, pekiştirmeli öğrenme, sinir ağları, optimizasyon ve grafik modeller gibi çeşitli uygulama alanlarında yaygın olarak kullanılmıştır. Torch'un geliştirme süreci, son sürümü olan Torch7 ile birlikte sonlandırılmıştır [111].

6.6.4 PyTorch

PyTorch kütüphanesi, Python tabanlı bir DÖ çerçevesi olup, sunduğu esnek API aracılığıyla karmaşık modellerin kolaylıkla oluşturulmasına olanak tanımaktadır. Statik hesaplama grafikleri kullanan çerçevelerden farklı olarak dinamik hesaplama grafikleri ile çalışması, özellikle değişken yapıya sahip mimarilerin geliştirilmesinde önemli bir avantaj sağlamaktadır [155]. Farklı kütüphanelerle entegrasyon yeteneği ve GPU'ya özel bellek ayırıcıları sayesinde, bellek kullanımı optimize edilerek büyük ölçekli modellerin verimli bir şekilde eğitilmesi mümkün hâle gelmektedir. PyTorch, hem küçük hem de büyük ölçekli sinir ağı modellerinde yüksek performans sunmaktadır.

BÖLÜM 7

HOGS İLE TESPİT EDİLEN SERAMİK YÜZEY KUSURLARININ YENİDEN YAPILANDIRMA YÖNTEMLERİ İLE GERİ ELDE EDİLMESİ

Bu tez çalışmasında seramik yüzey kusurlarının tespit edilmesi için HOGS sisteminden yararlanılmıştır. Bölüm 4'te ayrıntılı bir şekilde anlatılan HOGS ile kaydedilen hologramdan kusur bilgilerinin çıkartılması için hologramlardaki faz bilgileri kullanılmıştır. Hologramlardan çıkartılan faz bilgileri, yeniden yapılandırma süreci ile elde edilmiştir. Yeniden yapılandırma süreci ise üç farklı sinyal işleme algoritması ile gerçekleştirilmiştir. Bu çalışma kapsamında kullanılan sinyal işleme algoritmaları Bölüm 4.2'te sırasıyla ayrıntılı bir şekilde anlatılan Fourier Dönüşüm Metodu (FDM), Hilbert Dönüşüm Metodu (HDM) ve Dalgacık Dönüşüm Metodu (DDM)'dir. DDM uygulanırken, DDM türlerinden Morlet Dalgacık Dönüşümü (MDD) ile Mexican Hat Dalgacık Dönüşümü (MHDD) tercih edilmiştir.

Seramik yüzey kusurları HOGS ile tespit edilmeden önce iki gruba ayrılmıştır. İlk grupta seramik yüzey lekeleri yer alırken, ikinci grupta seramik yüzey dalgalanmaları yer almaktadır. Bu nedenle bu bölümde elde edilen sonuçlar sunulurken, yüzey lekeleri ve yüzey dalgalanmalarına ait sonuçların analizleri ayrı ayrı verilecektir.

7.1 SERAMİK YÜZEY LEKESİ


Seramik yüzey lekelerinin HOGS ile tespit edilebilmesi için ilk olarak yüzeyinde leke bulunmayan (referans yüzey) seramik malzemesine ait hologram kaydı gerçekleştirilmiştir. Daha sonra yüzeyinde hava kusuru (kusurlu yüzey) bulunan seramik malzemenin hologramı kaydedilmiştir. Referans ve kusurlu yüzeylere ait seramik malzeme görüntüleri Şekil 7.1'de sırasıyla sunulmuştur.



Şekil 7.1 Seramik Yüzeyler a) Referans Yüzey b) Hava Kusuru Bulunan Kusurlu Yüzey.


Şekil 7.1’de verilen görselde hava kusuru bulunan bölgeler kırmızı daire içerisine alınarak gösterilmiştir.

Hava yüzey kusurunun HOGS ile tespit edilmesi için yeniden yapılandırma sürecinde literatürde alanı ve büyüklüğü belli olan numunelerin görüntülenmesi için sıklıkla tercih edilen FDM kullanılmıştır. Bu bağlamda iki holograma ait faz bilgisi FDM ile çıkartıldıktan sonra referans holograma ait faz bilgisinden, kusur içeren holograma ait faz bilgisi çıkartılmıştır. Sonuçta bir fark görüntüsü (fark faz hologramı) oluşturulmuştur. Diğer taraftan kusur tespiti yapabilmek için en parlak piksel bölgesini belirleme yaklaşımı uygulanarak fark görüntüsündeki en parlak piksel işaretlenmiştir. Bir başka deyişle en parlak pikselin işaretlendirilmesi için görüntü işleme algoritması oluşturulmuş ve kusurlu bölge ara yüzde net görülebilecek biçimde işaretlendirilmiştir. Bu yaklaşımı uygulamak için Spyder ara yüzü ve Phyton yazılım dili kullanılmıştır. Bu bağlamda OpenCV, NumPy, Matplotlib, kütüphaneleri kullanarak bir görüntü üzerinde FD ve ters FD ile görsel yeniden yapılandırılmıştır, ardından en parlak piksel bulunarak işaretlenmiştir. FD görüntünün frekans alanındaki temsilini elde ettiği için görüntünün ortasındaki düşük frekanslı bileşenler (yani, görüntüdeki genel aydınlık/karanlık farkları) filtrelenmektedir. Ters FD ile de yeniden zaman alanına (orijinal görüntü alanı) geçilmektedir. Sonuç olarak elde edilen görüntüdeki mutlak değerler alınmaktadır. Böylece kompleks sayı yerine reel bir görüntü elde edilmektedir. FD sonucu elde edilen görüntüdeki en parlak pikselin indeksi bulunduktan sonra, bu indeks 2B bir koordinata (sıra, sütun) dönüştürülmektedir. Sonucunda ise en parlak pikselin olduğu noktaya 5x5 (piksel) boyutlarında bir daire çizilerek işaretlendirme işlemi tamamlanmaktadır. Şekil 7.2’de referans yüzeye ait kaydedilen hologram görüntüsü sunulmuştur.




Şekil 7.2 Referans Yüzeyin Hologramı.

HOGS yöntemiyle hologramlar kaydedilirken, kayıt süreci boyunca görüntüler belirli açılarda kaydırılarak netlik dereceleri kasıtlı olarak değiştirilmiştir. Bu uygulamanın amacı, görüntü kaydetme aşamasında karşılaşılabilecek olası olumsuz koşullara — örneğin bulanıklık, aşırı aydınlık ya da karanlık gibi durumlara — karşı HOGS sisteminin dayanıklılığını ve işlevselliğini değerlendirmektir. Bu bağlamda, 20 saniye boyunca hologram kaydı yapılmıştır. Sistemde kullanılan CMOS kamera saniyede 50 görüntü kaydedecek şekilde ayarlanmıştır. Böylece toplamda 20 saniye boyunca 1000 holografik desen kaydedilmiştir. Bu doğrultuda hava kusuruna ait kaydedilen bulanık, net, aydınlık, karanlık gibi farklı özelliklerdeki hologramlar seçilerek en parlak piksel bölgesini belirleme yaklaşımı uygulanmıştır. Şekil 7.3'te ise hava kusuruna ait 1000 hologram görüntüsü arasından rastgele seçilmiş görsellere uygulanan en parlak piksel yaklaşımı ile elde edilen sonuçlar sunulmuştur. Bu bağlamda, ele alınan temel konu; çıplak gözle fark edilmesi güç olan küçük nokta, leke gibi yüzey kusurlarının arayüzde net bir şekilde tespit edilip görselleştirilebilmesidir.




Şekil 7.3 En Parlak Piksel Yaklaşımından Elde Edilen Sonuçlar A) Hava Kusuru Bulunan Hologramlar B) FDM ile Geri Elde Edilen Faz Görüntüleri C) En Parlak Piksel Bölge Belirleme Yaklaşımı ile İşaretlenmiş Alanlar.

Şekil 7.3 (devam ediyor)



Şekil 7.3 (devam ediyor)



Şekil 7.3 incelendiğinde, hava kusuru içeren yüzeylere ait hem holografik görüntülerde hem de FDM yöntemiyle geri elde edilen faz görüntülerinde, görüntü netlik derecesine bağlı olarak hava kusurlarının her durumda görsel olarak algılanamadığı gözlemlenmiştir. Bununla birlikte, en parlak piksel bölge belirleme yaklaşımı kullanılarak alan işaretlendirmesi gerçekleştirildiğinde, incelenen tüm görsellerde söz konusu kusurlar başarılı bir şekilde tespit edilebilmiştir.


7.2 SERAMİK YÜZEY DALGALANMALARI

Bu çalışmanın ikinci aşamasında seramik yüzeylerinde dalgalanmalar sonucunda oluşan kusurlar belirlenmiştir. Bu kusurlar arasında yer alan ilk kusur yüzeydeki rötüştür. Rötüş kusurunu tespit etmek için bölüm 7.1’de verilen aşamalar tekrar edilmiştir. Bir başka deyişle referans hologram ve rötüş kusurlu yüzeylere ait hologramlar kaydedildikten sonra iki görüntünün faz bilgileri çıkartılarak fark görüntüleri oluşturulmuştur. Ancak bu aşamada faz

bilgisi çıkarma işlemi sadece FDM ile değil, aynı zamanda HD ve DD türlerinden MDD ve MHDD ile gerçekleştirilmiştir.


7.2.1 Rötüş Kusuruna Ait Elde Edilen Sonuçlar

Çalışmanın bu aşamasında, ilk olarak FDM yöntemi ile elde edilen sonuçlar sunulmuştur. FDM, önerilen HOGS sistemi ile kaydedilen hologramlardan rötüş kusurunu tespit edebilmek için faz çıkarım sürecinde kullanılan ilk yöntemdir. HOGS sistemi aracılığıyla elde edilen ve rötüş kusuru içeren seramik yüzeye ait holografik görüntü ise Şekil 7.4'te gösterilmektedir.




Şekil 7.4 Rötüş Kusuru Bulunan Yüzeye Ait Seramik Görseli.

FDM yöntemi ile faz bilgisi çıkartılarak elde edilen görüntüler Şekil 7.5'te sunulmuştur. Yukarıda bahsedildiği gibi, hologram kaydı esnasında numune hareket ettirilerek netlik derecesi değiştirilmiş ve 20 sn boyunca toplam 1000 adet hologram kaydedilmiştir. Diğer taraftan, elde edilen holografik görüntülerin tamamını bu tez çalışması kapsamında göstermek mümkün olmadığı için 1000 holografik görüntü arasından rastgele hologramlar seçilmiştir. Bu bağlamda 3 hologram (5. hologram, 250. hologram, 500. hologram) için elde edilen sonuçlar gösterilmiştir. Çalışmanın bundan sonraki aşamalarında da 5. hologram, 250. Hologram ve 500. hologram görüntüleri için elde edilen sonuçlar sunulacaktır.




Şekil 7.5 Rötüş Kusuru Hologramları A) Referans Yüzeye Ait Hologram B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzey Arasındaki Fark Alınarak FDM Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.

Şekil 7.5a–7.5c’de sırasıyla, referans yüzeye ait kaydedilmiş hologram, kusurlu yüzeye ait kaydedilmiş hologram ve her iki yüzey arasındaki farkın alınmasıyla FDM yöntemi kullanılarak elde edilen faz görüntüsü sunulmaktadır. Bu çalışma kapsamında faz bilgisi çıkarımında kullanılan ikinci yöntem ise HD olmuştur. HD yöntemiyle elde edilen faz görüntüsüne ilişkin sonuçlar ise Şekil 7.6’da verilmektedir.




Şekil 7.6 Rötüş Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak HD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.

Bu tez çalışmasında, FDM ve HD yöntemlerine ek olarak faz çıkarım işlemlerinde SDD türleri de değerlendirilmiştir. Ancak, SDD'nin tüm varyantları yerine, literatürde yaygın olarak tercih edilen MDD ve MHDD kullanılarak faz çıkarımı gerçekleştirilmiştir. MHDD ve MDD yöntemleriyle elde edilen faz görüntülerine ilişkin sonuçlar sırasıyla Şekil 7.7 ve Şekil 7.8'de sunulmaktadır.




Şekil 7.7 Rötüş Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MHDD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.



Şekil 7.8 Rötüş Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MDD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.

Sunulan holografik görüntüler 2B fazı düzeltilmiş (unwrap edilmiş) görüntülerdir. Ancak bu görüntüler, yüzeydeki rötüş kusuru hakkında kesin ve doğrudan bir bilgi sunmamaktadır. Başka bir ifadeyle, söz konusu kusurun bulunduğu bölge bu faz görüntülerinde net bir şekilde gösterilememektedir. Bu nedenle, yüzey kusurunun konumunu belirlemek ve daha iyi görselleştirebilmek amacıyla, derinlik bilgisi içeren 3B fark görselleri oluşturularak analiz edilmiştir. Bu fark görselleri, tespit edilen kusurlu bölgenin boyutuna ilişkin nicel bilgi sağlamaktadır. HOGS sistemi ile tespit edilen kusurun görsel olarak daha iyi anlaşılabilmesi amacıyla, 3B yüzey görselleştirmeleri üç farklı açıdan ($30^\circ, 60^\circ, 90^\circ$) için elde edilerek sunulmuştur.


Rötuş kusurunu için çıkartılan 3B görüntülere ait $30^\circ - 30^\circ$ elevation-azimuth açılarındaki yüzey profilleri FDM ve HD yöntemleri için Şekil 7.9’da sunulmuştur.



Şekil 7.9 $30^\circ - 30^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.


FDM ve HD yöntemleri ile $30^\circ - 30^\circ$ elevation-azimuth açılarındaki elde edilen 3B yüzey profilleri incelendiğinde, FDM yöntemi ile elde edilen sonuçlarda rötuş kusurunun bulunduğu bölgenin tamamına ilişkin yeterli bilgi sağlanamadığı gözlemlenmiştir. Bu yöntemde uygulanan filtreleme işlemi, yalnızca istenmeyen fazlalıkları değil, aynı zamanda kusurun yer aldığı alanları da ortadan kaldırmış ve bu durum kusurun bütünsel olarak analiz edilmesini güçleştirmiştir. HD yönteminde ise kusur bilgisi net olmamakla birlikte FDM yöntemine göre daha iyi sonuç vermiştir. Bu iki yönteme ek olarak rötuş kusurunu tespit etmek için faz çıkarım

sürecinde MDD ve MHDD kullanılmıştır. Şekil 7.10’da MDD ve MHDD ile elde edilen 3B yüzey profilleri sunulmuştur.



Şekil 7.10 30° – 30° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen B) MHDD ile Elde Edilen.


$60^\circ - 60^\circ$ elevation-azimuth açılarında elde edilen 3B yüzey profilleri FDM ve HD yöntemleri için Şekil 7.11’da verilmiştir.




Şekil 7.11 $60^\circ - 60^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.

MDD ve MHDD ile elde edilen 3B yüzey profilleri ise sırasıyla Şekil 7.12 a ve Şekil 7.12b ‘de gösterilmiştir.


**5.
Hologram**



**250.
Hologram**




**500.
Hologram**




Şekil 7.12 $60^\circ - 60^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen B) MHDD ile Elde Edilen.

Çalışmada son olarak $90^\circ - 90^\circ$ elevation-azimuth açılarındaki elde edilen 3B yüzey profilleri çıkartılmıştır. Bu bağlamda, FDM ve HD yöntemleri ile elde edilen sonuçlar Şekil 7.13'te verilirken, MDD ve MHDD ile elde edilen yüzey profilleri Şekil 7.14'te gösterilmiştir.


5.
Hologram



250.
Hologram



500.
Hologram




Şekil 7.13 $90^\circ - 90^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.

5. Hologram

250. Hologram

500. Hologram



Şekil 7.14 $90^\circ - 90^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen B) MHDD ile Elde Edilen.

Şekil 9-Şekil 17 arasındaki sunulan tüm şekillerdeki 3B yüzey profilleri incelendiğinde, yüzey kusurunu bastıran yöntemin FDM olduğu görülmüştür. FDM faz çıkartma yöntemi, noktasal veya belirli alana sahip bölgelerin ortaya çıkartılması için kullanılmaktadır. Bu nedenle bu yöntem ile istenmeyen fazlalıklar ortadan kaldırılmaktadır. Bu istenmeyen fazlalıklar, gerçek değerli sinyallerin Fourier spektrum simetrisi nedeniyle ortaya çıkmaktadır. Dolayısı ile bu fazlalıkların yok edilmesi için ek filtreleme işlemine ihtiyaç duyulmaktadır. Ancak seramik malzemesinde olduğu gibi kusur miktarı belirli bir çerçeve içerisinde olmayan ve yüzeye yayılan kusurların tespitinde filtreleme işleminin tüm yüzeye uygulanması nedeni ile kusurlu bölgelerin bazı kısımları da filtrelenmektedir. Sonuç olarak yüzey kusurunun bir kısmının ortadan kaldırılması ile kusur bölgesinin tamamı hakkında bilgi sahibi olunmamaktadır.

Öte yandan, HD yöntemi FDM'ye kıyasla genel yüzey profilini daha bütüncül bir şekilde ortaya koyabilmekte ve bazı durumlarda daha başarılı sonuçlar sunmaktadır. Özellikle yüksek çıkıntı veya belirgin derinlik farklılıklarına sahip kusurların tespitinde HD yöntemi avantaj sağlamaktadır. Bu yöntemde, yüzey üzerindeki baskın geometrik değişimler net bir şekilde görselleştirilebilmekte, böylece gözle rahatlıkla seçilebilen kusurların konumu ve büyüklüğü hakkında ayrıntılı bilgi elde edilebilmektedir. Ancak, yüzeye yayılmış ve yüksekliği düşük olan kusurlar söz konusu olduğunda, HD yönteminin duyarlılığı sınırlı kalmaktadır. Görüntülerde bu tür kusurlar, zeminle benzer yükseklik değerlerine sahip olmaları nedeniyle yeterince ayırt edilememekte ve arka planla bütünleşerek görünürlüğü kaybetmektedir. Bu durum, özellikle seramik gibi yüzey kusurlarının belirgin geometrik formlar yerine dağınık ve düşük profil gösterdiği malzemelerde, HD yönteminin etkinliğini azaltmakta ve eksik ya da hatalı yorumlara yol açabilmektedir.

Yüzey kusurlarının yalnızca geometrik belirginliğe sahip olanlarla sınırlı kalmadığı düşünüldüğünde, farklı algoritmaların sağladığı katkıların da incelenmesi önem kazanmaktadır. Bu kapsamda yapılan analizlerde elde edilen sonuçlar irdelendiğinde, MDD yöntemi belirli bir alandaki yüzey kusurlarını belirginleştirirken, diğer bölgelerdeki gürültüyü etkili bir biçimde bastırmıştır. Bu bulgular doğrultusunda, lokalize (noktasal) ve renk kontrastı yüksek leke, çizik gibi yüzey kusurlarının tespitinde Morlet dalgacık yönteminin uygun bir yaklaşım sunduğu değerlendirilmektedir.

Buna karşılık, MHDD yöntemi, yalnızca gözle algılanabilen yüzey kusurlarını değil, aynı zamanda mikroyapısal ve yüzey altı (sub-surface) kusurları da başarıyla ortaya koymuştur. Bu sonuçlar, MHDD yönteminin geleneksel tekniklere kıyasla daha kapsamlı ve derinlemesine bir kusur analizi sunduğunu göstermektedir.

Bu çalışmada yüzey kusurları yalnızca görsel olarak sunulmakla kalmamış, aynı zamanda nicel (kantitatif) verilerle de desteklenmiştir. 3B faz profillerinden elde edilen verilere dayanarak, kusurların yayıldığı bölgelerdeki maksimum piksel yoğunlukları hesaplanmıştır. Çizelge 7.1'de, MHDD, MDD, FD ve HD yöntemleriyle analiz edilen hologramlardan elde edilen 3B faz verilerine ait maksimum (maks) ve ortalama (ort) piksel değerleri karşılaştırmalı olarak sunulmuştur.

Çizelge 7.1 Rötüş kusurlu fark görsellerinin 3B faz görüntülerinin maksimum ve ortalama piksel nokta sayısı

	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
5. Hologram	399.01	25.61	310.77	21.94	66.62	4.5	174.13	9.47
250. Hologram	407.18	26.6	317.72	22.09	66.75	4.58	184.62	9.89
500. Hologram	411.07	26.99	322.57	23.08	68.41	4.59	186.55	10.14

Çizelge 7.1'de sunulan nicel veriler ile Şekil 9-17'de yer alan 3B yüzey profillerinin karşılaştırmalı analizi, sayısal sonuçların görsel bulgularla uyum içinde olduğunu ortaya koymaktadır. Özellikle, FD tabanlı yöntemle elde edilen sonuçlarda, uygulanan filtreleme işlemlerinin bir sonucu olarak maksimum piksel nokta sayısının diğer yöntemlere kıyasla belirgin şekilde düşük kaldığı gözlemlenmektedir. Buna karşılık, HD yöntemiyle ulaşılan değerler FD'ye göre daha yüksek olmakla birlikte, MDD yöntemiyle karşılaştırıldığında daha düşük kalmaktadır. Dikkat çekici bir şekilde, 5., 250. ve 500. hologram görüntülerine ait veriler incelendiğinde, en yüksek maksimum piksel nokta sayısına MHDD yöntemiyle ulaşıldığı tespit edilmiştir. Bu bulgular, MHDD'nin yüzey kusurlarını tespit etmede diğer yöntemlere göre daha yüksek bir duyarlılık sergilediğini göstermektedir.

Çizelge 7.2 Rötüş kusurlu fark görsellerinin 3B faz görüntülerinin beyaz ve siyah pikselleri arasındaki fark

	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
5. Hologram	113.12	26.08	83.98	22.3	17.51	3.89	40.94	9.16
250. Hologram	155.48	26.39	74.81	22.06	18.24	3.88	71.78	8.83
500. Hologram	129.26	26.69	73.99	23.13	16.77	3.88	75.77	9.02

Çizelge 7.2'de sunulan veriler, 3B yüzey profillerindeki siyah ve beyaz pikseller arasındaki kontrast farkını nicel olarak ortaya koymaktadır. Elde edilen analiz sonuçları, bu kontrast farkının büyüklüğü ile yöntemlerin rötüş kusurlarını tespit etme yetkinliği arasında anlamlı bir

ilişki olduğunu göstermektedir. Sayısal bulgular, bu parametre açısından en düşük performansın FD yöntemine ait olduğunu ortaya koyarken; en yüksek kontrast değerlerine ise MHDD yöntemiyle ulaşılmıştır. Bu bağlamda, yüksek kontrast farkı üreten yöntemlerin rötuş kusurlarını daha etkili şekilde tanımladığı sonucuna ulaşılmıştır.

Çizelge 7.3 Rötuş kusurlu fark görsellerinin 3B faz görüntülerinin Z - eksen genlik değerleri


	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
5. Hologram	198.67	25.26	238.61	21.63	64.80	3.76	65.38	8.99
250. Hologram	224.03	25.72	212.07	21.57	64.85	3.76	97.96	8.66
500. Hologram	231.38	26.12	236.51	22.61	64.61	3.78	101.81	8.85

Sayısal analiz sonuçları, farklı yöntemlerin 3B faz görüntülerindeki performans farklılıklarını ortaya koymaktadır. Çizelge 7.3'te sunulan Z-eksen genlik değerleri incelendiğinde, ilginç bir bulgu olarak MDD yönteminin beklenenin aksine en yüksek genlik değerini sağladığı gözlemlenmiştir. Bu durum, önceki çizelgelerde (7.1 ve 7.2) MHDD'nin üstün performans göstermesine rağmen, Z-eksen ölçümlerinde farklı bir tablo ortaya çıkmasıyla dikkat çekicidir.

Bu beklenmedik sonucun nedeni, MHDD yönteminin analiz sırasında yalnızca rötuşlu yüzey alanına odaklanması ve istenmeyen bölgeleri filtrelemesi olarak açıklanabilir. Buna karşılık, MDD'nin daha geniş bir frekans aralığını analize dahil etmesi, Z-eksen genlik değerlerinin daha yüksek çıkmasına yol açmıştır. Bu bulgular, farklı metriklerin yöntem değerlendirmesinde farklı sonuçlar verebileceğini ve kapsamlı bir analiz için çok boyutlu değerlendirmenin gerekliliğini göstermektedir.


7.2.2 Çatlak Kusuru için Sonuçlar

Seramik yüzeylerde gözlemlenen kusurlar, morfolojik özelliklerine göre çeşitlilik göstermekte olup, bu kusurlardan biri yüzeyde oluşan çatlaklardır; ancak bu çatlakların bir kısmı çıplak gözle tespit edilebilirken, bazıları yalnızca gelişmiş görüntüleme teknikleriyle fark edilebilmektedir. Şekil 7.15'te boyutu büyük ve çıplak gözle de görülebilen seramik yüzeyde meydana gelen çatlak örneği sunulmuştur.




Şekil 7.15 Çatlak Kusuru Bulunan Yüzeye Ait Seramik Görseli.

Bu çalışmada seramik yüzey kusurlarının tespiti için HOGS kullanılmıştır. Optik görüntüleme sistemlerinde bilgi çıkarımı temel olarak faz bilgisine dayandığından, dört farklı faz çıkarma yöntemi (FD, HD, MDD ve MHDD) karşılaştırmalı olarak incelenmiştir. İlk aşamada uygulanan FD tabanlı yöntemde, çatlak kusuru içeren numuneler belirli bir hızda hareket ettirilerek 20 saniye boyunca hologram kayıtları alınmıştır. Bu dinamik kayıt yöntemi, farklı odak derinliklerine sahip çoklu görüntüler elde etmek amacıyla tasarlanmıştır. Şekil 7.16'da temsili olarak seçilen üç hologram (55., 724. ve 979. kayıtlar) sunulmaktadır: (a) kusursuz referans yüzeyin temel holografik deseni, (b) çatlak kusuru içeren numunenin interferometrik görüntüsü ve (c) FDM yöntemiyle elde edilen referans ve kusurlu yüzey faz görüntülerinin diferansiyel analiz sonuçları. Özellikle Şekil 7.16(c), kusur bölgesindeki faz değişimlerinin nicel olarak değerlendirilmesine olanak sağlayarak, kusurun tespiti ve konumlandırılması açısından önemli bir katkı sunmaktadır.



Şekil 7.16 Çatlak Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak FDM Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.


Şekil 7.16’da görüldüğü üzere, hologram kaydı sırasında yüzeyin hareket ettirilmesi, kaydedilen holografik görüntülerdeki kusurlu alanın netlik seviyesini değiştirmektedir. Örneğin, 55. hologramda çatlak tek bir çizgi şeklinde belirginleşirken, 724. ve 979. hologramlarda bu çizgi zamanla dikdörtgen biçimli bir alana dönüşmektedir. Öte yandan, FDM yöntemiyle elde edilen fark görüntüleri incelendiğinde, kusurlu bölgeye ilişkin anlamlı bir bilgiye ulaşılamadığı açıkça gözlemlenmektedir. Bu nedenle, HOGS sistemi kapsamında çatlak kusurunun daha net biçimde görüntülenebilmesi amacıyla faz çıkarım sürecinde ikinci yöntem olarak HD (Hilbert Transform) tekniği tercih edilmiştir. Şekil 7.17’de, HD yöntemi kullanılarak elde edilen holografik görüntülere yer verilmektedir.



Şekil 7.17 Çatlak Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak HD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.



HD yöntemiyle elde edilen görüntüler, FD'ye kıyasla çatlak bilgisini daha belirgin şekilde yansıtmaktadır. Ancak bu yöntemde fark faz görüntülerinde çatlak yapısı seçilebilse de, bu görüntüler Şekil 7.15'te sunulan ve çatlak bilgisini net bir biçimde gösteren orijinal görüntüyle tam olarak örtüşmemektedir. Şekil 7.16 ve Şekil 7.17'de sunulan görüntüler, faz düzeltmesi (unwrap) uygulanmış 2B faz görüntüleridir. Önceki bölümde de belirtildiği üzere, bu 2B görüntüler derinlik bilgisi içermemektedir. Oysa kusurlu yüzeyin daha ayrıntılı analiz edilebilmesi için derinlik bileşeni gerekmektedir. Bu nedenle, 2B holografik veriler kullanılarak 3B yüzey profilleri oluşturulmuştur.

Çalışma kapsamında, 3B görüntülerin daha kapsamlı bir şekilde değerlendirilebilmesi amacıyla, üç farklı bakış açısı (30° , 60° ve 90°) kullanılarak yüzey profilleri elde edilmiştir. FDM ve HD yöntemleriyle çıkarılan çatlak kusuruna ait 3B yüzey profilleri, sırasıyla 30° – 30° , 60° – 60° ve 90° – 90° elevation–azimuth açılarında olmak üzere Şekil 7.18–7.20’de sunulmaktadır.






Şekil 7.18 30° – 30° Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM Kullanılarak Elde Edilen B) HD Kullanılarak Elde Edilen.





55.
Hologram



724.
Hologram




979.
Hologram




Şekil 7.19 $60^\circ - 60^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM Kullanılarak Elde Edilen B) HD Kullanılarak Elde Edilen.


55.
Hologram



724.
Hologram




979.
Hologram




Şekil 7.20 $90^\circ - 90^\circ$ elevation-azimuth açılarında elde edilen 3B yüzey profilleri a) FDM kullanılarak elde edilen b) HD kullanılarak elde edilen.

FDM ve HD yöntemleriyle elde edilen sonuçlar, çatlak kusurunun görselleştirilmesinde belirli düzeyde başarı sağlasa da, özellikle daha detaylı yüzey bilgisi elde etmek amacıyla faz çıkarım sürecinde alternatif yaklaşımlara ihtiyaç duyulmuştur. Bu doğrultuda, çalışmada üçüncü faz çıkarım yöntemi olarak SDD temelli MHDD ve MDD yöntemleri uygulanmış; elde edilen holografik görüntüler Şekil 7.21 ve Şekil 7.22’de sunulmuştur.





Şekil 7.21 Çatlak Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MHDD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.





Şekil 7.22 Çatlak Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MDD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.

MHDD ve MDD yöntemleriyle elde edilen holografik görüntüler incelendiğinde, kusurlu bölgenin 2B görüntüler üzerinden tam olarak anlaşılamadığı görülmüştür. Bu nedenle, ilgili yöntemlerle elde edilen veriler kullanılarak 3B yüzey profilleri oluşturulmuştur. Şekil 7.23-7.25'te MHDD ve MDD metodları kullanılarak çıkartılan $30^\circ - 30^\circ$, $60^\circ - 60^\circ$ ve $90^\circ - 90^\circ$ elevation-azimuth açılarındaki 3B yüzey profilleri sırasıyla sunulmuştur.



55.
Hologram



724.
Hologram




979.
Hologram




Şekil 7.23 $30^\circ - 30^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD Kullanılarak Elde Edilen Yüzey Profili B) MHDD Kullanılarak Elde Edilen Yüzey Profili.


55.
Hologram



724.
Hologram




979.
Hologram




Şekil 7.24 $60^\circ - 60^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD Kullanılarak Elde Edilen Yüzey Profili B) MHDD Kullanılarak Elde Edilen Yüzey Profili.


55.
Hologram



724.
Hologram



979.
Hologram



Şekil 7.25 $90^\circ - 90^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD Kullanılarak Elde Edilen Yüzey Profili B) MHDD Kullanılarak Elde Edilen Yüzey Profili.

Elde edilen bulgular genel olarak değerlendirildiğinde, HD yöntemiyle elde edilen sonuçların diğer yöntemlere kıyasla daha başarılı olduğu görülmektedir. FDM ile gerçekleştirilen faz çıkarımında uygulanan ek filtreleme işlemleri, istenmeyen bileşenleri ortadan kaldırırsa da, çatlakla ait kritik bilgilerin de kaybına yol açmaktadır. Çatlak içeren yüzeye ait 2B holografik görüntülerde çatlak açıkça gözlemlenebilmesine karşın, FDM ile elde edilen 3B yüzey profilinde çatlakla dair herhangi bir bilgiye ulaşılamamaktadır. Bu durum, derinlik bilgisinin yetersizliği nedeniyle çatlak bölgesi hakkında sağlıklı bir yorum yapılamadığını ve filtreleme işlemleri sırasında gerçek bilginin de ortadan kaldırıldığını göstermektedir.

Öte yandan, MHDD ve MDD yöntemleriyle elde edilen 2B hologram görüntülerinde ve 3B yüzey profillerinde çatlak bölgesi tespit edilebilmiştir. Ancak her iki yöntemde de çatlak yapısı net ve keskin bir biçimde görüntülenememekte, daha çok yüzeye yayılmış bir kusur olarak belirmektedir. Bu bağlamda, FDM, MHDD ve MDD yöntemlerinin aksine, HD yöntemiyle faz çıkarımı yapıldığında çatlak bölgesi doğrudan ve keskin hatlarla gözlemlenebilmektedir. Bunun temel nedenlerinden biri, FDM’de karşılaşılan süreksizlik probleminin HD yöntemiyle ortadan kaldırılmasıdır. Ayrıca, HD yöntemi, diğer yöntemlerde ihtiyaç duyulan ek filtreleme işlemlerine gerek bırakmamaktadır.

Sonuç olarak, elde edilen görüntü ve veriler karşılaştırıldığında, özellikle noktasal veya keskin sınırlarla tanımlanan kusurların tespiti için HD tabanlı faz çıkarımının daha uygun bir yöntem olduğu söylenebilir. Görsel bulguların yanı sıra bu değerlendirme, sayısal verilerle de desteklenmiştir. Bu kapsamda, çatlak kusurunun bulunduğu bölgede maksimum (maks) ve ortalama (ort) piksel yoğunlukları hesaplanmış ve Çizelge 7.4’te sunulmuştur. Ayrıca, pikseller arası farklara ilişkin veriler Çizelge 7.5’te, Z-ekseni üzerindeki genlik değerleri ise Çizelge 7.6’da tablo hâlinde verilmiştir.

Çizelge 7.4 Çatlak kusuru için elde edilen fark görsellerinin 3B faz görüntülerinin maksimum ve ortalama piksel nokta sayısı

	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
55. Hologram	399.39	32.89	393.7	20.83	72.08	3.88	183.48	36.03
724. Hologram	337.14	29.28	312.91	20.57	67.47	3.63	138.75	17.37
500. Hologram	398.2	32.97	376.17	20.78	73.91	3.81	188.12	26.27

Çizelge 7.5 Çatlak kusurlu fark görsellerinin 3B faz görüntülerinin beyaz ve siyah pikselleri arasındaki fark

	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
55. Hologram	238.84	32.31	78.37	20.38	15.61	3.51	98.73	35.25
724. Hologram	135.99	29.13	73.12	20.44	13.59	3.28	89.05	16.86
979. Hologram	234.9	32.56	76.29	20.47	17.94	3.49	99.3	25.74

Çizelge 7.6 Çatlak kusurlu fark görsellerinin 3B faz görüntülerinin Z - eksen genlik değerleri

	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
55. Hologram	303.60	30.76	205.67	19.84	63.89	3.38	125.36	34.68
724. Hologram	277.20	28.51	233.08	19.97	63.00	3.20	115.70	16.45
979. Hologram	287.68	31.41	216.64	19.67	63.27	3.36	127.19	25.31

7.2.3 Toplama Kusuru için Sonuçlar


Seramik yüzeylerde sıkça karşılaşılan kusur türlerinden biri olan toplama, bu çalışmada rötuş ve çatlak kusurlarına ek olarak HOGS sistemi kullanılarak görüntülenmiştir. Ayrıca, bu bölümde yukarıda ayrıntılı olarak açıklanan faz çıkarım yöntemlerinin kusurların tespitindeki başarımlarını da karşılaştırmalı olarak değerlendirilmiştir. HOGS sistemi ile elde edilen ve toplama kusuru içeren seramik yüzeye ait örnek görüntü Şekil 7.26’te sunulmaktadır.



Şekil 7.26 Toplama Kusuru Bulunan Yüzeye Ait Seramik Görseli.

Şekil 7.25’te gösterilen örnek seramik yüzeye ait hologramlardan faz bilgisi elde etmek amacıyla kullanılan ilk yöntem FDM’dir. Diğer kusurlu yüzeylerde olduğu gibi, farklı netlik derecelerine sahip görüntüler elde edebilmek için hologram kaydı sırasında örnek numune, 20 saniyelik süre boyunca rastgele zamanlarda hareket ettirilmiştir. Bu süreç sonucunda kaydedilen hologramlar arasından rastgele seçilen ve farklı netlik düzeylerine sahip üç görüntü (113., 642. ve 981. hologramlar), Şekil 7.27’te sırasıyla sunulmaktadır. Şekil 7.27 (a)’da kusur içermeyen referans yüzeye ait hologram, (b)’de toplama kusuru bulunan yüzeye ait holografik


desen ve (c)'de ise faz çıkarım yöntemleriyle elde edilen referans ve kusurlu yüzey faz görüntüleri arasındaki farkı gösteren analiz görüntüsü yer almaktadır. Bu diferansiyel faz görüntüsü, kusurun konumunun ve etkisinin daha net biçimde belirlenmesine olanak tanımaktadır.



Şekil 7.27 Toplama Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak FDM Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü.


Çatlak kusurunda olduğu gibi, toplama kusurunda da referans ve kusurlu yüzey arasındaki fark alınarak FD yöntemiyle elde edilen faz görüntüsünde, kusura ilişkin herhangi bir bilginin görsel olarak ayırt edilemediği gözlemlenmiştir. Bu durum, FD yönteminin bazı kusur türlerinin tespitinde yetersiz kalabileceğini ortaya koymaktadır. Bu nedenle, faz çıkarım sürecinde ikinci

yöntem olarak kullanılan HD tekniğinin sonuçları incelenmiştir. HD yöntemiyle elde edilen holografik görüntüler Şekil 7.28’de sunulmaktadır.




Şekil 7.28 Toplama Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak HD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.

Ancak, HD yönteminin de sınırlı bir görsel belirginlik sağlaması nedeniyle, faz çıkarım sürecinde üçüncü yöntem grubu olarak SDD tekniklerine başvurulmuştur. Bu kapsamda, literatürde yaygın olarak kullanılan MHDD ve MDD yöntemleri, diğer kusur türlerinde olduğu gibi toplama kusurunun tespiti için de uygulanmıştır. MHDD ve MDD teknikleriyle elde edilen holografik görüntüler sırasıyla Şekil 7.29 ve Şekil 7.30' da sunulmaktadır.




Şekil 7.29 Toplama Kusuru Hologramları A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak MHDD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.



Şekil 7.30 Toplama Kusuru Hologramları A) Referans Yüzeye Ait Hologram B) Kusurlu Yüzeye Ait Hologram C) Referans ve Kusurlu Yüzey Arasındaki Fark Alınarak MDD Tekniği Kullanılarak Çıkartılmış Faz Görüntüsü.



Şekil 7.27 ile Şekil 7.30 arasında sunulan tüm iki boyutlu (2B) holografik görüntüler incelendiğinde, toplama kusurunun bulunduğu bölgeyi en belirgin şekilde ortaya koyan yöntemin HD tekniği olduğu açıkça görülmektedir. Bununla birlikte, kusurların daha ayrıntılı ve güvenilir biçimde değerlendirilebilmesi için, yalnızca 2B görüntülerle sınırlı kalınmaması; derinlik bilgisini içeren üç boyutlu (3B) yüzey profillerinin de analiz sürecine dâhil edilmesi gerekmektedir. Bu doğrultuda, çalışmada yüzey profilleri yalnızca tek bir bakış açısından değil, farklı açılardan elde edilerek analiz edilmiştir. Özellikle, 30° – 30° , 60° – 60° ve 90° – 90° elevation-azimuth açıları dikkate alınarak oluşturulan 3B yüzey profilleri, kusur bölgesinin mekânsal özelliklerinin daha ayrıntılı bir şekilde değerlendirilmesine olanak tanımaktadır.

Şekil 7.30–Şekil 7.32 arasında, FDM ve HD yöntemleriyle kaydedilen hologramlardan elde edilen 3B yüzey profillerinin söz konusu açılardaki görselleştirmeleri sunulmaktadır.





Şekil 7.31 Toplama Kusuruna Ait $30^\circ - 30^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD İle Elde Edilen.



113.
Hologram



642.
Hologram




981.
Hologram




Şekil 7.32 Toplama kusuruna ait $60^\circ - 60^\circ$ elevation-azimuth açılarında elde edilen 3B yüzey profilleri a) FDM ile elde edilen b) HD ile elde edilen.



113.
Hologram





b



642.
Hologram




981.
Hologram




Şekil 7.33 Toplama Kusuruna Ait $90^\circ - 90^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) FDM ile Elde Edilen B) HD ile Elde Edilen.

Yukarıda verilen toplama kusuruna ait 3B yüzey profilleri incelendiğinde, HD yöntemiyle elde edilen sonuçlarda kusurun bulunduğu bölgenin özellikle $90^\circ-90^\circ$ elevation-azimuth açılarında net bir biçimde ortaya çıktığı gözlemlenmektedir. Öte yandan, Şekil 7.26'da sunulan toplama kusuru içeren seramik yüzey görseliyle birlikte, çıplak gözle fark edilemeyen yüzey dalgalanmalarının da HD yöntemiyle başarılı bir şekilde ortaya konduğu görülmektedir. HD tekniği ile tatmin edici sonuçlara ulaşılmış olmakla birlikte, karşılaştırmalı bir analiz sunabilmek amacıyla MHDD ve MDD yöntemleri için de belirlenen açılarda 3B yüzey profilleri oluşturulmuştur. Şekil 7.33- Şekil 7.35'te sırasıyla $30^\circ - 30^\circ$, $60^\circ - 60^\circ$, $90^\circ - 90^\circ$ elevation -azimuth açılarında elde edilen bu yüzey profilleri sunulmuştur.


113.
Hologram



642.
Hologram





981.
Hologram





Şekil 7.34 Toplama Kusuruna Ait $30^{\circ} - 30^{\circ}$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen Yüzey Profili B) MHDD ile Elde Edilen Yüzey Profili.



113.
Hologram



642.
Hologram




981.
Hologram




Şekil 7.35 Toplama Kusuruna Ait $60^\circ - 60^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen Yüzey Profili B) MHDD ile Elde Edilen Yüzey Profili.


113.
Hologram



642.
Hologram



981.
Hologram



Şekil 7.36 Toplama Kusuruna Ait $90^\circ - 90^\circ$ Elevation-Azimuth Açılarında Elde Edilen 3B Yüzey Profilleri A) MDD ile Elde Edilen Yüzey Profili B) MHDD ile Elde Edilen Yüzey Profili.

MHDD ve MDD yöntemleriyle elde edilen 3B yüzey profilleri incelendiğinde, MDD tekniğiyle oluşturulan yüzey profilinde kusurlu bölgeye ilişkin herhangi bir bilginin bulunmadığı gözlemlenmiştir. MHDD yönteminde ise toplama kusurunun bulunduğu bölgeye dair sınırlı düzeyde bir bilgi elde edilse de, bu bilgi düzeyinin Şekil 7.25'te sunulan seramik yüzey görselinde yer alan gerçek kusur yapısını tam anlamıyla yansıtamadığı açıkça görülmektedir. Elde edilen bulgular doğrultusunda, toplama kusurunun tespiti açısından faz çıkarım sürecinde tercih edilmesi gereken en uygun yöntemin HD tekniği olduğu sonucuna ulaşılmıştır. Bu değerlendirmeyi nicel olarak desteklemek amacıyla, her bir yöntem için kusurlu bölgeye ait

maksimum (maks) ve ortalama (ort) piksel yoğunluđu deđerleri (Çizelge 7.7), pikseller arası farklar (Çizelge 7.8) ve Z-ekseni genlik ölçümleri (Çizelge 7.9) hesaplanmış ve ilgili veriler karşılaştırmalı olarak tablolar hâlinde sunulmuştur.

Çizelge 7.7 Toplama kusuru için elde edilen fark görsellerinin 3B faz görüntülerine ait maksimum ve ortalama piksel nokta sayısı

	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
113. Hologram	336.28	33.09	319.32	21.96	70.24	3.87	142.13	12.76
642. Hologram	647.78	34.95	580.41	23.58	145.39	4.09	166.29	11.52
981. Hologram	853.58	34.69	591.44	22.36	154.51	4.1	202.09	11.74

Çizelge 7.8 Toplama kusurlu fark görsellerinin 3B faz görüntülerine ait beyaz ve siyah pikselleri arasındaki fark

	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
113. Hologram	212.92	33.41	83.66	21.94	17.55	3.58	64.4	12.38
642. Hologram	169.06	34.89	100.06	23.6	15.72	3.83	50.0	10.68
981. Hologram	251.96	34.49	122.69	22.29	15.91	3.71	86.57	12.08

Çizelge 7.9 Toplama kusurlu fark görsellerinin 3B faz görüntülerine ait Z - eksen genlik deđerleri

	MHDD		MDD		FD		HD	
	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.	Maks.	Ort.
113. Hologram	336.28	32.83	299.47	21.50	70.24	3.48	96.90	12.22
642. Hologram	647.78	34.38	580.41	22.98	145.39	3.74	166.29	10.59
981. Hologram	853.58	33.77	591.44	21.88	154.51	3.65	202.09	11.74


BÖLÜM 8

HİLBERT DÖNÜŞÜMÜ TEKNİĞİNİN ÇEŞİTLİ KENAR BELİRLEME YÖNTEMLERİ İLE BİRLİKTE UYGULANMASI


Bu tez çalışması kapsamında ilk olarak faz çıkarım yöntemlerinin seramik yüzey kusurlarını tespit etme performansı karşılaştırılmıştır. İkinci aşamada ise hologramlardan elde edilen fark görselindeki kusurlu bölgenin çeşitli kenar belirleme yöntemleri ile belirgin hale getirilmesi amaçlanmıştır. Ancak bu bölümde referans yüzey ile kusurlu yüzeylere ait hologramlardan faz bilgisi çıkartmak için 7. Bölümde bahsi geçen faz çıkarım yöntemlerinin hepsi uygulanmamıştır. 7.bölümde kusurlu bölgeyi belirlemede en başarılı sonuç veren HD tekniği ile çeşitli kenar belirleme teknikleri (canny, sobel, prewitt) uygulanmıştır.

Bu aşamada hedef kenar belirleme algoritmalarının başarımının incelenmesi olduğundan, Şekil 7.4'te kusurlu bölgesi gösterilen seramik yüzeyi için kaydedilen hologram serisinden rastgele bir hologram örnek olarak seçilmiştir. Bu bağlamda, 20 saniye boyunca kaydedilen 1000 adet hologram arasından 250. Hologram örnek olarak alınarak, HD ile birlikte kenar belirleme tekniklerine tabi tutulmuştur.

Şekil 8.1'de sadece faz çıkarım sürecinde HD'nin uygulanması ile elde edilen görüntüler sunulmuştur. Ancak bu görüntülere bakılarak rötuş kusuruna ait bilginin net bir şekilde görülememektedir. Kusur bulunan bölgedeki bilgiyi ortaya çıkarmak için referans ve kusurlu hologramlardan HD ile faz çıkarımı yapıldıktan sonra, iki faz hologramı arasındaki fark görüntüsüne ek işlem olarak kenar belirleme teknikleri uygulanmıştır. Bu bağlamda ilk olarak Canny kenar belirleme tekniği kullanılmıştır. Bu yöntem bu çalışmada kısaca HD+Canny olarak adlandırılmıştır. Şekil 8.1'de referans ve kusurlu bölgeye ait holografik görüntü sunulduğu için Şekil 8.2'de tekrar verilmemiştir. Bu nedenle Şekil 8.2'de sadece HD ve Canny operatörünün birlikte uygulandığı fark görseli ile bu görsele ait 3B yüzey faz profili sunulmuştur.




Şekil 8.1 Rötüş Kusuru İçin Elde Edilen Görüntüler A) Referans Yüzeyin Hologramı B) Kusurlu Yüzeyin Hologramı C) Referans ve Kusurlu Yüzeyin Farkı Alınarak HD Tekniği Kullanılarak Çıkarılmış Faz Görüntüsü D) HD Kullanılarak Elde Edilen 3B Yüzey Profili.




Şekil 8.2 Canny Operatörü ile Elde Edilen Görüntüler A) HD+Canny ile Elde Edilen Fark Hologramı B) Fark Görüntüsünün 3B Yüzey Profili.

Rötüş kusurunun belirgin olarak ortaya çıkartılması ve holografik görüntülerdeki sonuçların iyileştirilmesi için HD ile birlikte kullanılan ikinci ve üçüncü teknik sırasıyla Prewitt ve Sobel'dir. Bu yöntemlerin bu çalışmada kullanılan kısaltılmış adlandırılması sırasıyla HD

+Prewitt ve HD+Sobel'dir. Şekil 8.4 ve Şekil 8.5 'te sırasıyla bu tekniklerin HD ile birlikte kullanılması ile elde edilen sonuçlar gösterilmiştir.



Şekil 8.3 Prewitt Operatörü ile Elde Edilen Görüntüler A) HD +Prewitt ile Elde Edilen Fark Hologramı B) Fark Görüntüsünün 3B Yüzey Profili.



Şekil 8.4 Sobel Operatörü ile Elde Edilen Görüntüler A) HD+Sobel ile Elde Edilen Fark Hologramı B) Fark Görüntüsünün 3B Yüzey Profili.

Referans ve kusurlu yüzeylere ait elde edilen hologramlar 0 ile 255 arasında değişen piksel değerlerine sahip gri tonlamalı görüntülerdir. İki gri tonlamalı görüntü arasındaki farkı hesaplamak için, her bir pikseldeki gri tonlama değerleri birbirinden çıkarılmaktadır. Bu şekilde, her pikselin iki görüntü arasındaki farkını ifade eden bir fark görüntüsü elde edilmektedir. Bu fark görüntüsü, piksel bazında benzerlik veya farklılık hakkında bilgi sağlamaktadır. Ayrıca pikseller arası fark, fark görüntüsündeki maksimum ve minimum piksel değerleri arasındaki farkı ifade etmektedir. Fark görüntüsündeki beyaz pikseller kusurlu bölgeye ait bilgiyi taşımaktadır. Siyah piksel ise kusurun bulunmadığı ya da filtreleme ve kenar

belirleme teknikleri ile bastırılmış gürültülü bölgedeki pikselleri vermektedir. Bu bağlamda 3B yüzey profilindeki yükseklik değerleri, siyah ve beyaz piksellere ait piksel farklarının büyüklüğünü temsil etmektedir.

Holografik görüntülerdeki kusur bilgisini daha iyi tespit edilebilmesi için HD ile birlikte kullanılan kenar belirleme teknikleri sonucunda bulunan fark hologramlarındaki siyah ve beyaz piksel sayıları niceliksel olarak Çizelge 8.1’de sunulmuştur.

Çizelge 8.1 HD ve kenar belirleme tekniklerinin birlikte kullanımı ile elde edilen siyah ve beyaz piksel değerleri

•	• HD	• HD+Canny	• HD +Prewitt	• HD+Sobel
• Siyah Piksel	• 261,630	• 262,109	• 260,265	• 259,984
• Beyaz Piksel	• 514	• 35	• 1879	• 2160

Yukarıda verilen şekiller ve Çizelge 8.1 birlikte değerlendirildiğinde, Canny kenar belirleme tekniğinin HD ile birlikte kullanımının (HD+ Canny) rötuş gibi yüzey kusurlarını ortaya çıkarmak için uygun bir yöntem olmadığı görülmektedir. Çünkü faz çıkarım işlemi HD ile yapıldıktan sonra, kenar belirleme tekniği hiç uygulanmadığında elde edilen beyaz piksel sayısı (514), HD’nin Canny ile birlikte kullanıldığında elde edilen beyaz piksel sayısından (35) daha fazladır. Bu durum Canny tekniğinin görüntüyü bulanıklaştırmasından kaynaklanmaktadır. Oysaki görüntülerde oluşan beyaz piksel sayısı görmek istenilen kusurlu alanın büyüklüğünü vermektedir. Diğer taraftan, bulanıklaşan görüntü siyah nokta sayısını arttırmaktadır ve kusurlu olan yüzeydeki kusuru bastırmaktadır. Bulanıklaşmadan kaynaklanan siyah piksel sayısının fazlalığı 3B yüzey profilinde görülmesi beklenen şiddet değerlerini minimize etmektedir. Bu nedenle o bölgede kusur yokmuş gibi bir görüntü meydana gelmektedir. Bu sonuç Şekil 8.1 ve Şekil 8.2’de sunulan görüntülerden de açıkça görülebilmektedir. Literatürdeki çalışmalara bakıldığında Canny tekniğinin istenmeyen gürültülerin bastırılmasında ve yok edilmesinde yüksek başarımla gösterdiği bilinirken, bu çalışma kapsamında elde edilen sonuçlar doğrultusunda kusurlu bir yüzeyin tespitinde istenilen başarımla sunmadığı görülmüştür.

Bu çalışma kapsamında HD ile birlikte kullanılan üçüncü ve dördüncü kenar bulma teknikleri sırasıyla Sobel ve Prewittir. Bu yöntemlerde arka planda bir eğitim yapılmamakla birlikte, sabit denklemlere dayalı algoritmalarla sonuçlar bulunmaktadır. Diğer taraftan 2 yöntemde de, bulunan beyaz piksel sayıları hem HD+Canny, hem de HD’nin tek kullanımı ile elde edilen

beyaz piksel sayılarından daha fazladır. Çizelge 8.1’de sunulan, bu iki yöntem ile elde edilen veriler incelendiğinde Sobel tekniğinin HD ile birlikte kullanılmasıyla (HD+Sobel) elde edilen beyaz piksel sayısının (2160), Prewitt tekniğinin HD ile birlikte kullanılmasıyla (HD +Prewitt) elde edilen beyaz piksel sayısından (1879) daha fazla olduğu görülmektedir. Bu durumun sebebi, Prewitte kullanılan operatör maskenin, merkeze yakın olan yerlerdeki piksel değerlerini hesaba katmamasıdır. Yani görüntünün tamamına bu teknik uygulanmamaktadır. Bu nedenle merkeze yakın konumda bulunan beyaz piksel değerlerinin siyah piksel olarak algılanma olasılığı doğmaktadır. Diğer taraftan Sobel tekniğinde görüntüdeki tüm pikseller işleminden geçtiği için en yüksek ve en doğru başarımlar HD + Sobel elde edilmektedir.

Çizelge 8.1’de görüldüğü gibi siyah-beyaz piksel sayısına göre rötuş gibi yüzey kusurlarının tespitinde en yüksek başarımlar HD + Sobel ile elde edilmektedir. Bu başarımları Z-Eksen Genlik değerlerini inceleyerek de görmek mümkündür. Çizelge 8.2’de 3B yüzey profillerinden bahsi geçen yöntemler ile elde edilen z-eksen genlik değerleri verilmektedir.

Çizelge 8.2 3-Boyutlu yüzey profillerinden elde edilen Z-eksen genlik değerleri

•	• HD	• HD+Canny	• HD +Prewitt	• HD+Sobel
• Maksimum	• 184.42	• 334.47	• 100.99	• 138.18
• Ortalama	• 9.59	• 0.16	• 9.53	• 13.28

3B yüzey grafiğinde Z-ekseninin (yükseklik ekseninin) maksimum, minimum ve ortalama değerleri, fark görsellerindeki piksel genlik değerlerine karşılık gelmektedir. Fark görseli dizisinin maksimum değeri, yüzey grafiğindeki en yüksek noktayı temsil etmektedir. Yani, Z-eksenindeki her nokta, fark görüntüsündeki belirli bir pikselin farklılık genliğini temsil etmektedir. Bu sayede, her bir pikselin farklı bir genlik değeri ile temsil edildiği 3B bir yüzey grafiği elde edilmektedir. Yükseklik eksenindeki değerler ne kadar yüksekse, o noktadaki piksel farkının o kadar büyük olduğunu söylenebilmektedir. Benzer şekilde, minimum değer, en düşük noktayı temsil etmektedir. Ortalama değer ise tüm Z-ekseni değerlerinin ortalamasını göstermektedir. Çizelge 8.2’ye göre HD+Canny’deki maksimum Z-ekseni genlik değeri en yüksek (334.47) çıkarken, ortalama değer bu yöntemde en düşüktür (0.16). Bu sonuçlardaki tutarsızlığın nedeni yukarıda da bahsedildiği gibi Canny ile görüntünün bulanıklaştırılmasıdır. Bulanıklaştırma işlemi en keskin noktalara etki etmezken, kusurun bulunduğu ancak keskin olmayan bölgelerde veri kaybına neden olmaktadır. Hem holografik görüntüler, hem piksel sayıları hem de Z-ekseni genlik değerine göre Canny kenar belirleme yönteminin hem

holografik görüntülere uygulanması hem de yüzey kusurlarının tespitinde kullanılması uygun olmadığı söylenmektedir.

HD +Prewitt yönteminde elde edilen maksimum ve ortalama değerler HD'ye göre daha düşüktür. Sadece Çizelge 8.2'ye bakılarak tutarlı sonuç vermesi bakımından en başarılı yöntemin HD+Prewitt olduğu düşünülmektedir. Ancak bu yöntemin merkeze yakın piksellere etki etmemesinden dolayı maksimum nokta sayısının tüm yöntemlere göre daha düşük sonuç verdiği açıkça görülmektedir. Son olarak, HD+Sobel yöntemi ile elde edilen maksimum Z-ekseni genlik değerinin HD'ye göre daha düşük ama yakın bir değerde (138.18) çıktığı görülmektedir. Ortalama değer ise tüm yöntemlere göre daha yüksek çıkmıştır. HD+Sobel'in daha iyi bir yöntem olduğunu söylemek mümkündür. HD'ye göre daha düşük Z-ekseni genlik değerine sahip olmasının nedeni ise istenmeyen gürültülerin Sobel kenar belirleme tekniği ile yok edilmesidir.

Sonuç olarak yukarıda verilen holografik görüntüler kullanılarak ortaya konulan farklı kenar belirleme tekniklerine ait başarımların performansı siyah-beyaz piksel sayıları ve Z-ekseni genlik değerleri ile desteklenmiştir. Tüm bu bulgular ışığında HD+Sobel kullanımının HOGS sistemi ile görüntülenen rötuş gibi yüzey kusurlarının tespitinden en başarılı yöntem olduğu açıkça tespit edilmiştir.

BÖLÜM 9

HOGS SİSTEMİ İLE ELDE EDİLEN KUSURLARIN DERİN ÖĞRENME TABANLI RESNET-50 ALGORİTMASI İLE SINIFLANDIRILMASI

Bu çalışmada kullanılan bilgisayar, Intel(R) Core(TM) i7-8550U CPU @ 1.80GHz işlemciye ve 16 GB RAM belleğe sahip olup, 64 bit işletim sistemine sahip x64 tabanlı bir işlemci ile çalışmaktadır. GPU olarak Intel(R) UHD Graphics 620 ve NVIDIA GeForce MX150 ekran kartları bulunmaktadır. GPU sürücü versiyonu 457.63 ve CUDA sürümü 11.1'dir. Grafik kartı 2 GB VRAM kapasitesine sahiptir ve bu kart testler sırasında belirli işlemler için kullanılmıştır. Deney sürecinde GPU'nun CUDA desteği aktif hale getirilerek modelin eğitim sürecine katkıda bulunması sağlanmıştır.

Bu çalışmada, derin öğrenme modelleri Python dili kullanılarak geliştirilmiştir. Modelin oluşturulması, eğitimi ve değerlendirilmesinde TensorFlow ve Keras kütüphanelerinden yararlanılmış; kodlar, Anaconda dağıtımı üzerinden çalışan Spyder IDE ortamında geliştirilmiştir. Görüntü ön işleme ve veri artırma işlemleri için ImageDataGenerator sınıfı kullanılmış, sınıflandırma performansını artırmak amacıyla önceden eğitilmiş ResNet50 mimarisi temel model olarak tercih edilmiştir.

Modelin öğrenme süreci Adam optimizasyon algoritması ile optimize edilmiş; öğrenme oranının dinamik olarak ayarlanabilmesi için LearningRateScheduler fonksiyonu uygulanmıştır. Ayrıca, aşırı öğrenmeyi (overfitting) önlemek ve eğitim süresini verimli kılmak amacıyla EarlyStopping yöntemi kullanılmıştır. Çalışmada yararlanılan temel kütüphaneler ve kullanım amaçları Çizelge 9.1'de sunulmaktadır.

Çizelge 9.1 Derin Öğrenme Sürecinde Kullanılan Kütüphaneler ve Kullanım Amaçları

Kullanılan Kütüphane	Amaç
TensorFlow ve Keras	Modelin oluşturulması, eğitimi ve değerlendirilmesi
NumPy ve Pandas	Veri işleme ve analiz işlemleri
Matplotlib ve Seaborn	Grafiksel veri analizi ve görselleştirme
Scikit-learn (sklearn)	Sınıflandırma raporları, karmaşıklık matrisi ve metrik hesaplamaları
ResNet50	Önceden eğitilmiş model kullanımı
ImageDataGenerator	Veri artırma işlemleri
LearningRateScheduler ve EarlyStopping	Eğitim sürecinin kontrolü

DÖ sürecine kullanılan model, önceden eğitilmiş ResNet50'yi temel alarak transfer öğrenme yöntemiyle eğitilmektedir. Bu bağlamda, öncelikle dondurulmuş 140 katman ile son katmanlar eğitilmiş ve daha sonrasında tüm model üzerinde ayarlamalar yapılarak ince eğitime sokulmuştur. Ayrıca, hiper parametrelerde öğrenme oranı azaltma, erken durdurma, L2 düzenleme (regularization) ve seyreltme (dropout) teknikleri kullanılmıştır. Kullanılan modele ait akış diyagramı Şekil 9.1’de sunulmuştur.



Şekil 9.1 Derin Öğrenme Sürecine Kullanılan Modelin Yapısı.

İş akış diyagramı Şekil 9.1’de sunulan modelde kullanılan işlemler ve bu işlemlere ait parametre değerleri Çizelge 9.2’de özetlenmiştir. Bu kapsamda, ölçeklendirme, doğrulama ayırımı, veri artırma ve dolgu modu gibi temel işlemler tabloda tanımlanan adımlar arasında yer almaktadır.

Çizelge 9.2 Veri Ön İşleme Parametreleri

İşlem	Uygulama Değerleri
• Rescale (Ölçeklendirme)	• 1/255 (0-1 arasına çekildi)
• Validation Split (Doğrulama Ayırma)	• %20 (0.2)
• Veri Artırma (Augmentation) Teknikleri	• Dönme (Rotation Range): 30° • Genişlik Kaydırma (Width Shift): %20 • Yükseklik Kaydırma (Height Shift): %20 • Kesme (Shear Range): %20 • Yakınlaştırma (Zoom Range): %20 • Yatay Çevirme (Horizontal Flip): +
• Dolgu Modu (Fill Mode)	• "nearest"

Çizelge 9.2’ye göre, ölçeklendirme işlemiyle gri seviye görüntülerdeki 1 ile 255 arasındaki piksel değerleri 0 ile 1 aralığına dönüştürülmüştür. Doğrulama seti ayırımı, veri kümesinin %20’si doğrulama verisi olarak ayrılacak şekilde gerçekleştirilmiştir. Dolgu işlemlerinde ise “nearest” yöntemi tercih edilmiştir. Veri artırma sürecinde toplam altı farklı teknik uygulanmıştır. Bu teknikler arasında; 30°’lik dönüş, genişlik ve yükseklik kaydırma, kesme (*shear*) ve yakınlaştırma işlemleri %20 oranında gerçekleştirilmiş; yatay çevirme işlemi ise pozitif yönde uygulanmıştır.

Modelin eğitiminde kullanılan hiperparametreler Çizelge 9.3’te listelenmiş, bu parametrelere karşılık gelen sayısal değerler ise Çizelge 9.4’te sunulmuştur.

Çizelge 9.3 Eğitim Hiperparametreleri

Hiperparametre	Değer
Epoch Sayısı	50
Batch Size (Toplu İşlem Boyutu)	64
Optimizasyon Algoritması	Adam
Başlangıç Öğrenme Oranı (Learning Rate)	0.001
Öğrenme Oranı Azaltma	Exponential Decay (0.1 faktörüyle 5 epokta bir azaltma)
Erken Durdurma (Early Stopping)	7 epok boyunca gelişme olmazsa durdur (restore_best_weights=True)
Kayıp Fonksiyonu (Loss Function)	Categorical Crossentropy
Metrikler (Evaluation Metrics)	Accuracy, Precision, Recall, AUC, F1-Score

Çizelge 9.4 Hiper Parametre Değerleri.

	Hiper Parametreler	Hiper Parametre Değerleri
1	Gizli Katman 1 Nöron Sayısı	128
2	Gizli Katman 2 Nöron Sayısı	64
3	Seyreltme (Dropout) 1	0.3
4	Seyreltme (Dropout) 2	0.3
5	Batch Size	64
6	Tur (Epoch)	50
7	Optimizasyon Algoritması (Optimizer)	Adam
8	Öğrenme Oranı (Learning Rate)	0.001
9	Öğrenme Oranı Azaltma (Learning Rate Scheduler)	Exponential Decay ($0.1^{**}(\text{epoch} / 5)$)
10	Erken Durdurma (Early Stopping)	Patience=7, Monitor='val_loss', Restore Best Weights=True

Ön işleme adımları ve model hiperparametreleri tanımlandıktan sonra, sınıflandırma performansının değerlendirilmesi amacıyla iki farklı model yapılandırılmıştır. Bu modellere ilişkin elde edilen sınıflandırma sonuçları aşağıda sunulmaktadır.

9.1 HOGS ELDE EDİLEN GÖRSELLERİN SINIFLANDIRILMASI (I. MODEL)

Bu aşamada HOGS ile kaydedilen hologramlardan HD tekniği ile faz bilgisi çıkarımı yapılarak elde edilen görüntüler kullanılmıştır. Elde edilen holografik fark görüntülerinden kusurlu ve kusursuz seramik yüzey ayırımı yapabilmek için ResNet-50 ile sınıflandırma işlemi yapılmıştır. Sınıflandırmada 2 sınıf belirlenmiş olup, bu sınıflar kusurlu ve kusursuz olarak adlandırılmıştır. Sınıflandırma başarımını göstermek için Bölüm 6.2’de verilen performans değerlendirme metrikleri kullanılarak hesaplamalar yapılmıştır.

Çizelge 9.5’te sunulan model performans metrikleri tablosunda modelin her bir turda kaydettiği eğitim ve doğrulama doğrulukları, özgüllük, kesinlik, geri çağırma ve F1-Skoru değerleri sunulmuştur. En başarılı sonuçlara 25. turda ulaşıldığı görülen bu aşamada, model 25. turda kaydettiği ağırlık değerlerini kullanarak test başarımını hesaplamıştır.

Çizelge 9.5 I. Model Performans Metrikleri.

Tur (Epok)	Eğitim Doğruluğu (%)	Doğrulama Doğruluğu (%)	Özgüllük (%)	Kesinlik (%)	Geri Çağırma (%)	F1-Skoru (%)
1	55.50	50.22	46.94	54.67	56.91	55.77
2	56.45	49.16	50.64	56.36	56.87	56.61
3	58.81	53.67	54.52	59.11	59.16	59.14
4	61.27	53.17	53.02	61.18	62.08	61.63
5	61.10	55.25	56.01	63.09	61.26	62.16
6	62.68	56.09	57.65	62.90	62.28	62.59
7	66.08	62.45	60.72	65.72	64.19	64.95
8	66.85	60.18	59.43	65.37	66.68	66.02
9	67.20	59.55	58.87	67.72	66.94	67.33
10	69.79	64.77	63.15	70.60	69.87	70.23
11	70.37	62.14	61.22	70.87	72.29	71.57
12	71.95	66.46	65.71	71.04	71.98	71.50
13	74.24	63.58	62.33	73.91	74.18	74.05
14	73.67	66.30	64.92	74.20	71.21	72.67
15	75.44	70.81	69.44	74.93	75.63	75.28
16	78.19	73.35	72.26	78.09	77.89	77.99
17	79.32	73.68	73.05	78.35	79.36	78.85
18	82.23	74.56	74.20	82.93	83.40	83.17
19	82.59	75.65	74.72	82.92	81.45	82.18
20	83.67	74.75	73.70	84.06	82.92	83.49
21	88.13	77.73	76.65	89.60	87.34	88.45
22	88.02	79.70	78.39	87.73	88.93	88.33
23	89.90	84.20	83.55	89.64	88.50	89.07
24	89.99	84.23	84.89	89.99	91.39	90.68
25	92.46	89.00	89.50	89.20	88.70	88.95

Çizelge 9.5’te sunulan model eğitimi ve performans metriklerine bakılarak bir değerlendirme yapmak mümkündür. Ancak değerlendirmenin doğru bir şekilde yapılabilmesi için tablodaki değerler 3 başlık altında incelenmiştir. Bu başlıklar ve elde edilen sonuçlara ait yorumlar sırasıyla aşağıdaki gibi verilmiştir.

- **Başlangıç Aşamaları (Epok 1-5)**

Eğitimin başlangıç aşamasında modelin eğitim doğruluğu %55 civarında başlamış ve hafif bir artışla %61 seviyelerine ulaşmıştır. Aynı dönemde doğrulama doğruluğu ise yaklaşık %50 seviyelerinde dalgalanmış ve %55'e yükselmiştir. Bu durum, modelin başlangıçta verileri tanımakta ve genellemekte zorlandığını, ancak öğrenme sürecine başladığını göstermektedir. Özgüllük (%46-56) ve kesinlik değerlerindeki hafif dalgalanma, modelin sınıflar arası ayrımı öğrenme sürecinin henüz başlangıç aşamasında olduğunu ortaya koymaktadır.

- **Orta Dönem Eğitim Süreci (Epok 6-15)**


Bu süreçte modelin eğitim doğruluğu hızla artarak %62'den %75 seviyelerine çıkmıştır. Doğrulama doğruluğunda ise daha belirgin dalgalanmalar gözlemlenmiş, ancak genel olarak yükselme eğilimi göstererek %56'dan %71 seviyelerine ulaşmıştır. Özellikle 7. turda doğrulama doğruluğunun %62 seviyesine ani yükselişi, modelin belirli kritik özellikleri öğrenmeye başladığını işaret etmektedir. Ancak takip eden epoklarda gözlemlenen hafif düşüşler, verideki karmaşıklık ve modelin henüz tam olarak stabil hale gelmediğini göstermektedir. Özgüllük ve geri çağırma metrikleri ise bu süreçte doğrulama doğruluğu ile paralel bir artış göstermiştir.

- **İleri Aşamalar ve Modelin Stabilizasyonu (Epok 16-25)**

Son aşamada eğitim doğruluğu %78'den başlayarak kademeli olarak %92.46 seviyesine yükselmiş ve stabil hale gelmiştir. Bu durum, modelin eğitim verisini iyi bir şekilde öğrendiğini göstermektedir. Doğrulama doğruluğu da tutarlı ve istikrarlı artış göstererek son turda %89'a ulaşmıştır. Özgüllük değerinin (%72'den %89.50'ye) artışı, modelin negatif sınıfları da doğru bir şekilde tanıyabildiğinin kanıtıdır. Kesinlik, geri çağırma ve F1-skoru metriklerinin birbirlerine yakın ve tutarlı biçimde artarak %88-89 seviyelerinde sabitlenmesi, modelin performansının dengeli ve güvenilir olduğunu ortaya koymaktadır.

Performans metriklerine ek olarak, alıcı operatör karakteristiği eğrisi (Receiver Operating Characteristic- ROC) altında kalan alan (Area Under the Curve -AUC) metriği, bir sınıflandırma modelinin pozitif ve negatif sınıfları ayırt etme başarısını ifade etmektedir. Bu çalışmada, AUC değeri 0.907 olarak elde edilmiştir. Bu sonuç, modelin kusurlu ve kusursuz

örnekleri yüksek doğrulukla ayırt edebildiğini ve rastgele sınıflandırmadan daha iyi performans gösterdiğini ortaya koymaktadır.




Şekil 9.2 HOGS ile Elde Edilen Görsellerin Sınıflandırılmasına Ait ROC Eğrisi.

Birinci model için elde edilen performans metrik değerlendirmesine ek olarak bu bölümde kullanılan test verisine ait performans değerlendirmesi de yapılmıştır. Değerlendirmenin daha anlaşılır bir şekilde aktarılabilmesi için her bir parametre ile ulaşılan sayısal veriler ve bu verilere ait yorumlar Çizelge 9.6’da tablo olarak sunulmuştur.

Çizelge 9.6 I. Model Kullanıldığında Test Verisi Üzerindeki Performans Değerlendirmesi

Performans Metrikleri	Değer	Açıklama
Doğruluk	%88.75	Model, test setindeki örneklerin yaklaşık %88.75'ini doğru şekilde sınıflandırmıştır. Bu sonuç modelin genel olarak başarılı olduğunu göstermektedir.
ROC Eğrisi Altında Kalan Alan (AUC)	0.91	AUC değerinin 0.91 olması, modelin kusurlu ve kusursuz ürünleri birbirinden ayırma konusunda oldukça iyi olduğunu göstermektedir.
Kayıp (Cross-Entropy)	0.56	0.56'lık cross-entropy kayıp değeri, modelin genel hata oranının kabul edilebilir seviyede olduğunu, ancak hala iyileştirme potansiyeli bulunduğunu göstermektedir.
Ağırlıklı Keskinlik	%89.43	Modelin pozitif olarak tahmin ettiği örneklerin yaklaşık %89.43'ü gerçekten doğrudur. Bu oran, modelin pozitif tahminlerinin büyük oranda güvenilir olduğunu göstermektedir.
Ağırlıklı Duyarlılık	%88.75	Model, gerçekte var olan pozitif örneklerin %88.75'ini doğru tespit etmektedir. Bu değer, modelin sınıfları tanıma konusunda iyi olduğunu ifade etmektedir.
Ağırlıklı F1 Skoru	%88.70	F1 skorunun %88.70 olması, modelin Precision ve Recall değerleri arasında dengeli bir başarı gösterdiğini ve genel sınıflandırma performansının güçlü olduğunu ortaya koymaktadır.

Tespit edilen kusurlu ve kusursuz yüzeylerin sınıflandırılmasındaki başarımlar karmaşıklık matrisi ile verilebilmektedir. Birinci model kullanılarak elde edilen karmaşıklık matrisi Şekil 9.3'te gösterilirken, bu matristeki veriler Çizelge 9.7'de tablo halinde verilmiştir.




Şekil 9.3 I. Model Uygulanan Seramik Görsellerin Sınıflandırmasına Ait Karmaşıklık Matrisi.

Çizelge 9.7 I. Model Uygulanan Seramik Görsellerin Sınıflandırmasına Ait Karmaşıklık Matrisi

Gerçek / Tahmin	ffcref (Kusursuz)	Kusurlu (Defective)
ffcref (Gerçek Kusursuz)	3752 (Doğru sınıflandırıldı)	184 (Yanlış sınıflandırıldı)
Kusurlu (Gerçek Kusurlu)	702 (Yanlış sınıflandırıldı)	3234 (Doğru sınıflandırıldı)

Şekil 9.7'de karmaşıklık matrisine bakılarak yapılan sınıflandırma işleminde modelin kusursuz (ffcref) ürünlerin çoğunu doğru tahmin ettiği görülmektedir. Model, kusursuz sınıfını (ffcref) oldukça iyi tanımaktadır. Kusurlu ürünlerde ise 3234 kusurlu ürün doğru tahmin edilirken, 702 kusurlu ürün yanlışlıkla kusursuz (ffcref) olarak etiketlenmiştir. Model kusurlu ürünlerde %17.84, kusursuz ürünlerde ise %4.67 oranında hata yapmaktadır. Modelin test doğruluğu %88.75'tir. Bu sonuçlar kusurlu modelleri daha belirginleştirecek bir eğitim sürecinin uygulanması gerektiğini ortaya koymaktadır.

Öte yandan, modelin sınıflandırma başarımları, eğitim ve doğrulama süreçlerine ait kayıp ile doğruluk değerlerinin zamana bağlı değişimini gösteren grafikler aracılığıyla da değerlendirilebilmektedir. İlgili eğitim ve doğrulama doğruluğu ile kayıp grafiklerine Şekil 9.4'te sunulmaktadır.



Şekil 9.4 I. Model ile Elde Edilen Eğitim ve Doğrulama Kaybı ile Eğitim ve Doğrulama Doğruluğu Grafikleri.

Elde edilen sonuçlar doğrultusunda modelin oldukça yüksek doğruluk oranına sahip olduğu görülmektedir. %88,75 doğruluk oranı, modelin kusurlu ve kusursuz sınıfları başarılı şekilde ayırt edebildiğini göstermektedir. AUC değerinin 0.91 seviyesinde olması, modelin ROC eğrisi açısından iyi bir performans sergilediğini göstermektedir. F1-skorunun yüksek ve dengeli olması, modelin hem kusurlu hem de kusursuz sınıfları doğru sınıflandırmada başarılı olduğunu göstermektedir. Ayrıca, modelin başlangıçta rastgele tahmin yaparken, eğitim sürecinin ilerleyen epoklarında doğruluk ve AUC değerlerinde önemli bir artış gözlemlenmiştir. Bununla birlikte, eğitim ve doğrulama doğruluğundaki dalgalanmalar, kullanılan veri setinin model için zorlayıcı olabileceğini veya belirli sınıflar arasında dengesizliklerin mevcut olduğunu göstermektedir.

Genel olarak, elde edilen sonuçlar modelin başarılı bir şekilde eğitildiğini ve test verisinde yüksek bir performans sergilediğini ortaya koymaktadır. Ancak, eğitim ve doğrulama setindeki dalgalanmalar göz önünde bulundurularak modelin daha dengeli bir hale getirilmesi için ek iyileştirmeler yapılması gerektiği görülmektedir.

9.2 YENİDEN YAPILANDIRILMIŞ (HD+Sobel) GÖRSELLERİN SINIFLANDIRILMASI (II. Model)

Çalışmanın bu aşamasında HOGS ile elde edilen holografik görüntülere HD+Sobel uygulanarak yapılan sınıflandırma işlemi gerçekleştirilmiştir. Bu işlem çalışmada II. Model olarak adlandırılmıştır. II. Modelde HD+Sobel kullanılmasının nedeni 8. bölümdeki uygulamalarda diğer yöntemlere kıyasla en iyi başarıyı göstermesidir. Bu modele ait performans metrikleri ve bu metriklerle elde edilen sayısal veriler Çizelge 9.8 'de sunulmuştur.

Çizelge 9.8 II. Model Performans Metrikleri.

Tur (Epok)	Eğitim Doğruluğu (%)	Doğrulama Doğruluğu (%)	Özgüllük (%)	Kesinlik (%)	Geri Çağırma (%)	F1-Skoru (%)
1	60.41	58.00	65.00	58.37	58.93	58.65
2	61.41	59.66	65.00	60.56	60.10	60.33
3	62.88	61.24	66.88	62.04	61.86	61.95
4	64.38	62.62	68.23	62.86	63.38	63.12
5	65.87	62.69	67.76	63.11	63.53	63.32
6	67.22	64.45	69.98	65.23	65.10	65.16
7	69.10	66.35	71.12	67.45	67.08	67.26
8	70.35	68.00	72.45	69.30	68.98	69.14
9	72.02	70.12	74.55	70.88	70.53	70.70
10	73.78	71.45	75.78	72.20	72.08	72.14
11	75.35	73.02	77.45	74.00	73.78	73.89
12	76.90	74.40	78.90	75.95	75.65	75.80
13	78.45	76.25	80.50	77.44	77.12	77.28
14	79.78	77.90	81.75	78.69	78.50	78.59
15	81.05	79.55	83.12	80.23	80.10	80.16
16	82.30	81.10	84.50	81.60	81.35	81.48
17	84.05	82.80	86.20	83.12	83.00	83.06
18	85.50	84.20	87.50	84.90	84.65	84.77
19	87.10	86.00	89.10	86.44	86.22	86.33
20	88.45	87.50	90.55	87.80	87.60	87.70
21	89.90	88.75	91.78	89.00	88.80	88.90
22	91.05	90.10	93.12	90.15	90.00	90.07
23	92.20	91.35	94.30	91.25	91.10	91.17
24	93.10	92.45	95.45	92.40	92.30	92.35
25	94.00	93.55	96.50	93.55	93.40	93.47
26	94.85	94.15	97.00	94.10	94.00	94.05
27	95.50	95.00	97.50	94.90	94.80	94.85
28	96.10	95.60	97.80	95.55	95.50	95.52
29	96.50	96.10	97.95	96.10	96.05	96.08
30	97.00	96.50	98.00	96.50	96.40	96.45

Çizelge 9.8’te sunulan sayısal verilerin değerlendirilmesi ve turlar arası model performans Analizi Bölüm 9.1’de olduğu gibi 3 başlık altında yapılmıştır. Bu üç başlık sırasıyla, başlangıç, orta ve ileri dönem olarak adlandırılmıştır. Başlangıç dönemi, ilk 5 tura ait verileri sunarken, orta dönem 6-15 turlar arasındaki verileri göstermektedir. 16-30 turlar arasındaki veriler ise ileri dönem olarak tanımlanmıştır.

•Başlangıç Dönemi (Epok 1-5)

Eğitim sürecinin ilk aşamalarında modelin doğruluk seviyesi %60.41 civarında başlamış ve kısa sürede %64.38 seviyelerine kadar yükselmiştir. Modelin ağırlıkları henüz optimal seviyeye ulaşmadığı için, özgüllük, kesinlik ve geri çağırma metriklerinde belirgin dalgalanmalar gözlemlenmiştir.

Bu dönemde doğrulama doğruluğunun eğitim doğruluğuna kıyasla daha düşük olması, modelin aşırı öğrenme riski taşımadığını göstermektedir. Ancak, modelin kararlılığı tam olarak oluşmadığı için bazı epoklarda doğrulukta ani değişimler gözlenmiştir.

Özgüllük değeri başlangıçta %65.00 olup modelin kusursuz ürünleri ayırt etme konusunda henüz iyi bir performans göstermediğini ortaya koymaktadır. Bununla birlikte, F1-Skoru ve kesinlik değerleri %58.65 seviyelerinde kalmış, modelin tahmin performansının henüz istikrarlı bir noktaya ulaşmadığını göstermektedir.

•Orta Dönem (Epok 6-15)

Bu dönemde modelin öğrenme süreci daha istikrarlı hale gelmiş ve doğruluk seviyesi hızla yükselerek %73.78 seviyelerine ulaşmıştır. Epok 10 itibarıyla doğruluk %73.78, kesinlik %72.20 ve geri çağırma %72.08 seviyelerine ulaşmıştır.

Bu sonuçlar, modelin hem kusurlu hem de kusursuz örnekleri daha iyi ayırt edebildiğini ve eğitim sürecinde başarılı bir dengelenme sağlandığını göstermektedir. Özgüllük değeri %75.78 seviyesine ulaşarak yanlış pozitif tahminlerin giderek azaldığını ve modelin daha güvenilir tahminler yapmaya başladığını göstermektedir.

Ayrıca, doğrulama doğruluğunun eğitim doğruluğuna yaklaşması, modelin genelleme yeteneğinin geliştiğini göstermektedir. Ancak, bazı epoklarda doğrulama doğruluğunda küçük dalgalanmalar gözlemlenmiştir. Bu durum, modelin bazı örneklerde karar verme hassasiyetinin henüz tam olarak oturmadığını düşündürmektedir.

• İleri Dönem (Epok 16-30)


Son epoklarda modelin doğruluk değeri %97.00 seviyelerine ulaşmış ve metriklerde istikrarlı bir performans sergilenmiştir. Kesinlik, geri çağırma ve F1-Skoru gibi değerler, %96.5 seviyelerine ulaşarak sabitlenmiştir. Bu noktada modelin eğitim sürecini büyük ölçüde tamamladığı ve karar mekanizmasının daha sağlam hale geldiği görülmektedir.

Özgüllük değeri %98.00 seviyesine ulaşmış olup, kusursuz ürünlerin yanlış pozitif olarak tahmin edilme oranı minimum seviyeye inmiştir. Bu, modelin karar mekanizmasının yüksek güvenilirlikle çalıştığını göstermektedir.

Bunun yanı sıra, eğitim doğruluğu ile doğrulama doğruluğu arasındaki farkın %1'den az olması, modelin aşırı öğrenme (overfitting) yapmadığını göstermektedir. Modelin genelleme kapasitesi yüksektir ve bu doğrultuda test verisinde başarılı olacağı öngörülmektedir.

Modelin kesinlik ve geri çağırma oranlarının birbirine yakın olması, tahmin dengesinin sağlandığını ve modelin yanlış negatifleri minimum seviyeye indirdiğini göstermektedir. Bu sayede, hem kusurlu hem de kusursuz örnekler başarılı şekilde sınıflandırılmıştır.

Şekil 9.5'te II. Modele ait elde edilen ROC eğrisi gösterilmiştir. Bu grafikte yer alan doğru pozitif oranı (DPO), gerçekten pozitif olan örneklerin ne kadarını doğru bir şekilde pozitif olarak sınıflandırdığını göstermektedir. Bu, aynı zamanda "duyarlılık" veya "recall" olarak da adlandırılmaktadır. Diğer yandan yanlış pozitif oranı (YPO) ise modelin, aslında negatif olan örneklerin ne kadarını yanlışlıkla pozitif olarak sınıflandırdığını göstermektedir. Elde edilen ROC eğrisinin sol üst köşeye yakın olduğu görülmektedir. Bu sonuç modelin hem DPO'nın yüksek hem de YPO'nın düşük olduğunu, yani iyi ayırt edici özelliklere sahip olduğunu göstermektedir.




Şekil 9.5 II. Modele Ait Elde Edilen ROC Eğrisi.

Bu bölümde II. Model kullanıldığında test verisinin performansının nasıl değiştiği analiz edilmiştir. Kullanılan performans metrikleri ve ulaşılan sayısal veriler yorumlar Çizelge 9.9’da verilmiştir.

Çizelge 9.9 II. Model Kullanıldığında Test Verisi Üzerindeki Performans Değerlendirmesi.

Performans Metrikleri	Değer	Açıklama
Doğruluk (Accuracy)	%96.68	Test verisindeki doğru sınıflandırma oranı.
ROC (Receiver Operating Characteristic) Eğrisi Altında kalan alan (AUC)	0.97	ROC Eğrisi altında kalan alanı gösterir. Modelin sınıflar arası ayırım gücünün yüksek olduğunu göstermektedir.
Kayıp (Cross-Entropy ile hesaplanan)	0.47	Düşük kayıp değeri, modelin aşırı öğrenmeden kaçındığını göstermektedir.
Ağırlıklı Kesinlik	%96.67	Her iki sınıfın örnek sayısına göre ağırlıklandırılmış ortalama kesinlik değeri.
Ağırlıklı Duyarlılık	%96.75	Her iki sınıfın örnek sayısına göre ağırlıklandırılmış ortalama geri çağırma değeri.
Ağırlıklı F1 Skoru	%96.57	Kesinlik ve geri çağırmanın dengeli birleşimi; modelin her iki sınıfa da başarılı tahmin yaptığını gösterir.

II. model kullanılarak tespit edilen kusurlu ve kusursuz yüzeylere ait çıkartılan karmaşıklık matrisi ve bu matristeki sayısal veriler sırasıyla Şekil 9.6’da ve Çizelge 9.10’da verilmiştir.




Şekil 9.6 II. Model Uygulanan Seramik Görsellerin Sınıflandırmasına Ait Karmaşıklık Matrisi.

Çizelge 9.10 II. Model Uygulanan Seramik Görsellerin Sınıflandırmasına Ait Karmaşıklık Matrisi

Gerçek / Tahmin	ffcref (Kusursuz)	kusurlu (Defective)
ffcref (Gerçek Kusursuz)	3770 (Doğru sınıflandırıldı)	14 (Yanlış sınıflandırıldı)
kusurlu (Gerçek Kusurlu)	248 (Yanlış sınıflandırıldı)	3840 (Doğru sınıflandırıldı)

Elde edilen karmaşıklık matrisi, modelin kusursuz (ffcref) ve kusurlu sınıfları ayırt etme başarısını ortaya koymaktadır. Model, kusursuz ürünleri %99.63, kusurlu ürünleri ise %93.94 doğruluk oranıyla başarılı bir şekilde sınıflandırmıştır. Genel doğruluk oranının (test doğruluğu) %96.68 olması, modelin yüksek güvenilirlikle çalıştığını göstermektedir. Bununla birlikte, toplamda 262 yanlış sınıflandırılmış örnek bulunmakta olup, bunların 248’i (%6.07’si) kusurlu olmasına rağmen kusursuz olarak etiketlenmiştir. Bu durum göz önünde bulundurulduğunda, modelin performansının daha da artırılması için veri artırma) tekniklerinin veya ek veri kullanımının faydalı olabileceği değerlendirilmektedir. Genel olarak, modelin pratik uygulamalar için yeterli bir başarıya ulaştığı ve kusurlu ile kusursuz sınıfları yüksek doğruluk oranıyla ayırt edebildiği görülmektedir. Modelin yüksek keskinlik ve duyarlılık değerlerine sahip olması, sınıflandırma performansının güçlü olduğunu ve güvenilir sonuçlar ürettiğini kanıtlamaktadır.

Bu modelin başarımını göstermek için Şekil 9.6 'da eğitim ve doğrulama kaybı ile eğitim ve doğrulama doğruluğu grafikleri sunulmuştur.



Şekil 9.7 II. Model ile Elde Edilen Eğitim ve Doğrulama Kaybı ile Eğitim ve Doğrulama Doğruluğu Grafikleri.

Elde edilen sonuçlar, modelin başarılı bir şekilde öğrenme sürecini tamamladığını ve %96'nın üzerinde (test doğruluğu) doğruluk ile yüksek performans gösterdiğini ortaya koymaktadır. Başlangıç aşamasında rastgele tahminler yapan model, Epok 6'dan itibaren belirgin bir şekilde öğrenmeye başlamış ve Epok 16'dan sonra stabil hale gelerek optimum doğruluk seviyesine ulaşmıştır. Eğitim ve doğrulama doğruluklarının paralel şekilde ilerlemesi, modelin overfitting problemini yaşamadığını göstermektedir. Genel olarak, bu modelin kusurlu ve kusursuz sınıflar arasındaki ayrımı başarıyla gerçekleştirdiği ve endüstriyel kullanım için uygun olduğu kanaatine varılmıştır. Modelin daha da stabil hale gelmesi ve doğruluk oranının artırılması için daha fazla veri ile eğitim yapılması, veri arttırma (data augmentation) tekniklerinin uygulanması ve dropout oranlarının optimize edilmesi önerilmektedir.



BÖLÜM 10

SONUÇLAR VE TARTIŞMA

Bu çalışmada, seramik yüzeylerindeki kusurların tespiti amacıyla hibrit optik görüntüleme sistemi (HOGS) ve çeşitli görüntü işleme tekniklerinden yararlanılmıştır. Çalışmanın temel hedefi, insan gözüyle algılanması güç olan mikro düzeydeki yüzey kusurlarını nesnel biçimde tespit etmek ve sınıflandırmaktır. HOGS sistemi ile elde edilen interferometrik görüntüler üzerinde gerçekleştirilen analizler, yüzey topografyasındaki nanometrik düzeydeki değişimleri dahi hassasiyetle belirleyebilmiştir. Bu sayede, geleneksel yöntemlerle fark edilemeyen ancak ürün kalitesini doğrudan etkileyen mikro çatlaklar, hava boşlukları ve yüzey düzensizlikleri başarılı bir şekilde tespit edilmiştir.

Görüntü işleme sürecinde, faz dönüşüm yöntemleri (Hilbert, Fourier, Mexican Hat, Morlet) ile kenar belirleme algoritmaları (Canny, Prewitt, Sobel) kullanılmış ve bu yöntemler farklı çözünürlük seviyelerine sahip, net, orta bulanık ve bulanık olmak üzere en az üç görsel üzerinde uygulanarak karşılaştırmalı analizler gerçekleştirilmiştir. Yapılan değerlendirmelerde, HD tekniği, kusurlu bölgeleri diğer yöntemlere kıyasla daha başarılı şekilde tespit etmiştir. Özellikle z-ekseni üzerindeki genlik değerlerinde gözlemlenen maksimum ve minimum farklar, kusurların lokalizasyonunda belirleyici bir kriter olarak öne çıkmıştır. MHDD detaylı sonuçlar üretmesine karşın, düşük kontrastlı bölgelerde yüksek gürültü seviyesi nedeniyle performans açısından sınırlamalar göstermiştir. Buna karşılık, FD yüzey kusurlarını belirlemede yetersiz kalmış ve genel olarak düşük başarı sergilemiştir. Bu sonuçlar, faz dönüşüm tekniklerinin kusur tespitindeki etkinliğinin görüntü çözünürlüğü ve yüzey özelliklerine bağlı olarak değiştiğini göstermektedir.

Kenar tespit algoritmalarının değerlendirilmesinde, HD ile birleştirilen hibrit yaklaşımlar test edilmiştir. Bu kapsamda uygulanan Hilbert+Canny, Hilbert+Prewitt ve Hilbert+Sobel kombinasyonları arasında en yüksek performans, Hilbert+Sobel yaklaşımıyla elde edilmiştir. Bu yöntem, hem makro düzeydeki yüzey dalgalanmalarını hem de mikro düzeydeki noktasal

kusurları yüksek doğrulukla tespit etmiştir. Sobel filtresi, kenar yönelimine olan duyarlılığı, gürültülü ortamlarda kararlı performansı ve kenar yapısına olan hassasiyeti sayesinde öne çıkmıştır. Hilbert+Prewitt kombinasyonu orta düzeyde başarı sağlarken, Hilbert+Canny yöntemi ise kenar tespitinde beklenen etkinliği gösterememiştir. Elde edilen sonuçlar, kenar belirleme algoritmalarının, uygun faz dönüşüm tekniğiyle entegre edildiğinde kusur tespitinde önemli ölçüde performans artışı sağlayabileceğini ortaya koymuştur.

Mikroskobik boyuttaki kusurların tespitine yönelik olarak geliştirilen “en parlak piksel analizi” yöntemi, özellikle hava kabarcığı gibi noktasal ve gözle fark edilemeyecek düzeyde küçük kusurların belirlenmesinde yüksek başarı göstermiştir. Bu teknik, 10 mikron altı boyuttaki kusurları bile tanımlayarak, geleneksel yöntemlerin ötesinde bir hassasiyet sağlamıştır. Bu bulgular, yöntemin endüstriyel kalite kontrol süreçlerinde tamamlayıcı ve kritik bir analiz aracı olarak kullanılabileceğini göstermektedir.

Derin öğrenme mimarisi olarak ResNet-50 kullanılarak iki farklı veri seti üzerinde sınıflandırma gerçekleştirilmiştir. Doğrudan HOGS görüntüleriyle eğitilen model %85 doğruluk oranı elde ederken, görüntü işleme teknikleriyle ön işlemden geçirilen görsellerle eğitilen modelin doğruluk oranı %96’ya yükselmiştir. Bu sonuçlar, uygun ön işleme adımlarının derin öğrenme mimarilerinin performansını anlamlı ölçüde artırabileceğini ortaya koymaktadır. Özellikle noktasal ve düşük kontrastlı kusurların tespitinde, görüntü işleme ile zenginleştirilmiş verilerin sınıflandırma başarımına doğrudan katkı sağladığı görülmüştür.

Gelecek çalışmalarda, sistemin performansını daha da artırmaya yönelik çeşitli iyileştirmeler planlanmaktadır. İlk olarak, özellikle Vision Transformer tabanlı modeller olmak üzere, farklı derin öğrenme mimarilerinin sınıflandırma performansları incelenecektir. Bununla birlikte, gerçek zamanlı uygulamalara yönelik olarak adaptif görüntü işleme algoritmalarının geliştirilmesi hedeflenmektedir. Ayrıca, geliştirilen sistemin genelleme yeteneğini değerlendirmek amacıyla, farklı seramik türleri (porselen, fayans, teknik seramikler vb.) üzerinde testler gerçekleştirilecektir. Son olarak, sistemin bulut tabanlı ve dağıtık bir kalite kontrol altyapısına entegre edilerek endüstriyel ölçekli uygulamalara uygun hale getirilmesi amaçlanmaktadır.

Bu çalışmanın en önemli katkısı, seramik endüstrisinde kalite kontrol süreçlerinin tam otomasyona geçirilmesine olanak sağlayacak bir sistem önerisidir. Geliştirilen yaklaşım, yalnızca seramik karo yüzeylerine değil, benzer yüzey özelliklerine sahip cam paneller, metal yüzeyler ve kompozit malzemeler gibi diğer endüstriyel ürünlere de uygulanabilecek geniş bir kullanım potansiyeline sahiptir. Elde edilen sonuçlar, sistemin Endüstri 4.0 kapsamında yer alan otomatik kalite kontrol alanına önemli bir katkı sunduğunu göstermektedir.





KAYNAKLAR

- [1] **Uluç Ergüven E** (2015) Seramik Yer ve Duvar Kaplama Sektöründe Toz Maruziyetinin İş Hijyeni Açısından Değerlendirilmesi. *Uzmanlık Tezi*, T.C. Çalışma ve Sosyal Güvenlik Bakanlığı İş Sağlığı ve Güvenliği Genel Müdürlüğü, Ankara, 63 s.
- [2] **Karamanlı İ A ve Günay M** (2022) Seramik Malzemelerin İşlenmesinde Uygulanan Alışılmamış İmalat Yöntemleri. *KONJES*, 10(4): 1061–1082.
- [3] **Kara O, Erdal H ve Çelik H H** (2017) Tahribatsız Test Yöntemleri: Karşılaştırmalı Bir Derleme Çalışması. *MFBD*, 29(3): 82–93.
- [4] **Wang H, Li Y, Pan Q, Xu C, Zhao X and Xia S** (2012) Ultrasonic Transmission Method For Testing Curved Composite Parts. *International Conference on Mechatronics and Automation (ICMA)*, 05-08 August 2012, Chengdu, China, 2093–2097.
- [5] **Ari A C** (2022) Kompozit Malzemelerin Tahribatsız Muayene Yöntemlerinden Olan Ultrasonik Test ile Ölçülmesi Üzerine Yapılan Çalışmaların İncelenmesi. *Uluslararası Mühendislik, Tasarım ve Teknoloji Dergisi*, 1–2.
- [6] **Taskin M, Elazig U C and Turkmen M** (2011) X-Ray Tests Of AISI430 And 304 Stainless Steels And AISI 1010 Low Carbon Steel Welded By CO₂ Laser Beam Welding. *Radiography*, 53(11–12): 741–747.
- [7] **Kurama S, Görgülü S ve Eren E** (2011) Görüntü İşleme Tekniği ile Porselen Karoların İncelenmesi. *Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 24(2): 133–143.
- [8] **Meinlschmidt P** (2005) Thermographic Detection Of Defects in Wood And Wood-Based Materials. *14th International Symposium of Nondestructive Testing of Wood*, 2–4 May 2005, Hannover, Germany, 2–4.
- [9] **Maldague X P V** (2001) Theory And Practice Of İnfrared Technology For Nondestructive Testing. ISBN: 978-0-471-18190-3, *John Wiley & Sons*, 703–704.
- [10] **Cho Y, Lee D, Chung K R, Kim Y and Yun S H** (2007) The Fus3/Kss1 MAP Kinase Homolog Amk1 Regulates The Expression Of Genes Encoding Hydrolytic Enzymes in *Alternaria Brassicicola*. *Fungal Genetics and Biology*, 44(6): 543–553.
- [11] **Sun L, Li Y, Li C, Wang L and Wu J** (2010) Active Defects Detection And Localization Using Acoustic Emission Method. *8th World Congress on Intelligent Control and Automation (WCICA)*, 07-09 July 2010, Jinan, China, *IEEE*, 5348–5351.

KAYNAKLAR (devam ediyor)

- [12] **URL-1** <<https://web.itu.edu.tr/~arana/ndt.pdf>>, Ziyaret tarihi: 30.01.2025.
- [13] **URL-2** <<https://www.linkedin.com/pulse/video-optik-kameralı-ölçüm-sistemleri-ile-üretim-süreçleri-qw43f/>> , Ziyaret tarihi: 30.01.2025.
- [14] **Ewald A J, McBride H, Reddington M, Fraser S E and Kerschmann R** (2002) Surface Imaging Microscopy, an Automated Method for Visualizing Whole Embryo Samples in Three Dimensions at High Resolution. *Developmental Dynamics: An Official Publication of the American Association of Anatomists*, 225(3): 369–375.
- [15] **Ustabaş Kaya G** (2023) Development of Hybrid Optical Sensor Based on Deep Learning to Detect and Classify the Micro-Size Defects in Printed Circuit Board. *Measurement*, 2023, 206:112247.
- [16] **Falk O A and Marsavina I** (2019) Experimental Determination of Strain Distribution on Printed Circuit Boards Using Digital Image Correlation. *Procedia Structural Integrity*, 18: 214–222.
- [17] **Tsenev V, Videkov V and Spasova N** (2021) Measurement of PCB Deformation During Parametric Testing And Evaluation of the Impact on the Installed Components. *International Scientific Conference Electronics (ET)*, 15-17 September 2021, Sozopol, Bulgaria, *IEEE*, 1–4.
- [18] **Kim T, Choi Y and Ko Y H** (2021) Development of Underwater 3D Shape Measurement System with Improved Radiation Tolerance. *Nuclear Engineering and Technology*, 53(4): 1189–1198.
- [19] **Tran V L and Lin H Y** (2018) A Structured Light RGB-D Camera System For Accurate Depth Measurement. *International Journal of Optics*, 2018(1): 8659847.
- [20] **Khokhlov M, Fischer A and Rittel D** (2012) Multi-Scale Stereo-Photogrammetry System for Fractographic Analysis Using Scanning Electron Microscopy. *Experimental Mechanics*, 52: 975–991.
- [21] **Wang Y, Xie F, Ma S and Dong L** (2017) Review of Surface Profile Measurement Techniques Based on Optical Interferometry. *Optics and Lasers in Engineering*, 93: 164–170.
- [22] **Hariharan P** (2003) *Optical Interferometry*. 2nd edition, ISBN: 978-0-12-311630-7, 9-55.
- [23] **Malacara D, Servin M and Malacara Z** (2018) *Interferogram Analysis For Optical Testing*. ISBN: 9781315221021, CRC Press, 568 pp.

KAYNAKLAR (devam ediyor)

- [24] **Cheng-Yang L, Yen T P and Chien-Wen C** (2020) High-Resolution Three-Dimensional Surface Imaging Microscope Based on Digital Fringe Projection Technique. *Measurement Science Review*, 20(3): 139–144.
- [25] **Yin Y, Wang M, Gao B Z, Liu X and Peng X** (2015) Fringe Projection 3D Microscopy with the General Imaging Model. *Optics Express*, 23(5): 6846–6857.
- [26] **Yang T D, Kim H J, Lee K J, Kim B M and Choi Y** (2016) Single-Shot and Phase-Shifting Digital Holographic Microscopy Using A 2-D Grating. *Optics Express*, 24(9): 9480–9488.
- [27] **Wu R, Wu H, Arola D and Zhang D** (2016) Real-Time Three-Dimensional Digital Image Correlation for Biomedical Applications. *Journal of Biomedical Optics*, 21(10): 107003.
- [28] **Wang Y, Xie F, Ma S and Dong L** (2017) Review of Surface Profile Measurement Techniques Based on Optical Interferometry. *Optics and Lasers in Engineering*, 93: 164–170.
- [28] **Van der Jeught S and Dirckx J J** (2016) Real-Time Structured Light Profilometry: A Review. *Optics and Lasers in Engineering*, 87: 18–31.
- [29] **Zuo C, Feng S, Huang L, Tao T, Yin W and Chen Q** (2018) Phase Shifting Algorithms for Fringe Projection Profilometry: A Review. *Optics and Lasers in Engineering*, 109: 23–59.
- [30] **Kemao Q** (2004) Windowed Fourier Transform for Fringe Pattern Analysis. *Applied Optics*, 43(13): 2695–2702.
- [31] **Proll K P, Nivet J M, Körner K and Tiziani, H J** (2003) Microscopic Three-Dimensional Topometry With Ferroelectric Liquid-Crystal-On-Silicon Displays. *Applied Optics*, 42(10): 1773–1778.
- [32] **Li D, Liu C and Tian J** (2014) Telecentric 3D Profilometry Based on Phase-Shifting Fringe Projection. *Optics Express*, 22(26): 31826–31835.
- [33] **Celik Bayar C, Onur T O, Ustabas Kaya G and Nazım K** (2024) Imaging of Foam Concrete Air Bubbles With an Alternative Method Of Combined Digital Holographic Microscopy. *Journal of Materials Science*, 59: 8706–8720.
- [34] **Ayenu-Prah A Y and Attah-Okine N O** (2009) Comparative Study of Hilbert–Huang Transform, Fourier Transform and Wavelet Transform in Pavement Profile Analysis. *Vehicle System Dynamics*, 47(4): 437–456.
- [35] **Liu G, Li M Z, Mao Z and Yang Q S** (2022) Structural Motion Estimation Via Hilbert Transform Enhanced Phase-Based Video Processing. *Mechanical Systems and Signal Processing*, 166: 108418.

KAYNAKLAR (devam ediyor)

- [36] **Kim H, Lee J, Anand A, Cho M and Lee M** (2023) Phase Differences Averaging (PDA) Method for Reducing The Phase Error in Digital Holographic Microscopy (DHM). *Journal of Information and Communication Convergence Engineering*, 21: 90–97.
- [37] **Kim H W, Cho M and Lee M C** (2022) Noise Filtering Method of Digital Holographic Microscopy for Obtaining an Accurate Three-Dimensional Profile of Object Using a Windowed Sideband Array (WiSA). *Sensors*, 22(13): 4844.
- [38] **Kim H W, Cho M and Lee M C** (2023) Noise Reduction Method Using a Variance Map of the Phase Differences in Digital Holographic Microscopy. *ETRI Journal*, 45(1): 131–137.
- [39] **Ahmed A S** (2018) Comparative Study Among Sobel, Prewitt and Canny Edge Detection Operators Used in Image Processing. *Journal of Theoretical and Applied Information Technology*, 96(19): 6517–6525.
- [40] **Wei P, Liu C, Liu M, Gao Y and Liu H** (2018) CNN-Based Reference Comparison Method for Classifying Bare PCB Defects. *The Journal of Engineering*, 1528–1533.
- [41] **Ustabaş Kaya G, Kocabaş S, Kartal S, Kaya H, Tekin İ O, Tigli Aydın R S and Kutoğlu Ş H** (2022) Detection of Airborne Nanoparticles with Lateral Shearing Digital Holographic Microscopy. *Optics and Lasers in Engineering*, 151: 106934.
- [42] **Ganin Y, Ustinova E, Ajakan H, Germain P, Larochelle H, Laviolette F, March M and Lempitsky V** (2016) Domain-Adversarial Training of Neural Networks. *Journal of Machine Learning Research*, 17(59): 1–35.
- [43] **McCulloch W S and Pitts W** (1943) A Logical Calculus of The Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 5: 115–133.
- [44] **Rumelhart D E, Hinton G E and Williams R J** (1986) *Learning Internal Representations by Error Propagation*. D E Rumelhart and J L McClelland (Eds.), MIT Press, vol 1: 318-362.
- [45] **Deng J, Dong W, Socher R, Li L J, Li K and Fei-Fei L** (2009) Imagenet: A Large-Scale Hierarchical Image Database. *IEEE Conference on Computer Vision and Pattern Recognition*, 20-25 June 2009, Miami, FL, 248–255.
- [46] **Krizhevsky A, Sutskever I and Hinton G E** (2012) Imagenet Classification with Deep Convolutional Neural Networks. *25th International Conference on Neural Information Processing Systems (NIPS'12)*. Lake Tahoe, NV, USA, 1097–1115.
- [47] **Dağlı İ ve Öztürk A** (2021) Görüntü Sınıflandırmada Derin Öğrenme Yöntemlerinin Karşılaştırılması. *Konya Mühendislik Bilimleri Dergisi (KONJES)*, 9(4): 872–888.

KAYNAKLAR (devam ediyor)

- [48] **Krizhevsky A** (2009) Learning Multiple Layers of Features From Tiny Images, *Master Thesis*, Department of Computer Science, University of Toronto, Toronto, 58.
- [49] **Akpınar B** (2019) Görüntü Sınıflandırma için Derin Öğrenme ile Bayeşçi Derin Öğrenme Yöntemlerinin Karşılaştırılması, *Yüksek Lisans Tezi*, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı, Afyon, 74 s.
- [50] **URL-3** <<https://malzemebilimi.net/seramikler.html>>, Ziyaret tarihi: 02.02.2025.
- [51] **URL-4** <<https://www.scribd.com/document/663123768103098/yapiend-seramik>>, Ziyaret tarihi: 02.02.2025.
- [52] **URL-5** <<https://www.yapideko.com/blog/icerik/seramik--uretimi-nedir--asamaları-nelerdir>>, Ziyaret tarihi: 02.02.2025.
- [53] **URL-6** <<https://cevresehiriklimkutuphanesi.csb.gov.tr/Books/Book/5b96Bd93b5-137c-41e2-a99a-7a1f98730ef4>>, Ziyaret tarihi: 02.02.2025.
- [54] **URL-7** <<https://naramica.com/blog/seramik-uretim-sureci>>, Ziyaret tarihi: 02.02.2025.
- [55] **Salahlı M A, Bayram V ve Bayram U** (2008) Seramik Karo Kalitesinin Görsel Parametrelere Göre Değerlendirilmesi. *ELECO 2008 - Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu*, Bursa, Türkiye, 322–324.
- [56] **Gültekin E E, Sarı H ve Kurama S** (2016) Seramik Sağlık Gereçlerinin Sinterleme Sıcaklığının Fiziksel Özelliklere ve Tahribatsız Muayene Yöntemine Etkisi. *AUJST-A*, 17(3): 438–446.
- [57] **Kreis T** (2005) *Handbook of Holographic Interferometry: Optical and Digital Methods (1st Ed.)*. Wiley-VCH Verlag GmbH & Co. KGaA.
- [58] **Kaya G** (2013) Fourier Dönüşümü ile Sayısal Faz Hologramının Elde Edilmesi, *Yüksek Lisans Tezi*, Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Zonguldak, 75 s.
- [59] **Bateman H** (1955). *The Mathematical Analysis of Electrical And Optical Wave Motion on The Basis of Maxwell's Equations*. Dover Publications, New York, USA, 159.
- [60] **Kaya H, Saraç Z, Özer M and Taşkın H** (2010) Optical Signal Processing Of Interference Fringes By Hartley Transform Method. *17th Slovak-Czech-Polish Optical Conference on Wave and Quantum Aspects of Contemporary Optics*, December 2010, SPIE, 7746: 567–576.
- [61] **Girişim URL-8** <<http://80.251.40.59/science.ankara.edu.tr/aozansoy/girisim.pdf>> Ziyaret tarihi: 10.02.2025.
- [62] **Hetch E** (1987) *Optics*, 2nd Edition, Addison-Wesley, Boston, 1-676.

KAYNAKLAR (devam ediyor)

- [63] URL-9 <<https://www.scientificamerican.com/article/what-is-an-optical-interf/>>, Ziyaret Tarihi: 10.02.2025.
- [64] Ustabaş Kaya G (2019) Sayısal Holografi Tekniğine Dayalı Ses Kaydedici ve Tahribatsız Muayene için Kullanılması, *Doktora Tezi*, Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Zonguldak, 117 s.
- [65] Wilson J and Hawkes J (2000) *Optoelectronics* (İ. Okur, Çev.), ISBN: 975-828-910-1, Değişim Yayınları, 518 s.
- [66] Schnars U and Jüptner W (2005) *Digital Holography: Digital Hologram Recording, Numerical Reconstruction and Related Techniques*, 1st edition, ISBN: 3-540-21934-x Springer-Verlag Berlin Heidelberg, 1-161.
- [67] Cooley J W, Lewis P A W and Welch P D (1969) The Fast Fourier Transform Algorithm: Programming Considerations in The Calculation Of Sine, Cosine and Laplace Transforms. *Journal of Sound and Vibration*, 12: 315–337.
- [68] Nahin P J (2006) *Dr. Euler's Formula: Cures Many Mathematical Ills*, ISBN:978069 1175911, Princeton University Press, New York, 1-416.
- [69] Born M and Wolf E (1999) *Principles Of Optics*, 7th edition, ISBN: 9781139644181, Cambridge University Press, New York, 1-237.
- [70] James D F V and Wolf E (1991) Spectral Changes Produced in Young's Interference Experiment. *Optics Communications*, 81: 150–154.
- [71] Schnars U, Falldorf C, Watson J and Jüptner W (2015) *Digital Holography And Wavefront Sensing*. ISBN: 978-3-662-44693-5, Springer.
- [72] URL-10 <<https://bilimgenc.tubitak.gov.tr/hologram-nasil-calisir>> Ziyaret tarihi: 15.02.2025.
- [73] Petrov V, Pogoda A, Sementin V, Sevryugin A, Shalymov E, Venediktov D and Venediktov V (2022) Advances in Digital Holographic Interferometry. *Journal of Imaging*, 8(7): 196.
- [74] Hernández-Montes M D S, Mendoza-Santoyo F, Flores Moreno M, de la Torre-Ibarra M, Silva Acosta L and Palacios-Ortega N (2020) Macro to Nano Specimen Measurements Using Photons and Electrons With Digital Holographic Interferometry: A Review. *Journal of the European Optical Society-Rapid Publications*, 16: 1–31.
- [75] Osten W, Faridian A, Gao P, Körner K, Naik D, Pedrini G, Singh A K Takeda M and Wilke M (2014) Recent Advances in Digital Holography. *Applied Optics*, 53(27): 44–63.
- [76] Rastogi V, Agarwal S, Kumar V and Shakher C (2019) Holographic Optical Element Based Digital Holographic Interferometer for the Study of Macro Flames, Micro Flames And Their Temperature Instability. *Optics and Lasers in Engineering*, 122: 29–36.

KAYNAKLAR (devam ediyor)

- [77] **Seo K B, Kim B M and Kim E S** (2014) Digital Holographic Microscopy Based on a Modified Lateral Shearing Interferometer for Three-Dimensional Visual Inspection of Nanoscale Defects on Transparent Objects. *Nanoscale Research Letters*, 9(1): 1–14.
- [78] **URL-11** <<http://optronis.com/nwp-content/uploads/2017/02/Camera-manual-english-1830-SU-02-N.pdf>>, Ziyaret tarihi: 18.02.2025.
- [79] **Hu Y, Chen Q, Tao T, Li H and Zuo C** (2017) Absolute Three-Dimensional Micro Surface Profile Measurement Based on a Greenough-Type Stereomicroscope. *Measurement Science and Technology*, 28(4): 045004.
- [80] **Wang Z, Nguyen D A and Barnes J C** (2010) Some Practical Considerations in Fringe Projection Profilometry. *Optics and Lasers in Engineering*, 48(2): 218–225.
- [81] **Cooley J W and Tukey J W** (1965) An Algorithm For The Machine Calculation of Complex Fourier Series. *Mathematics of Computation*, 19(90): 297–301.
- [82] **Duhamel P and Vetterli M** (1990) Fast Fourier Transforms: A Tutorial Review and a State of the Art. *Signal Processing*, 19(4): 259–299.
- [83] **Saikia S, Fernández-Robles L, Alegre E and Fidalgo E** (2021) Image Retrieval Based on Texture Using Latent Space Representation of Discrete Fourier Transformed Maps. *Neural Computing and Applications*, 33(20): 13301–13316.
- [84] **King F W** (2009). *Hilbert transforms*, 2nd edition, ISBN: 9780511735271, Cambridge University Press, New York, 1-696.
- [85] **Liu Y W** (2012) Hilbert Transform and Applications. *In Fourier Transform Applications*, 291–300.
- [86] **Bracewell R N** (1989) The Fourier Transform. *Scientific American*, 260(6): 86–95.
- [87] **Takeda M and Mutoh K** (1983) Fourier Transform Profilometry for the Automatic Measurement of 3-D Object Shapes. *Applied Optics*, 22(24): 3977–3982.
- [88] **Şeker H İ, Tuna M and Koyuncu İ** (2018) Design and Implementation of FPGA-Based Mexican Hat Wavelet for Real-Time Wavelet Transforming. *3rd International Conference on Engineering Technology and Applied Sciences (ICETAS)*, 17-21 July 2018, Skopje, Macedonia, 168-173.
- [89] **Battle J, Martí J, Ridao P and Amat J** (2002) A New FPGA/DSP-Based Parallel Architecture for Real-Time Image Processing. *Real-Time Imaging*, 8(5): 345–356.
- [90] **Sifuzzaman, M, Islam M R and Ali M Z** (2009) Application of Wavelet Transform and its Advantages Compared to Fourier Transform. *Journal of Physical Sciences*, 13: 121–134.

KAYNAKLAR (devam ediyor)

- [91] **Bilgehan B and Kavalcıoğlu C** (2020) Continuous Wavelet Transform (CWT) Based Filtering Method for Treating Type 1 Diabetes With Continuous Glucose Monitoring (CGM) Signals. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(2): 581–594.
- [92] **Haşiloğlu A** (2001) Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Döndürmeye Duyarsız Doku Analizi ve Sınıflandırma. *Turkish Journal of Engineering and Environmental Sciences*, 25: 405-413.
- [93] **Wang S, Wang J and Zhu T** (2015) High-Dimensional Resolution Enhancement in the Continuous Wavelet Transform Domain. *GeoConvention 2015: New Horizons*, 4-8 May 2015, Calgary, AB, Canada, 1-5.
- [94] **Lindsey A R** (1997) Wavelet Packet Modulation for Orthogonally Multiplexed Communication. *IEEE Transactions on Signal Processing*, 45(5): 1336-1339.
- [95] **Gonzalez-Nuevo J, Argüeso F, López-Caniego M, Toffolatti L, Sanz J L, Vielva P and Herranz D** (2006) The Mexican Hat Wavelet Family: Application to Point-Source Detection in Cosmic Microwave Background Maps. *Monthly Notices of the Royal Astronomical Society*, 369(4): 1603–1610.
- [96] **Karadağ A** (2009) Dalgacık Ağlarıyla Elektrokardiyografik Aritmilerin Sınıflandırılması, *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Ana Bilim Dalı, İstanbul, 73 s.
- [97] **Kabataş M B** (2014) Suspended Sediment Load Prediction By Using Wavelet-Fuzzy Logic Combination Model, *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Ana Bilim Dalı, İstanbul, 97 s.
- [98] **Timur E and Sarı C** (2010) Agora (Magnesia/Aydın) Manyetik Verilerinin Kenar Belirleme İşlemleri Ve 3-Boyutlu Ters Çözümle Modellenmesi. *Yerbilimleri*, 31(2): 67-82.
- [99] **Caya M V, Padilla D, Ombay G and Hernandez, A J** (2019) Detection and Counting Of Red Blood Cells in Human Urine Using Canny Edge Detection and Circle Hough Transform Algorithms. *IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)*, 29 November 2019- 01 December 2019, Laoag, Philippines, 1-5.
- [100] **Xu Z, Ji X, Wang M and Sun X** (2021) Edge Detection Algorithm of Medical Image Based on Canny Operator. *Journal of Physics: Conference Series*, 1955(1): 012080.
- [101] **Avcı D ve Çöteli R** (2018) Meksika Şapkası Dalgacık Görüntü Bölütlemesi ve Dalgacık Entropisi Tabanlı Akıllı Hedef Tanıma. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9(1): 13–26.

KAYNAKLAR (devam ediyor)

- [102] **Hoang N D and Nguyen Q L** (2018) Metaheuristic Optimized Edge Detection for Recognition of Concrete Wall Cracks: A Comparative Study on the Performances Of Roberts, Prewitt, Canny, And Sobel Algorithms. *Advances in Civil Engineering*, 2018(1): 7163580.
- [103] **Lynn N D, Sourav A I and Santoso A J** (2021) Implementation of Real-Time Edge Detection Using Canny and Sobel Algorithms. In *IOP Conference Series: Materials Science and Engineering* ,1096(1): 012079.
- [104] **Mathur N, Mathur S and Mathur D** (2016) A Novel Approach to Improve Sobel Edge Detector. *Procedia Computer Science*, 93: 431–438.
- [105] **Zhang K, Zhang Y, Wang P, Tian Y and Yang J** (2018) An Improved Sobel Edge Algorithm and FPGA Implementation. *Procedia Computer Science*, 131: 243–248.
- [106] **Gao W, Zhang X, Yang L and Liu H** (2010) An Improved Sobel Edge Detection. *3rd International Conference on Computer Science and Information Technology*, 09-11 July 2010, Chengdu, IEEE, 5: 67-71.
- [107] **Doğan F ve Türkoğlu İ** (2018) Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1): 10–21.
- [108] **Hinton G E, Srivastava N, Krizhevsky A, Sutskever I and Salakhutdinov R R** (2012) Improving Neural Networks by Preventing Co-Adaptation Of Feature Detectors. *arXiv preprint*, arXiv:1207.0580.
- [109] **Guo Y, Liu Y, Oerlemans A, Lao S, Wu S and Lew M S** (2016) Deep Learning For Visual Understanding: A Review. *Neurocomputing*, 187: 27–48.
- [110] **Chollet F** (2021) *Deep learning with Python*. 2nd edition, ISBN: 9781617296864, Simon & Schuster, USA, 1-504 pp.
- [111] **Aktürk S ve Serbest K** (2022) Nesne Tespiti için Derin Öğrenme Kütüphanelerinin İncelenmesi. *Journal of Smart Systems Research*, 3(2): 97–119.
- [112] **İnik Ö ve Ülker E** (2017) Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3): 85–104.
- [113] **Lee H, Grosse R, Ranganath R and Ng A Y** (2009) Convolutional Deep Belief Networks for Scalable Unsupervised Learning of Hierarchical Representations. *Proceedings of the 26th Annual International Conference on Machine Learning*. 609-616.
- [114] **Ciresan D C, Meier U, Masci J, Gambardella L M and Schmidhuber J** (2011) Flexible, High Performance Convolutional Neural Networks for Image Classification. *Twenty-second International Joint Conference on Artificial Intelligence*. Manno-Lugano, Switzerland 22(1):1237.

KAYNAKLAR (devam ediyor)

- [115] **Metlek S ve Kayaalp K** (2020) Derin Öğrenme ve Destek Vektör Makineleri ile Görüntüden Cinsiyet Tahmini. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(3): 2208–2228.
- [116] **Pang Y, Sun M, Jiang X and Li X** (2017) Convolution in Convolution For Network in Network. *IEEE Transactions on Neural Networks and Learning Systems*, 29(5): 1587–1597.
- [117] **Hinton G** (2010) A Practical Guide to Training Restricted Boltzmann Machines. *Momentum*, 9(1): 9–26.
- [118] **Nabiyev N and Malekzadeh, S** (2021) Anomalous Sound Localization Estimation.
- [119] **Aslan M** (2022) Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1): 399-407.
- [120] **Bulut F** (2017) Örnek Tabanlı Sınıflandırıcı Topluluklarıyla Yeni Bir Klinik Karar Destek Sistemi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 32(1).
- [121] **Siuly S, Alçin Ö F, Kabir E, Şengür A, Wang H, Zhang Y and Whittaker, F** (2020) A New Framework For Automatic Detection Of Patients With Mild Cognitive Impairment Using Resting-State EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(9): 1966-1976.
- [122] **Gülcü A and Kuş Z** (2019) A Survey Of Hyper-Parameter Optimization Methods in Convolutional Neural Networks. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 7(2): 503-522.
- [123] **Şişmanoğlu G, Koçer F, Önde M A ve Sahingöz O K** (2020) Derin Öğrenme Yöntemleri İle Borsada Fiyat Tahmini. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1): 434-445.
- [124] **Wilson D R and Martinez T R** (2003) The General Inefficiency of Batch Training for Gradient Descent Learning. *Neural Networks*, 16(10): 1429-1451.
- [125] **Kandel I and Castelli M** (2020) The Effect of Batch Size on The Generalizability of the Convolutional Neural Networks On A Histopathology Dataset. *ICT Express*, 6(4): 312-315.
- [126] **Radiuk P M** (2017) Impact of Training Set Batch Size on The Performance of Convolutional Neural Networks for Diverse Datasets. *Information Technology and Management Science*, 20(1):20-24
- [127] **Bengio Y** (2012) *Practical Recommendations for Gradient-Based Training of Deep Architectures*, In *Neural networks: Tricks of the trade*, 2nd edition, Berlin, Heidelberg: Springer Berlin Heidelberg, 437-478.
- [128] **Masters D and Luschi C** (2018) Revisiting Small Batch Training for Deep Neural Networks. *arXiv preprint arXiv:1804.07612*.

KAYNAKLAR (devam ediyor)

- [129] **He K, Zhang X, Ren S and Sun J** (2016) Deep Residual Learning For Image Recognition. *In Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
- [130] **Demuth H, Beale M and Hagan M** (1992) Neural Network Toolbox for Use with MATLAB. *The MathWorks Inc.*
- [131] **Sinha S, Singh T N, Singh V K and Verma A K** (2010) Epoch Determination for Neural Network by Self-Organized Map (SOM). *Computational Geosciences*, 14: 199-206.
- [132] **Tato A and Nkambou R** (2018) Improving Adam Optimizer. *Workshop track - ICLR*.
- [133] **Alpaydın G** (2018) An Adaptive Deep Neural Network for Detection and Recognition of Objects with Long Range Auto Surveillance. *IEEE 12th International Conference on Semantic Computing (ICSC)*, 31 January- 02 February 2018, Laguna Hills, CA, USA, IEEE, 316-317.
- [134] **Seyyarer E, Ayata F Uçkan T ve Karci A** (2020) Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması ve Kıyaslanması. *Computer Science*, 5(2): 90-98.
- [135] **URL-12** <<https://ruder.io/optimizing-gradient-descent/>>, Ziyaret tarihi: 20.02.2025.
- [136] **URL-13** <<https://medium.com/deep-learning-turkiye/gradient-descent-nedir-3ec6afcb9900>>, Ziyaret tarihi: 20.02.2025.
- [137] **Yazan E and Talu M F** (2017) Comparison of the Stochastic Gradient Descent Based Optimization Techniques. *International Artificial Intelligence and Data Processing Symposium (IDAP)*, 16-17 September 2017, Malatya, Turkey, IEEE, 1-5.
- [138] **Matthew D Z** (2012) Adadelta: An Adaptive Learning Rate Method. *arXiv preprint arXiv:1212.5701*.
- [139] **URL-14** <<https://towardsdatascience.com/10-gradient-descent-optimisation-algorithms-86989510b5e9>>, Ziyaret tarihi: 20.02.2025.
- [140] **Alpaydın E** (2011) Yapay Öğrenme. *Boğaziçi Üniversitesi Yayınevi*, 44-45.
- [141] **Buscema M** (1998) Back Propagation Neural Networks. *Substance Use & Misuse*, 33(2): 233-270.
- [142] **Igiri C P, Anyama O U and Silas A I** (2015) Effect Of Learning Rate On Artificial Neural Network in Machine Learning. *International Journal of Engineering Research & Technology (IJERT)*, February 2015, 4(2).
- [143] **Orriols-Puig A, Casillas J and Bernadó-Mansilla E** (2008) A Comparative Study of Several Genetic-Based Supervised Learning Systems. *In Learning Classifier Systems in Data Mining*, Berlin, Heidelberg: Springer Berlin Heidelberg, 205-230.

KAYNAKLAR (devam ediyor)

- [144] **Hoffer E Hubara I and Soudry D** (2017) Train Longer, Generalize Better: Closing the Generalization Gap in Large Batch Training of Neural Networks. *Advances in Neural Information Processing Systems*, 1-30.
- [145] **Srivastava N, Hinton G, Krizhevsky A, Sutskever I and Salakhutdinov R** (2014) Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *The Journal of Machine Learning Research*, 15(1): 1929-1958.
- [146] **Glorot X and Bengio Y** (2010) Understanding The Difficulty Of Training Deep Feedforward Neural Networks. In *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, JMLR Workshop and Conference Proceedings, 249-256.
- [147] **He K, Zhang X, Ren S and Sun J** (2015) Delving Deep into Rectifiers: Surpassing Human-Level Performance on Imagenet Classification. In *Proceedings of the IEEE International Conference on Computer Vision*, 1026-1034.
- [148] **Toğaçar M ve Ergen B** (2019) Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1): 109-121.
- [149] **Wu S, Zhong S and Liu Y** (2018) Deep Residual Learning for Image Steganalysis. *Multimedia Tools and Applications*, 77: 10437-10453.
- [150] **Doğan F ve Türkoğlu İ** (2019) Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2): 409-445.
- [151] **Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, Huang Z, Karpathy A, Khosla A, Bernstein M, Berg A C and Fei-Fei, L** (2015) Imagenet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115: 211-252.
- [152] **Nguyen G, Dlugolinsky S, Bobák M, Tran V, López García Á, Heredia I, Malik P and Hluchý, L** (2019) Machine Learning And Deep Learning Frameworks And Libraries For Large-Scale Data Mining: A Survey. *Artificial Intelligence Review*, 52: 77-124.
- [153] **Daşgın A** (2023) COVID19 Yayılımını Azaltmak için Yüz Maskesinin Evrişimsel Sinir Ağı Modelleri ile Tespiti, *Yüksek Lisans Tezi*, Aksaray Üniversitesi, Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri Ana Bilim Dalı, Aksaray, 66 s.
- [154] **Erdoğan A A** (2021) Derin Öğrenme Yöntemi ile El Yazısı Tanıma, *Yüksek Lisans Tezi*, Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Konya, 81 s.
- [155] **Aksoy İ** (2023) Görüntü Sınıflandırması için Evrişimsel Sinir Ağlarında Parametrelerin Sınıflandırma Performansına Etkisi, *Yüksek Lisans Tezi*, Aksaray Üniversitesi Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri Ana Bilim Dalı, Aksaray, 58 s.

ÖZGEÇMİŞ

Duygu DEMİRCAN, İlk ve orta öğrenimini Ankara’da tamamladı. Lise eğitimini Zonguldak Fen Lisesi’nde, lisans eğitimini ise 2017–2021 yılları arasında Zonguldak Bülent Ecevit Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü’nde aldı. 2023 yılı Şubat ayında aynı üniversitede, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı’nda yüksek lisans eğitimine başladı. 2024 yılı Aralık ayından itibaren Zonguldak Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü’nde araştırma görevlisi olarak görev yapmaktadır.