

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ÇOKLU-ODAKLI GÖRÜNTÜ BİRLEŞTİRME İÇİN YENİ YAKLAŞIMLAR

DOKTORA TEZ

Bil. Yük. Müh. SAMET AYMAZ

**MART 2022
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ÇOKLU-ODAKLI GÖRÜNTÜ BİRLEŞTİRME İÇİN YENİ YAKLAŞIMLAR

Bil. Yük. Müh. Samet AYMAZ

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 06 / 03 / 2022

Tezin Savunma Tarihi : 31 / 03 / 2022

Tez Danışmanı : Prof. Dr. Cemal KÖSE

Trabzon 2022

ÖNSÖZ

Tez çalışması kapsamında, aynı sahneye ait farklı odak noktaları içeren görüntülerin birleştirilerek tüm-odaklı tek bir görüntü oluşturulmasına yönelik Çoklu-odaklı görüntü birleştirme alanında iki yeni yaklaşım önerilmiştir. Bu yaklaşımlar, literatürdeki açıklıkları giderebilecek ve yeni çalışmalara yol gösterebilecek şekilde tasarlanmıştır.

Doktora eğitimim ve tez danışmanlığım boyunca ilgi, destek ve tecrübelerini esirgemeyen saygıdeğer hocam Prof. Dr. Cemal KÖSE'ye,

Bu süreçte pozitif enerjisi ve neşesi ile yorgunluk nedir hissettirmeyen oğlum Burak AYMAZ'a, sevgi ve desteğiyle her an yanımda olan eşim Şeyma AYMAZ'a ve değerli aileme teşekkürü bir borç bilirim.

Samet AYMAZ

Trabzon 2022

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Çoklu-odaklı Görüntü Birleştirme için Yeni Yaklaşımlar” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Cemal KÖSE’nin sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 31/03/2022

Samet AYMAZ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ	IV
İÇİNDEKİLER	V
ÖZET.....	X
SUMMARY	XI
ŞEKİLLER DİZİNİ.....	XII
TABLolar DİZİNİ	XXIII
SEMBOLLER DİZİNİ.....	XXV
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Literatür Araştırması	4
1.3. Çoklu-odaklı Görüntü Birleştirme	9
1.3.1. Çoklu-odaklı Görüntü Birleştirme Veri Setleri.....	9
1.3.2. Kaynak Görüntülere Uygulanacak Ön İşlemler.....	11
1.3.2.1. Bulanıklık Giderme Yöntemleri.....	11
1.3.2.2. Süper-çözünürlük Yöntemleri	12
1.3.3. Çoklu-odaklı Görüntü Birleştirme Seviyeleri	14
1.3.3.1. Piksel Seviyesi Birleştirme..	14
1.3.3.2. Özellik Seviyesi Birleştirme	15
1.3.3.3. Karar Seviyesi Birleştirme..	15
1.3.4. Çoklu-odaklı Görüntü Birleştirme Yöntemlerinin Sınıflandırılması.....	15
1.3.4.1. Uzamsal Alan Teknikler..	16
1.3.4.2. Frekans Alan Teknikler.....	17
1.3.4.3. Derin Öğrenmeye Dayalı Teknikler.....	17
1.3.5. Çoklu-odaklı Görüntü Birleştirme Kuralları.....	18
2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME.....	21
2.1. Giriş.....	21

2.2.	Gradyan-tabanlı Yeni Birleştirme Kuralı Kullanarak Süper- çözünürlüklü Farklı Veri Setleri İçin Çoklu-odaklı Görüntü Birleştirme	22
2.2.1.	Kullanılan Teorik Kavramlar	26
2.2.1.1.	Bikübik İnterpolasyon Yöntemi.....	26
2.2.1.2.	Sabit Dalgacık Dönüşümü.....	28
2.2.1.3.	Sobel-tabanlı Görüntü Gradyanı	30
2.2.2.	Önerilen Yöntem.....	31
2.2.2.1.	Yeni Veri Seti Oluşturulması.....	31
2.2.2.2.	Süper-çözünürlük ile Kaynak Görüntü Detaylarının Artırılması.....	32
2.2.2.2.1.	Bikübik İnterpolasyon Yöntemi ile Kaynak Görüntü Çözünürlüklerinin Artırılması.....	33
2.2.2.3.	Sabit Dalgacık Dönüşümü ile Kaynak Görüntülerin Ayırıştırılması	34
2.2.2.4.	Gradyan-tabanlı Birleştirme Kuralı.....	36
2.3.	Çoklu-odaklı Görüntü Birleştirmede Dinamik Karaz Mekanizması (DDM) ile Yeni Bir Yaklaşım	37
2.3.1.	Kullanılan Teorik Kavramlar	41
2.3.1.1.	Derin Öğrenmeye Dayalı Yaklaşımlar.....	41
2.3.1.1.1.	Çekişmeli Üretici Ağ (GAN) Tabanlı Yaklaşımlar	41
2.3.1.1.2.	Yinelemeli Sinir Ağları (RNN) Tabanlı Yaklaşımlar	42
2.3.1.1.3.	Evrişim Sinir Ağları (CNN) Tabanlı Yaklaşımlar	43
2.3.1.1.3.1.	Evrişim Sinir Ağları (CNN) Mimarisinin Yapı Taşları	44
2.3.1.1.3.1.1.	Evrişim Katmanı	44
2.3.1.1.3.1.1.1.	Evrişim İşlemi	44
2.3.1.1.3.1.2.	Aktivasyon Katmanı.....	45
2.3.1.1.3.1.2.1.	Sigmoid Aktivasyon Fonksiyonu.....	45
2.3.1.1.3.1.2.2.	Tanh Aktivasyon Fonksiyonu	46
2.3.1.1.3.1.2.3.	ReLu Aktivasyon Fonksiyonu.....	46
2.3.1.1.3.1.2.4.	LeakyReLu Aktivasyon Fonksiyonu	47
2.3.1.1.3.1.3.	Havuzlama Katmanı.....	48
2.3.1.1.3.1.3.1.	Maksimum Havuzlama İşlemi	48
2.3.1.1.3.1.3.2.	Küresel Ortalama Havuzlama İşlemi	49
2.3.1.1.3.1.4.	Tam-Bağılantılı Katmanı	49
2.3.1.2.	Derin Sinir Ağlarının Eğitilmesi	49

2.3.1.2.1.	Eğitim İçin Yaygın olarak Kullanılan Veri Setleri	50
2.3.1.2.1.1.	CIFAR-100 Veri Seti	50
2.3.1.2.1.2.	MNIST Veri Seti	50
2.3.1.2.1.3.	ImageNet Veri Seti.....	50
2.3.1.2.2.	Eğitim İçin Kullanılan Hiperparametreler	50
2.3.1.2.2.1.	Optimizasyon Parametreleri.....	51
2.3.1.2.2.1.1.	Öğrenme Katsayısı	51
2.3.1.2.2.1.2.	Dönem (Epoch) Sayısı	52
2.3.1.2.2.1.3.	Aktivasyon Fonksiyonu	52
2.3.1.2.2.1.4.	Miniparti Boyutu.....	52
2.3.1.2.2.2.	Model Parametreleri.....	52
2.3.1.2.2.2.1.	Katman Sayıları.....	52
2.3.1.2.2.2.1.1.	Gizli Katman Sayıları.....	53
2.3.1.2.2.2.2.	Kayıp Fonksiyonları.....	53
2.3.1.2.2.2.2.1.	Ortalama Kare Hatası (MSE) Kayıp Fonksiyonu	53
2.3.1.2.2.2.2.2.	Çapraz Entropi (Cross-Entropy) Kayıp Fonksiyonu.....	54
2.3.1.2.3.	Optimizasyon Yöntemleri	55
2.3.1.2.3.1.	Gradyan İnişi Optimizasyon Yöntemi	55
2.3.1.2.3.1.1.	Stokastik Gradyan İnişi Optimizasyon Yöntemi.....	55
2.3.1.2.3.1.2.	Mini-parti Gradyan İnişi Optimizasyon Yöntemi	56
2.3.1.2.3.2.	AdaGrad Optimizasyon Yöntemi.....	56
2.3.1.2.3.3.	Adam Optimizasyon Yöntemi	57
2.3.1.3.	Odak Ölçüm Metrikleri	58
2.3.1.3.1.	Gradyan-tabanlı Metrikler.....	58
2.3.1.3.1.1.	Gradyan Enerjisi (EOG).....	58
2.3.1.3.2.	Laplas-tabanlı Metrikler.....	59
2.3.1.3.2.1.	Laplas Enerjisi Metriği (EOL)	59
2.3.1.3.2.2.	Toplam-değiştirilmiş Laplas Metriği (SML)	60
2.3.1.3.3.	Dalgacık-tabanlı Metrikler	60
2.3.1.3.4.	İstatistiksel Metrikler	60
2.3.1.3.4.1.	Uzamsal Frekans (SF) Metriği	61
2.3.1.3.5.	DCT-tabanlı Metrikler	61
2.3.1.3.6.	Diğer Metrikler	62

2.3.1.4.	Morfolojik İşlemler	62
2.3.2.	Önerilen Yöntem.....	63
2.3.2.1.	Önerilen Çalışma İçin Veri Setlerinin Oluşturulması	64
2.3.2.1.1.	Eğitim Veri Seti Oluşturulması.....	64
2.3.2.1.2.	Çoklu-odaklı Görüntü Birleştirme İçin Yeni Veri Seti Oluşturulması	66
2.3.2.2.	Evrişim Sinir Ağları (CNN) Modeli Tasarlanması ve Görüntü Yamalarının Bu Ağa Beslenmesi	67
2.3.2.2.1.	Önerilen Çalışma İçin Tasarlanan CNN Modeli.....	67
2.3.2.2.2.	Kaynak Görüntülerin Önerilen Ağa Beslenmesi.....	70
2.3.2.3.	Önerilen İyileştirme Mekanizması.....	71
2.3.2.4.	Önerilen Birleştirme Kuralı.....	75
2.3.2.4.1.	Gradyan-tabanlı Birleştirme Kuralı.....	76
3.	BULGULAR VE İRDELEME.	79
3.1.	Tez Çalışmasında Kullanılan Veri Setleri.....	79
3.2.	Performans Ölçüm Metrikleri.	80
3.2.1.	Sübjektif Metrikler.....	81
3.2.1.1.	Ortalama Karekök Hatası (RMSE) Metriği.	82
3.2.1.2.	Yapısal Benzerlik (SSIM) Metriği.	82
3.2.1.3.	Maksimum Sinyal Gücü (PSNR) Metriği.	83
3.2.2.	Objektif Metrikler.	83
3.2.2.1	Standart Sapma (SD) Metriği.....	84
3.2.2.2.	Uzamsal Frekans (SF) Metriği.	84
3.2.2.3.	Karşılıklı Bilgi (MI) Metriği.	85
3.2.2.4.	QAB/F Metriği.	85
3.2.2.5.	Ortalama Gradyan (AG) Metriği.....	86
3.2.2.6.	Korelasyon Katsayısı (CC) Metriği.	86
3.3.	Gradyan-tabanlı Yeni birleştirme Kuralı Kullanılarak Süper-çözünürlüklü Farklı Veri Setleri İçin Çoklu-odaklı Görüntü Birleştirme Sonuçları	87
3.3.1.	Yeni Veri Seti İçin Objektif Değerlendirme Sonuçları.....	89
3.3.2.	Önerilen Çalışma İçin Sübjektif Değerlendirme Sonuçları	95
3.3.3.	Önerilen Çalışmanın Literatürdeki Çalışmalar ile Objektif Metrikler Kullanılarak Karşılaştırılması	98

3.3.4.	Önerilen Çalışmanın Literatürdeki Çalışmalar ile Sübjektif Metrikler Kullanılarak Karşılaştırılması	107
3.4.	Çoklu-odaklı Görüntü Birleştirmede Dinamik Karar Mekanizmalı Yeni Bir Yaklaşım İçin Sonuçlar.	110
3.4.1.	Yeni Veri Seti İçin Önerilen Çalışmanın Görsel ve Sayısal Sonuçları	111
3.4.2.	Durga Prasad Veri Seti İçin Görsel ve Sayısal Sonuçlar	123
3.4.3.	Lytro Veri Seti İçin Görsel ve Sayısal Sonuçlar	131
3.4.4.	Önerilen Çalışmanın Farklı Ağ Girişi Boyutları İçin Değerlendirme Sonuçları	141
3.5.	Tez Kapsamında Önerilen Çalışmaların Birbirleri ve Literatürdeki Çalışmalar ile Karşılaştırılması	143
4.	SONUÇLAR VE TARTIŞMA.	149
5.	ÖNERİLER.....	151
6.	KAYNAKLAR	153
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

ÇOKLU-ODAKLI GÖRÜNTÜ BİRLEŞTİRME İÇİN YENİ YAKLAŞIMLAR

Samet AYMAZ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Cemal KÖSE
2022, 163 Sayfa

Çoklu-odaklı görüntü birleştirme, aynı sahnenin farklı odak noktalarına sahip iki veya daha fazla görüntüsünün birleştirilerek tüm-odaklı bir görüntü oluşturulması işlemidir. Tez çalışmasında kusursuza yakın tüm-odaklı görüntüler elde edebilecek iki özgün yaklaşım önerilmektedir. Birinci yaklaşımda, bikübik-tabanlı süper-çözünürlük yöntemiyle kaynak görüntülerin detay bilgileri artırılarak Sabit Dalgacık Dönüşümü yardımıyla alt bileşenlerine ayrılmıştır. Sonuç olarak çoklu-odaklı görüntü birleştirme yöntemlerinin amacına uygun olarak tasarlanan gradyan-tabanlı birleştirme kuralı ile görüntüler birleştirilmiştir. Önerilen ikinci yaklaşım, öğrenmeye dayalı yenilikler içeren bir yaklaşımdır. Bu çalışma için renkli görüntülerden oluşan iki veya daha fazla kaynak görüntü içeren zengin bir veri seti oluşturulmuştur. Önerilen yöntemde, odaklı ve odaksız parçaları sınıflandırabilecek yeni bir CNN modeli tasarlanmıştır. Kaynak görüntüler ilk olarak önerilen bu mimarinin girdi katmanı boyutu olan 8x8'lik örtüşen bloklara ayrılarak önerilen ağa verilir ve her bir kaynak görüntü için ilk karar haritaları oluşturulur. Daha sonra, literatürde daha önce kullanılmayan odak metriklerine dayalı iyileştirme mekanizması yardımıyla, önerilen ağın kararsız kaldığı durumlar en aza indirgenmiştir. Son olarak dinamik karar mekanizmalı birleştirme kuralı yardımıyla birleştirilmiş görüntüler oluşturulur. Önerilen yaklaşımların çoklu-odaklı görüntü birleştirme amaçlarını gerçekleştirmede oldukça başarılı olduğu görülmektedir.

Anahtar Kelimeler: Derin Öğrenme, süper-çözünürlük, SWT, Gradyan-tabanlı füzyon, odak metrikleri, İnterpolasyon.

PhD Thesis

SUMMARY

NEW APPROACHES FOR MULTI-FOCUS IMAGE FUSION

Samet AYMAZ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Cemal KÖSE
2022, 163 Pages

Multi-focus image fusion is the process of combining two or more images of the same scene with different focus points to create a all-focus image. In this thesis, two unique approaches are proposed to obtain near-perfect all-focus images. In the first approach, the detail information of the source images is increased by bicubic-based super-resolution method and separated into subbbands with the help of Stationary Wavelet Transform. As a result, images are combined with the gradient-based fusion rule. The second proposed approach is based on learning that includes innovations at every step. For this approach, a rich dataset consisting of two or more color source images is created. Also, a new CNN model is designed to classify focused and unfocused parts. The source images are first divided into 8x8 overlapping blocks, which is the input layer size of this proposed architecture, and given to the proposed network, and initial decision maps are created for each source image. Then, with the help of the improvement mechanism based on focus metrics, which has not been used before in the literature, the cases where the proposed network is unstable are minimized. After this step, morphological operations are applied to the initial decision maps and final decision maps are created. Finally, the fused images are created with the help of the fusion rule with dynamic decision mechanism. It is seen that the approaches are quite successful in multi-focus image fusion.

Key Words: Deep-learning, Super-Resolution, SWT, Focus Metrics, Gradient-based Fusion, Interpolation

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1. Çoklu-odaklı görüntü birleştirme yöntemleri kullanım alanları	2
Şekil 1.2. Lytro veri setinden alınan örnek görüntüler	10
Şekil 1.2. (a) Sol-odaklı kaynak görüntü	10
Şekil 1.2. (b) Sağ-odaklı kaynak görüntü	10
Şekil 1.3. Durga Prasad veri setinden alınan örnek görüntüler	10
Şekil 1.3. (a) Pepsi sol-odaklı kaynak görüntü	10
Şekil 1.3. (b) Pepsi sağ-odaklı kaynak görüntü	10
Şekil 1.3. (c) Book sol-odaklı kaynak görüntü	10
Şekil 1.3. (d) Book sağ-odaklı kaynak görüntü	10
Şekil 1.4. En yakın komşuluk interpolasyonu matris gösterimi	12
Şekil 1.5. En yakın komşu interpolasyonu.....	13
Şekil 1.6. Çiftdoğrusal aradeğerleme.....	14
Şekil 1.7. Çoklu-odaklı görüntü birleştirme seviyeleri	14
Şekil 1.8. Çoklu-odaklı görüntü birleştirme yöntemleri	16
Şekil 1.9. Ortalama alma birleştirme kuralı	19
Şekil 1.10. Maksimumu seçme birleştirme kuralı.....	20
Şekil 2.1. Önerilen 1. çalışma akış diyagramı.....	25
Şekil 2.2. Bikübik interpolasyon.....	26
Şekil 2.3. Sabit dalgacık dönüşümü.....	28
Şekil 2.4. Sabit dalgacık dönüşümü ile görüntülerin ayrıştırılması	35
Şekil 2.5. Gradyan-tabanlı birleştirme kuralı.....	37
Şekil 2.6. Önerilen 2. çalışma akış diyagramı.....	40
Şekil 2.7. Çekişmeli üretici ağ (GAN) mimarisi örneği.....	42
Şekil 2.8. Yinelemeli sinir ağları (RNN) örnek mimari.....	42
Şekil 2.9. Evrişim sinir ağları (CNN) örnek mimari.....	43
Şekil 2.10. Tanh aktivasyon fonksiyonu.....	46
Şekil 2.11. Relu aktivasyon fonksiyonu.....	47
Şekil 2.12. LeakyRelu aktivasyon fonksiyonu.....	48
Şekil 2.13. Evrişim sinir ağları (CNN) hiper parametreler.....	51

Şekil 2.14. Morfolojik yapılar.....	62
Şekil 2.15. CIFAR-100 veri setinden alınan örnek görüntüler	65
Şekil 2.16. Oluşturulan yeni veri setinden alınan örnekler	66
Şekil 2.17 Önerilen çalışma için tasarlanan ağ modeli	68
Şekil 2.18. Kaynak görüntülerin ağa beslenmesi	71
Şekil 2.19. Yeni veri seti NOTEBOOK görüntüsü.	73
Şekil 2.19. (a) Kaynak görüntü 1.....	73
Şekil 2.19. (b) Kaynak görüntü 2.....	73
Şekil 2.19. (c) Kaynak görüntü 3.....	73
Şekil 2.19. (d) Kaynak görüntü 4.....	74
Şekil 2.19. (e) Kaynak görüntü 1 için iyileştirme mekanizmasından önce ve sonra karar haritaları.	74
Şekil 2.19. (f) Kaynak görüntü 2 için iyileştirme mekanizmasından önce ve sonra karar haritaları.	74
Şekil 2.19. (g) Kaynak görüntü 3 için iyileştirme mekanizmasından önce ve sonra karar haritaları.	74
Şekil 2.19. (h) Kaynak görüntü 4 için iyileştirme mekanizmasından önce ve sonra karar haritaları.	74
Şekil 2.19. (ı) Kaynak görüntü 1 için nihai karar haritası.....	74
Şekil 2.19. (i) Kaynak görüntü 2 için nihai karar haritası.....	74
Şekil 2.19. (j) Kaynak görüntü 3 için nihai karar haritası.....	74
Şekil 2.19. (k) Kaynak görüntü 4 için nihai karar haritası	74
Şekil 2.19. (l) Tüm-odaklı görüntü.	74
Şekil 3.1. Lytro veri setinden alınan örnek görüntüler.....	79
Şekil 3.1. (a) Sol-odaklı kaynak görüntü.	79
Şekil 3.1. (b) Sağ-odaklı kaynak görüntü.....	79
Şekil 3.2. Durga Prasad veri setinden alınan örnek görüntüler.....	80
Şekil 3.2. (a) Pepsi sol-odaklı kaynak görüntü.	80
Şekil 3.2. (b) Pepsi sağ-odaklı kaynak görüntü.....	80
Şekil 3.2. (c) Book sağ-odaklı kaynak görüntü.....	80
Şekil 3.2. (d) Book sol-odaklı kaynak görüntü.	80
Şekil 3.3. Performans ölçüm metrikleri	81
Şekil 3.4. Çoklu-odaklı Livingroom görüntüsü.	92

Şekil 3.4. (a) Kaynak görüntü 1.	92
Şekil 3.4. (b) Kaynak görüntü 2.	92
Şekil 3.4. (c) Kaynak görüntü 3.	92
Şekil 3.4. (d) Kaynak görüntü 4.	92
Şekil 3.4. (e) 2 SR faktörü ile birleştirilmiş görüntü.	92
Şekil 3.4. (f) 3 SR faktörü ile birleştirilmiş görüntü.	92
Şekil 3.4. (g) 4 SR faktörü ile birleştirilmiş görüntü.	92
Şekil 3.5. Çoklu-odaklı Astronaut görüntüsü.	93
Şekil 3.5. (a) Kaynak görüntü 1.	93
Şekil 3.5. (b) Kaynak görüntü 2.	93
Şekil 3.5. (c) Kaynak görüntü 3.	93
Şekil 3.5. (d) Kaynak görüntü 4.	93
Şekil 3.5. (e) 2 SR faktörü ile birleştirilmiş görüntü.	93
Şekil 3.5. (f) 3 SR faktörü ile birleştirilmiş görüntü.	93
Şekil 3.5. (g) 4 SR faktörü ile birleştirilmiş görüntü.	93
Şekil 3.6. Çoklu-odaklı Trucks görüntüsü.	94
Şekil 3.6. (a) Kaynak görüntü 1.	94
Şekil 3.6. (b) Kaynak görüntü 2.	94
Şekil 3.6. (c) Kaynak görüntü 3.	94
Şekil 3.6. (d) Kaynak görüntü 4.	94
Şekil 3.6. (e) 2 SR faktörü ile birleştirilmiş görüntü.	94
Şekil 3.6. (f) 3 SR faktörü ile birleştirilmiş görüntü.	94
Şekil 3.6. (g) 4 SR faktörü ile birleştirilmiş görüntü.	94
Şekil 3.7. Çoklu-odaklı Lake görüntüsü.	95
Şekil 3.7. (a) Kaynak görüntü 1.	95
Şekil 3.7. (b) Kaynak görüntü 2.	95
Şekil 3.7. (c) Kaynak görüntü 3.	95
Şekil 3.7. (d) Kaynak görüntü 4.	95
Şekil 3.7. (e) 2 SR faktörü ile birleştirilmiş görüntü.	95
Şekil 3.7. (f) 3 SR faktörü ile birleştirilmiş görüntü.	95
Şekil 3.7. (g) 4 SR faktörü ile birleştirilmiş görüntü.	95
Şekil 3.8. Çoklu-odaklı Saras görüntüsü.	97
Şekil 3.8. (a) Sol-odaklı kaynak görüntü	97

Şekil 3.8. (b) Sağ-odaklı kaynak görüntü.....	97
Şekil 3.8. (c) Referans görüntü.	97
Şekil 3.8. (d) 2 SR faktörü ile birleştirilmiş görüntü.....	97
Şekil 3.8. (e) 3 SR faktörü ile birleştirilmiş görüntü.....	97
Şekil 3.8. (f) 4 SR faktörü ile birleştirilmiş görüntü.	97
Şekil 3.9. Çoklu-odaklı Flower görüntüsü.	98
Şekil 3.9. (a) Sol-odaklı kaynak görüntü	98
Şekil 3.9. (b) Sağ-odaklı kaynak görüntü.....	98
Şekil 3.9. (c) Referans görüntü.	98
Şekil 3.9. (d) 2 SR faktörü ile birleştirilmiş görüntü.....	98
Şekil 3.9. (e) 3 SR faktörü ile birleştirilmiş görüntü.....	98
Şekil 3.9. (f) 4 SR faktörü ile birleştirilmiş görüntü.	98
Şekil 3.10. Çoklu-odaklı Clock görüntüsü.....	101
Şekil 3.10. (a) Sol-odaklı kaynak görüntü.	101
Şekil 3.10. (b) Sağ-odaklı kaynak görüntü.....	101
Şekil 3.10. (c) 2 SR faktörü ile birleştirilmiş görüntü.....	101
Şekil 3.10. (d) 3 SR faktörü ile birleştirilmiş görüntü.....	101
Şekil 3.10. (e) 4 SR faktörü ile birleştirilmiş görüntü.....	101
Şekil 3.11. Çoklu-odaklı Balloon görüntüsü.....	102
Şekil 3.11. (a) Sol-odaklı kaynak görüntü.	102
Şekil 3.11. (b) Sağ-odaklı kaynak görüntü.....	102
Şekil 3.11. (c) 2 SR faktörü ile birleştirilmiş görüntü.....	102
Şekil 3.11. (d) 3 SR faktörü ile birleştirilmiş görüntü.....	102
Şekil 3.11. (e) 4 SR faktörü ile birleştirilmiş görüntü.....	102
Şekil 3.12. Çoklu-odaklı Clock görüntüsü.....	103
Şekil 3.12. (a) 2 SR faktörü ile sol-odaklı kaynak görüntü.....	103
Şekil 3.12. (b) 3 SR faktörü ile sol-odaklı kaynak görüntü	103
Şekil 3.12. (c) 4 SR faktörü ile sol-odaklı kaynak görüntü.....	103
Şekil 3.12. (d) 2 SR faktörü ile sağ-odaklı kaynak görüntü.....	103
Şekil 3.12. (e) 3 SR faktörü ile sağ-odaklı kaynak görüntü	103
Şekil 3.12. (f) 4 SR faktörü ile sağ-odaklı kaynak görüntü	103
Şekil 3.13. Çoklu-odaklı Balloon görüntüsü.....	104
Şekil 3.13. (a) 2 SR faktörü ile sol-odaklı kaynak görüntü.....	104

Şekil 3.13. (b) 3 SR faktörü ile sol-odaklı kaynak görüntü	104
Şekil 3.13. (c) 4 SR faktörü ile sol-odaklı kaynak görüntü.....	104
Şekil 3.13. (d) 2 SR faktörü ile sağ-odaklı kaynak görüntü.....	104
Şekil 3.13. (e) 3 SR faktörü ile sağ-odaklı kaynak görüntü	104
Şekil 3.13. (f) 4 SR faktörü ile sağ-odaklı kaynak görüntü	104
Şekil 3.14. Çoklu-odaklı Lytro-02 görüntüsü	105
Şekil 3.14. (a) 2 SR faktörü ile sol-odaklı kaynak görüntü.....	105
Şekil 3.14. (b) 3 SR faktörü ile sol-odaklı kaynak görüntü	105
Şekil 3.14. (c) 4 SR faktörü ile sol-odaklı kaynak görüntü.....	105
Şekil 3.14. (d) 2 SR faktörü ile sağ-odaklı kaynak görüntü.....	105
Şekil 3.14. (e) 3 SR faktörü ile sağ-odaklı kaynak görüntü	105
Şekil 3.14. (f) 4 SR faktörü ile sağ-odaklı kaynak görüntü	105
Şekil 3.15. Çoklu-odaklı Lytro-01 görüntüsü.	106
Şekil 3.15. (a) Sol-odaklı kaynak görüntü	106
Şekil 3.15. (b) Sağ-odaklı kaynak görüntü	106
Şekil 3.15. (c) 2 SR faktörü ile birleştirilmiş görüntü.....	106
Şekil 3.15. (d) 3 SR faktörü ile birleştirilmiş görüntü.	106
Şekil 3.15. (e) 4 SR faktörü ile birleştirilmiş görüntü.....	106
Şekil 3.16. Çoklu-odaklı Lytro-02 görüntüsü.	107
Şekil 3.16. (a) Sol-odaklı kaynak görüntü.	107
Şekil 3.16. (b) Sağ-odaklı kaynak görüntü.....	107
Şekil 3.16. (c) 2 SR faktörü ile birleştirilmiş görüntü.....	107
Şekil 3.16. (d) 3 SR faktörü ile birleştirilmiş görüntü.	107
Şekil 3.16. (e) 4 SR faktörü ile birleştirilmiş görüntü.....	107
Şekil 3.17. Çoklu-odaklı Lab görüntüsü.	109
Şekil 3.17. (a) Sol-odaklı kaynak görüntü	109
Şekil 3.17. (b) Sağ-odaklı kaynak görüntü	109
Şekil 3.17. (c) Referans görüntü.	109
Şekil 3.17. (d) 2 SR faktörü ile birleştirilmiş görüntü.	109
Şekil 3.17. (e) 3 SR faktörü ile birleştirilmiş görüntü.....	109
Şekil 3.17. (f) 4 SR faktörü ile birleştirilmiş görüntü.	109
Şekil 3.18. Çoklu-odaklı Book görüntüsü.....	110
Şekil 3.18. (a) Sol-odaklı kaynak görüntü	110

Şekil 3.18. (b) Sağ-odaklı kaynak görüntü	110
Şekil 3.18. (c) Referans görüntü.	110
Şekil 3.18. (d) 2 SR faktörü ile birleştirilmiş görüntü.....	110
Şekil 3.18. (e) 3 SR faktörü ile birleştirilmiş görüntü.....	110
Şekil 3.18. (f) 4 SR faktörü ile birleştirilmiş görüntü.	110
Şekil 3.19. Yeni veri seti GOODS görüntüsü.	112
Şekil 3.19. (a) Kaynak görüntü 1.	112
Şekil 3.19. (b) Kaynak görüntü 2.	112
Şekil 3.19. (c) Kaynak görüntü 3.	112
Şekil 3.19. (d) Kaynak görüntü 4.	112
Şekil 3.19. (e) Kaynak görüntü 1 için nihai karar haritası.	112
Şekil 3.19. (f) Kaynak görüntü 2 için nihai karar haritası.....	112
Şekil 3.19. (g) Kaynak görüntü 3 için nihai karar haritası.	112
Şekil 3.19. (h) Kaynak görüntü 4 için nihai karar haritası.	112
Şekil 3.19. (i) Tüm-odaklı görüntü.	112
Şekil 3.20. Yeni veri seti HORSEANDCOW görüntüsü.....	113
Şekil 3.20. (a) Kaynak görüntü 1.	113
Şekil 3.20. (b) Kaynak görüntü 2.	113
Şekil 3.20. (c) Kaynak görüntü 3.	113
Şekil 3.20. (d) Kaynak görüntü 4.	113
Şekil 3.20. (e) Kaynak görüntü 1 için nihai karar haritası.	113
Şekil 3.20. (f) Kaynak görüntü 2 için nihai karar haritası.....	113
Şekil 3.20. (g) Kaynak görüntü 3 için nihai karar haritası.	113
Şekil 3.20. (h) Kaynak görüntü 4 için nihai karar haritası.	113
Şekil 3.20. (i) Tüm-odaklı görüntü.	113
Şekil 3.21. Yeni veri seti DOG görüntüsü.	114
Şekil 3.21. (a) Kaynak görüntü 1.	114
Şekil 3.21. (b) Kaynak görüntü 2.	114
Şekil 3.21. (c) Kaynak görüntü 1 için nihai karar haritası.	114
Şekil 3.21. (d) Kaynak görüntü 2 için nihai karar haritası.	114
Şekil 3.21. (e) Tüm-odaklı görüntü.....	114
Şekil 3.22. Yeni veri seti JETS görüntüsü.	115
Şekil 3.22. (a) Kaynak görüntü 1.	115

Şekil 3.22. (b) Kaynak görüntü 2.	115
Şekil 3.22. (c) Kaynak görüntü 3.	115
Şekil 3.22. (d) Kaynak görüntü 4.	115
Şekil 3.22. (e) Kaynak görüntü 1 için nihai karar haritası.	115
Şekil 3.22. (f) Kaynak görüntü 2 için nihai karar haritası.	115
Şekil 3.22. (g) Kaynak görüntü 3 için nihai karar haritası.	115
Şekil 3.22. (h) Kaynak görüntü 4 için nihai karar haritası.	115
Şekil 3.22. (ı) Tüm-odaklı görüntü.	115
Şekil 3.23. Yeni veri seti KNIFEANDBANANA görüntüsü.	116
Şekil 3.23. (a) Kaynak görüntü 1.	116
Şekil 3.23. (b) Kaynak görüntü 2.	116
Şekil 3.23. (c) Kaynak görüntü 3.	116
Şekil 3.23. (d) Kaynak görüntü 4.	116
Şekil 3.23. (e) Kaynak görüntü 1 için nihai karar haritası.	116
Şekil 3.23. (f) Kaynak görüntü 2 için nihai karar haritası.	116
Şekil 3.23. (g) Kaynak görüntü 3 için nihai karar haritası.	116
Şekil 3.23. (h) Kaynak görüntü 4 için nihai karar haritası.	116
Şekil 3.23. (ı) Tüm-odaklı görüntü.	116
Şekil 3.24. Yeni veri seti APPLE görüntüsü.	117
Şekil 3.24. (a) Kaynak görüntü 1.	117
Şekil 3.24. (b) Kaynak görüntü 2.	117
Şekil 3.24. (c) Kaynak görüntü 3.	117
Şekil 3.24. (d) Kaynak görüntü 4.	117
Şekil 3.24. (e) Kaynak görüntü 1 için nihai karar haritası.	117
Şekil 3.24. (f) Kaynak görüntü 2 için nihai karar haritası.	117
Şekil 3.24. (g) Kaynak görüntü 3 için nihai karar haritası.	117
Şekil 3.24. (h) Kaynak görüntü 4 için nihai karar haritası.	117
Şekil 3.24. (ı) Tüm-odaklı görüntü.	117
Şekil 3.25. Yeni veri seti ELEPHANT görüntüsü.	118
Şekil 3.25. (a) Kaynak görüntü 1.	118
Şekil 3.25. (b) Kaynak görüntü 2.	118
Şekil 3.25. (c) Kaynak görüntü 1 için nihai karar haritası.	118
Şekil 3.25. (d) Kaynak görüntü 2 için nihai karar haritası.	118

Şekil 3.25. (e) Tüm-odaklı görüntü.....	118
Şekil 3.26. Yeni veri seti BIKER görüntüsü.	119
Şekil 3.26. (a) Kaynak görüntü 1.	119
Şekil 3.26. (b) Kaynak görüntü 2.	119
Şekil 3.26. (c) Kaynak görüntü 1 için nihai karar haritası.	119
Şekil 3.26. (d) Kaynak görüntü 2 için nihai karar haritası.	119
Şekil 3.26. (e) Tüm-odaklı görüntü.....	119
Şekil 3.27. Yeni veri seti ROSE görüntüsü.....	120
Şekil 3.27. (a) Kaynak görüntü 1.	120
Şekil 3.27. (b) Kaynak görüntü 2.....	120
Şekil 3.27. (c) Kaynak görüntü 1 için nihai karar haritası.	120
Şekil 3.27 (d) Kaynak görüntü 2 için nihai karar haritası.	120
Şekil 3.27. (e) Tüm-odaklı görüntü.....	120
Şekil 3.28. Yeni veri seti MOTORCYCLE görüntüsü.	121
Şekil 3.28. (a) Kaynak görüntü 1.	121
Şekil 3.28. (b) Kaynak görüntü 2.....	121
Şekil 3.28. (c) Kaynak görüntü 1 için nihai karar haritası.	121
Şekil 3.28. (d) Kaynak görüntü 2 için nihai karar haritası..	121
Şekil 3.28. (e) Tüm-odaklı görüntü.....	121
Şekil 3.29. Yeni veri seti MINICAT görüntüsü.....	122
Şekil 3.29. (a) Kaynak görüntü 1.	122
Şekil 3.29. (b) Kaynak görüntü 2.....	122
Şekil 3.29. (c) Kaynak görüntü 1 için nihai karar haritası.	122
Şekil 3.29. (d) Kaynak görüntü 2 için nihai karar haritası.	122
Şekil 3.29. (e) Tüm-odaklı görüntü.....	122
Şekil 3.30. Çoklu-odaklı Flower görüntüsü.	124
Şekil 3.30. (a) Kaynak görüntü 1.	124
Şekil 3.30. (b) Kaynak görüntü 2.....	124
Şekil 3.30. (c) Kaynak görüntü 1 için nihai karar haritası.	124
Şekil 3.30. (d) Kaynak görüntü 2 için nihai karar haritası.	124
Şekil 3.30. (e) Tüm-odaklı görüntü.....	124
Şekil 3.31. Çoklu-odaklı Leopard görüntüsü.	125
Şekil 3.31. (a) Kaynak görüntü 1.	125

Şekil 3.31. (b) Kaynak görüntü 2.....	125
Şekil 3.31. (c) Kaynak görüntü 1 için nihai karar haritası.	125
Şekil 3.31. (d) Kaynak görüntü 2 için nihai karar haritası.	125
Şekil 3.31. (e) Tüm-odaklı görüntü.....	125
Şekil 3.32. Çoklu-odaklı Leaf görüntüsü.	126
Şekil 3.32. (a) Kaynak görüntü 1.	126
Şekil 3.32. (b) Kaynak görüntü 2.....	126
Şekil 3.32. (c) Kaynak görüntü 1 için nihai karar haritası.	126
Şekil 3.32. (d) Kaynak görüntü 2 için nihai karar haritası.	126
Şekil 3.32. (e) Tüm-odaklı görüntü.....	126
Şekil 3.33. Çoklu-odaklı Cameraman görüntüsü.	127
Şekil 3.33. (a) Kaynak görüntü 1.	127
Şekil 3.33. (b) Kaynak görüntü 2.....	127
Şekil 3.33. (c) Kaynak görüntü 1 için nihai karar haritası.	127
Şekil 3.33. (d) Kaynak görüntü 2 için nihai karar haritası.	127
Şekil 3.33. (e) Tüm-odaklı görüntü.....	127
Şekil 3.34. Çoklu-odaklı Hoed görüntüsü.....	128
Şekil 3.34. (a) Kaynak görüntü 1.	128
Şekil 3.34. (b) Kaynak görüntü 2.....	128
Şekil 3.34. (c) Kaynak görüntü 1 için nihai karar haritası.	128
Şekil 3.34. (d) Kaynak görüntü 2 için nihai karar haritası.	128
Şekil 3.34. (e) Tüm-odaklı görüntü.....	128
Şekil 3.35. Çoklu-odaklı Lytro-14 görüntüsü.	132
Şekil 3.35. (a) Kaynak görüntü 1.	132
Şekil 3.35 (b) Kaynak görüntü 2.....	132
Şekil 3.35. (c) Kaynak görüntü 1 için nihai karar haritası.	132
Şekil 3.35. (d) Kaynak görüntü 2 için nihai karar haritası.	132
Şekil 3.35. (e) Tüm-odaklı görüntü.....	132
Şekil 3.36. Çoklu-odaklı Lytro-13 görüntüsü.	133
Şekil 3.36. (a) Kaynak görüntü 1.	133
Şekil 3.36. (b) Kaynak görüntü 2.....	133
Şekil 3.36. (c) Kaynak görüntü 1 için nihai karar haritası.	133
Şekil 3.36. (d) Kaynak görüntü 2 için nihai karar haritası.	133

Şekil 3.36. (e) Tüm-odaklı görüntü.....	133
Şekil 3.37. Çoklu-odaklı Lytro-12 görüntüsü.	134
Şekil 3.37. (a) Kaynak görüntü 1.	134
Şekil 3.37. (b) Kaynak görüntü 2.	134
Şekil 3.37. (c) Kaynak görüntü 1 için nihai karar haritası.	134
Şekil 3.37 (d) Kaynak görüntü 2 için nihai karar haritası.	134
Şekil 3.37. (e) Tüm-odaklı görüntü.....	134
Şekil 3.38. Çoklu-odaklı Lytro-11 görüntüsü.	135
Şekil 3.38. (a) Kaynak görüntü 1.	135
Şekil 3.38. (b) Kaynak görüntü 2.	135
Şekil 3.38. (c) Kaynak görüntü 1 için nihai karar haritası.	135
Şekil 3.38. (d) Kaynak görüntü 2 için nihai karar haritası.	135
Şekil 3.38. (e) Tüm-odaklı görüntü.....	135
Şekil 3.39. Çoklu-odaklı Lytro-10 görüntüsü.	136
Şekil 3.39. (a) Kaynak görüntü 1.	136
Şekil 3.39. (b) Kaynak görüntü 2.	136
Şekil 3.39. (c) Kaynak görüntü 1 için nihai karar haritası.	136
Şekil 3.39. (d) Kaynak görüntü 2 için nihai karar haritası.	136
Şekil 3.39. (e) Tüm-odaklı görüntü.....	136
Şekil 3.40. Çoklu-odaklı Lytro-03 görüntüsü.	137
Şekil 3.40. (a) Kaynak görüntü 1.	137
Şekil 3.40. (b) Kaynak görüntü 2.	137
Şekil 3.40. (c) Kaynak görüntü 1 için nihai karar haritası.	137
Şekil 3.40. (d) Kaynak görüntü 2 için nihai karar haritası.	137
Şekil 3.40. (e) Tüm-odaklı görüntü.....	137
Şekil 3.41. Çoklu-odaklı Lytro-01 görüntüsü.	138
Şekil 3.41. (a) Kaynak görüntü 1.	138
Şekil 3.41. (b) Kaynak görüntü 2.	138
Şekil 3.41. (c) Kaynak görüntü 1 için nihai karar haritası.	138
Şekil 3.41. (d) Kaynak görüntü 2 için nihai karar haritası.	138
Şekil 3.41. (e) Tüm-odaklı görüntü.....	138
Şekil 3.42. Çoklu-odaklı Lytro-08 görüntüsü.	139
Şekil 3.42. (a) Kaynak görüntü 1.	139

Şekil 3.42. (b) Kaynak görüntü 2.....	139
Şekil 3.42. (c) Kaynak görüntü 1 için nihai karar haritası.	139
Şekil 3.42. (d) Kaynak görüntü 2 için nihai karar haritası.	139
Şekil 3.42. (e) Tüm-odaklı görüntü.....	139



TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 3.1. Oluşturulan yeni veri seti için önerilen 1. çalışmanın objektif metrikler ile değerlendirme sonuçları	90
Tablo 3.2. Önerilen 1. çalışma için subjektif metrikler ile değerlendirme sonuçları.....	96
Tablo 3.3. Durga Prasad veri seti için önerilen 1. çalışma ve literatürdeki çalışmaların objektif metrikler ile karşılaştırma sonuçları	99
Tablo 3.4. Durga Prasad veri seti için önerilen 1. çalışma ve literatürdeki çalışmaların subjektif metrikler ile karşılaştırma sonuçları.....	108
Tablo 3.5. Oluşturulan yeni veri seti için önerilen 2. çalışmanın objektif ve subjektif metrikler ile değerlendirme sonuçları	123
Tablo 3.6. Durga Prasad veri seti için önerilen 2. çalışma ve literatürdeki çalışmaların objektif metrikler ile karşılaştırma sonuçları	129
Tablo 3.7. Önerilen 2. çalışma ile Moushmi ve ark. çalışması subjektif metrikler ile karşılaştırma sonuçları	131
Tablo 3.8. Önerilen 2. çalışma ile Li ve ark. yöntemi subjektif metrikler ile karşılaştırma sonuçları	131
Tablo 3.9. Önerilen 2. çalışma ile literatürdeki çalışmaların Lytro veri seti için objektif metrikler ile karşılaştırma sonuçları	140
Tablo 3.10. Önerilen 2. çalışmanın farklı ağ girişi boyutları için değerlendirme sonuçları.....	142
Tablo 3.11. Önerilen yaklaşımların birbirleri ve literatürdeki yaklaşımlar ile subjektif metrikler kullanılarak karşılaştırma sonuçları	144
Tablo 3.12. Clock görüntüsü için önerilen yaklaşımların birbirleri ve literatürdeki yaklaşımlar ile objektif metrikler kullanılarak karşılaştırma sonuçları	145
Tablo 3.13. Lab görüntüsü için önerilen yaklaşımların birbirleri ve literatürdeki yaklaşımlar ile objektif metrikler kullanılarak karşılaştırma sonuçları.....	146
Tablo 3.14. Disk görüntüsü için önerilen yaklaşımların birbirleri ve literatürdeki yaklaşımlar ile objektif metrikler kullanılarak karşılaştırma sonuçları.....	147

Tablo 3.15. Önerilen yaklaşımların ikiden fazla görüntüyü birleştirmede performans karşılaştırma sonuçları	148
--	-----



SEMBOLLER DİZİNİ

CNN	Konvolüsyonel Yapay Sinir Ağları (Convolutional Neural Networks)
FC	Tam-bağlantılı (Fully-connected)
MSD	Çok Ölçekli Ayırıştırma (Multi Scale Decomposition)
SR	Seyrek Gösterim (Sparse Representation)
LP	Laplas Piramidi (Laplacian Pyramid)
GP	Gradyan Piramidi (Gradient Pyramid)
FSD	Süzgeç-Çıkarma-Kırma (Filter-Subtract-Decimate)
NSCT	Örneklenmemiş Konturlet Dönüşümü (Nonsubsampled Counterlet Transform)
PCNN	Darbeye bağlı Yapay Sinir Ağları (Pulse-coupled Neural Networks)
OMP	Ortogonal Eşleştirme Takibi (Orthogonal Matching Pursuit)
EOG	Gradyan Enerjisi (Energy of Gradient)
EOL	Laplas Enerjisi (Energy of Laplacian)
SML	Toplam Değiştirilmiş Laplas (Sum-modified Laplacian)
QWT	Kuaterniyon Dalgacık Dönüşümü (Quaternion Wavelet Transform)
GAN	Çekişmeli Üretici Ağ (Generative Adversarial Network)
LSGAN	Küçük Kareler Çekişmeli Üretici Ağı (Least Square Generative Adversarial Network)
SSIM	Yapı Benzerliği (Structural Similarity)
SISR	Tek Görüntü ile Süper-çözünürlük (Single Image Super-resolution)
LR	Düşük Çözünürlük (Low Resolution)
HR	Yüksek Çözünürlük (High Resolution)
SR	Süper Çözünürlük (Super-resolution)
DNN	Derin Sinir Ağı (Deep Neural Network)
SWT	Sabit Dalgacık Dönüşümü (Stationary Wavelet Transform)
ISWT	Ters Sabit Dalgacık Dönüşümü (Inverse Stationary Wavelet Transform)
MI	Karşılıklı Bilgi (Mutual Information)
QAB/F	Petrovic Tarafından Önerilen Metrik (Petrovic's Metric)
QCB	Chen ve ark. Tarafından Önerilen Metrik (Chen Blum's Metric)
AG	Ortalama Gradyan (Average Gradient)

RMSE	Ortalama Karesel Hata (Root Mean Square Error)
PSNR	Tepe Sinyal Gürültü Oranı (Peak Signal-to-Noise Ratio)
SD	Standart Sapma (Standard Deviation)
SF	Uzamsal Frekans (Spatial Frequency)
CC	Korelasyon Katsayısı (Correlation Coefficient)
LL	Alçak-Alçak Altband (Low-Low Subband)
LH	Alçak-Yüksek Altband (Low-High Subband)
HL	Yüksek-Alçak Altband (High-Low Subband)
HH	Yüksek-Yüksek Altband (High-High Subband)
SR	Süper-Çözünürlük (Super-Resolution)
Dmey	Ayrık Meyer Süzgeci (Discrete Meyer Filter)
DB	Daubechies Sügeci (Daubechies Filter)
DCT	Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform)
IHS	Yoğunluk Tonu Doygunluğu (Intensity Hue Saturation)
hPCA	Hiyerarşik Temel Bileşen Analizi (Hierarchical Principal Component Analysis)
BLI	Çiftdoğrusal Aradeğerleme (Bilinear Interpolation)

1. GENEL BİLGİLER

1.1. Giriş


Görüntü birleştirme, görüntü üzerinde yapılacak işlemleri kolaylaştırabilecek ve karar vermede yardımcı olabilecek bilgilendirici bir görüntü oluşturmak için farklı türde sensörler tarafından elde edilen ve odaksız bölümler içeren görüntüleri birleştirmeyi amaçlayan bir geliştirme tekniğidir. İyi bir görüntü birleştirme tekniği kaynak görüntülerdeki önemli bilgileri birleştirilmiş görüntüye aktarmalı ve kusursuz bir birleştirilmiş görüntü elde edilmesini sağlamalıdır. Gelişmiş uygulamalar, görüntüler hakkında çok fazla bilgiye ihtiyaç duymaktadır. Buna rağmen aynı tipteki sensörler sadece bir yönden bilgi alabilirler ve bu tür uygulamalar için gerekli bilgiyi sağlayamazlar. Görüntü birleştirme teknikleri kullanılarak farklı sensör bilgileri birleştirilmekte ve uygulamalar için çok daha detaylı görüntüler elde edilmiş olmaktadır. Bu nedenle birleştirme teknikleri modern uygulamalar ve bilgisayarla görme uygulamalarında sıklıkla tercih edilmektedir.

Görüntü birleştirme teknikleri, uzaktan algılama, uydu görüntülerinin birleştirilmesi, medikal görüntülerin birleştirilerek tanıların kolaylaştırılması ve Çoklu-odaklı görüntülerin birleştirilmesi gibi farklı alanlarda kullanılmaktadır. Bu tez çalışmasında, görüntüleme cihazlarının yaygınlaşmasıyla artan bir probleme yönelik Çoklu-odaklı görüntülerin birleştirilmesi alanına katkı yapılmaktadır. Çoklu-odaklı görüntü birleştirme yöntemleri sınırlı alan derinliğine sahip görüntüleme cihazları ile alınan görüntülerin iyileştirilmesini amaçlamaktadır. Görüntüleme cihazlarının bu özelliği eğer pahalı uzman ve optik sensörler yoksa tüm nesnelerin odaklı olarak bulunduğu kusursuz bir görüntü elde etmeyi imkânsız hale getirmektedir. Çoklu-odaklı görüntü birleştirme yöntemleri bu problemleri ortadan kaldırmak, farklı odaklı nesneler içeren görüntüleri birleştirerek tüm odaklı kusursuz tek bir görüntü oluşturmayı amaçlamaktadır.

Uzamsal alana dayalı yöntemler ve dönüşüm alana dayalı yöntemler, Çoklu-odaklı görüntü birleştirme için iki ana kategoridir [1]. Uzamsal alana dayalı yöntemler, piksel parlaklık değerlerini doğrudan kullanır. Literatürde uzamsal alanı kullanan birçok yöntem bulunmaktadır. Kaynak görüntülerde karşılık gelen piksellerin piksel yoğunluklarının ortalamasını almak ve kaynak görüntülerde karşılık gelen piksellerin maksimum yoğunluğunu seçmek, görüntüleri uzamsal alanda birleştirmenin geleneksel yollarıdır. Bu

yöntemlerin yanı sıra Kılavuz süzgeç tabanlı yöntemler, temel bileşen analizine dayalı yöntemler Çoklu-odaklı görüntü birleştirme amacıyla kullanılan diğer yöntemlerdir. Bu yöntemlerin hız, uygulama kolaylığı gibi avantajları vardır, ancak sadece piksel yoğunluğu değerlerini kullanmak yüksek detaylı birleştirilmiş görüntüler oluşturmak için yeterli değildir [2]. Dönüşüm tabanlı yöntemler ise, uzamsal yöntemlere kıyasla görüntülerin ayrıntılı olarak incelenmesine olanak tanımaktadır. Bu tür yöntemler, görüntüleri birleştirmek için kaynak görüntülerin frekans bileşenlerini kullanmaktadır. Frekans bileşenleri; kenarlar, köşeler, düz alanlar vb. gibi ayrıntılı bilgiler vermektedir. Bu bilgiler ayrı ayrı kullanılarak daha ayrıntılı birleştirilmiş görüntüler elde edilebilmektedir. Dalgacık-tabanlı yöntemler, piramit-tabanlı yöntemler, Fourier-tabanlı yöntemler en çok kullanılan dönüşüm tabanlı yöntemlerdir [3]. Son yıllarda bu kategorilerdeki yöntemlerin yanı sıra derin öğrenmeye dayalı yöntemler araştırmacılar tarafından sıklıkla tercih edilmektedir. Derin öğrenmeye dayalı yöntemler görüntülerdeki odaklı ve odaksız bölgelerin sınıflandırılması mantığına dayanmaktadır. Evrişim Sinir Ağları ve Çekişmeli Üretici Ağları, literatürde popüler olarak kullanılan iki tür derin öğrenme yöntemidir [4] ve Çoklu-odaklı görüntü birleştirmede sıklıkla uygulanmaktadır.

Görüntü birleştirme yöntemleri farklı alanlarda kullanılmaktadır. Uzaktan algılama [5,6], tıbbi teşhis [7], gözetim [8] ve fotoğrafçılık [9] gibi alanlar görüntü birleştirme kullanılan alanlardan bazılarıdır. Görüntü birleştirme yöntemleri kullanım alanları Şekil 1.1.' de verilmektedir.



Şekil 1.1. Görüntü birleştirme yöntemleri kullanım alanları

Medikal görüntülerde birleştirme, insan vücudu, organları ve hücrelerinin görüntülerinden ortaya çıkarılan tıbbi sorunları ele alan ve geniş bir alanda çalışan birleştirme çeşididir. Bu birleştirme çeşidi tıbbi teşhis, analiz işlemlerinde görüntüleme teknolojileri kullanımının giderek yaygınlaşmaktadır. Bilgisayar destekli görüntüleme teknikleri, görüntülerin nicel olarak değerlendirilmesine olanak sağladığından, tıp pratisyenlerinin kısa sürede nesnel bir karara varmadaki etkinliğini artırmaya yardımcı olmaktadır. Ek olarak, çoklu-sensörlü ve çok kaynaklı görüntü birleştirme yöntemlerinin kullanılması, tıbbi analiz için kullanılan özelliklerin çeşitlenmesini sağlamaktadır; bu genellikle insan gözünün göremediği bilgilerin kullanılan teknikler sayesinde görülebilmesini sağlamaktadır. Birleştirilmiş görüntülerden elde edilen ek bilgiler, hastalardaki anormalliklerin kesin lokalizasyonu için kullanılabilir.

Uzaktan algılama görüntü birleştirme, aynı sahneye ait farklı sensörlerden elde edilen uzak görüntü verilerini alarak bu görüntülerin detay bilgilerini birleştirmek için çeşitli yöntemler kullanan teknolojidir. Bu birleştirme, uzaktan algılama görüntüsünün işlenmesi ve daha kolay irdelenmesi için önemli bir araçtır. Özellikle, uzaktan algılama teknolojisinin mevcut hızlı gelişimi, çok kaynaklı uzaktan algılama verilerine (çoklu sensör, çok zamanlı, çok bantlı, çok platformlu, çok çözünürlüklü) erişimi giderek daha kolay hale getirmekte olup bu durum uzaktan algılama uygulamalarının gelişimine katkı sunmaktadır. Uzaktan Algılama görüntü birleştirme yöntemleri genellikle PAN ve MS görüntülerinin birleştirmesini amaçlamaktadır [10]. Son yıllarda bu tür uygulamalar uydulardan alınan görüntülerin netleştirilmesi için kullanılmaktadır.

Çoklu-odaklı görüntü birleştirme ise son yıllarda literatürde sıklıkla kullanılan bir diğer görüntü birleştirme tekniğidir. Görüntülerde, görüntüleme cihazlarının sınırlı derinliklere ulaşabilmesinden kaynaklanan bazı problemler mevcuttur. Bu problemlerin başında görüntüdeki tüm nesnelerin odaklı olmaması gelmektedir. Çoklu-odaklı görüntü birleştirme bu problemi ortadan kaldırmak amacıyla kullanılmaktadır. Bu birleştirme türü aynı sahneye ait iki veya daha fazla farklı odak değerlerine sahip görüntüyü birleştirerek daha net ve detaylı tüm odaklı tek bir görüntü oluşturmayı amaçlamaktadır. Bu işlem yapılırken kaynak görüntülerden doğru bilginin aktarılması ve kenar bilgilerinin korunması oldukça önemlidir. Oluşturulan birleştirilmiş görüntü, görüntü analizi için kolaylıkla kullanılabilir.

1.2. Literatür Araştırması

Görüntü birleştirme yöntemleri, modern uygulamaların detaylı, incelenmesi kolay görüntülerle daha verimli çalışabilmesinden dolayı günümüzde sıklıkla tercih edilmektedir. Bu yöntemler kullandıkları algoritmalara göre iki temel sınıfa ayrılmaktaydı. Bunlar uzamsal alan teknikler ve dönüşüm alan tekniklerdir. Fakat çoklu-odaklı görüntü birleştirme teknolojisi ilerledikçe bu tekniklerin ayrı ayrı uygulanmasından ziyade beraber kullanılmasına dayanan birleştirilmiş teknikler yaygınlaşmaya başlamıştır. Bunlara ek olarak son yıllarda derin öğrenmeye dayanan yöntemler popüler yöntemler olarak ortaya çıkmaktadır. Bu tekniklerin de ortaya çıkmasıyla klasik olarak iki sınıfta incelenen çoklu-odaklı görüntü birleştirme yöntemleri günümüzde dört ana başlığa ayrılmaktadır. Her bir sınıf için literatürde yapılan çalışmalar bu bölümde aktarılacaktır.

Dönüşüm alanına dayanan yöntemler temelde üç aşamadan oluşmaktadır. Kaynak görüntülerin frekans bileşenlerine ayrılması, frekans bileşenlerinin birleştirme kuralı ile birleştirilmesi ve elde edilen frekans bileşenlerinden birleştirilmiş görüntü oluşturulmasıdır. Uygulanan görüntü dönüşümüne göre, dönüşüm alanı yöntemleri çok ölçekli ayrıştırma (MSD) tabanlı yöntemler, seyrek gösterim (SR) tabanlı yöntemler, gradyan alanı (GD) tabanlı yöntemler [4] vb. gibi yöntemler olarak sınıflandırılabilir.

1985'te Burt ve Adelson [11] ilk olarak Laplas piramidine (LP) [12] dayanan çoklu-odaklı görüntü birleştirme yöntemi önermişlerdir. Yöntemlerinde, aktivite düzeyi ölçümü olarak ayrıştırılmış bir katsayının mutlak değeri kullanılmakta ve kaynaşmış görüntü piksel değerini elde etmek için maksimum seçim kuralı uygulanmaktadır.

Burt ve ark. [13] tarafından, Çoklu-odaklı görüntü Birleştirme için yönlü süzgeçlemeye dayalı bir gradyan piramidi (GP) modeli önerilmektedir. Bu yöntemde, küçük bir pencere içinde kalan katsayıların karelerinin toplamı etkinlik ölçüsü olarak kullanılmaktadır. İki kaynak görüntüde karşılık düşen katsayı arasındaki benzerlik fazla olduğunda ağırlıklı ortalama kuralı uygulanmakta, benzerlik az olduğunda ise maksimum seçim kuralı uygulanmaktadır. Katsayıya göre değişen dinamik bir birleştirme kuralı önerilmekte olup bu birleştirme stratejisi, daha sonraki görüntü birleştirme çalışmalarında sıklıkla kullanılmaktadır.

Bogoni ve Hansen [14], Laplas Piramidi'nin hesaplama açısından verimli bir varyasyonu olan süzgeç-çıkarma-kırma (FSD) piramidine dayalı çoklu-odaklı görüntü

birleştirme yöntemi önermektedir. Bu yöntemi YUV renk uzayında uygulayarak renkli görüntü birleştirme için de çalışabilir duruma getirmektedirler.

Petrovic ve ark. [15] tarafından, çoklu-odaklı görüntü Birleştirme için gradyan tabanlı bir piramit ayrıştırma yöntemi önerilmektedir. Çoğu MSD tabanlı yöntemlerin aksine, bu yöntemde farklı ölçeklerde kaynaşmış frekans bileşenler elde etmek için "birleştir-sonra-ayır" tekniği sunulmakta ve birleştirilmiş görüntü elde edilmektedir.

Yang ve ark. [16] örneklenmemiş konturlet dönüşümü (NSCT) ile ayrıştırılan kaynak görüntüleri geleneksel pencere tabanlı ve maksimumu seçim birleştirme kuralları yardımıyla birleştirmektedir.

Qu ve ark. [17], NSCT-tabanlı görüntü birleştirme için Darbeye bağlı Yapay Sinir Ağları (PCNN)-tabanlı bir birleştirme stratejisi uygulamaktadır. NSCT ile oluşturulan alt bantların uzamsal frekansı (SF), birleştirilmiş görüntüdeki ağırlığını belirlemek amacıyla PCNN'ye beslenmektedir. Bu yayın sonrasında PCNN tabanlı çoklu-odaklı görüntü birleştirme yöntemleri yaygınlaşmaya başlamaktadır.

Son on yılda, Seyrek Temsil (SR) tabanlı yöntemler, görüntü birleştirme alanında hızla yaygınlaşmaktadır. Yang ve Li [18] ilk olarak çoklu-odaklı görüntüler için görüntü birleştirmede SR'yi uygulamaktadır. Yöntemlerinde, her kaynak görüntüyü bir dizi örtüşen yamaya bölmek için kayan pencere tekniği uygulanmakta ve ortogonal eşleştirme takibi (OMP) algoritması ile her bir yama üzerinde bağımsız olarak seyrek ayrıştırma yapılmaktadır. Daha sonra, aktivite ölçüsü olarak seyrek katsayı vektörünün L1-normu kullanılmakta ve kaynaşmış seyrek katsayı vektörünü elde etmek için maksimum seçim birleştirme kuralı uygulanmaktadır. Son olarak, kaynaşmış yama, kaynaşmış seyrek vektör ve sözlük tarafından yeniden oluşturulmaktadır. Birleştirilmiş görüntünün tamamını oluşturmak için, tüm birleştirilmiş yamalar karşılık gelen konumlarına yapıştırılmaktadır.

Chen ve ark. [19] seyrek katsayıların birleştirilmesi için bölge-tabanlı bir strateji önermektedir. Görüntü sabit parçalara ayrılmakta ve her bir parça için seyrek vektörlerden elde edilen netlik bilgisinin ortalaması birleştirilmiş görüntüye aktarılmaktadır. Birleştirilmiş görüntü bu şekilde oluşturulmaktadır.

Çoklu-odaklı görüntü birleştirme yöntemlerinden ikincisi uzamsal-tabanlı yöntemlerdir. Bu yöntemler dönüşüm tabanlı yöntemlerin aksine doğrudan piksel parlaklık değerlerini kullanmaktadır. Uzamsal-tabanlı yöntemler blok, alan ve piksel tabanlı olarak uygulanmaktadır. Literatürde bulunan uzamsal tabanlı çalışmaların bir kısmı bu bölümde aktarılacaktır.

Li ve ark. [20], her kaynak görüntünün sabit boyutlu bir dizi bloğa bölündüğü uzamsal alan Çoklu-odaklı görüntü birleştirme yöntemi uygulamaktadır. Uzamsal frekans, her bloğun birleştirilmiş görüntüdeki temsil oranını belirlemek için kullanılmaktadır. Kaynaşmış görüntü, nihai olarak, büyük bir süzgeçlemeye dayalı tutarlılık doğrulama yaklaşımı uygulandıktan sonra oluşturulmaktadır. Bu çalışmadan itibaren, blok tabanlı yöntemler, Çoklu-odaklı görüntü birleştirmede aktif olarak kullanılmaya başlamış olup üzerinde iyileştirmeler devam etmektedir.

Huang ve Jing [21], varyans, gradyan enerjisi (EOG), Laplas enerjisi (EOL), toplam değiştirilmiş Laplas (SML), uzamsal frekans (SF), vb. gibi odak ölçüm metrikleri kullanarak bir blok yaklaşımı birleştirme önermektedirler. Bu yaklaşımlarda blokların birleştirilmiş görüntü için önemini belirleyebilmek amacıyla EOL ve PCNN yöntemlerinin birleşiminden oluşan bir algoritma kullanılmaktadır.

Blok yaklaşımı yöntemler ile birlikte bölge tabanlı yaklaşımlar da literatürde yer bulmaktadır. İlk bölge tabanlı yaklaşım Li ve ark. [22] tarafından önerilmektedir. Bu yaklaşım PCNN tabanlı bölütleme yardımıyla bölge tabanlı çoklu-odaklı görüntü birleştirme yöntemi gerçekleştirmektedir. Belirginliği ve görünürlük metriklerini kullanarak oluşturdukları birleştirme kuralı yardımıyla birleştirilmiş görüntü oluşturmaktadırlar.

Bu yaklaşım bölge tabanlı yaklaşımların yaygınlaşmasında önemli rol almaktadır. Li ve Yang [23] normalleştirilmiş kesim tabanlı bölütleme ve SF tabanlı odak ölçümü ile bölge tabanlı çoklu-odaklı bir görüntü birleştirme yöntemi önermektedir. Hao ve ark. [24], ortalama kayma bölütleme yaklaşımına dayalı renkli görüntüler için çoklu-odaklı görüntü birleştirme yöntemi önermekte ve aktivite ölçüsü olarak SML'yi benimsemektedir.

Son yıllarda, piksel tabanlı uzamsal alan yöntemleri, birleştirme için piksel bazında ağırlık haritası elde etme avantajı nedeniyle, çoklu-odaklı görüntü birleştirmede popüler hale gelmektedir. Piksel tabanlı yöntemlerin çoğu, doğrusal ağırlıklı toplam çerçevesi altında tasarlanmakta, yani, kaynaşmış görüntü, tüm kaynak görüntülerin piksel değerlerinin ağırlıklı toplamı olmaktadır. Bu yöntemler için en önemli nokta her pikselin ağırlığının bulunmasıdır. Varyans, SF, EOG, EOL, SML gibi geleneksel odak metrikleri piksel tabanlı uzamsal alan yöntemlerinde sıklıkla kullanılmaktadır [25]. Ek olarak, bir dizi piksel tabanlı yöntemler, Kuaterniyon Dalgacık Dönüşümü (QWT) [26,27] , Örneklenmemiş Konturlet Dönüşümü (NSCT) [28] , ND Süzgeçleme [29] , Ayrık Bileşen Analizi (ICA) [30] , Seyrek Gösterim (SR) [31-35], gibi dönüşüm alanı yöntemlerini kullanılmaktadırlar.

Uzamsal ve dönüşüm tabanlı yöntemler son yıllarda yerini hibrit yöntemlere bırakmakta bu da yeni bir çoklu-odaklı görüntü birleştirme sınıfını ortaya çıkarmaktadır. Bu sınıflara ait yöntemler birleştirilerek etkin çoklu-odaklı görüntü birleştirme yöntemleri geliştirilmektedir. Li ve ark. [36] odak bölgesi tespiti için çok boyutlu pencere tabanlı bir strateji önermekte ve benzerlik ölçümü için korelasyon katsayısını kullanmaktadırlar. Yang ve ark. [37], ilk kaynaşmış görüntüyü elde etmek için İkili ağaç karmaşık dalgacık dönüşümü (DTCWT) tabanlı bir yöntem önermekte ve benzerlik ölçüsü olarak blok kalıntısını kullanmaktadır. Yang ve ark. [38], ilk birleştirme sonucunu elde etmek için NSCT tabanlı bir yaklaşım önermekte ve odaklanmış bölgeleri saptamak için Ortalama Karesel Hata (RMSE) ölçüsünü uygulamaktadır.

Zhang ve ark. [39] çoklu-odaklı görüntü birleştirme için görsel belirginliğe dayalı bir odaklı bölge algılama yaklaşımı önermektedir. Yöntemlerinde, her kaynak görüntü odaklanmış ve odaklanmamış bölgelere ayrıştırılmaktadır. Kaynak görüntülerin odaklanmış bölgeleri birleştirilmiş görüntüye doğrudan aktarılırken, diğer tüm bölgeler Shearlet tabanlı bir birleştirme kuralı ile aktarılmaktadır.

Bu bölümde son sınıf olarak derin öğrenme tabanlı yaklaşımlar aktarılacaktır. Derin Öğrenme son yıllarda her alanda sıklıkla tercih edilmektedir. Bu alanda da derin öğrenmeye dayalı yaklaşımlar son zamanlarda ağırlık kazanmaya başlamıştır. Bu yöntemlerde regresyon ve sınıflandırma tabanlı olarak temelde iki alt alana bölünmektedir.

Sınıflandırma tabanlı yaklaşımlardan ilki Liu ve ark. [40] tarafından önerilmektedir. Bu çalışmada çoklu-odaklı görüntü Birleştirme alanında evrişimli sinir ağları (CNN) ilk defa kullanılmaktadır. Yöntemlerinde, Siyameşe mimarisine sahip sınıflandırmaya yönelik bir CNN, kaynak görüntülerin sabit boyutlu parçalarını odaklı veya odaksız olarak sınıflandırarak birleştirilmiş görüntü oluşturmaktadır.

Amin-Naji ve ark. [41] CNN modelinin sınıflandırma başarısını artırabilmek amacıyla öznitelik seviyesinde öğrenme yöntemini benimsemektedirler. Bu yöntem özellik seviyesi ve karar seviyesinde birleştirme yapabilmektedir. Yang ve ark. [42], ağırlık özellik çıkarma yeteneğini geliştirmek için atlamalı bağlantı tekniğini uygulayarak CNN'ye rehberlik eden çok seviyeli bir öznitelik önermektedirler.

Tang ve ark. [43] her kaynak görüntüdeki pikselleri odaklanmış olanlar, odaklanmamış olanlar ve bilinmeyenler olarak sınıflandırmak için bir piksel tabanlı CNN modeli önermektedirler. Daha sonra, kaynaşmış görüntüyü elde etmek için bir uzamsal alan birleştirme yaklaşımı benimsemektedirler.

Guo ve ark. [44] çoklu-odaklı görüntü birleştirme için en küçük kareler Çekişmeli Üretici Ağ (LSGAN) tabanlı bir yöntem önermektedir. Üretici ağın çıktısı bir odak haritasıdır. İkili çapraz entropi kaybına ek olarak, çıktı ve temel gerçek arasındaki benzerliği daha da geliştirmek için bir ayrımcı model tasarlanmaktadır. Birleştirme sürecinde, üretici ağ tarafından elde edilen odaklanmış harita ikili bir şekilde bölümlere ayrılmakta ve birleştirme için nihai karar haritasını elde etmek için kullanılmaktadır.

Derin öğrenme tabanlı yöntemler için diğer bir sınıf regresyon tabanlı yaklaşımlardır. Bu yaklaşımların ilki Xu ve ark. tarafından uygulanmaktadır. Xu ve ark. [45], Çoklu-odaklı görüntü birleştirme için tamamen evrişimli iki akışlı bir ağ önermekte ve ayrıca eğitim veri setini oluşturmak için Gauss süzgeçlemesini kullanmaktadır. Zhao ve ark. [46], Çoklu-odaklı görüntü birleştirme için CNN'ye dayalı çok seviyeli bir öznitelik işleme mekanizması önermektedir. Özellik çıkarma, birleştirme ve yeniden yapılandırma aşamalarının tümü farklı seviyelerde gerçekleştirilmektedir.

Li ve ark. [47], öznitelik çıkarma yeteneğini geliştirmek için U-şekilli uçtan uca evrişimli bir ağ sunmaktadır. Burada yapı benzerliği (SSIM) temelli yeni bir kayıp fonksiyonu tasarlanmıştır. Lai ve ark. [48], çoklu-odaklı görüntü Birleştirme için çok ölçekli bir görsel evrişim ağı önermektedirler. Çok ölçekli öznitelikleri çıkarmak için genişletilmiş evrişim işlemini uygulamakta ve çıkarılan öznitelikleri iyileştirmek için bir uzamsal dikkat modülü tasarlanmaktadır.

Li ve ark. [49] ağırlık haritası çiftlerini regrese etmek için tam evrişimli bir ağ tasarlamakta ve kaynaşmış görüntü doğrudan ağırlıklı toplamla elde edilmektedir. Kayıp fonksiyonu, ağırlık alanında ve uzamsal görüntü alanında eş zamanlı olarak tasarlanmaktadır. Li ve ark. [50] dalgacık düzleminde çalışan CNN tabanlı çoklu-odaklı görüntü birleştirme yöntemi önermektedir. Bu çalışmada iki uçtan uca evrişimli ağ, sırasıyla yüksek frekanslı ve alçak frekanslı bileşenleri birleştirmek için tasarlanmaktadır.

Literatürde bulunan bazı yöntemler bu bölümde aktarılmaya çalışılmıştır. Çoklu-odaklı görüntü birleştirme yöntemleri, görüntüleme cihazlarının artışıyla hızla artmaya devam etmektedir ve bu yöntemlere ait literatürde mevcut eksiklikler hala devam etmektedir. Bu tez çalışmasında literatürdeki eksiklikleri giderebilecek ve literatüre katkıda bulunabilecek yeni yaklaşımlar önerilmektedir.

1.3. Çoklu-odaklı Görüntü Birleştirme

Görüntülerde, görüntüleme cihazlarının sınırlı derinliklere ulaşabilmesinden kaynaklanan bazı problemler mevcuttur. Bu problemlerin başında görüntüdeki tüm nesnelerin odaklı olmaması gelmektedir. Çoklu-odaklı görüntü birleştirme bu problemi ortadan kaldırmak amacıyla kullanılmaktadır. Bu birleştirme türü aynı sahneye ait iki veya daha fazla farklı odak değerlerine sahip görüntüyü birleştirerek daha net ve detaylı tüm odaklı tek bir görüntü oluşturmayı amaçlamaktadır. Bu işlem yapılırken kaynak görüntülerden doğru bilginin aktarılması ve kenar bilgilerinin korunması oldukça önemlidir. Oluşturulan birleştirilmiş görüntü, görüntü analizi için kolaylıkla kullanılabilir.

Çoklu-odaklı görüntü birleştirme yöntemlerinin temel adımları aşağıdaki gibidir;

Adım 1: Kaynak görüntülerin ön işlemlerden geçirilmesi

Adım 2: Kaynak görüntülerin analizini kolaylaştıracak yöntemin belirlenmesi

Adım 3: Kaynak görüntülerin birleştirilmiş görüntülerdeki temsilini belirleyen birleştirme kuralı oluşturulması

Adım 4: Birleştirilmiş görüntü oluşturulması ve yöntemin performansının değerlendirilmesi

Tüm çoklu-odaklı görüntü birleştirme yöntemleri temelde bu adımlardan oluşmaktadır. Yöntemlerin genel amacı tüm adımlar sonrası detaylı bir birleştirilmiş görüntü elde edilmesinin sağlanmasıdır. Temel adımlara ait detaylı bilgiler bu bölümde aktarılacaktır.

1.3.1. Çoklu-odaklı Görüntü Birleştirme Veri Setleri

Çoklu-odaklı görüntü birleştirme için hazırlanan veri setleri genellikle sıg veri setleridir. Bu veri setleri içerisinde sadece birleştirebilecek iki kaynak görüntü bulunmaktadır ve görüntü setleri sayısı oldukça sınırlıdır. Literatürde yaygın olarak Lytro [51] veri seti ve Prasad [52] tarafından oluşturulan veri seti kullanılmaktadır.

M. Nejati ve ark. [51] tarafından 2015 yılında hazırlanan Lytro veri setinde birleştirmek için 20 adet renkli görüntü seti mevcuttur. Her bir görüntünün boyutu 520x520 pikseldir. Renkli görüntülerde birleştirme yapan yayınlarda sıklıkla kullanılmaktadır. Lytro veri setinden alınan örnek bir görüntü için farklı kaynak görüntüler Şekil 1.2.'de verilmektedir.



(a)

(b)

Şekil 1.2. Lytro veri setinden alınan örnek görüntüler a) Sol-odaklı kaynak görüntü, b) Sağ-odaklı kaynak görüntü

Literatürde kullanılan diğer bir veri seti Durga Prasad [52] tarafından hazırlanan ve 31 görüntü setinden oluşan veri setidir. Bu veri setinde görüntüler manuel olarak düzenlenmiştir. Görüntüler renkli ve gri seviye olmak üzere farklı seviyelerde ve boyutları farklıdır. Görüntü setlerinde görüntülerin orijinal biçimleri de bulunmaktadır. Durga Prasad veri setinden alınan farklı örnek görüntülere ait farklı kaynak görüntüler Şekil 1.3.'de verilmektedir.



(a)

(b)

(c)

(d)

Şekil 1.3. Durga prasad veri setinden alınan örnek görüntüler a) Pepsi sol-odaklı kaynak görüntü, b) Pepsi sağ-odaklı kaynak görüntü, c) Book sağ-odaklı kaynak görüntü, d) Book sol-odaklı kaynak görüntü

1.3.2. Kaynak Görüntülere Uygulanacak Ön işlemler

Çoklu-odaklı görüntü birleştirme yöntemleri kaynak görüntülerdeki doğru odak bilgisinin maksimum seviyede birleştirilmiş görüntüye aktarılmasını amaçlamaktadır. Bu nedenle kaynak görüntülerin ön işlemlerle detaylarının artırılması sonuçları olumlu etkilemektedir. Literatürde ön işlem olarak kullanılan bulanıklık giderme, süper-çözünürlük yöntemleri gibi işlemler kaynak görüntüdeki doğru bilgi miktarını artırmak için kullanılmaktadır.

1.3.2.1. Bulanıklık Giderme Yöntemleri

Kameraların sarsılması veya hareketli nesnelerden dolayı görüntülerde bulanıklık sorunu ortaya çıkmaktadır. Bu sorunun giderilebilmesi için farklı bulanıklık azaltma yöntemleri uygulanmaktadır. Genellikle süzgeçler kullanılarak bulanıklık giderme işlemleri yapılmaktadır. Literatürde bu alanda sıklıkla kullanılan filtreler ortalama süzgeci ve Wiener süzgecidir.

Ortalama süzgeci bulanıklık giderme için kullanılan en temel süzgeçlerden birisidir. Süzgeçleme için farklı boyutta pencereler seçilebilmektedir. Bu pencereler görüntü üzerinde gezdirilerek, üzerinde bulunduğu alanın ortalaması oluşacak görüntüye yeni değer olarak atanır. Böylece bulanıklık etkisi azaltılmaya çalışılmaktadır.

Wiener süzgeci istatistiksel bir yaklaşıma dayanmaktadır. Ortalama süzgecinde olduğu gibi bu süzgeç de farklı pencere boyutları ile uygulanabilmektedir. Bu filtrelerin amacı uyarlanırlar olarak gürültüyü yumuşatmasının yanında görüntülerin önemli parçalarının da korunmasını sağlamaktır. Bunu yaparken ortalama kare hatasını minimuma indirmeye çalışmaktadır. Wiener süzgeci denklem 1.1 ile verilmektedir.

$$W(f_1, f_2) = \frac{H^*(f_1, f_2) x S_{xx}(f_1, f_2)}{|H(f_1, f_2)|^2 x S_{xx}(f_1, f_2) + S_{nn}(f_1, f_2)} \quad (1.1)$$


Kaynak görüntünün güç spektrumu, gürültü ve bulanıklaştırma süzgeci sırasıyla $S_{xx}(f_1, f_2)$, $S_{nn}(f_1, f_2)$ ve $H^*(f_1, f_2)$ ile temsil edilmektedir [53].

1.3.2.2. Süper-çözünürlük Yöntemleri

Görüntü süper çözünürlüğü (SR), düşük çözünürlüklü (LR) görüntülerden yüksek çözünürlüklü (HR) görüntüler elde etme işlemidir[54]. Bilgisayarla görme alanında önemli bir görüntü işleme tekniğidir. Tıbbi görüntüleme, uydu görüntüleme, gözetleme ve güvenlik, astronomik görüntüleme gibi çok çeşitli uygulamalarda kullanılmaktadır.


Görüntü süper çözünürlük (SR) sorunu, özellikle tek görüntü ile süper çözünürlük (SISR), araştırmalarda sıklıkla kullanılmaktadır. SISR, tek bir düşük çözünürlüklü görüntüden yüksek çözünürlüklü bir görüntü oluşturmayı amaçlamaktadır. Genel olarak, düşük çözünürlüklü görüntü ve orijinal yüksek çözünürlüklü görüntü arasındaki ilişki, duruma bağlı olarak değişebilmektedir. Birçok çalışma, düşük çözünürlüklü görüntünün yüksek çözünürlüklü olanın biküçük alt örneklenmiş bir versiyonu olduğunu varsaymaktadır, ancak pratik uygulamalar için bulanıklık veya gürültü gibi diğer faktörler de dikkate alınmalıdır.

İnterpolasyon, yaygın olarak kullanılan süper-çözünürlük yöntemlerindendir. Görüntü interpolasyonu (görüntü ölçekleme), dijital görüntülerin yeniden boyutlandırılması anlamına gelir ve görüntü ile ilgili uygulamalar tarafından yaygın olarak kullanılır[55]. Geleneksel yöntemler arasında en yakın komşu interpolasyonu, doğrusal, çift doğrusal, biküçük interpolasyon vb. türleri bulunmaktadır. En yakın komşu İnterpolasyon işleminin uygulanaşına ait örnek bir matris Şekil 1.4.' te verilmektedir.



Şekil 1.4. En yakın komşuluk interpolasyonu matris gösterimi

En yakın komşu interpolasyonu basit ve sezgisel bir algoritmadır. Diğer piksellerden bağımsız olarak interpolasyon yapılacak her konum için en yakın pikselin değerini seçer [56]. Şekil 1.5 en yakın komşu interpolasyonunu temsil etmektedir.




Şekil 1.5. En yakın komşu interpolasyonu

$$v(x,y) = \begin{cases} f\left(\left\lceil \frac{x}{s} \right\rceil, \left\lceil \frac{y}{s} \right\rceil\right), & \frac{x}{s} \leq 0.5 \text{ ve } \frac{y}{s} \leq 0.5 \\ f\left(\left\lceil \frac{x}{s} \right\rceil, \left\lceil \frac{y}{s} \right\rceil\right), & \frac{x}{s} > 0.5 \text{ ve } \frac{y}{s} \leq 0.5 \\ f\left(\left\lceil \frac{x}{s} \right\rceil, \left\lceil \frac{y}{s} \right\rceil\right), & \frac{x}{s} \leq 0.5 \text{ ve } \frac{y}{s} > 0.5 \\ f\left(\left\lceil \frac{x}{s} \right\rceil, \left\lceil \frac{y}{s} \right\rceil\right), & \frac{x}{s} > 0.5 \text{ ve } \frac{y}{s} > 0.5 \end{cases} \quad (1.2)$$

En yakın komşu interpolasyon hesabı denklem 1.2 ile verilmektedir. Denklemden $v(x,y)$ ile interpolasyon sonucu oluşan piksel değerlerini içeren matris verilmektedir. Ayrıca f ile orijinal sinyal ifade edilirken s katsayısı ile süper-çözünürlük faktörü ifade edilmektedir.

Çift-doğrusal aradeğerleme (BLI) işleminde, önce görüntünün bir ekseninde doğrusal interpolasyon gerçekleştirilir ve ardından diğer ekseninde aynı işlem gerçekleştirilir. Bu işlemde ikinci dereceden bir interpolasyon uygulandığından, en yakın komşu interpolasyonundan çok daha iyi performans göstermektedir[56]. Çift-doğrusal aradeğerlemeye ait görsel Şekil 1.6 ile verilmektedir.

$$f(x,y) \cong \frac{1}{(x_2-x_1)(y_2-y_1)} x(f(Q1)(x_2-x)(y_2-y)) + (f(Q1)(x-x_1)(y_2-y)) + (f(Q1)(x_2-x)(y-y_1)) + (f(Q1)(x-x_1)(y-y_1)) \quad (1.3)$$



Şekil 1.6. Çift doğrusal aradeğerleme

Çift doğrusal aradeğerleme hesaplaması denklem 1.3 ile verilmektedir. Denklemde x ve y değerleri piksellerin satır ve sütun koordinatlarını verirken $f(Q1)$ fonksiyonu bu koordinatlara denk düşen gri seviye parlaklık değerlerini ifade etmektedir.

1.3.3. Çoklu-odaklı Görüntü Birleştirme Seviyeleri

Çoklu-odaklı görüntüler için farklı seviyelerde birleştirme işlemi yapılmaktadır. Çoklu-odaklı birleştirme seviyeleri Şekil 1.7 ile verilmektedir. Genellikle üç ana sınıfa ayrılmaktadır. Bunlar piksel seviyesi, özellik seviyesi ve karar seviyesidir [57].



Şekil 1.7. Çoklu-odaklı görüntü birleştirme seviyeleri

1.3.3.1. Piksel Seviyesi Birleştirme

Piksel düzeyinde birleştirme, temel olarak, insan algısına makine görüşünden daha fazla öncelik verilen dijital fotoğrafçılık, tıbbi görüntüleme, uzaktan algılama, gözetleme,

pilot navigasyon vb. gibi görüntü işleme uygulamalarında kullanılmaktadır. Kaynak görüntülerdeki her bir pikselin birleştirilmiş görüntü için önemi saptanmaya çalışılmaktadır [58].

1.3.3.2. Özellik Seviyesi Birleştirme


Özellik düzeyindeki birleştirme, görüntü birleştirmenin orta düzeyi olarak adlandırılmaktadır. Bu seviye, sınıflandırma ve tanıma görevlerini gerçekleştirmek için kullanılabilir. Kaynak görüntülerden çıkarılan özellik vektörlerinin uygun görüntü birleştirme kuralı ile birleştirilerek tüm odaklı görüntü oluşturulması bu seviyenin ana amacıdır [58].

1.3.3.3. Karar Seviyesi Birleştirme

Karar düzeyinde birleştirme, son yıllarda çok fazla tercih edilen üst düzey bir birleştirme çeşididir. Düşük ve orta seviye birleştirmeye karşılaştırıldığında, yüksek seviye birleştirmenin doğruluğu daha yüksektir, gerçek zamanlı çalışmayı destekler ve ayrıca tek sensörlü görüntülemenin dezavantajlarını çözebilir. Karar seviyesi birleştirme, kaynak görüntülerden çıkarılan parçaların odaklı veya odaksız olarak sınıflandırılmasına olanak sağlamaktadır [58]. Son yıllarda ortaya çıkan derin öğrenmeye dayalı yöntemler bu seviyede çalışmaktadır.

1.3.4. Çoklu-odaklı Görüntü Birleştirme Yöntemlerinin Sınıflandırılması

Çoklu-odaklı görüntü birleştirme yöntemleri son yıllara kadar uzamsal alan teknikler ve frekans alan teknikler olmak üzere iki alt sınıfa ayrılmaktaydı [59]. Son yıllarda derin öğrenme yöntemlerinin literatürde hız kazanmasıyla yeni bir sınıf ortaya çıktı ve artık yöntemler üç sınıfta incelenmeye başladı. Sınıflandırmaya ait görsel Şekil 1.8 ile verilmektedir.



Şekil 1.8. Çoklu-odaklı görüntü birleştirme yöntemleri sınıflandırılması

1.3.4.1. Uzamsal Alan Teknikler

Uzamsal alan teknikleri doğrudan piksel parlaklık değerleri üzerinden görüntü birleştirmeyi amaçlamaktadır. Bu yöntemler temel yöntemlerdir ve son yıllarda çok fazla tercih edilmemektedir. Ortalama alma ve maksimumu seçme literatürde sıklıkla kullanılan uzamsal alan tekniklerine örnektir [59].

Ortalama alma yöntemi, çoklu-odaklı görüntü birleştirme için en temel yöntemdir. Bu yöntem kaynak görüntülerde karşılık düşen piksel parlaklık değerlerinin ortalamasını alarak uzamsal görüntüye aktarmaktadır [60]. Ortalama alma işlemi kenar, köşe vb. gibi önemli bileşenleri yumuşatacağından bu alanda başarı sağlayamamaktadır.

Maksimumu seçme yöntemi ise, ortalama alma yönteminde olduğu gibi piksel parlaklık değerlerini doğrudan kullanan klasik bir yaklaşımdır [60]. Bu yaklaşım ortalama alma yöntemine göre daha başarılı olsa da, kaynak görüntülerde karşılık düşen piksel parlaklık değerinin maksimum olanının her zaman birleştirilmiş görüntü için doğru bilgi olmayacağından çok fazla tercih edilmemektedir.

1.3.4.2. Frekans Alan Teknikler

Frekans alan teknikler, çoklu-odaklı görüntü birleştirme için kullanılmakta olan diğer bir sınıftır. Bu sınıfa ait yöntemler kaynak görüntülerin frekans bileşenlerinden faydalananarak birleştirilmiş görüntü oluşturmayı amaçlamaktadır. Bu yöntemler görüntünün farklı bölümlerinin analizini kolaylaştırması ve her bir frekans bileşeni için farklı birleştirme kuralları uygulanmasına imkân sağlamasından dolayı literatürde daha fazla tercih edilmektedir. Piramit-tabanlı ve dalgacık-tabanlı yaklaşımlar bu sınıfa ait popüler yaklaşımlardır.

Piramit-tabanlı yöntemlerde, kaynak görüntüler alçak geçiren süzgeçlerden geçirilerek gürültüsü giderilmiş alt frekans bileşenler oluşturulmaktadır. Yöntemlerin başarısında alçak geçiren süzgeçlerin seçimi oldukça önemlidir. Oluşturulan bileşenlerin boyutları, ana görüntünün yarısı boyutundadır. Temel olarak birleştirme aşamalarında, kaynak görüntüler alt bileşenlere ayrılır, bu bileşenlere birleştirme kuralı uygulanır ve birleştirme kuralı uygulanan bileşenlere ters piramit uygulanarak tek bir birleştirilmiş görüntü oluşturulur. Bu alanda, Laplas piramidi ve Gauss piramidi en fazla tercih edilenler yöntemlerdir [61].

Bu alanda kullanılan frekans alana ait yöntemlerden diğeri Dalgacık-tabanlı yöntemlerdir. Görüntülerin geometrik analizini kolaylaştıran dalgacık-tabanlı yöntemler birçok görüntü işleme alanında olduğu gibi bu alanda da sıklıkla tercih edilmektedir. Dalgacık dönüşümleri temel olarak, kaynak görüntüleri alçak ve yüksek frekans bileşenlerine ayırarak birleştirme işlemi yapmaktadır. Bu bileşenler için farklı birleştirme kuralları uygulanabilmesi esnek birleştirme işlemine olanak sağlamaktadır. Birleştirme kuralları ile birleştirilen alt bileşenlere ters dönüşüm uygulanarak birleştirilmiş görüntü oluşturulmaktadır. Dalgacık dönüşümleri diğer sınıflardaki yöntemlerle hibrit olarak kullanıldığında daha başarılı sonuçlar elde edilmektedir. Sabit Dalgacık dönüşümü [62], Ayırık dalgacık dönüşümü [63, 64] gibi yöntemler literatürde sıklıkla tercih edilen, bu sınıfa ait yaklaşımlardır.

1.3.4.3. Derin Öğrenmeye Dayalı Teknikler

Son yıllarda, diğer görüntü işleme alanlarında olduğu gibi çoklu-odaklı görüntü birleştirme yöntemlerinde de derin öğrenmeye dayalı yöntemler sıklıkla tercih edilmektedir. Bu yöntemler özellikle sınıflandırma [65], bölütleme [66], süper-çözünürlük [67] gibi

alanlarda sıklıkla tercih edilmektedir. Bu nedenle derin öğrenmeye dayalı teknikler literatürde üçüncü sınıf olarak incelenmeye başlamıştır.


Derin öğrenme teknikleri makine öğrenimi teknikleri, örüntü tanıma, doğal dil işleme ve hesaplamalı öğrenme gibi çeşitli alanlarda yaygın olarak uygulanmaktadır. Ayrıca derin öğrenme yaklaşımları geçtiğimiz yıllar boyunca, makine öğrenimi, verimli web araması, kendi kendine sürüş sistemleri, bilgisayarla görme ve optik karakter tanıma gibi örneklerle günlük yaşamımızı oldukça etkilemektedir. Bu alanlarda derin sinir ağı modelleri, makine öğrenimi ve yapay zekâ için güçlü bir araçtır. Derin sinir ağı (DNN), giriş ve çıkış katmanları arasında çok katmanlı bir yapay sinir ağıdır (YSA).

Derin sinir ağı modelleri orijinal olarak nörobiyolojiden esinlenmiştir. Yüksek düzeyde, biyolojik bir nöron, dendritleriyle temas eden sinapslar aracılığıyla çoklu sinyaller alır ve aksonları aracılığıyla tek bir aksiyon akışı gönderir. Birden çok girdinin karmaşıklığı, girdi kalıplarının kategorilere ayrılmasıyla azaltılır. Bu sezgiden ilham alan yapay sinir ağı modelleri, birden fazla girdiyi birleştiren ve tek bir çıktı üreten birimlerden oluşur. Sinir ağları, beyin benzeri işlevselliği hedefler ve basit bir yapay nörona dayanır. Bu sözde nöronlar katmanlar halinde toplanır ve bir katmanın çıktıları sıradaki diğer katmanın girdileri olur.

1.3.5. Çoklu-odaklı Görüntü Birleştirme Kuralları


Birleştirme kuralının belirlenmesi, çoklu-odaklı görüntü birleştirme yöntemlerinin en önemli parçalarından birisidir. Bu kurallar kaynak görüntülerden birleştirilmiş görüntüye aktarılacak doğru odak bilgisinin belirlenmesinde kullanılmaktadır. Dolayısıyla, önerilecek yöntemlerin başarılarının belirlenmesinde oldukça önemlidir. Literatürde farklı birleştirme kuralları uygulanmaktadır. Ortalama alma, maksimumu seçme, temel bileşen analizine dayalı kurallar, gradyan operatörüne dayalı kurallar vb. literatürde kullanılan birleştirme kurallarından bazılarıdır.

Ortalama alma kuralı, temel bir birleştirme kuralıdır. Bu kural, kaynak görüntülerdeki karşılık düşen değerlerin ortalamasının alınarak birleştirilmiş görüntüye aktarılması mantığına dayanmaktadır. Ortalama alma işlemi, görüntülerdeki önemli bilgilerin kaybolmasına neden olduğundan çok başarılı olamamaktadır [59]. Ortalama alma birleştirme kuralına ait görsel Şekil 1.9. ile verilmektedir.



Şekil 1.9. Ortalama alma birleştirme kuralı

Maksimumu seçme kuralı ise, bu alanda kullanılan diğer bir temel kuraldır. Ortalama alma kuralına göre daha fazla tercih edilmektedir. Bu kural, kaynak görüntülerde karşılık düşen değerlerin maksimumunun birleştirilmiş görüntüye aktarılması yaklaşımına dayanmaktadır. Fakat maksimum değerler her zaman birleştirilmiş görüntü için en doğru odak bilgisini taşımadığından bu kural ile oluşturulan görüntüler bulanıklık, kenar kaybı vb. gibi sorunlar içerebilmektedir [59]. Maksimumu seçme birleştirme kuralına ait görsel Şekil 1.10. ile verilmektedir.



Şekil 1.10. Maksimumu seçme birleştirme kuralı

Son olarak literatürde gradyan-tabanlı birleştirme kuralları sıklıkla tercih edilmektedir. Gradyan [68], görüntülerin analizi için kullanılan önemli bir araçtır. Bu araç birinci türeve dayalı olarak çalışmaktadır. Görüntünün önemli kısımlarında gradyan büyük değerler alırken, arka plan gibi pürüzsüz bölgelerde neredeyse sıfıra yakın değerler almaktadır. Görüntü birleştirme yöntemleri kaynak görüntülerdeki önemli bilgileri birleştirilmiş görüntüye aktarmayı amaçladığından gradyan operatörü bu amacı gerçekleştirmede kullanılabilir. Bu analize dayanan bir gradyan tabanlı kural Aymaz ve ark.[68] tarafından oluşturulmuştur. Bu kuralla oluşturulan birleştirilmiş görüntüler pürüzsüz, önemli bilgileri korunan detaylı görüntülerdir.

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

2.1. Giriş

Çoklu-odaklı görüntü birleştirme yöntemleri, görüntüleme cihazlarının sınırlı derinlikteki nesnelere odaklanıp diğer nesneleri odak dışında bırakmasından kaynaklanan problemleri ortadan kaldırmak için kullanılmaktadır. Bu yöntemlerin iki ana amacı bulunmaktadır. Birincisi kaynak görüntülerdeki odak bilgisini en doğru şekilde birleştirilmiş görüntüye aktarmak, ikincisi ise kaynak görüntülerdeki doğru kenar bilgisini maksimum seviye birleştirilmiş görüntüde korumaktır. Bu tez çalışmasında bu iki ana amacı optimum seviyede gerçekleştirebilecek iki farklı yöntem önerilmektedir. Önerilen yöntemler Bölüm 2.2 ve Bölüm 2.3’ te detaylı olarak aktarılabacaktır.

Önerilen birinci yaklaşım, çoklu-odaklı görüntü birleştirme için kullanılan özgün hibrit bir yaklaşımdır. İkidenden fazla kaynak görüntü içeren gri görüntülerden oluşturulan yeni bir veri seti ilk kez bu yaklaşımda kullanılmaktadır. Önerilen bu yöntem, kaynak görüntülerin detay bilgilerini artırabilmek amacıyla bikübik tabanlı süper-çözünürlük yöntemini kullanmaktadır. Bu ön işlem çoklu-odaklı görüntü birleştirme için literatürde ilk defa kullanılmaktadır. Detayları artırılan kaynak görüntüler Sabit Dalgacık Dönüşümü yardımıyla alt bileşenlere ayrılmakta ve alt bileşenler tasarlanan gradyan-tabanlı birleştirme kuralı ile birleştirilmektedir. Daha sonra ters dönüşüm yardımıyla birleştirilmiş görüntüler elde edilmektedir. Çalışmanın detayları Bölüm 2.2.’ de aktarılmaktadır.

Önerilen ikinci yaklaşım, birinci yaklaşımda olduğu gibi literatüre yenilikler kazandıran öğrenmeye dayalı bir yaklaşımdır. Bu çalışma için iki ve ikiden fazla kaynak görüntü içeren renkli görüntülerden oluşan zengin bir veri seti oluşturulmaktadır. Bu veri seti ve geleneksel veri setlerinden alınan görüntüler ilk olarak örtüşen bloklara ayrılmaktadır. Daha sonra her bir görüntüden alınan görüntü blokları tasarlanan CNN ağına verilmektedir. CNN ağı odaklı ve odaksız görüntüleri ayıracak şekilde tasarlanmaktadır. Her bir görüntü bloğu tasarlanan ağa verildikten sonra her bir kaynak görüntü için ilk karar haritaları oluşturulmaktadır. Bu karar haritaları literatürde ilk kez kullanılan iyileştirme mekanizması ile iyileştirilmektedir. İyileştirilen karar haritalarına morfolojik işlemler uygulanarak karar haritalarının son hali elde edilmektedir. Son olarak tasarlanan dinamik birleştirme kuralı ile

birleştirilmiş görüntüler oluşturulmaktadır. Bu çalışmanın detayları Bölüm 2.3' te aktarılmaktadır.


2.2. Gradyan-tabanlı Yeni Birleştirme Kuralı Kullanarak Süper-çözünürlüklü Farklı Veri Setleri İçin Çoklu-odaklı Görüntü Birleştirme

Çoklu-odaklı görüntü birleştirme yöntemleri, kaynak görüntülerden daha fazla görsellik ve daha fazla bilgiye sahip birleştirilmiş görüntü oluşturulmasını amaçlar. Bu yöntemler görüntüyü oluştururken, kaynak görüntülerden kaynaşmış görüntüye ne kadar önemli bilginin aktarıldığına ve ne kadar kenarın korunduğuna odaklanır. Önerilen yöntemde bu amaçların gerçekleştirilmesi dikkate alınmıştır. Bu çalışmada, çoklu-odaklı görüntü için yüksek dereceli süper çözünürlük yöntemi, Sabit Dalgacık Dönüşümü(SWT) tabanlı ayrıştırma ve gradyan analizlerine dayalı yeni bir birleştirme kuralı içeren yeni bir yaklaşım önerilmiştir. Bu yöntemlerin yanı sıra geleneksel veri setlerinden farklı olarak yeni veri seti oluşturulmuştur. Literatürdeki yöntemler genellikle farklı odaklanmış bölümlere sahip iki kaynak görüntüyü kaynaştırmaya odaklanır, ancak bu durum gerçek hayatta her zaman böyle değildir. Odaklanmamış kısımlar herhangi bir sayıya sahip olabilir ve bu kısımlar görüntünün herhangi bir yerinde meydana gelebilir. Veri seti orijinal olarak bu durumlar göz önünde bulundurularak oluşturulmuştur. Bu veri setinin gelecekteki çalışmalar için ilgi çekici olması beklenmektedir.

Önerilen yöntem birkaç aşamanın birleşimini içermektedir ve bu yöntemler bu bölümde adım adım anlatılacaktır. Önerilen yaklaşımda ilk adım olarak kaynak görüntülerin çözünürlüğü bikübik interpolasyon tabanlı süper çözünürlük yöntemi kullanılarak artırılmıştır. Bu yöntemlerde, görüntülerin ne kadar çözünürlükte katlanacağına karar vermek için sabit değerler olan süper çözünürlük faktörleri kullanılır. Bu yazıda süper çözünürlük faktörleri ayrı ayrı 2, 3 ve 4 olarak seçilmiştir. Çoklu-odaklı görüntü birleştirme yöntemlerinin iki temel amacı vardır; bunlardan biri, kaynak görüntülerden kaynaşmış görüntüye ne kadar doğru bilginin aktarıldığıdır. Kaynak görüntüler sınırlı bilgi ve ayrıntılara sahip olduğundan, bu amaca ulaşmak için kaynak görüntülerin bilgisini artıran ve küçük detayları ortaya çıkaran süper çözünürlüklü yöntemler bu çalışmada uygulanmaktadır. Süper çözünürlük yöntemleri, kaynak görüntülerin uzamsal çözünürlüğünü artırır. Yüksek uzamsal çözünürlüklü görüntüler, düşük olanlardan daha fazla ayrıntı ve bilgi içerir, bu nedenle kaynaşmış görüntüye iletilen bilgi, uzamsal çözünürlük oranına göre artacaktır. Bu

özellikler incelendiğinde, çoklu-odaklı görüntü birleştirmenin hedeflerine ulaşmak için süper çözünürlük yönteminin çok faydalı olabileceği söylenebilir. İkinci olarak, kaynak görüntülerin analizini kolaylaştırmak için her kaynak görüntü için dmey (Discrete Meyer) dalgacık ailesi ile Sabit Dalgacık Dönüşümü(SWT) uygulanır. Önerilen yöntemde faz bozulmalarının azalması nedeniyle mükemmel ayrıştırma ve yeniden oluşturma sağlayan dmey (Discrete Meyer) dalgacık ailesi alçak geçiren ve yüksek geçiren süzgeç olarak seçilmiştir. SWT, kaynak görüntüleri LL (alçak-alçak), LH (alçak-yüksek), HL (yüksek-alçak) ve HH (yüksek-yüksek) olmak üzere dört alt banda ayırır. LL, kaynak görüntülerin düzgün kısımlarını içeren yaklaşıklık katsayısı, diğerleri ise kenarları, gürültüleri vb. içeren ayrıntılı katsayılarıdır. Ayrıntılı katsayılarda önerilen yöntemin başarısını artıran yumuşak eşikleme gürültü giderme yöntemi, gürültüyü azaltmak için uygulanmaktadır. Bu işlemlerden sonra kaynaşmış alt bantlar oluşturulur. SWT, yalnızca yukarı örnekleme işlemini kullandığı için diğer dalgacık dönüşümlerinden ayrılır. SWT tabanlı ayrıştırma sonrası oluşturulan alt bantlar orijinal görüntülerle aynı boyuta sahip olduğundan, alt bantlar diğer dalgacık dönüşümleri ile oluşturulan alt bantlara göre kaynak görüntüler hakkında daha fazla bilgi içerir ve ayrıca yeniden yapılandırılmadan kaynaklanan bilgi kaybı diğer dalgacıklara oranla daha azdır. Önerilen yöntemin bir sonraki ve önemli adımı, kaynak görüntülerden kaynaşmış görüntüye aktarılan piksellerin ağırlıklarını belirten birleştirme kuralının uygulanmasıdır. Önerilen yöntemde, Sobel operatörü ile gradyan tabanlı yöntemi kullanan bir birleştirme kuralı uygulanmaktadır. Gradyan analizleri genellikle literatürde odaklanılan alanları tespit etmek için kullanılır [69, 70]. Literatürün aksine, önerilen yöntemdeki birleştirme kuralı, kaynak görüntülerin odaklanmış kısımlarını tespit etmek için bir adım olarak kullanılan gradyan görüntüleri yerine kaynak görüntülerden çıkarılan bir özellik olan gradyan büyüklüğünü kullanır. Literatürdeki yöntemler ön işleme olarak gradyanları kullanırken, önerilen yöntem Birleştirmen ana parçası olan birleştirme kuralı olarak gradyanları kullanır. Önerilen birleştirme kuralı, kaynak görüntülerde karşılık gelen piksellerin gradyan büyüklüklerinin yorumlanmasına dayanır. Bu yorum incelendiğinde, görüntünün homojen kısımlarında büyüklüğün sıfır civarında yani önemsiz olduğu, ancak kenarlarda ve önemli kısımlarda metriklerin daha büyük değerler aldığı görülmektedir. Çoklu-odaklı görüntü birleştirme yöntemleri, kaynaşmış görüntü için kaynak görüntülerdeki önemli bilgilerin çoğunu aktarmayı ve kaydetmeyi amaçlar, bu nedenle gradyan büyüklükleri bu amaca ulaşmak için oldukça uygundur. İlk olarak, kaynak görüntülerin her bir LL alt bandının gradyan büyüklükleri, Sobel operatörü ile gradyan yöntemi kullanılarak

hesaplanır. Daha sonra kaynak görüntüdeki karşılık gelen piksellerin kaynaşmış görüntü üzerindeki önem oranını belirlemek için kullanılan ağırlık katsayıları, tarafımızca tasarlanan denklemler kullanılarak hesaplanmıştır. LL alt bandı orijinal görüntüye daha yakın olduğu için, her kaynak görüntünün bu alt bantları kullanılarak ağırlık katsayıları çıkarılır. Kaynak görüntülerin homojen kısımlarında gradyan büyüklükleri sıfıra yakın olacağından bu kısımlarda denklem sonuçları sonsuz olacaktır. Bu nedenle bu kısımlarda ağırlık katsayıları 0,5 olarak ayarlanmıştır. Ağırlık katsayısı matrisi kaynak görüntülerle aynı boyuttadır ve her kaynak görüntü için oluşturulur. Birleştirme kuralının son adımı olarak, her bir alt-bant için birleştirilmiş pikseller denklemler kullanılarak hesaplanır. Önerilen birleştirme kuralı, kaynaşmış görüntü için kaynak görüntülerdeki her pikselin önem oranını belirlediğinden, bu kuralın etkin birleştirme için uygun olduğu ve deneysel sonuçların bu durumu desteklediği görülmektedir. Son olarak, kaynaşmış görüntüyü yeniden oluşturmak için Ters Sabit Dalgacık dönüşümü uygulanır. Yeniden oluşturulan görüntünün boyutu kaynak görüntülerden daha büyüktür, bu nedenle önerilen yöntemin performansını objektif olarak ölçmek için bikübik interpolasyon tabanlı yeniden boyutlandırma yöntemi kullanılarak kaynaşmış görüntü orijinal boyutuna yeniden boyutlandırılır. Önerilen yöntemin bu alandaki performansını ölçmek ve literatürde bulunan yöntemlerle karşılaştırma yapmak için objektif ve subjektif metrikler kullanılmaktadır. Ayrıca bu kalite ölçütlerinin yanı sıra, önerilen yöntemin literatürdeki çalışma süresini veren yöntemlerle karşılaştırılması için zaman kriteri de kullanılmaktadır. Çoklu-odaklı görüntü birleştirme alanındaki veri setleri çok sınırlıdır, yalnızca iki odaksız kısım içeren kaynak görüntülere sahiptir, dolayısıyla bu alanda yeni bir veri setine ihtiyaç olduğu açıktır. Yeni veri seti, açık kaynak kodlu görüntü düzenleme programı olan GIMP kullanılarak oluşturulmuş ve bu çalışmada geleneksel veri setlerine ek olarak ilk kez kullanılmıştır. Deneyler hem geleneksel veri setleri hem de yeni veri setleri ile yapılmıştır. Önerilen yöntemin akış şeması iki kaynak görüntüye sahip örnek bir görüntü için Şekil 2.1’de gösterilmektedir.




Şekil 2.1. Önerilen 1. çalışma akış diyagramı

2.2.1. Kullanılan Teorik Kavramlar

Önerilen yöntem farklı teorik kavramların etkin şekilde birleştirilmesiyle oluşturulmaktadır. Bu teorik yaklaşımlar çoklu-odaklı görüntü birleştirme yöntemi amaçlarına uygun olarak seçilmektedir. İlk olarak kaynak görüntülerin detayını artırmak amacıyla ön işlem olarak biküçük tabanlı süper-çözünürlük yöntemi uygulanmış, daha sonra sabit dalgalık dönüşümü yardımıyla görüntüler ayrıştırılmış ve önerilen gradyan tabanlı birleştirme kuralı yardımıyla alt bileşenler birleştirilmiş ve detaylı birleştirilmiş görüntüler oluşturulmuştur. Bu yöntemlere ilişkin detaylar alt bölümlerde aktarılacaktır.

2.2.1.1. Biküçük İnterpolasyon Yöntemi

Biküçük interpolasyona dayalı yöntemler, araştırmacılar tarafından süper-çözünürlük elde etmede en yaygın olarak kullanılan süper-çözünürlük yöntemleridir, çünkü biküçük interpolasyon ile oluşturulan görüntüler diğer interpolasyon yöntemleri ile oluşturulan görüntülerden daha düzgün kenarlara sahip olmaktadır [71]. Biküçük interpolasyon; Photoshop, GIMP vb. gibi görüntü düzenleme programlarında da kullanılmaktadır. Biküçük interpolasyona dayalı süper çözünürlük, komşu pikseller arasındaki ilişkiyi ele almakta ve yüksek çözünürlüklü bir görüntü elde etmek için piksellerin yoğunluğunu kullanmaktadır.



Şekil 2.2. Biküçük interpolasyon

Bikübik interpolasyon için 16 komşu piksel seçilmektedir ve bu pikseller kullanılarak oluşturulan komşuluk matrisi Denklem 2.1 ile verilmektedir. Pikselin satır konumu r ile temsil edilirken ve sütun konumu ise c ile temsil edilmektedir. Bikübik interpolasyon işlemine dair görsel Şekil 2.2 ile verilmektedir.

$$\begin{bmatrix} P11 & P12 & P13 & P14 \\ P21 & P22 & P23 & P24 \\ P31 & P32 & P33 & P34 \\ P41 & P42 & P43 & P44 \end{bmatrix} = \begin{bmatrix} f(r-1, c-1) & f(r-1, c) & f(r-1, c+1) & f(r-1, c+2) \\ f(r, c-1) & f(r, c) & f(r, c+1) & f(r, c+2) \\ f(r+1, c-1) & f(r+1, c) & f(r+1, c+1) & f(r+1, c+2) \\ f(r+2, c-1) & f(r+2, c) & f(r+2, c+1) & f(r+2, c+2) \end{bmatrix} \quad (2.1)$$

Bu değerlerin hesaplanması denklem 2.2 ile verilmektedir. Denklemde $v(x, y)$ yüksek çözünürlüklü görünüş bloğunu temsil etmektedir.

$$v(x, y) = \sum_{i=0}^3 \sum_{j=0}^3 a_i P_{ij} b_j \quad (2.2)$$

Denklemde a_{ij} değerleri yüksek çözünürlük değerlerini elde edilmesinde kullanılan katsayılardır ve denklem 2.3-2.4 ile hesaplanmaktadır.

$$a_i = \prod_{k=0}^3 k \neq i \frac{(x - [sx(c+k)])}{[sx(c+i)] - [sx(c+k)]} \quad (2.3)$$


$$b_j = \prod_{k=0}^3 k \neq j \frac{(y - [sx(r+k)])}{[sx(r+j)] - [sx(r+k)]} \quad (2.4)$$

Sonuç olarak süper çözünürlüklü blok denklem 2.5 ile verilmektedir.

$$v(x, y) = [a1 \ a2 \ a3 \ a4] \begin{bmatrix} P11 & P12 & P13 & P14 \\ P21 & P22 & P23 & P24 \\ P31 & P32 & P33 & P34 \\ P41 & P42 & P43 & P44 \end{bmatrix} \begin{bmatrix} b1 \\ b2 \\ b3 \\ b4 \end{bmatrix} \quad (2.5)$$

2.2.1.2. Sabit Dalgacık Dönüşümü

Dalgacık dönüşümleri, kaynak sinyallere alçak ve yüksek geçiren süzgeçler uygulayarak bu sinyalleri alt bileşenlere ayırmayı amaçlamaktadır [72]. Bu dönüşümler sonrası oluşan alt bileşenlerin boyutları genellikle orijinal sinyal boyutundan daha küçüktür. Bunun nedeni dönüşümlerde uygulanan alt örnekleme işlemidir. Sabit dalgacık dönüşümü alt örnekleme işlemini kullanmadığından diğer yöntemlerden ayrılmaktadır. Bu nedenle sabit dalgacık dönüşümü ile oluşturulan alt bileşenler orijinal sinyal ile aynı boyutta olmaktadır. Ayrıca alt örnekleme işlemi bazı pikselleri ortadan kaldırdığından orijinal sinyaldeki detayların kaybolmasına neden olabilmektedir. Sabit dalgacık dönüşü sonrası oluşturulan alt bileşenler bu nedenlerle daha detaylıdır. LL (alçak-alçak), LH (alçak-yüksek), HL (yüksek-alçak) ve HH (yüksek-yüksek) bantları iki seviyeli dönüşüm sonrası oluşan alt bileşenlerdir. Yüksek geçiren filtre uygulanmış bileşenler detay bileşeni iken, LL (alçak-alçak) bileşeni yaklaşım bileşenidir. Sabit Dalgacık Dönüşümü sonrası oluşan bileşenler Şekil 2.3’de verilmektedir.



Şekil 2.3. Sabit dalgacık dönüşümü

Sabit Dalgacık dönüşümü yöntemi uygulanırken önce satırlara daha sonra sütunlara alçak ve yüksek frekans geçiren süzgeçleme işlemleri yapılmaktadır. Bu bölümde örnek bir $X(t)$ sinyalinin Sabit Dalgacık Dönüşümü yardımıyla frekans bileşenlerine ayrıştırılması işlemi anlatılacaktır. $X(t)$ sinyaline ait dönüşüm $W(a,b)$ ile temsil edilmekte olup denklem 2.6 ile verilmektedir.

$$W(a, b) = \int_{-\infty}^{\infty} X(t) \varphi_{a,b}(t) dt \quad (2.6)$$

$\varphi_{a,b}$, ana dalgacığın döndürülmesi veya ötelenmesi sonrası hesaplanmasını vermektedir ve denklem 2.7. İle hesaplanmaktadır.

$$\varphi_{a,b}(t) = \frac{1}{\sqrt{a}} \varphi\left(\frac{t-a}{b}\right) \quad (2.7)$$

Denklemde a ve b sırasıyla genişleme ve döndürmeyi temsil eden gerçekte pozitif sayılardır. Sinyalin dalgacık dönüşümü denklem 2.8 ile verilmektedir.

$$W(a, b) = \sum_{m=-\infty}^{\infty} x[m] \varphi_{k,l}[m] \quad (2.8)$$

$\varphi_{k,l}[m]$ ana dalgacığın genişlemiş ve döndürülmüş biçimini temsil eder ve denklem 2.9 ile elde edilmektedir.

$$\varphi_{k,l}[m] = 2^{\frac{-k}{l}} \varphi[2^{-k}m - l] \quad (2.9)$$

j. düzeyde bir Sabit Dalgacık Dönüşümünün MxN boyutundaki bir sinyale uygulanması sonucu oluşacak alt bileşenler denklem 2.10, 2.11, 2.12 ve 2.13 ile gösterilmektedir [73].

$$LL_{j+1}(a+b) = \sum_x \sum_y l_x^j l_y^j LL_j(a+x, b+y) \quad (2.10)$$

$$HL_{j+1}(a+b) = \sum_x \sum_y h_x^j l_y^j LL_j(a+x, b+y) \quad (2.11)$$

$$LH_{j+1}(a+b) = \sum_x \sum_y l_x^j h_y^j LL_j(a+x, b+y) \quad (2.12)$$

$$HH_{j+1}(a+b) = \sum_x \sum_y h_x^j h_y^j LL_j(a+x, b+y) \quad (2.13)$$

Denklemlerde alçak geçiren süzgeçler l ile temsil edilirken yüksek geçiren süzgeçler h ile gösterilmektedir. j ve j+1 seviye dönüşüm sonrası oluşan alçak frekans bileşenleri LL_{j+1} ve LL_j ile gösterilmektedir. j+1 seviyedeki yatay detay bileşeni LH_{j+1} ile temsil edilirken

aynı seviyedeki dikey detay bileşeni HL_{j+1} ile temsil edilmektedir. Son olarak çapraz detay bileşeni HH_{j+1} ile gösterilmektedir.

2.2.1.3. Sobel-tabanlı Görüntü Gradyanı

Görüntü gradyan yöntemleri, bir yöndeki yoğunluğu ve renk değişikliklerini ortaya koymak için kullanılırlar. Sobel, Canny vb. gibi kenar algılama operatörlerinin çoğu, yoğunluk veya renklerdeki yüksek değişiklikler kenarları veya köşeleri temsil ettiği için kenarları çıkarmak için görüntü gradyanını kullanırlar. Sobel operatörü, görüntü gradyanını hesaplamak için iyi bir operatördür. Görüntünün ayrıntıları, sobel tabanlı görüntü gradyanı [30] kullanılarak elde edilebilir. Sobel operatörünün 3x3, 5x5 ve 7x7 gibi farklı boyutlarda farklı maskeleri vardır. Bu çalışmada 3x3 Sobel maskesi uygulanmıştır çünkü daha büyük boyutlu maskeler küçük detayları kaldırabilir ve görüntüyü yumuşatabilir [36].

Gradyan, görüntü işlemede sinyalin birinci dereceden türevi olarak açıklanır. Bir görüntü vektörünün gradyanı Denklem 2.14'deki gibi gösterilebilir.

$$\nabla I = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial I}{\partial x} \\ \frac{\partial I}{\partial y} \end{bmatrix} \quad (2.14)$$

Denklem 2.14'te g_x ve g_y , sırasıyla I görüntüsü için x ve y yönündeki gradyan değerlerini göstermektedir. Ve toplam gradyan değeri ∇I ile gösterilir. Gradyan büyüklükleri hesaplanması denklem 2.15 ile verilmektedir.

$$\nabla I = \text{mag}(\nabla I) = (g_x^2 + g_y^2)^{1/2} = \left(\left(\frac{\partial I}{\partial x} \right)^2 + \left(\frac{\partial I}{\partial y} \right)^2 \right)^{1/2} \quad (2.15)$$

Gradyan büyüklükleri, kaynak görüntüler için bir çözümleyici gibi çalışır. Görüntünün önemli kısımlarında, gradyan büyüklüğü daha büyük değerler alır, ancak arka plan gibi önemsiz kısımlar için minimum değerler alır. Bu özelliklerden dolayı, görüntü gradyanları görüntü birleştirme kuralı olarak faydalı olabilir. Çoklu-odaklı görüntü birleştirme yöntemlerinin iki önemli amacı vardır; görüntülerde kenarları ve önemli noktaları korumak

ve birleştirilmiş görüntüye doğru şekilde aktarmak. Gradyan büyüklükleri, özellikleri incelendiğinde bu amaçlara ulaşmak için oldukça faydalıdır.

2.2.2. Önerilen Yöntem

Önerilen yöntem, önceki bölümlerde aktarılan teorik kavramların verimli bir şekilde birleştirilmesi ile elde edilmiştir. Yönteme ait adımlar aşağıdaki gibidir;

Adım1: İki veya daha fazla kaynak görüntü içeren yeni bir veri seti oluşturulması.

Adım2: Kaynak görüntülerin detaylarının artırılması için bikübik-tabanlı süper-çözünürlük yönteminin uygulanması

Adım3: Detaylı inceleme için süper-çözünürlüklü kaynak görüntülerin frekans alt bileşenlerine ayrılması

Adım4: Frekans bileşenlerinin yöntem için hazırlanan özgün gradyan-tabanlı birleştirme kuralı ile birleştirilmesi

Adım5: Birleştirilen frekans alt bileşenlerinin ters Sabit Dalgacık Dönüşümü yardımıyla tüm-odaklı birleştirilmiş görüntüye dönüştürülmesi

Alt bölümlerde her bir adım detaylı olarak aktarılacaktır.

2.2.2.1. Yeni Veri Seti Oluşturulması

Çoklu-odaklı görüntü Birleştirme için veri setleri çok sınırlıdır. Literatürdeki yayınlar genellikle aynı görüntüleri kullanır. Bu görüntülerde iki bulanık kısım vardır. Bu sınırlamalar nedeniyle, bu alan için yeni bir veri seti oluşturulması ihtiyacı ortaya çıkmıştır. Gerçek zamanlı görüntüler literatürdeki veri setlerinin aksine her zaman yalnızca iki odaklanmamış alan içermeyebilir. Bu çalışmada, tarafımızca ikiden fazla odaklanmış veya odaklanmamış parça içeren yeni bir veri seti oluşturulmuştur. Görüntüler, açık kaynaklı bir görüntü düzenleme programı olan GIMP kullanılarak oluşturulmaktadır. Gauss bulanıklaştırma yöntemi, görüntülerin subjektif olarak belirlenen alanlarına uygulanır. Bulanıklaştırılacak alanlar manuel olarak seçilir ve en az bir nesneye sahiptir. Bu veri seti, farklı odaklanmış alanlara sahip 150 görüntü içermektedir. Veri setindeki görüntüler genellikle 512x512 boyutlarında ve farklı nesnelere sahiptir. Literatürde kullanılan veri setinin genellikle iki odaksız alana sahip olması nedeniyle bu veri setinin gelecekte çoklu-

odaklı görüntü birleştirme yöntemleri için önemli olması beklenmektedir. Tüm bu özellikler veri setini literatürdeki diğer veri setlerinden üstün kılmaktadır.

2.2.2.2. Süper-Çözünürlük ile Kaynak Görüntü Detaylarının Artırılması

Süper çözünürlük, düşük çözünürlüklü görüntüler kullanarak yüksek çözünürlüklü bir görüntü oluşturan algoritmadır. Düşük çözünürlüklü görüntüler, yüksek çözünürlüklü görüntülere göre daha az bilgi, daha az netlik vb. içerir, bu nedenle birçok görüntü işleme uygulamasında bu dezavantajları ortadan kaldırmak için bu yöntemlere ihtiyaç vardır. Süper çözünürlük yöntemleri, kaynak görüntülerin bilgilerini artırmayı ve düşük çözünürlüklü görüntülerin küçük ayrıntılarını ortaya çıkarmayı amaçlar. Görüntüyü küçük boyutlara yeniden boyutlandırmak gibi yüksek çözünürlüklü görüntüler oluşturmak için geleneksel teknikler vardır, ancak bu teknikler görüntüleri bulanık ve gürültülü hale getirir. Süper çözünürlük yöntemleri bu dezavantajları ortadan kaldırabilir. Süper çözünürlük yöntemleri iki ana kategoriye ayrılır; tek görüntü süper çözünürlük ve çoklu görüntü süper çözünürlük yöntemleri [74].

Tek görüntü süper çözünürlüklü yöntemler, tek bir düşük çözünürlüklü görüntü kullanarak yüksek çözünürlüklü bir görüntü oluştururlar. Çoklu görüntü süper çözünürlüklü yöntemler ise, yüksek çözünürlüklü bir görüntü oluşturmak için bir dizi düşük çözünürlüklü görüntü kullanır. Çok odaklı görüntü birleştirmede bir dizi düşük çözünürlüklü görüntü bulmak genellikle zordur, bu nedenle çok görüntülü süper çözünürlük yöntemleri bu alanda nadiren tercih edilir. Bu zorluk nedeniyle, bu çalışmada önerilen yöntemin başarısını artırmak için tek görüntülü süper çözünürlük yöntemi tercih edilmiştir. Bu yöntem, kaynak görüntülerin uzamsal çözünürlüğünü artırır. Daha yüksek uzamsal çözünürlüklü görüntüler, düşük olanlardan daha fazla bilgi ve daha fazla ayrıntı içerir, bu nedenle süper çözünürlük yönteminin birleştirme başarısını artıracığı öngörülmektedir.

Son yıllarda farklı süper çözünürlük yöntemleri önerilmiştir. En popüler yöntem türleri öğrenme tabanlı yöntemler, örnek tabanlı yöntemler ve interpolasyon tabanlı yöntemlerdir. Öğrenme tabanlı ve örnek tabanlı yöntemler, interpolasyon tabanlı yöntemlerden daha karmaşık ve daha fazla zaman tüketimine sahiptir. Bu dezavantajlar bir görüntü için göz ardı edilebilir, ancak çoklu-odaklı görüntü birleştirmede ikiden fazla görüntü kaynaştırılmak için kullanıldığından yöntemlerin dezavantajlarını göz ardı etmek mümkün olmamaktadır.

İnterpolasyon tabanlı süper çözünürlük yöntemleri, daha az karmaşıklık ve daha az zaman tüketimine ek olarak iyi bir görsel algı yaratır, bu nedenle bu yazıda kaynak görüntülerin bilgilerini geliştirmek için interpolasyon tabanlı tek kare görüntü süper çözünürlüğü uygulanır. İnterpolasyon tabanlı tekniklerin başlıca üç türü vardır; bikübik, çiftdoğrusal ve en yakın komşu interpolasyonu. En yakın komşu interpolasyonu sadece bir komşuyu dikkate alır ve bunu kullanarak interpolasyonlu noktaları belirler. Bu yöntem etkili değildir, çünkü bir komşu interpolasyonlu değere doğru bir şekilde karar vermek için yeterli değildir. Çiftdoğrusal aradeğerleme dört komşu kullanır ve interpolasyonlu piksel, bu komşulara dayalı lineer denklem kullanılarak hesaplanır. Bu yöntem, en yakın komşu tabanlı interpolasyondan daha iyidir, ancak kenarlar ve diğer parçalar genellikle doğrusal değildir. Bikübik interpolasyon, ortalanmış pikselin 16 komşusunu kullanır. Bu değerler kullanılarak kübik polinom oluşturulur ve bu polinom kullanılarak interpolasyonlu piksel değeri hesaplanır. Yöntem, kenarları ve önemli noktaları korur ve diğer interpolasyon tabanlı yöntemlerden daha başarılıdır [75].

2.2.2.2.1. Bikübik İnterpolasyon Yöntemi ile Kaynak Görüntü Çözünürlüklerinin Artırılması

İnterpolasyon tabanlı yöntemler, bilinen piksellerin etrafındaki bilinmeyen noktalarda piksel değerlerini tahmin eder. Yöntemler interpolasyonlu pikselleri belirlerken bazı polinom veya doğrusal eşitlikler kullanır. İnterpolasyon tabanlı yöntemler, görüntü süper çözünürlüğü, bulanıklaştırma efektlerinin veya gürültülerin giderilmesi gibi birçok alanda kullanılabilir. Bu teknikler genellikle daha az karmaşıklık ve daha az zaman tüketimi nedeniyle görüntü süper çözünürlüğünde tercih edilir [56]. Bu özelliklerin yanı sıra bu teknikler yüksek çözünürlüklü görüntü oluşturmada iyi sonuçlar vermektedir. Bu çalışmada görüntü uzamsal çözünürlüğünü artırmak için araştırmacılar tarafından en çok tercih edilen Bikübik interpolasyon yöntemi kullanılmıştır. Bu teknikte interpolasyonlu piksel değerlerini bulmak için 4x4 komşuluk matrisi kullanılır. Bu matris kullanılarak kübik polinom oluşturulur ve interpolasyonlu noktalar bu polinom kullanılarak çıkarılır. Bikübik interpolasyon yöntemi, görüntülerin kenarlarını ve diğer önemli kısımlarını korur ve bu teknik kullanılarak oluşturulan görüntüler daha az bozulma içerir. Bu özelliklerden dolayı önerilen yöntemde bu interpolasyon tercih edilmiştir. Bikübik interpolasyon tabanlı süper çözünürlük, daha az zaman tüketimine ve iyi görsel sonuçlara sahiptir [76].


2.2.2.3. Sabit Dalgacık Dönüşümü ile Görüntülerin Ayırıştırılması

Dalgacık dönüşümleri genellikle iki işlem içermektedir. Bu işlemler görüntüleri ayırştırmak için kullanılan aşağı-örnekleme ve yukarı-örnekleme işlemleridir. Diğer dalgacıklar, görüntünün tek değerlerini ortadan kaldıran alt örnekleme işlemini uygular; bu işlemle oluşturulan alt bantlar, kaynak görüntüler hakkında daha az bilgi içerir. Bu dalgacık dönüşümlerinin aksine, SWT görüntüleri ayırştırmak için her seviyede yalnızca yukarı örnekleme işlemini kullanır, bu dalgacıkla oluşturulan alt bantlar kaynak görüntülerle aynı boyuta sahiptir ve aşağı örnekleme kullanan diğer dalgacık dönüşümleriyle oluşturulan alt bantlardan daha fazla bilgiye sahiptir. Yani, SWT sinyal boyutunu korur ve özellikle orijinal sinyalin detaylarını tutar. DWT (Ayrık Dalgacık Dönüşümü) de birleştirme algoritmalarında tercih edilir, ancak SWT, DWT'den üç özelliğiyle ayrılır; artıklık, öteleme değişmezliği ve doğrusallık. Ayrıca SWT, standart dalgacıkların aksine alçak frekans alt bantlarında iyi örnekleme oranlarına sahiptir. Bu avantajlar, SWT'yi bu alan için daha değerli kılmaktadır. Orijinal sinyal, ikinci derece SWT kullanılarak dört alt banda ayrıştırılır. Bu alt bantlar LL (alçak - alçak), LH (alçak -yüksek), HL (yüksek- alçak) ve HH (yüksek-yüksek) şeklindedir. LL alt bandı yaklaşıklık alt bandıdır ve diğerleri detay alt bantlarıdır. Yaklaşım alt bandı, orijinal sinyalin pürüzsüz versiyonunu içerir ve detay alt bantları, kenarlar, gürültüler vb. gibi detay bileşenlerini içermektedir.

Sabit Dalgacık Dönüşümü ile görüntülerin ayırıştırılması şekil 2.4 ile verilmektedir. Şekil 2.4. incelendiğinde, alçak geçiren süzgeç ve yüksek geçiren süzgeç, öncelikle SWT'nin birinci derecesi için orijinal sinyalin satırlarına ayrı ayrı uygulanır. Alçak geçiren süzgeç, yüksek frekans katsayılarını ortadan kaldırırken, yüksek geçiren süzgeç, alçak frekans katsayılarını ortadan kaldırmaktadır. Bu işlemlerden sonra iki sinyal oluşturulur. Yöntemin ikinci derecesinde, alçak geçiren ve yüksek geçiren süzgeçler, yöntemin birinci derecesinden sonra oluşturulan sinyal sütunlarına ayrı ayrı uygulanır. Son olarak LL (alçak-alçak), LH (alçak-yüksek), HL (yüksek-alçak) ve HH (yüksek-yüksek) olmak üzere dört alt bant oluşturulur. Bu alt bantlar, orijinal sinyal ile aynı boyuta sahiptir ve Ayrık Dalgacık Dönüşümü' nün alt örnekleme adımını ortadan kaldırdığı için orijinal görüntüler hakkında daha fazla bilgi içerir.

Dalgacık ailesi, dalgacık yöntemlerinin en önemli parçasıdır. Aile, ayırştırma ve yeniden yapılandırmanın ne kadar başarılı olduğunu belirtir. Literatürde aileler genellikle araştırmacılar tarafından göz ardı edilmektedir. Yapaylıkların ve faz bozulmalarının

azalması nedeniyle, alçak geçişli ve yüksek geçişli süzgeç olarak mükemmel ayrıştırma ve yeniden oluşturma sağlayan dney (Discrete Meyer) dalgacık ailesi seçilmiştir. Diğer dalgacık aileleri incelendiğinde bu alanda dney süzgecinin daha başarılı olduğu görülmektedir. Bu süzgeç, diğer dalgacık süzgeçlerinden farklı olarak hızlı bozulma ve sonsuz türevlenebilirlik gibi çekici özelliklere sahiptir [41].




Şekil 2.4. Sabit dalgacık dönüşümü ile görüntülerin ayrıştırılması

2.2.2.4. Gradyan-tabanlı Birleştirme Kuralı

Görüntü gradyanları, piksel değerlerinin hangi yönde nasıl değiştiğini analiz etmek için kullanılır. Analiz, kaynak görüntülerin önemli ve önemsiz kısımlarını ayırmaya izin verir. Görüntünün homojen kısımları daha düşük gradyan büyüklüklerine sahiptir ve kenarlar, köşeler vb. gibi önemli kısımlar daha yüksek gradyan büyüklüklerine sahiptir. Görüntü birleştirme yöntemlerinde, odaklanmış alanları tespit etmek için genellikle gradyan tabanlı yöntemler kullanılır. Önerilen yöntemde gradyan analizine dayalı yeni bir yaklaşım uygulanmaktadır. Bu yaklaşım, literatürdeki gradyan bazlı yöntemlerin aksine, Sobel tabanlı gradyan yöntemi kullanılarak kaynak görüntülerde karşılık gelen piksellerin önem oranlarını gösteren ağırlıkların çıkarılmasına dayanmaktadır. Kaynak görüntülerdeki karşılık gelen pikseller, kaynaşmış görüntü için aynı öneme sahip değildir, bu nedenle başarılı birleştirme için önem oranlarını belirleyen bir mekanizmaya ihtiyaç vardır. Bu mekanizma, bu yazıda orijinal olarak tarafımızca oluşturulmuştur. Kaynak görüntülerdeki pikseller, bu mekanizma kullanılarak çıkarılan önem oranlarına göre kaynaşmış görüntüde temsil edilmekte ve bu durum birleştirme yönteminin başarısını artırmaktadır. Yönteme ait diyagram Şekil 2.5. ile verilmektedir.

Yöntemin matematiksel olarak temsili 2.3.2.4.1 bölümünde verilmektedir.



Şekil 2.5. Gradyan-tabanlı birleştirme kuralı

2.3. Çoklu-odaklı Görüntü Birleştirmede Dinamik Karar Mekanizması (DDM) ile Yeni Bir Yaklaşım


Tez çalışması kapsamında önerilen yöntemin adımlarında literatürdeki yöntemlerin eksikliklerini giderebilecek yenilikler içeren ve derin öğrenmeye dayalı yeni bir yaklaşım önerilmektedir. Öncelikle, Photoshop kullanılarak çoklu-odaklı görüntü Birleştirme için yeni bir veri seti oluşturulmuş ve bu çalışmada kullanılmıştır. Literatürde kullanılan veri setleri kaynaştırılacak yalnızca iki kaynak görüntüye sahiptir. Bu veri setlerinde kaynak görüntüler birbirinin tam tersidir. Yani, kaynak görüntülerden birinde nesne odaklanır ve başka bir kaynak görüntüde ilk görüntüde odaklanan nesne odaktan çıkar ve görüntünün geri kalanı odaklanır. Bu durum, portre fotoğrafları gibi bir tür dijital fotoğrafçılık için uygun olabilir, ancak gerçekte, görüntülerde ikiden fazla nesne odaklı veya odaksız olabilir. Derin öğrenmeye dayalı yöntemler genellikle iki kaynak görüntüye sahip veri setlerini kullanır, bu nedenle kaynak görüntüleri birleştirmek için yalnızca bir karar haritası oluştururlar, ancak tek karar haritası genellikle en iyi sonucu elde etmek için yetersizdir. Tarafımızdan oluşturulan yeni veri seti, farklı odaklanmış ve odaklanılmamış bölümlere sahip iki veya

ikiden fazla kaynak görüntü içermektedir. Yeni veri setinin, literatürde kullanılan veri setlerinden farklılıklar içermesi gelecekte yapılacak çalışmalara yeni bir boyut kazandıracaktır.

Ayrıca önerilen yöntemde, kaynak görüntülerden alınan yamaları odaklanmış veya odaklanmamış olarak sınıflandırabilen değiştirilmiş bir CNN mimarisi tasarlanmıştır. Yeni veri setinden ve geleneksel veri setlerinden alınan kaynak görüntüler, tasarlanan ağ girişinin boyutu olan 8x8 giriş boyutuyla örtüşen yamalara bölünmüştür. Her kaynak görüntü için elde edilen bu yamalar, eğitilmiş ağa ayrı ayrı beslenir. Bu işlemden sonra, odaklanmamış yamalar için 0 etiketli ve odaklanmış yamalar için 1 etiketli olan her bir görüntü yaması için ağın tahminleri, kaynak görüntülerin ilk karar haritalarına kaydedilir. Her bir kaynak görüntü için tüm yamalar sınıflandırılır ve bu görüntüler için ikili görüntü olan karar haritaları oluşturulur. Önerilen yöntemde ilk karar haritaları oluşturulurken literatürden farklı olarak bir iyileştirme mekanizması tasarlanmıştır. Önerilen mekanizma, kaynak görüntülerde karşılık gelen tüm görüntü yamaları odaklanmamış olarak etiketlendiğinde devreye girer. Bu tür durumlar genellikle odaklanmış ve odaklanmamış bölgeler arasındaki sınır noktalarında meydana gelir ve kararsız durumlar olarak adlandırılabilir. Kaynaşmış bir görüntü elde etme başarısını olumsuz etkileyeceğinden bu durumlar en aza indirilmelidir. Bu amaçla, kararsız durumlarda karar mekanizması olarak odak ölçüm metriklerine dayalı bir ara mekanizma kullanılır. Bu mekanizmada literatürde bulunan, odaklanmış ve odaklanmamış ayırımında sıklıkla kullanılan üç metrik seçilmiştir; dalgacık varyansı (WAVV), değiştirilmiş Laplas (SML) ve uzamsal frekans (SF) toplamı. Bu metrikler, hem sorunsuz hem de ayrıntılı yamalar için doğru kararları bulmaya yardımcı oldukları için seçilmiştir. Bu metrikler kullanılarak, kaynak görüntülerdeki her bir görüntü yamasının puanlarını içeren bir puan haritası, her kaynak görüntü için ayrı ayrı oluşturulur. Bu işlemden sonra ilgili yamaların puanları karşılaştırılır ve daha büyük puanın yamaları odaklanmış, diğer yamalar odaksız yani 0 olarak etiketlenir. Bu adımlardan sonra oluşturulan ilk haritalar bazı eksiklikler içerebilir. Kara delikler, merdiven etkileri vb. gibi, bu eksikliklerin üstesinden gelmek için morfolojik operatörler uygulanır. Kapatma işlemleri, başlangıç haritalarında istenmeyen boşluklar, eksiklikler vb. için uygulanır. Ayrıca, kapalı başlangıç haritalarına eşikleme tabanlı bir yöntem uygulanmaktadır. Bu yöntemde öncelikle her görüntü için haritalar bir evrişim çekirdeği kullanılarak bulanıklaştırılır, böylece 0 ve 1 değerlerini alan pikseller 0 ile 1 arasında değerler alır. Bu piksel değerleri kullanılarak eşik değerleri hesaplanır ve eşik değerinden daha küçük olan gereksiz parçalar atılarak düzgün ikili karar görüntüleri elde

edilir. Morfolojik işlemlerden sonra elde edilen haritalar nihai karar haritaları olarak adlandırılır.

Her kaynak görüntü için nihai karar haritaları oluşturulduktan sonraki adım, tüm odaklı görüntüye hangi piksel değerlerinin aktarılacağını belirlemektir. Bu aşamada, nihai karar haritalarında karşılık gelen değerleri kullanan DDM birleştirme kuralı, kaynak görüntülerdeki en uygun piksel değerlerini kaynaşmış görüntüye aktarmak için tasarlanmıştır. DDM birleştirme kuralı, karar haritalarında bulunan etiket değerlerine göre iki farklı seçenek sunar. Haritalarda karşılık gelen değerler aynı ise ilk seçenek olan gradyan tabanlı birleştirme kuralı uygulanır. Haritalardaki karşılık gelen değerler farklı ise ikinci bir seçenek olarak nihai karar haritalarındaki karşılık gelen değerlerin ve kaynak görüntülerin piksel parlaklık değerleri çarpımı doğrudan tüm odaklanılan görüntüye aktarılır. Literatürdeki yöntemler iki kaynak görüntüyü tek bir karar haritası ile birleştirdiği için karar haritalarında karşılık gelen değerlerin aynı olması söz konusu değildir ancak bu durum yöntemlerin ölçeklenebilirliği açısından olumsuzluk yaratmaktadır. Önerilen yöntemde, tüm kaynak görüntüler için hem ayrı karar haritaları oluşturulmakta hem de iki veya daha fazla görüntüyü birleştirebilen ölçeklenebilir bir sistem tasarlanırken, karar haritalarındaki kesişim noktaları (karar haritalarından karşılık gelen etiket değerleri aynıdır) olabilmektedir. Bu gibi durumlarda önerilen DDM birleştirme kuralının ilk seçeneğine göre, bu kesişme noktalarında doğru piksel değerlerinin kaynaşmış görüntüye aktarılması için gradyan tabanlı birleştirme kuralı uygulanır. Bu birleştirme kuralı, kaynaşmış görüntü için kaynak görüntülerdeki karşılık gelen piksellerin önem oranlarını belirler ve daha iyi kaynaşmış görüntüler oluşturulmasına katkıda bulunur. Literatürdeki yöntemlerde benzer bir mekanizma kullanılmadığından, bu katkı önerilen yöntemin bu alana getirdiği yeniliklerden biri olarak kabul edilebilir ve bunun sayesinde sadece bir karar haritası kullanılarak yapılan birleştirmelerin neden olabileceği dezavantajlar ortadan kaldırılabilir. Son olarak, tüm odaklanmış görüntü oluşturulur ve kalite ölçümleri için hazırdır. Kalite ölçümleri için objektif ve subjektif metrikler hesaplanır. Önerilen yöntemin akış diyagramı Şekil 2.6.'da gösterilmiştir.



Şekil 2.6. Önerilen 2. çalışma akış diyagramı

2.3.1. Kullanılan Teorik Kavramlar


Önerilen yaklaşımda, farklı yöntemlerden faydalanılarak başarılı bir birleştirme işlemi gerçekleştirilmiştir. Bu yaklaşımda, odaklı ve odaksız görüntü parçalarının sınıflandırılması amacıyla derin öğrenme yöntemleri kullanılmıştır. Ayrıca sınıflandırma hatalarından kaynaklı problemleri gidermek amacıyla odak metriklerini kullanan bir iyileştirme mekanizması önerilmiştir. İyileştirme mekanizmasının başarısız olduğu bölümlerin düzeltilmesi amacıyla morfolojik işlemlerden faydalanılmıştır. Son olarak özgün olarak tasarlanan gradyan-tabanlı birleştirme kuralı ile tüm-odaklı birleştirilmiş görüntüler oluşturulmuştur. Alt bölümlerde kullanılan teorik kavramlara ilişkin detaylar verilecektir.

2.3.1.1. Derin Öğrenmeye Dayalı Yaklaşımlar

Derin öğrenme yaklaşımları her alanda olduğu gibi görüntü birleştirme alanında da son yıllarda sıklıkla tercih edilmektedir. Bu yaklaşımlar genellikle odaklı ve odaksız görüntü parçalarını sınıflandırma üzerine yoğunlaşmaktadır. Literatürde Derin Sinir Ağlarının 3 popüler türü vardır [77]. Bunlar Çekişmeli Üretici Ağlar(GAN), Tekrarlayan Sinir Ağları(RNN), Evrişimli Sinir Ağları(CNN)'dir.

2.3.1.1.1. Çekişmeli Üretici Ağ (GAN) Tabanlı Yaklaşımlar


GAN kavramı ilk olarak Goodfellow ve ark. [78] tarafından ortaya atılmıştır. Bu model, iki oyunculu minimax oyununu örnek alarak en iyi hedef görüntüyü elde etmek amacıyla kullanılmaktadır. GAN mimarileri iki farklı ağ modeli içermektedir. Bunlar G ile temsil edilen üretici model ve D ile temsil edilen ayrıştırıcı modellerdir. G modeli veri dağılımından yola çıkarak örnekler oluştururken D modeli ise G yerine gelebilecek en iyi hedefi ayrıştırmaktadır. Yani, GAN modeli ayrıştırıcı ve üretici arasında oynanan bir casusluk oyununu andırmaktadır. Üretici model, ayrıştırıcı modeli yanıltabilecek farklı örnekler üretmeye çalışır ve ayrıştırıcı model bu örneklerin gerçek olup olmadığını ayırt etmeye çalışır. Bu aşamalar sonrasında hedefe en yakın görüntü oluşturulmaktadır [79]. Örnek bir GAN mimarisi Şekil 2.7. ile verilmektedir.



Şekil 2.7. Çekişmeli üretici ağ (GAN) mimarisi örneği

2.3.1.1.2. Yinelemeli Sinir Ağları (RNN) Tabanlı Yaklaşımlar

Tekrarlayan sinir ağı (RNN), sıralı veri beslemeyi kullanan bir yapay sinir ağı sınıfıdır. RNN'ler, sıralı giriş verilerinin zaman serisi sorununu çözmek için geliştirilmiştir [80]. RNN girişi, mevcut giriş ve önceki örneklerden oluşur. Bu nedenle, düğümler arasındaki bağlantılar, zamansal bir dizi boyunca yönlendirilmiş bir grafik oluşturur. Ayrıca, bir RNN'deki her nöron, önceki örneklerin hesaplama bilgilerini tutan bir dâhili belleğe sahiptir. Örnek bir RNN mimarisi Şekil 2.8. ile verilmektedir.




Şekil 2.8. Yinelemeli sinir ağları (RNN) örnek mimari

RNN modelleri, verileri sabit olmayan bir giriş uzunluğu ile işlemenin üstünlüğü nedeniyle doğal dil işlemede (NLP) yaygın olarak kullanılmaktadır. Yapay zekânın buradaki görevi, insanlar tarafından konuşulan doğal dili, örneğin doğal dil modelleme, kelime yerleştirme ve makine çevirisini anlayabilecek bir sistem oluşturmaktır. RNN'lerde, sonraki her katman, ağırlıklı çıktı toplamlarının ve önceki durumun doğrusal olmayan fonksiyonlarının bir koleksiyonudur. RNN'nin temel birimine hücre denir ve her hücre, tekrarlayan sinir ağı modellerinin sıralı işlenmesini sağlayan katmanlardan ve bir dizi hücreden oluşur.

2.3.1.1.3. Evrişim Sinir Ağları (CNN) Tabanlı Yaklaşımlar

Evrişimli sinir ağları (CNN veya ConvNet), derin sinir ağlarının başka bir sınıfıdır. CNN'ler bilgisayarla görmede en yaygın kullanılan ağlardır. CNN'de gerçek dünyadan bir dizi görüntü veya video giriş olarak verilebilmektedir. CNN mimarileri, görüntü sınıflandırma, yüz doğrulama ve görüntü anlamsal bölümlendirme görevlerini yerine getirebilmek için bu girdilerden otomatik özellik çıkarmaktadır [81-83]. CNN modellerinde, bir veya birden fazla evrişim katmanı, evrişim işlemlerini yürüterek basit özellikleri girdiden çıkarmaktadır. Her katman, ağırlıkların yeniden kullanılmasına izin vermektedir. Örnek bir CNN mimarisi Şekil 2.9. ile verilmektedir.



Şekil 2.9. Evrişim sinir ağları (CNN) örnek mimari

Çeşitli konvolüsyonel süzgeçler uygulayan CNN, makine öğrenimi modelleri, giriş verilerinin üst düzey temsilde oldukça başarılı olmakta ve bu özellikler CNN'i görüntü sınıflandırma gibi bilgisayarla görme problemleri için popüler hale getirmektedir.

2.3.1.1.3.1. Evrişim Sinir Ağları (CNN) Mimarisinin Yapı Taşları

CNN mimarisi, evrişim katmanları, havuzlama katmanları ve tamamen bağlı katmanlar gibi yapıtaşlarından oluşmaktadır. Tipik bir mimari, bu katmanların tekrarlarından oluşan bloklarla elde edilmektedir. Girdi verilerinin bu katmanlar aracılığıyla çıktıya dönüştürüldüğü adıma ileri yayılma denmektedir. Ayrıca bu mimarilerde geri yayılım da kullanılmaktadır. Bu bölümde açıklanacak evrişim ve havuzlama işlemleri 2D-CNN için olmasına rağmen, benzer işlemler üç boyutlu (3D)-CNN [84] için de gerçekleştirilebilmektedir.

2.3.1.1.3.1.1. Evrişim Katmanı

Evrişim katmanı, tipik olarak doğrusal ve doğrusal olmayan işlemlerin bir kombinasyonundan oluşan, özellik çıkarımını gerçekleştiren CNN mimarisinin temel bir bileşenidir [85].

2.3.1.1.3.1.1.1. Evrişim İşlemi

Evrişim, öznitelik çıkarma için kullanılan, çekirdek adı verilen küçük bir sayı dizisinin, tensör adı verilen bir sayı dizisi olan girişe uygulandığı özel bir doğrusal işlem türüdür. Çekirdeğin her elemanı ile giriş tensörü arasındaki bir eleman için, tensörün her konumunda hesaplama yapılır ve çıkış tensörünün karşılık gelen değer özellik olarak elde edilir. Bu prosedür, giriş tensörlerinin farklı özelliklerini temsil eden, rastgele sayıda özellik haritası oluşturmak için birden çok çekirdek uygulanarak tekrarlanır. Bu nedenle farklı çekirdekler kullanılarak farklı öznitelikler hesaplanabilmektedir. Evrişim işlemini tanımlayan iki anahtar hiperparametre, boyut ve çekirdek sayısıdır. Boyut tipik olarak 3×3 , 5×5 veya 7×7 olabilmektedir. Çekirdek sayısı uygulamaya bağlı olarak değişebilir ve özellik haritalarının derinliğini belirler.

Evrişim işleminde, giriş tensörünün en dıştaki elemanı ile çekirdeğin merkez pikselinin örtüşmesi problem oluşturmaktadır. Bu problem, giriş tensörü ile çıkış özellik haritası boyutlarının farklı olmasına neden olmaktadır. Bu nedenle, doldurma işlemi uygulanmaktadır. Genelde sıfır ile doldurma işlemi yaygın olarak kullanılmaktadır. Bu doldurma işlemi, giriş sinyalinin her iki tarafına sıfırlarla dolu satır ve sütunlarının eklendiği, giriş ile çıkış tensör boyutlarının eşitlendiği bir işlemdir. Modern CNN mimarileri, daha fazla katman uygulamak için düzlem içi boyutları korumak amacıyla genellikle sıfır dolgu kullanmaktadır. Sıfır dolgu olmadan, her ardışık özellik haritası, evrişim işleminden sonra küçülmektedir.

2.3.1.1.3.1.2. Aktivasyon Katmanı

Aktivasyon fonksiyonunun amacı, sinir ağına bir tür doğrusal olmayan özellik eklemektir. Aktivasyon fonksiyonları olmadan, sinir ağı yalnızca x girişlerinden y çıkışlarına doğrusal eşlemeler gerçekleştirebilmektedir. Bu fonksiyonlar kullanılmadığında, ileriye doğru yayılma sırasındaki tek matematiksel işlem, bir girdi vektörü ile bir ağırlık matrisi arasındaki nokta-çarpımlar olacaktır. Doğrusal olmayan özellikleri hesaplayabilmek için sinir ağları, giriş özelliklerinden çıkış etiketlerine kadar doğrusal olmayan ilişkileri tahmin edebilmelidir. Genellikle, öğrenmeye çalıştığımız veriler ne kadar karmaşık, özelliklerin gerçek etiketine eşlenmesi o kadar doğrusal olmayan şekilde olmaktadır. Herhangi bir aktivasyon fonksiyonu olmayan bir sinir ağı, bu tür karmaşık eşlemeleri matematiksel olarak gerçekleştiremez ve ağı çözmesini istediğimiz görevleri yerine getiremez [86]. Bu sorunları ortadan kaldırmak amacıyla, derin öğrenme uygulamalarında farklı aktivasyon fonksiyonları kullanılmaktadır.

2.3.1.1.3.1.2.1. Sigmoid Aktivasyon Fonksiyonu


Literatürde en yaygın olarak kullanılan aktivasyon işlevi sigmoid işlevidir [87]. Sigmoid işlevi, gelen girişleri 0 ile 1 arasında bir aralığa indirgemektedir. Sigmoid işlevi, geçmişte çok popüler olsa da literatüre yeni aktivasyon işlevlerinin eklenmesiyle popülerliğini kaybetmiştir. Bu işlevin, iki önemli dezavantajı vardır: Birincisi, sigmoidlerin gradyanları doyurması ve öldürmesidir. İkincisi ise, sigmoid aktivasyonunun çıktılarının

sıfır merkezli olmamasıdır. Genellikle bu durumlar, sinir ağının eğitimini daha zor ve kararsız hale getirmektedir. Sigmoid aktivasyon fonksiyonu denklem 2.16 ile verilmektedir.

$$\text{sigmoid}(x) = \frac{e^x}{1+e^x} \quad (2.16)$$

2.3.1.1.3.1.2.2. Tanh Aktivasyon Fonksiyonu

Derin öğrenmede yaygın olarak kullanılan bir başka etkinleştirme işlevi de Tanh işlevidir [88]. Tanjant doğrusalsızlığı Şekil 2.10. ile gösterilmektedir.



Şekil 2.10. Tanh aktivasyon fonksiyonu

İşlev, gerçekte değerli bir sayıyı denklem 2.17 kullanarak $[-1, 1]$ aralığına indirgemektedir.


$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.17)$$

Sigmoid fonksiyonunda olduğu gibi, nöronlar büyük negatif ve pozitif değerler için doyuma uğrar ve fonksiyonun türevi sıfıra (mavi alan) gider. Ancak sigmoidin aksine fonksiyon çıktıları sıfır merkezlidir.

2.3.1.1.3.1.2.3. Relu Aktivasyon Fonksiyonu

ReLU, son yıllarda derin öğrenme mimarilerinde çok yaygın olarak kullanılmaktadır. Bu fonksiyon 2010 yılında Nair ve ark. tarafından önerilmiştir. ReLU, gradyan iniş ile

optimize edilen doğrusal modellerin özelliklerini koruyan bir fonksiyondur [89]. Bu fonksiyon, sıfırın altındaki her değeri sıfıra eşitlerken sıfırın üstündeki değerleri korumaktadır. Aktivasyon fonksiyonu grafiği Şekil 2.11. ile verilmektedir.




Şekil 2.11. Relu aktivasyon fonksiyonu

Bu fonksiyon için birçok avantaj ve dezavantaj mevcuttur. Uygulamada, ReLU'nun, diğer aktivasyon fonksiyonlarına kıyasla kayıp fonksiyonunun global minimumuna doğru gradyan inişinin yakınsamasını hızlandığı gösterilmiştir. Bu, doğrusal, doygun olmayan özelliğinden kaynaklanmaktadır. Diğer etkinleştirme işlevleri (tanh ve sigmoid), üstel vb. gibi hesaplama açısından büyük işlemleri içerirken, ReLU, bir değer vektörünü sıfırda eşikleyerek kolayca uygulanabilir. Bu fonksiyonun dezavantajı, sıfırın altındaki giriş değerleri için bu fonksiyonun çıkışları sıfır olduğundan, ağırlık nöronlarının eğitim sırasında çok kırılgan olmasıdır.

2.3.1.1.3.1.2.4. LeakyReLU Aktivasyon Fonksiyonu

Sızdıran ReLU, ReLU aktivasyon fonksiyonundan yola çıkılarak oluşturulan ve geliştirilmiş Relu olarak adlandırılabilen bir aktivasyon fonksiyonudur [90]. Relu fonksiyonu sıfırın altındaki değerleri göz ardı ettiğinden bazı nöronların ölmesine yol açmaktadır. Sızdıran ReLU, bu sorunu çözmek için ortaya atılmaktadır. Sıfırın altındaki giriş değerleri için tüm çıkışların sıfır olduğu ReLU'nun aksine, sızdıran ReLU az da olsa bu değerleri eğitime katmaktadır. Aktivasyon fonksiyonu Şekil 2.12. ile verilmektedir.

$$R(x) = \begin{cases} x & \text{if } x \geq 0 \\ ax & \text{otherwise} \end{cases} \quad (2.18)$$



Şekil 2.12. LeakyRelu aktivasyon fonksiyonu

2.3.1.1.3.1.3. Havuzlama Katmanı

Havuzlama katmanı, küçük kaymalara ve bozulmalara bir öteleme değişmezliği eklemek ve sonraki öğrenilebilir parametrelerin sayısını azaltmak için özellik haritalarının düzlem içi boyutluluğunu azaltan tipik bir alt örnekleme işlemidir. Havuzlama katmanlarının hiçbirinde öğrenilebilir bir parametre bulunmamaktadır. Süzgeç boyutu, adım ve dolgu, havuzlama işlemlerinde evrişim işlemlerine benzer hiper parametrelerdir [85].

2.3.1.1.3.1.3.1. Maksimum Havuzlama İşlemi

Havuzlama işleminin en popüler biçimi, girdi özellik haritalarından yamaları çıkaran, her yamadaki maksimum değeri veren ve diğer tüm değerleri atan maksimum havuzlamadır. Bu işlem, özellik haritalarının düzlem içi boyutunu 2 faktörü ile alt örnekleme işlemidir. Bu işlem sonrasında, yükseklik ve genişlikten farklı olarak, özellik haritalarının derinlik boyutu da değişmeden kalmaktadır.

2.3.1.1.3.1.3.2. Küresel Ortalama Havuzlama İşlemi

Küresel ortalama havuzlama, havuzlama katmanında kullanılan bir diğer işlemdir [26]. Bu işlem, bir özellik haritasının tüm öğelerinin ortalaması alınarak 1×1 diziye alt örneklendiği bir işlemdir. Bu işlem genel olarak tamamen bağlı katmanlardan önce yalnızca bir kez uygulanır. Küresel ortalama havuzlama uygulaması, öğrenilebilir parametrelerin sayısını azaltması ve CNN'nin değişken büyüklükteki girdileri kabul etmesi gibi avantajlar sağlamaktadır.

2.3.1.1.3.1.4. Tam-Bağlantılı Katmanı

Evrişim veya havuzlama katmanının çıktı özellik haritaları tek boyutlu bir sayı dizisine dönüştürülmekte ve yoğun katmanlar olarak da bilinen her girdinin her çıktıya öğrenilebilir bir ağırlıkla bağlı olduğu bir veya daha fazla tam bağlantılı katmana bağlanmaktadır [85]. Evrişim katmanları tarafından çıkarılan ve havuzlama katmanları tarafından alt örneklenen özellikler, tamamen bağlı katmanların bir alt kümesi tarafından ağırlık nihai çıktılarına eşlenir. Nihai tam-bağlantılı katman, sınıf sayısı ile aynı sayıda çıktı düğümüne sahiptir. Her tam-bağlantılı katmanı, doğrusal olmayan bir işlev içeren aktivasyon katmanı takip eder.

2.3.1.2. Derin Sinir Ağlarının Eğitilmesi

Bir ağı eğitilmesi, eğitim veri setinde çıktı tahminleri ve verilen gerçek etiketleri arasındaki farkları en aza indiren evrişim katmanı için çekirdek boyutu ve adedi ile tam bağlantılı katmanlardaki ağırlık değerlerini bulma işlemidir. Geri yayılım algoritması, kayıp fonksiyonu ve gradyan iniş optimizasyon algoritmasının önemli roller oynadığı sinir ağlarını eğitmek için yaygın olarak kullanılan bir yöntemdir. Belirli çekirdekler ve ağırlıklar altındaki bir model performansı, bir eğitim veri seti üzerinde ileriye doğru yayılma yoluyla bir kayıp fonksiyonu ile hesaplanır ve çekirdekler ve ağırlıklar gibi öğrenilebilir parametreler, diğerleri arasında geri yayılım ve gradyan inişi olarak adlandırılan bir optimizasyon algoritması aracılığıyla kayıp değerine göre güncellenir.

2.3.1.2.1. Eğitim İçin Yaygın olarak Kullanılan Veri Setleri

2.3.1.2.1.1. CIFAR-100 Veri Seti

CIFAR-100 veri seti, Alex Krizhevsky, Vinod Nair ve Geoffrey Hinton tarafından toplanan 80 milyon küçük görüntü veri setinin etiketli bir alt kümesidir [91]. Bu veri seti, her biri 600 görüntü içeren 100 sınıfa sahiptir. Sınıf başına 500 eğitim görüntüsü ve 100 test görüntüsü vardır. CIFAR-100'deki 100 sınıf, 20 üst sınıfa ayrılmıştır. Her görüntü ait olduğu sınıf ve ait olduğu üst sınıfa ait etiketler ile birlikte gelmektedir.

2.3.1.2.1.2. MNIST Veri Seti

MNIST veri seti, derin öğrenme için önemli veri tabanlarından biridir. El yazısı rakamlardan oluşan MNIST veri setine Microsoft ve Google laboratuvar araştırmacılarının katkıda bulunduğu bilinmektedir [92]. Temel olarak, el yazısı rakamlarının ikili görüntülerini içermektedir. Veri seti, 60.000 eğitim ve 10.000 test görüntüsü içermektedir.


2.3.1.2.1.3. ImageNet Veri Seti

ImageNet veri seti, görüntü işleme alanındaki artan duyarlılıktan esinlenmiştir ve bilgisayarla görme alanındaki sınıflandırma algoritmaları için veri seti olarak sıklıkla kullanılmaktadır. Bu veri seti [93], WordNet hiyerarşisine göre düzenlenmiş bir görüntü veri setidir. Toplam görüntü sayısı 14.197.122'dir. WordNet'teki kavram, "eş anlamlı küme" veya "eş zamanlı küme" olarak tanımlanır ve WordNet'te, ImageNet'in her bir sözdizimine ortalama 1000 görüntü sağladığı 100.000'den fazla alt set yer almaktadır.

2.3.1.2.2. Eğitim İçin Kullanılan Hiperparametreler

Hiperparametreler, bir veri setine öğrenme algoritması uygulamadan önce ayarlamamız gereken değişkenlerdir. Hiperparametrelerle ilgili zorluk, her alanda maksimum verimlilikle çalışan optimum değerler olmamasıdır. Optimum parametre

değerleri, her göreve ve her veri setine bağlı olarak değişmektedir. Hiperparametreler temel olarak 2 kategoriye ayrılmaktadır.



Şekil 2.13. Evrişim sinir ağı (CNN) hiper parametreler

2.3.1.2.2.1. Optimizasyon Parametreleri

Daha çok optimizasyon ve eğitim süreci ile ilgili parametrelerden oluşmaktadır.

2.3.1.2.2.1.1. Öğrenme Katsayısı

Öğrenme katsayısı, global minimuma ulaşmada oldukça önemli bir parametredir. Bu katsayı, optimal değerden çok küçükse, ideal duruma ulaşmak çok daha uzun süre alacaktır. Optimal değerden çok büyükse, ideal durum aşılmakta ve algoritma yakınsama problemi ortaya çıkabilmektedir. Bu yüzden öğrenme katsayısı optimizasyon için önemli bir değişkendir.

2.3.1.2.2.1.2. Dönem (Epoch) Sayısı

Ağın eğitimi için doğru dönem sayısını seçmek için göz önünde bulundurmanız gereken ölçüm doğrulama hatasıdır. Doğrulama hatası düştüğünde eğitim otomatik olarak durdurulabilmektedir. Dönem sayısı çalışmalarda genellikle 30 olarak seçilmektedir.

2.3.1.2.2.1.3. Aktivasyon Fonksiyonu

Aktivasyon işlevleri, derin öğrenme modellerinin doğrusal olmayan durumları öğrenmesine olanak tanıyan ve modellerin doğrusal olmayan nesneleri tanıyabilmesi için kullanılmaktadır. Bu nedenle iyi bir aktivasyon fonksiyonu seçimi başarıyı artıracaktır.

2.3.1.2.2.1.4. Miniparti Boyutu

Parti büyüklüğü, eğitim sürecinin kaynak gereksinimleri, hız ve yineleme sayısı üzerinde önemli bir etkiye sahiptir.

Daha büyük bir mini parti boyutu, eğitim hesaplamalarında matris çarpımı kullanıldığından eğitim için çok fazla belleğe ihtiyaç duyulmasına neden olmaktadır. Daha küçük bir mini parti boyutu, hata hesaplamalarında daha fazla gürültüye neden olmasına rağmen eğitim sürecinin yerel minimumda durmasını önlemede daha faydalı olmaktadır. Bu değer çalışmalarda genellikle 32 olarak seçilmekte olup değerler uygulamaya bağlı olarak değişmektedir.

2.3.1.2.2.2. Model Parametreleri

Bu parametreler, daha çok modelin yapısını oluşturmak için kullanılmaktadır. Katman sayıları, kayıp fonksiyonları, optimizasyon yöntemleri bu sınıfta yer almaktadır.

2.3.1.2.2.2.1. Katman Sayıları

Uygulamada, 3 katmanlı yapay sinir ağlarının 2 katmanlı olanlardan daha iyi performans gösterdiği belirtilmektedir. Fakat Evrişimli Sinir Ağlarında durum tam tersidir

ve katman sayısı arttıkça ağın performansı da çok daha iyi olmaktadır. Bu nedenle optimum katman sayısının belirlenmesi önem arz etmektedir.

2.3.1.2.2.1.1. Gizli Katman Sayıları

Gizli birimlerin sayısı, kestirilmesi güç olan hiperparametrelerden biridir. Sinir Ağları, evrensel fonksiyon tahmincisidir ve ağı bir fonksiyonu öğrenebilmesi için yeterli kapasiteye sahip olması gerekir. Optimum sayıdan biraz daha fazla birim bir sorun oluşturmamaktadır, ancak çok daha büyük bir sayı modelin yerel minimumlara takılmasını ihtimalini artıracaktır. Bu nedenle çok fazla kapasiteye sahip bir model sağlanması, veri setini ezberleme problemine neden olabilmektedir.

2.3.1.2.2.2. Kayıp Fonksiyonları

Sinir ağları, gradyan inişi metodunu temel alan optimizasyon yöntemleri yardımıyla eğitilirken, bu yöntemlere yardımcı olarak kayıp fonksiyonları kullanılmaktadır. Literatürde kullanılan birçok kayıp işlevi vardır ve bu fonksiyonlar amaca uygun olarak her bir yöntem için değişiklik göstermektedir. Optimizasyon algoritmalarında aday çözümleri elde etmek için kullanılan fonksiyonlar amaç fonksiyonu olarak adlandırılmaktadır. Ağı eğitimi aşamasında bu amaç fonksiyonu maksimize veya minimize edilmeye çalışılmaktadır, Yani sırasıyla en yüksek veya en düşük değere sahip bir aday çözüm aranmaktadır. Sinir ağlarında genel amaç hatayı en aza indirmeye çalışmaktır. Bu nedenle, bu ağlardaki amaç fonksiyonu maliyet fonksiyonu veya kayıp fonksiyonu olarak adlandırılmaktadır. Kayıp fonksiyonu, olası karmaşık bir sistemin tüm iyi ve kötü yönlerini tek bir sayıya, aday çözümlerin sıralanması ve karşılaştırılmasına izin veren bir skaler değere indirgemektedir. Ortalama kare hatası ve Çapraz-entropi kayıp fonksiyonu literatürde sıklıkla tercih edilen kayıp fonksiyonlarıdır.

2.3.1.2.2.2.1. Ortalama Kare Hatası (MSE) Kayıp Fonksiyonu

Ortalama kare hatası, tahminler ve gerçek değerleri arasındaki kare farkının ortalaması olarak ifade edilmektedir. Bu fonksiyon birtakım avantaj ve dezavantajlara sahiptir.

Fonksiyonun dezavantajı, kare alma nedeniyle, gerçek değerlerden uzak olan tahminlerin, gerçek değerlere yakın tahminlere göre daha fazla cezalandırılmasıdır. Avantajı ise gradyanları hesaplamayı kolaylaştıran matematiksel özelliklere sahip olmasıdır [94]. Bu fonksiyon genellikle regresyon tabanlı yöntemlerde tercih edilmektedir.

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (2.19)$$

Ortalama Kare alma kayıp fonksiyonu hesaplanması denklem 2.19 ile gösterilmektedir. Denklemde y ile gerçek değerler gösterilirken $\hat{y}$ ile tahmini değerler gösterilmektedir. N , ise dizi boyutunu vermektedir.

2.3.1.2.2.2.2. Çapraz Entropi (Cross – entropy) Kayıp Fonksiyonu

Çapraz entropi kaybı genellikle "çapraz entropi", "logaritmik kayıp", "lojistik kayıp" veya kısaca "log kaybı" olarak adlandırılmaktadır [95]. Bu fonksiyonda tahmin edilen her olasılık, gerçek sınıf çıktı değeriyle karşılaştırılmakta ve beklenen değerden uzaklığa dayalı olarak olasılığı cezalandıran bir puan hesaplanmaktadır. Burada hesaplanan ceza logaritmiktir ve küçük farklar için küçük bir puan (0,1 veya 0,2) ve büyük bir fark için çok büyük bir puan (0,9 veya 1,0) sunmaktadır. Daha küçük değerlerin modelin başarısı için daha iyi olduğu durumlarda çapraz entropi kaybı en aza indirilmeye çalışılmaktadır. Durumları hatasız olarak tahmin eden bir modelin çapraz entropisi veya log kaybı 0 olmaktadır.

$$CrossEntropyLoss = -(y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (2.20)$$

Çapraz-Entropi kaybının hesaplanması denklem 2.20 ile gerçekleştirilmektedir. Bu denklemde gerçek etiket 1 ($y(i) = 1$) olduğunda, fonksiyonun ikinci yarısı kaybolmakta, gerçek etiketin 0 ($y(i) = 0$) olması durumunda ise denklemin ilk yarısı etkisiz olmaktadır. Bu durum çapraz entropi kaybının, kendinden emin olduğu ama yanlış olan tahminleri ağır şekilde cezalandırması için önemli olmaktadır.

2.3.1.2.3. Optimizasyon Yöntemleri

Optimizasyon yöntemleri, yapay sinir ağlarının ağırlıklar ve öğrenme katsayısı gibi özelliklerini değiştirerek modelin kayıplarını en aza indirmeye çalışmaktadır. Bu algoritmalar, kayıpları azaltmaktan ve mümkün olan en doğru sonuçları sağlamaktan sorumludur. Literatürde Gradyan İnişi, Adagrad, Adam vb. gibi farklı optimizasyon yöntemleri bulunmaktadır.

2.3.1.2.3.1. Gradyan İnişi Optimizasyon Yöntemi

Gradyan inişi, bir kayıp fonksiyonunun birinci dereceden türevine bağlı olan bir optimizasyon yöntemidir. Bu yöntem temel olarak fonksiyonun minimuma ulaşabilmesi için ağırlıkların hangi yönde değiştirilmesi gerektiğini hesaplamaktadır. Geri yayılım ile kayıp bir katmandan diğerine aktarılmakta ve modelin ağırlık olarak da bilinen parametreleri kayıplara bağlı olarak değiştirilmekte, böylece kayıp en aza indirilebilmektedir [96].

Avantajlar:

1. Hesaplanması kolay
2. Uygulaması kolay.
3. Anlaması kolay.

Dezavantajlar:

1. Yerel minimumda kapana kısılabılır.
2. Ağırlıklar, tüm veri setindeki gradyan hesaplandıktan sonra değiştirilir. Bu nedenle, veri seti çok büyükse kayıpların minimuma yakınsaması yıllar alabilir.
3. Tüm veri setindeki gradyanı hesaplamak için büyük bellek gerekmektedir.

2.3.1.2.3.1.1. Stokastik Gradyan İnişi Optimizasyon Yöntemi

Bu yöntem gradyan iniş optimizasyon algoritmasının bir çeşididir. Yöntemin temel farkı modelin parametrelerini daha sık güncellemeye çalışmasıdır. Bu yöntemde, model parametreleri, her eğitim örneğindeki kaybın hesaplanmasından sonra değiştirilmektedir [97,98]. Bu nedenle, veri seti 1000 satır içeriyorsa SGI, model parametrelerini gradyan iniş yönteminin aksine bir kez yerine bir veri seti için 1000 kez güncelleyecektir. Model

parametreleri sık sık güncellendiğinden, parametreler yüksek varyansa ve farklı yoğunluklara sahip kayıp fonksiyonlarında dalgalanmalara sahip olacaktır.

Avantajlar:

1. Model parametrelerinin sık güncellenmesi.
2. Kayıp fonksiyonlarının değerlerini saklamaya gerek olmadığından daha az bellek gerektirir.

Dezavantajlar:

1. Model parametrelerinde yüksek varyans oluşmaktadır.
2. Gradyan inişiyle aynı yakınsamayı elde etmek için öğrenme hızının değerini yavaş yavaş azaltmak gerekmektedir.

2.3.1.2.3.1.2. Mini-parti Gradyan İnişi Optimizasyon Yöntemi

Mini-parti gradyan iniş optimizasyonu, gradyan iniş algoritmalarının tüm varyasyonları arasında en iyi yöntem olarak belirtilmektedir. Hem SGI hem de standart gradyan inişi yöntemleri için ek geliştirmeler içermektedir. Bu yöntemde, her parti boyutu için model parametreleri güncellenmektedir. Yani, yöntemde veri seti, seçilen boyuttaki bloklara bölünür ve her bloktan sonra parametreler tekrar tekrar güncellenir [99].

Avantajlar:

1. Model parametrelerini sık sık günceller ve daha az varyansa sahiptir.
2. Orta miktarda bellek gerektirir.

2.3.1.2.3.2. AdaGrad Optimizasyon Yöntemi

Gradyan iniş optimizasyon yöntemlerinde temel problem öğrenme katsayısının tüm parametreler ve her döngü için sabit olmasıdır. AdaGrad optimizasyon yöntemi, sabit öğrenme katsayısı yerine dinamik olarak değişen öğrenme katsayısını kullanmaktadır. Bu yöntemde her parametre için ve her zaman adımında 't' öğrenme katsayısı, 'η' katsayısı ile değiştirilmektedir. AdaGrad optimizasyon yaklaşımı, ikinci dereceden bir optimizasyon yaklaşımıdır [100,101].

$$g_{t,i} = \nabla_{\theta} J(\theta_{t,i}) \quad (2.21)$$

Denklem 2.21 belirli bir t zamanında verilen parametreler için kayıp fonksiyonunun türevini hesaplamaktadır.

$$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \varepsilon}} \cdot g_{t,i} \quad (2.22)$$

Denklem 2.22 verilen i girişinin parametrelerini t zamanında güncellemek için kullanılmaktadır. η , verilen $\theta(i)$ parametresi için hesaplanan önceki gradyanlara dayalı olarak oluşturulan öğrenme katsayısını temsil etmektedir. Bu yöntemde seyrek parametreler için büyük güncellemeler ve sık parametreler için küçük güncellemeler yapılmaktadır.

Avantajlar:

1. Her eğitim parametresi için öğrenme hızı değişkendir.
2. Öğrenme katsayısının manuel olarak ayarlanması gerekmez.
3. Seyrek veriler üzerinde eğitim imkânı sunmaktadır.

Dezavantaj:

1. İkinci dereceden türeve bağlı bir yöntem olduğundan hesap yükü fazladır.

2.3.1.2.3.3. Adam Optimizasyon Yöntemi

Adam (Uyarlamalı Moment Tahmini) birinci ve ikinci dereceden momentumlara bağlı olarak çalışmaktadır. Adam yöntemi, AdaGrad yöntemi gibi geçmiş kare gradyanlarının üstel olarak azalan bir ortalamasını depolamaktadır. Bu yöntemde Adagrad yöntemine ilaveten, geçmiş moment değerlerinin gradyanlarının ortalamaları da tutulmaktadır, Adam optimizasyon yöntemi ile parametre güncellenmesi, denklem 2.23, 2.24 ve 2.25 kullanılarak yapılmaktadır.

Denklem 2.23 ve 2.24 de $m(t)$ ve $V(t)$, sırasıyla gradyanların ortalaması olan birinci momenti ve gradyanların merkezlenmemiş varyansı olan ikinci momenti temsil etmektedir [102].

$$\widehat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (2.23)$$

$$\widehat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (2.24)$$

Sonuç olarak parametrelerin güncellenmesi denklem 2.25 ile yapılmaktadır.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \quad (2.25)$$

Avantaj:

1. Yöntem çok hızlıdır ve hızla yakınsama yapmaktadır.

Dezavantaj:

1. Hesaplama olarak maliyetlidir.

2.3.1.3. Odak Bilgisi Ölçüm Metrikleri

Odak ölçümü operatörlerinin amacı, bir görüntünün veya görüntü pikselinin netlik derecesini veya odak derecesini değerlendirmektir. Literatürde uygulamaya bağlı olarak tüm görüntünün veya görüntü pikselinin odak derecesini ölçmek için çok çeşitli algoritmalar ve operatörler önerilmektedir. Odak ölçüm operatörleri genellikle 6 ana grupta incelenmektedir; gradyan tabanlı, Laplas tabanlı, dalgacık tabanlı, istatistik tabanlı, DCT tabanlı ve diğer [103]. Bu bölüm, her sınıf için kısa bir açıklama sunmaktadır. Odak ölçüm metrikleri görüntü içeriğinden bağımsız olma, düşük hesaplama yükü, gürültüye dayanıklı olma gibi bazı şartları yerine getirebilmelidir.

2.3.1.3.1. Gradyan-tabanlı Metrikler

Gradyan-tabanlı operatörler, odaklanmış görüntülerin bulanık olanlardan daha keskin kenarlara sahip olduğunu varsaymaktadır. Böylece, odak derecesini tahmin etmek için gradyanın enerjisinden yararlanılabileceği öngörülmektedir. Bu prensibe dayalı operatörlerin, görüntülenen sahne yüksek dokulu olduğu sürece verimli çalışması beklenmektedir. Bu durum çoğu odak ölçüm operatörü için ortak bir kısıtlama olarak görülmektedir.

2.3.1.3.1.1. Gradyan Enerjisi (EOG)

Gradyan enerjisi metriği detay bileşenleri miktarını ölçerek odak miktarını vermeye çalışmaktadır [104]. Metrik hesaplanması, denklem 2.26, 2.27 ve 2.28 kullanılarak hesaplanmaktadır.

$$EOG = \sum_x \sum_y f_x^2 + f_y^2 \quad (2.26)$$

$$f_x = f(x+1, y) - f(x, y) \quad (2.27)$$

$$f_y = f(x, y+1) - f(x, y) \quad (2.28)$$

Denklemlerde $f(x, y)$, x ve y koordinatlarına denk gelen gri seviye parlaklık değerini göstermektedir.

2.3.1.3.2. Laplas-tabanlı Metrikler

Gradyan tabanlı operatörler ile benzer şekilde, bu operatörlerin amacı, ikinci türev veya Laplas aracılığıyla, görüntülerde bulunan kenarları tespit etmektir. Laplas ayrıca kenar algılama ve görüntü iyileştirme için yaygın olarak kullanılan bir görüntü işleme aracıdır. Laplas-tabanlı operatörlerin, görüntü gradyanı-tabanlı operatörlerine göre gürültüye karşı artan duyarlılığı dezavantaj olarak ifadeedilmektedir.

2.3.1.3.2.1. Laplas Enerjisi Metriği (EOL)

Görüntü kenarlarının keskinliği ile ilişkili yüksek uzamsal frekansları analiz etmek için başka bir odak ölçüsü Laplas operatörüdür [104]. Metriğin hesaplanması, denklem 2.29 ve 2.30 kullanılarak yapılmaktadır.

$$EOL = \sum_x \sum_y (f_{xx} + f_{yy})^2 \quad (2.29)$$

$$f_{xx} + f_{yy} = -f(x-1, y-1) - 4f(x-1, y) - f(x-1, y+1) - 4f(x, y-1) + 20f(x, y) - 4f(x, y+1) - f(x+1, y-1) - 4f(x+1, y) - f(x+1, y+1) \quad (2.30)$$

Denklemlerde $f(x, y)$, x ve y koordinatlarına denk gelen gri seviye parlaklık değerini göstermektedir. EOL, ise Laplas enerjisini temsil etmektedir.

2.3.1.3.2.2. Toplam-değiştirilmiş Laplas Metriği (SML)

Nayar ve ark. [105] Laplas için uygulanan ikinci türevlerin birbirlerini iptal etme eğiliminde olacağını ve bundan dolayı x ve y yönlerinde zıt işaretlerde olabileceğini ortaya atmışlardır. Bu nedenle, modifiye Laplas (ML) adında yeni bir yaklaşım önermektedirler. ML hesaplanması denklem 2.31 ile verilmektedir.

$$\nabla_{ML}^2 f(x, y) = |2f(x, y) - f(x - step, y) - f(x + step, y)| + |2f(x, y) - f(x, y - step) - f(x, y + step)| \quad (2.31)$$

Nayar, doku elemanlarının boyutundaki olası varyasyonlara uyum sağlamak için, ML'yi hesaplamak için pikseller arasında değişken bir boşluk (step) kullandı.

$$SML = \sum_{i=x-N}^{i=x+N} \sum_{j=y-N}^{j=y+N} \nabla_{ML}^2 f(i, j) \quad \nabla_{ML}^2 f(i, j) \geq T \quad (2.32)$$

Denklem 2.32'de T, eşik değerini temsil etmektedir.

2.3.1.3.3. Dalgacık-tabanlı Metrikler

Bir görüntünün dalgacık ayrıştırması, eşzamanlı bir frekans ve ölçek-uzay analizi olarak yorumlanabilmektedir. Dalgacık ayrıştırması sonucu görüntüler yüksek ve alçak frekans bileşenlerine ayrılmaktadır. Yüksek frekans bilgileri kenar, köşe gibi detay bilgileri temsil ederken alçak frekans bilgileri yumuşak bölgeleri temsil etmektedir. Diğer operatörler ile aynı mantıkla, detay alt-bantlarının enerjisinin, görüntünün en yüksek frekansları ile ilişkili olduklarından, bir görüntünün odak derecesini tahmin etmek için kullanılabileceği varsayılmaktadır. Uzamsal alan perspektifinden dalgacık dönüşümü, bir görüntünün farklı çözünürlüklerinin temsili olarak yorumlanabilir.

2.3.1.3.4. İstatistiksel Metrikler

Uzamsal alanda, bulanıklaştırmanın etkisi, görüntülenen sahnenin dokuları üzerindeki etkilerinden değerlendirilebilir. İstatistiksel operatörler doku tanımlayıcıları olarak oldukça

başarılı oldukları kanıtlanmıştır. Bu nedenle doku değerlendirilmesinde sıklıkla kullanılmaktadır. Sezgisel olarak, odaklanmamış bir görüntü, artan odaklanma seviyeleri için düzgünlüğü artan bir doku olarak yorumlanabilir. Bu yorumlama kullanılarak odak ölçümü başarılı bir şekilde yapılabilmektedir.

2.3.1.3.4.1. Uzamsal Frekans (SF) Metriği

Görüntü gradyanının (EOG) enerjisinin değiştirilmiş bir versiyonudur. Uzamsal frekans metrik hesaplanması denklem 2.33 ile verilmektedir [106].

$$SF = \sqrt{RF^2 + CF^2} \quad (2.33)$$

Denklem 2.34 ve 2.35’ te RF ve CF sırasıyla satır ve sütun frekanslarını göstermektedir.

$$RF = \sqrt{\frac{1}{M \times N} \sum_{x=1}^M \sum_{y=2}^N [f(x, y) - f(x, y - 1)]^2} \quad (2.34)$$

$$CF = \sqrt{\frac{1}{M \times N} \sum_{x=2}^M \sum_{y=1}^N [f(x, y) - f(x - 1, y)]^2} \quad (2.35)$$

2.3.1.3.5. DCT-tabanlı Metrikler


Ayrık kosinüs dönüşümü (DCT), sinyallerin frekans alanındaki temsili için Fourier dönüşümüne bir alternatif olarak gösterilmektedir. Ana özelliklerinden birisi, giriş sinyalinin bilgilerinin dönüşümün en düşük katsayılarında saklanması yeteneğidir. Bu karakteristik, enerji sıkıştırma özelliği olarak adlandırılmaktadır. Sıkıştırma özelliği, görüntü ve video sinyallerinin kayıplı olarak sıkıştırılması için kullanılabilir. Uzamsal alanda, DCT katsayıları görüntü netliğinin tahmini için kullanılabilir. DCT'nin AC bileşenlerinin toplamı, görüntü yoğunluğunun varyansına eşittir ve bu da odak ölçüsü olarak kullanılabileceğini göstermektedir. Birçok popüler video ve görüntü formatının parçası olan DCT'yi odak ölçümü için kullanmanın ana motivasyonu, hesaplama maliyetini düşürmektedir.

2.3.1.3.6. Diğer Metrikler

Diğer operatörler, önceki beş grubun hiçbirine ait olmayan operatörleri temsil etmektedir. Bu gruptaki operatörler, diğerlerinin yanı sıra görüntü kontrastı, yerel ikili modeller ve yönlendirilebilir süzgeçler gibi farklı kavramları ele almaktadır.

2.3.1.4. Morfolojik İşlemler

Morfolojik görüntü işleme, bir görüntüdeki özelliklerin karakteristiği ile ilgilenen bir dizi görüntü işleme tekniği olarak tanımlanmaktadır [107]. Morfolojik işlemler genellikle bölütleme sırasında ortaya çıkan ikili görüntülerin kusurlarını gidermek için uygulanmaktadır. Yapı elemanı, morfolojik bir işlem uygulamak için kullanılan temel yapılara verilen isimdir. Bir yapı elemanının şekli, bir görüntüde ne tür bir şekil aradığımıza bağlı olarak değişebilecek esnekliktedir. Literatürde kullanılan bazı yapı elemanı örnekleri Şekil 2.14. ile verilmektedir.



Şekil 2.14. Morfolojik yapılar

Bu bölümde Erozyon, Genişletme, Açma ve Kapama olmak üzere 4 farklı morfolojik işlem anlatılacaktır.

Erozyon işleminde, seçilen yapı elemanı görüntü boyunca hareket etmektedir. Görüntü modeli ile yapı elemanı modelinin tam olarak eşleştiği yerlerde, görüntüdeki yapı elemanının merkez noktasındaki piksel 1 ile değiştirilirken, eşleşme olmayan yerlerde piksel değerleri 0 ile değiştirilmektedir [107]. Erozyon işlemin genellikle $\ominus$ simgesi ile temsil edilmektedir.

Erozyon İşlemi Özellikleri:

1. Erozyon, nesne sınırlarındaki pikselleri kaldırmaktadır. Başka bir deyişle, ön planda olan nesneleri küçültmektedir.
2. Erozyon işlemi, ön planda bulunan boşlukları büyütmektedir.
3. Görüntü işleme çekirdeklerinde olduğu gibi, yapı elemanının daha büyük boyutta olması erozyon işleminin etkisini artırmaktadır.

Genişletme işleminde de olduğu gibi, yapı elemanı görüntü boyunca hareket etmektedir. Bu işlem sırasında görüntü deseni ile yapı elemanı deseninin eşleştiği alanlarda merkez piksel 1 değeri ile değiştirilirken eşleşme olmayan alanlarda merkez piksel 0 ile değiştirilmektedir [107]. Genişletme işlemi genellikle $\oplus$ simgesi ile temsil edilmektedir.

Genişletme İşlemi Özellikleri:

1. Genişletme işlemi etkileri erozyon işleminin tam tersidir.
2. Genişletme işlemi, nesne sınırlarına pikseller eklemektedir.
3. Genişletme, ön plandaki boşlukların doldurulmasını sağlamakta ve ön plan nesnelerini büyütmektedir.
4. Erozyon işlemi ile paralel olarak genişletme işleminde, daha büyük bir yapı elemanı daha büyük bir genişleme etkisi vermektedir.

Açma işlemi, genişletme işleminin ardından gelen erozyon işleminin başka bir ismidir. Bu işlem, görüntülerdeki tuz gürültüsünü gidermede etkilidir [107].

Kapama işlemi, erozyon işleminin takip ettiği genişleme işleminin başka bir ismidir. Bu işlem görüntülerdeki biber gürültüsünü gidermede etkilidir [107].

2.3.2. Önerilen Yöntem

Bu çalışmada özgün olarak oluşturulan ve farklı yöntemlerin birleştirilmesinden elde edilen başarılı bir birleştirme işlemi sağlanmıştır. Önerilen yaklaşım yenilikçi adımlardan oluşmaktadır. Bu adımlar;

Adım1: Birleştirme işlemi için kullanılacak iki veya daha fazla kaynak görüntü içeren bir veri seti ve öğrenmeye dayalı yöntemin başarılı şekilde çalışması için zengin bir eğitim veri seti hazırlanması.

Adım2: Yeni bir CNN mimarisi tasarlanması, sonrasında yeni veri seti ve geleneksel veri setlerinden alınan kaynak görüntülerin önerilen ağa beslenmesi

Adım3: İlk karar haritalarında oluşan sınıflandırma hatalarının en aza indirilebilmesi için oluşturulan odak metriklerine dayalı iyileştirme mekanizması oluşturulması

Adım4: Karar haritalarındaki bozulmaları gidermek amacıyla morfolojik işlemlerin uygulanması

Adım5: Karar haritalarının birleştirilmesi için oluşturulan özgün dinamik karar mekanizmalı birleştirme kuralı uygulanması

Adım6: Birleştirme edilmiş görüntü oluşturulması ve performans ölçümleri


Alt bölümlerde bu adımlar detaylı olarak aktarılacaktır.

2.3.2.1. Önerilen Çalışma İçin Veri Setlerinin Oluşturulması

2.3.2.1.1. Eğitim Veri Seti Oluşturulması

Eğitim setinin hazırlanması, ağın eğitim doğruluğunda önemli bir role sahiptir. Eğitim setiniz ne kadar iyiye eğitim sonuçlarınızın da o kadar iyi olacağı söylenebilir, bu nedenle çalışmada geniş bir eğitim veri seti hazırlanmıştır. Önerilen çalışmada sınıflandırma tabanlı bir derin öğrenme yöntemi uygulandığından, eğitim seti 0 etiketli ve 1 etiketli iki sınıf için görüntüler içerir. Etiket 0, odaklanmamış görüntü yamalarını temsil eder ve etiket 1, odaklanmış görüntü yamalarını temsil eder. Yani, bu makaledeki yöntem, kaynak görüntülerdeki yama sınıflarını bulmayı amaçlamaktadır. Her biri 600 görüntü içeren 100 sınıflı CIFAR-100 [91] veri seti, yeni eğitim veri seti oluşturmak için kullanılmıştır. 32x32 boyutlarında toplam 60.000 adet görsel bulunmaktadır. CIFAR-100 veri setindeki her görüntü 8x8 boyutunda yamalar halinde bölünür ve bu işlemden sonra 1 etiketli 800.000 odaklı yama elde edilir. Ayrıca, yamalara döndürme, kesme, öteleme, kontrast iyileştirme gibi modifikasyonlar uygulanarak 1.600.000 ekstra yama elde edilmiştir, böylece etiket 1 için toplam 2.400.000 adet 8x8 boyutunda görüntü yaması oluşturulmuştur. Odaklanmayan yamalar oluşturulurken, yamaları bulanıklaştırmak için kullanılan 6 farklı boyuttaki Gauss süzgeci, odaklanmış yamalar üzerinde uygulanmış ve 2.400.000 odaklanmamış yama elde


edilmiştir. Gauss süzgecinin boyutları ayrı ayrı 3, 5, 7, 9, 11, 13 olarak seçilmektedir. Bu çalışmada, eğitmek için toplamda 4.800.000 adet görüntü yaması kullanılmıştır. Bu görüntülerin %70'i eğitim ve %30'u validasyon için kullanılmaktadır. Literatürdeki diğer yöntemlerden farklı olarak, eğitim seti oluşturulurken görüntü yamalarına öteleme, kesme, döndürme, kontrast iyileştirme gibi modifikasyonlar uygulanarak eğitim setinin zenginleştirilmesi amaçlanmıştır. Eğitim veri setini oluşturmak için kullanılan Cifar-100 veri setinden bazı görüntüler Şekil 2.15.'de verilmiştir.



Şekil 2. 15. CIFAR-100 veri setinden alınan örnek görüntüler

2.3.2.1.2. Çoklu-odaklı Görüntü Birleştirme İçin Yeni Veri Seti Oluşturulması

Literatürde kullanılan veri setleri genellikle aynı mantığa sahiptir. Bu veri setlerinin birleştirilecek yalnızca iki kaynak görüntüsü vardır. Bu veri setlerinde kullanılan kaynak görüntüler, odaklı bir nesne içerir ve kaynak görüntünün geri kalanı odaklanmaz. Bu durum gerçeğe aykırıdır, çünkü cihazlar tarafından yakalanan görüntüler, rastgele odaklanmış veya odaklanmamış ikiden fazla nesne içerebilir. Bu nedenle bu alanda kullanılacak yeni bir veri setine ihtiyaç duyulmaktadır. Tarafımızdan oluşturulan veri seti bu ihtiyaçlar göz önünde bulundurularak hazırlanmıştır. Photoshop kullanılarak hazırlanan yeni veri seti, farklı görüntü sayılarından oluşan 155 set ile toplam 715 renkli görüntü içermektedir. Bu kümeler, en az 2, en fazla 6 kaynak görüntüye sahip olacak şekilde düzenlenmiştir. Orijinal görüntüler COCO veri setinden [108] alınır ve Photoshop kullanılarak değiştirilir. Bu veri setlerindeki kaynak görüntüler farklı boyutlara ve farklı odaklanmış alanlara sahiptir. Bu veri seti, literatürdeki veri setlerinin kaynaştırılacak yalnızca iki kaynak görüntü içermesi ve ayrıca görüntülerin sınırlı olması nedeniyle yeni olarak adlandırılabilir. Bu durumlar göz önüne alındığında yeni veri setinin [109] bu alanda büyük bir boşluğu dolduracağı ve yeni çalışmalara da yön vereceği söylenebilir. Yeni veri setinden alınan bazı kaynak görüntüler Şekil 2.16. ile verilmektedir.




Şekil 2.16. Önerilen 2. çalışmada oluşturulan yeni veri setinden alınan örnekler

2.3.2.2. Evrişim Sinir Ağları (CNN) Modeli Tasarlanması ve Görüntü Yamalarının Bu Ağa Beslenmesi

2.3.2.2.1. Önerilen Çalışma İçin Tasarlanan CNN Modeli

Derin sinir ağının bir türü olan Evrişimli Sinir Ağları (CNN veya ConvNet), görüntülerin kenarlar, köşeler vb. gibi önemli özelliklerini çıkararak görüntü analizini kolaylaştırır. CNN mimarilerinde üç ana katman vardır; Evrişim Katmanı, Havuzlama Katmanı ve Tam Bağlantılı Katman. Evrişim katmanı, farklı boyut ve miktarlarda süzgeçlerle görüntü yamalarının özelliklerini çıkarmak için kullanılır. Bu katmanın süzgeç boyutu, süzgeç miktarları vb. girdi parametreleri vardır. Evrişim katmanının çıktısı havuz katmanına girdi olarak verilir. Havuzlama katmanı, girdiyi aşağı örneklemek için kullanılır, böylece hesaplama yükü azaltılır. Son olarak, tam-bağlantılı katman (FC), her girişin tüm nöronlara bağlı olduğu bir giriş üzerinde çalışır. FC katmanları genellikle CNN mimarisinin sonlarına doğru bulunur ve sınıf puanları gibi hedefleri optimize etmek için kullanılabilir. Genellikle Softmax işlevi, tam-bağlantılı katmandan sonra yer alır. Bu fonksiyon, sınıflandırma çıktısının olasılığını ve etiketini sağlar. Bu katmanların yanı sıra, sızdıran ReLU katmanları ve normalleştirme katmanları, eğitimin başarısını iyileştirmek için kullanılabilir. Normalleştirme katmanı ağ başlatma hassasiyetini azaltırken, sızıntılı ReLU katmanı normalleştirme katmanından sonra yer alır ve doğrusallığı doğrusal olmayanıya dönüştürmek için kullanılır. Ayrıca, sızıntılı ReLU katmanı, doğrusallığa ek olarak doğrusal olmayanlığı da öğrenmemizi sağlar.

Önerilen çalışmada, CNN mimarisine dayalı yeni bir ağ tasarlanmıştır. Ağ toplamda 21 katmandan oluşmaktadır. Öncelikle 8x8 görüntü yamalarını girdi olarak kabul eden görüntü girdi katmanıdır. Küçük girdi boyutları seçilerek küçük detayların öngörülebilirliğinin ve yöntemin başarısının artırılması amaçlanmaktadır. Ayrıca ağ girişi olarak gri görüntüler tercih edildiğinden RGB görüntülerin ağa girilebilmesi için gri görüntülere dönüştürülmesi gerekir. Değiştirilmiş CNN mimarisi için kullanılan diğer katmanlar, evrişim katmanı, doğrusal olmayan aktivasyon katmanları ve tam-bağlantılı katmanlardır. Görüntünün tüm karakteristik özelliklerini en iyi şekilde öğrenmek için bu katmanlar birleştirilir ve yeni bir ağ tasarımı oluşturulur. Ağ tasarımı Şekil 2.17. ile verilmektedir.



Şekil 2.17. Önerilen 2. çalışma için tasarlanan ağ modeli

Evrişim katmanında, 3x3 süzgeç boyutunda ve sekiz süzgeç ile başlayan ve her blokta artan değişken süzgeç sayısı olan bir katman oluşturulmuştur. Bu katman, görüntülerin önemli özelliklerini çıkarmak için kullanılır ve ağın başarısında büyük rol oynar. Tasarlanan ağdaki ilk evrişim süzgeçleri, yerel özellikleri daha iyi çıkarmak için küçük boyutlarla başlar. Bu değerler, daha genel özellikleri öğrenmek için ağın alt bloklarında kademeli olarak artırılır. Evrişim katmanında belirlenmesi gereken diğer özellikler adım boyutu ve dolgu boyutudur. Tasarlanan ağda, görüntü yamalarının küçük boyutu nedeniyle adım boyutu 1 olarak ayarlanmış ve dolgu boyutu, giriş yamalarının orijinal boyutlarını değiştirmemek ve görüntülerin sınır noktalarındaki detayları kaybetmeyecek şekilde belirlenmiştir. Gerçek hayattaki veriler doğrusal değildir, bu nedenle doğrusal olmayan aktivasyon fonksiyonları tasarlanan ağlarda önemli bir yere sahiptir. Tasarlanan ağda,

aktivasyon katmanı olarak Leaky ReLU kullanılmıştır. Bu katman sayesinde, gradyanların ölmesi problemi ortadan kaldırılmış dolaylı olarak eğitim erken sonlanması da önlenmiştir.

Havuzlama katmanı, CNN mimarilerinde giriş boyutunu küçültmek, hesaplama yükünü azaltmak gibi amaçlar için kullanılmaktadır. Önerilen çalışmada, ağır girdi boyutları zaten oldukça küçük olduğundan havuzlama katmanı kullanılmamıştır. Ayrıca havuzlama katmanı içinde kullanılan alt örnekleme işlemi, önemli özelliklerin ortadan kaldırılmasına neden olabilmekte ve bu sorun tasarlanan ağır başarısını azaltabilmektedir. Bu sorunlar, havuzlama katmanının önerilen çalışma için tercih edilmemesinin diğer nedenleridir.

Tam-bağılantılı katmanlar, ağır diğer katmanlarından gelen özelliklerin girdiği ve bu özelliklerin optimize edildiği katmanlardır. Evrişim katmanı, havuzlama katmanı gibi katmanlardan gelen özellik vektörleri bir boyutlu bir vektöre dönüştürülerek bu katmana girmektedir. Bu katmanda yapılan işlemler sonrasında optimize ağırlık katsayıları bulunmaktadır.

Önerilen mimariye ait tüm ağ katmanları Şekil 2.17 ile gösterilmiştir. Son olarak, 2 sınıf için hem etiket değerlerinin hem de bu etiketlerin olasılık değerlerinin belirlendiği çıktı katmanı bulunmaktadır.


Ağır doğruluğu için eğitim seçeneklerinin belirlenmesi oldukça önemlidir. Bu yazıda, büyük veri setleri için diğer optimize edicilerden daha hızlı minimuma yaklaşan Stokastik Gradyan İniş (SGD) iyileştirici olarak seçilmiş, öğrenme oranı 0,001, mini parti boyutu 256, momentum 0,9 olarak ayarlanmış, eğitim dönemi 30 olarak belirlenmiştir. Kayıp fonksiyonu çapraz entropi olarak seçilmiştir. Görüntüler bu parametreler kullanılarak eğitilir. Eğitim doğruluğu ve validasyon doğruluğu sırasıyla %99,50 ve %98,34 olarak elde edilmektedir. Deneysel sonuçlar, tasarlanan ağır çoklu-odaklı görüntü Birleştirme için uygun olduğunu göstermektedir.

Önerilen CNN mimarisi, iki sınıfı ayırmak için tasarlanmış bir mimaridir. Önerilen çalışmadaki sınıflar, ağır çıktı katmanından da görülebileceği gibi, odaklanmış ve odaklanmamış bölümlerdir. Kaynak görüntülerden alınan 8x8 görüntü yamaları, hangi sınıfa ait olduklarını belirlemek için eğitilmiş ağa verilir. Sonuç olarak, ağır kararları farklı mekanizmalarla iyileştirilir ve tam odaklı bir görüntü elde edilir.

2.3.2.2.2. Kaynak Görüntülerin Önerilen Ağa Beslenmesi

Eğitim için kullanılacak ağ, görüntü yamalarını odaklanmış veya odaklanmamış olarak sınıflandırmak için tasarlanmıştır. Bu ağ, görüntü girdi katmanı, evrişim katmanı, doğrusal olmayan katman ve tam-bağlantılı katman gibi katmanların birleştirilmesiyle oluşturulur. CNN mimarisinde genellikle kullanılan bir diğer katma Havuzlama katmanıdır fakat bu katman giriş sinyallerinin önemli özelliklerini ortadan kaldırılmasına yol açabilmektedir. Bu nedenle önerilen ağda havuzlama katmanı kullanılmamıştır.

Önerilen çalışmada, hem geleneksel veri setlerindeki görüntüler hem de tarafımızca oluşturulan yeni veri setindeki görüntüler kaynaştırmak için kullanılmıştır. Bu veri setlerinden alınan görüntüler önerilen ağa beslenmeden önce 8x8'lik küçük örtüşen yamalara bölünür ve bu yamalar eğitilmiş ağa ayrı ayrı beslenir. Bu işlemden sonra ilgili yamalar için yapılan tahminler kaynak görüntülere ait karar haritalarına kaydedilir. Tahminler, odaklanmış alanlar için etiket 1 ve odaklanmamış alanlar için etiket 0 olarak temsil edilir. Önerilen yöntemde her tahminden sonra bir kontrol mekanizması uygulanmaktadır. Literatürde daha önce uygulanmayan bu mekanizma önerilen ağa ait tahminler için yeni bir iyileştirme mekanizmasıdır. Tasarlanan mekanizma yalnızca kaynak görüntülerdeki karşılık gelen görüntü yamalarının tahminleri 0 olarak etiketlendiğinde etkinleştirilir. Görüntülerde karşılık düşen yamaların her birinin odaksız olarak etiketlenmesi önerilen çalışmada kararsız durumlar olarak ifade edilmektedir. Kararsız durumlarda, kaynak görüntülerden birleştirilmiş görüntülere istenmeyen pikseller aktarılır ve birleştirilmiş görüntü bu durumdan olumsuz olarak etkilenir. Bu nedenle, önerilen çalışmada kararsız durumların belirlenmesi hem önerilen çalışma hem de gelecek çalışmalar için önemli olacaktır. Görüntülerin ağa beslenmesi işlemi Şekil 2.18. ile verilmektedir.



Şekil 2.18. Kaynak görüntülerin ağa beslenmesi

2.3.2.3. Önerilen İyileştirme Mekanizması

Odaklanmış alanlar, odaklanmamış alanlara göre daha net ve ayrıntılı bileşenlere sahiptir. Bu nedenle, odak ölçüm metriklerinin odaklanılan bölgelerde maksimum değer vermesi beklenir. Böylece odaklanmış ve odaklanmamış bölgeler, odak ölçüm metrikleriyle kolayca ayrılmaktadır. Literatürde, görüntüde veya görüntü yamalarında odaklanılan alanlara karar vermede oldukça başarılı odak derecesini ölçen farklı metrikler önerilmiştir. Önerilen çalışmada derin öğrenme ağın kararsız olduğu durumlarda başarıyı artırmak için bu metrikleri kullanılır. Odak ölçüm metrikleri genellikle beş farklı gruba ayrılır. Bunlar,

Laplas tabanlı, gradyan tabanlı, istatistik tabanlı, dalgacık tabanlı ve DCT tabanlı metriklerdir. Bu çalışmada, üç gruptan Dalgacık Varyansı (WAVV), Toplam Modifiye Laplas (SML) ve Uzamsal Frekans (SF) olmak üzere üç farklı metrik kullanılmıştır. Kullanılan metrikler, kaynak görüntülerde kenarlar, köşeler vb. gibi ayrıntıları daha iyi temsil edebildikleri için seçilmiştir.

Her kaynak görüntüdeki karşılık gelen görüntü yamaları için puan haritaları oluşturulurken SML, WAVV ve SF metrikleri kullanılarak hesaplanır. Puan haritaları ve kaynak görüntüler, her bir görüntü yaması için yapılan hesaplamayla aynı boyuttadır. Bir görüntü yamasının puanı bulunurken, her bir metrik değer, diğer kaynak görüntülerdeki karşılık gelen görüntü yamalarındaki metrik değerle ayrı ayrı karşılaştırılır. Karşılaştırma sonucunda, her metrik için daha yüksek değerli görüntü yamasına 1 puan eklenir. Böylece her kaynak görüntü için 0 ile 3 arasında değişen puanlardan oluşan bir puan haritası oluşturulur. Oluşturulan puan haritası, önerilen değiştirilmiş CNN mimarisinin kararsız olduğu durumlarda kullanılır (her görüntü yamasını odak dışı olarak etiketlendiği durumlar). Bu durumlarda, karşılık gelen yamalar için puan haritalarındaki puanlar birbirleriyle karşılaştırılır ve daha yüksek puana sahip görüntü yaması odaklanmış, diğerleri odaklanmamış olarak etiketlenir. Literatürde daha önce kullanılmayan bu mekanizma ile kararsız durumlar kararlı hale gelir ve daha kaliteli kaynaşmış görüntüler oluşturulur. İyileştirme mekanizmasının algoritması Algoritma 1'de verilmiştir.

Algoritma 1. Kararsız Durumlar için İyileştirme Mekanizması

Giriş: Görüntü1, Görüntü2.

Çıkış: for i : row for Görüntü1, Görüntü2:

for j : column for Görüntü1, Görüntü2:

Görüntü1'in patch (i,j) için network çıktısı: network_output1 (i,j)

Görüntü2'in patch (i,j) için network çıktısı: network_output2 (i,j)

Görüntü1 skor tablosu: sc1 (i,j)

Görüntü2 skor tablosu: sc2 (i,j)

if (network_output1 (i,j) == 0) and (network_output2 (i,j) == 0)

if sc1 (i,j) > sc2 (i,j)

Görüntü1 karar haritası decision (i,j) 1 etiketi alır : dc1 (i,j) // label 1 is

focused

```


Görüntü2 karar haritası decision (i,j) 0 etiketi alır: dc2 (i,j) // label 0 is
non-focused

else

Görüntü1 karar haritası decision (i,j) 0 etiketi alır: dc1 (i,j)
Görüntü2 karar haritası decision (i,j) 1 etiketi alır: dc2 (i,j)


```

Kaynak görüntülerden çıkarılan tüm görüntü yamaları için işlemler tekrarlanır. Algoritma 1, iki kaynak görüntü için temsil edilen iyileştirme mekanizmasının uygulananıdır, fakat aynı mekanizma birden fazla kaynak görüntü için de kullanılabilir. Algoritma 1'e göre her görüntü yaması sınıflandırılır. Ağ çıkışı, ilgili görüntü yamasının sınıflandırma etiketini verir. Her iki etiketin de sıfır olması durumunda kararsızlık yaşanmaması için ilgili yamanın puanlarının tutulduğu tablo kontrol edilir. Tabloda, daha yüksek puana sahip görüntü yaması odaklanmış olarak etiketlenmiştir. Karar matrisi, kaynak görüntüler için başlangıç sınıflandırma etiketlerini içerir ve her görüntü için ayrı ayrı oluşturulur. Şekil 2.19.'da iyileştirme mekanizmasının etkilerini gösterebilmek için örnek görsel sonuçları verilmiştir.



Şekil 2.19. Yeni veri seti NOTEBOOK görüntüsü: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) Kaynak görüntü 1 için iyileştirme mekanizmasından önce ve sonra karar haritaları (512x512), (f) Kaynak görüntü 2 için iyileştirme mekanizmasından önce ve sonra karar haritaları (512x512), (g) Kaynak görüntü 3 için iyileştirme mekanizmasından önce ve sonra karar haritaları (512x512), (h) Kaynak görüntü 4 için iyileştirme mekanizmasından önce ve sonra karar haritaları (512x512), (i) Kaynak görüntü 1 için nihai karar haritası (512x512), (j) Kaynak görüntü 2 için nihai karar haritası (512x512), (k) Kaynak görüntü 3 için nihai karar haritası (512x512), (l) Kaynak görüntü 4 için nihai karar haritası (512x512), (m) Tüm odaklı Görüntü (512x512)

Şekil 2.19'un devamı



Şekil 2.19'da birleştirme için kullanılan kaynak görüntüler, ağ çıktıları kullanılarak oluşturulan ilk karar haritaları, odak metriklerine dayalı iyileştirme mekanizması sonuçları, nihai karar görüntüleri ve tam olarak odaklanmış görüntü verilmektedir. Yeni veri setinden alınan (a)-(d) görüntüleri, birleştirme için kullanılacak kaynak görüntülerdir. (e)-(h)

görüntüleri iki parçalı (sol ve sağ) görüntülerdir. Bu görüntülerin sol parçası kaynak görüntülerdeki yamaların önerilen ağ ile sınıflandırılmasıyla oluşan ilk karar haritasını, sağ parçası ise ilk karar haritalarına önerilen yöntemde oluşturulan iyileştirme mekanizması uygulanması sonrası karar haritalarını vermektedir. (1)-(k) görüntüleri önerilen yöntemin tüm aşamalarından sonra oluşan nihai karar haritalarını vermektedir. Birleştirme işlemi nihai karar haritaları kullanılarak gerçekleştirilmektedir. Son olarak, (l) görüntüsü önerilen yöntem kullanılarak oluşturulan nihai birleştirilmiş görüntüyü verir. Görsel incelendiğinde, ilk karar haritalarını iyileştirmek için kullanılan mekanizmanın birleştirme için etkili bir araç olduğu görülebilir.

2.3.2.4. Önerilen Birleştirme Kuralı

Çoklu-odaklı görüntü birleştirme yöntemlerinin en önemli ve son adımı olan birleştirme kuralı, kaynak görüntülerdeki piksel değerlerinin önemini belirler ve birleştirilmiş bir görüntü oluşturur. Yani birleştirme kuralları yöntemin başarısını doğrudan etkileyen en önemli bileşenlerdir. Literatürde kullanılan yöntemler genellikle iki kaynak görüntüyü birleştirir ve karar haritaları birbirine zıttır. Bu durumda karar haritalarının ve kaynak görüntülerin karşılık gelen piksel değerleri çarpılarak birleştirilmiş görüntüye aktarılır. Ancak bu yöntemlerle bulunan karar haritasındaki bir hata (odaklanan bölgenin odaksız olarak etiketlenmesi) geri dönüşü olmayan bir soruna neden olur. Önerilen yöntemde, bu sorunu engellemek için dinamik karar mekanizmalı (DDM) bir birleştirme kuralı tasarlanmıştır. Bu kural, karar haritalarında karşılık gelen etiket değerlerine göre birleştirme kuralının dinamik olarak seçilmesine dayanır. Bu dinamik karar mekanizması birleştirme kuralının iki seçeneği vardır; karar haritalarında karşılık gelen değerler farklı ve aynı olduğunda çalışan kurallar. Karar haritalarında karşılık gelen değerler farklı ise bu değerler ve kaynak görüntülerdeki karşılık gelen piksel değerleri çarpılarak kaynaşmış görüntüye aktarılır. Karar haritalarında karşılık gelen değerler aynı ise gradyan tabanlı birleştirme kuralı uygulanarak ilgili pikseller kaynaşmış görüntüye aktarılır. Gradyan tabanlı birleştirme kuralı bölüm 2.3.2.4.1 'de anlatılmaktadır. DDM birleştirme kuralının algoritması Algoritma 2' de verilmiştir. Bu algoritmada karar haritaları kullanılarak kaynaşmış görüntünün piksel değerlerine nasıl ulaşılacağı anlatılmaktadır.

Algoritma 2. Dinamik Birleştirme Kuralı

Giriş: Kaynak görüntü1 için karar haritası (dc1), Kaynak görüntü 2 için karar haritası (dc2),

Çıkış: for i : satırlar for Görüntü1, Görüntü2:

for j : sütunlar for Görüntü1, Görüntü2:

if (dc1 (i,j) == 1 and dc2 (i,j) == 1) or (dc1 (i,j) == 0 and dc2

(i,j) == 0)

Seçenek 1: fused (i,j) hesapla: gradient_based_rule (Görüntü1

(i,j), Görüntü2 (i,j))

else

Seçenek 2: fused (i,j) hesapla: dc1 (i,j) * Görüntü1 (i,j) + dc2 (i,j)

* Görüntü2 (i,j)

DDM birleştirme kuralı sayesinde, iki veya daha fazla kaynak görüntünün farklı karar haritaları başarıyla birleştirilebilir, yani yöntem ölçeklenebilirdir. Karar haritalarındaki etiket değerlerine göre iki farklı birleştirme seçeneği sunar. Böylece literatürdeki yöntemlerin aksine DDM birleştirme kuralı, yanlış sınıflandırma sonuçlarının kaynaşmış görüntü üzerindeki etkisini en aza indirir.

2.3.2.4.1. Gradyan-tabanlı Birleştirme Kuralı

Gradyan, önemli bileşenleri vurgulayan önemsiz bileşenleri bastıran önemli bir araçtır. Çoklu-odaklı görüntü birleştirme yöntemleri, kaynak görüntülerdeki önemli bileşenleri kaynaşmış görüntüye aktarmayı amaçladığından, bu yöntemlerin amacı ile gradyan aracı aynı doğrultuda çalışmaktadır.

Önerilen yöntemde, DDM birleştirme kuralını iyileştirmek için gradyan tabanlı bir birleştirme kuralı kullanılmıştır. Kaynak görüntülerdeki her piksel için gradyan büyüklüğü hesaplanır. Karşılık gelen gradyan büyüklükleri, denklem 2.42 ile kullanılarak hesaplanır ve birleştirilmiş görüntü için piksellerin önemi belirlenir. Her piksel önem oranına göre kaynaşmış görüntüye aktarılır. Bu kural ilk olarak Aymaz ve ark. [68] tarafından uygulanmıştır. Önerilen yöntemde Sobel tabanlı olan bu kural birleştirme aşamasında bir iyileştirme mekanizması olarak önerilmektedir. Sobel operatörü olarak 3x3 maske tercih edilmiştir. Maske ne kadar büyük olursa, ayrıntıları yakalamak o kadar zor olur, bu nedenle

büyük bir maske boyutu seçilmez. Sobel operatörü kullanılarak, her kaynak görüntü için gradyan büyüklüklerinin haritaları oluşturulur.

İlk olarak Sobel operatörleri yardımıyla görüntünün tamamı taranır ve gradyan görüntüsü elde edilir. X ve y yönündeki gradyan operatörleri sırasıyla denklem 2.36 ve 2.37 ile ifade edilmektedir.

$$S_x = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 1 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (2.36)$$

$$S_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (2.37)$$

S_x ve S_y , sırasıyla x ve y yönündeki sobel operatörünü temsil eder. Gradyan görüntüleri Denklem 2.38-2.40 kullanılarak hesaplanmaktadır.

$$\frac{\partial I}{\partial x} = S_x \otimes f \quad (2.38)$$

$$\frac{\partial I}{\partial y} = S_y \otimes f \quad (2.39)$$

$$\nabla I = \left[\frac{\partial I}{\partial x}, \frac{\partial I}{\partial y} \right] \quad (2.40)$$

Ve son olarak, her görüntü için gradyan büyüklükleri Denklem 2.41 kullanılarak hesaplanır.

$$\|\nabla I\| = \sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2} \quad (2.41)$$

Hesaplamalardan sonra her bir kaynak görüntü için görüntülerle aynı boyutta gradyan büyüklük matrisi oluşturulur. Birleştirilmiş görüntü için oluşturulan büyüklük matrisinin önemi, karşılık gelen değerlerin oranlanmasıyla belirlenir. Önemlilik oranlarını belirlemek için denklem 2.42 kullanılmaktadır.

$$Imp_k = \frac{Mag_k}{Mag_1 + Mag_2 + \dots + Mag_n} \quad (2.42)$$

Imp_k , kaynaşmış görüntü için kaynak görüntü piksellerinin önem oranlarını depolayan matristir. Mag_k matrisi, kaynak görüntülerin gradyan büyüklüklerini depolayan matristir. k o anda hesaplanacak görüntü sayısı iken, n toplam kaynak görüntü sayısıdır. Bu optimizasyon mekanizması, yöntemin kararsız olduğu durumlarda çalışır. Sistemin kararsız olduğu pikseller için kaynaşmış değerlerin elde edilmesi için denklem 2.43 kullanılmaktadır.

$$Fused(i, j) = Imp_1 * Img_1 + Imp_2 * Img_2 + \dots + Imp_n * Img_n \quad (2.43)$$

Birleştirilmiş görüntü $Fused$ ile temsil edilir. Ek olarak, Img kaynak görüntüleri temsil ederken Imp , kaynaşmış görüntü için o kaynak görüntünün önem oranlarını temsil eder. Normalde bu tür bir iyileştirme literatürde yer almamaktadır çünkü literatürde bulunan yöntemler kaynak görüntüleri tek bir karar haritası ile birleştirmekte ve dolayısıyla bu çalışmalarda karar haritalarında kesişme noktaları bulunmamaktadır. Bu durum, literatürde bulunan bir açıklık olarak ifade edilebilir, çünkü yalnızca bir karar haritası her zaman görüntüyü mükemmel bir şekilde temsil edemez. Dolayısıyla çalışmalar için bu durum telafisi mümkün olmayan sorunlara neden olabilir. Bu nedenlerle önerilen yöntemde kullanılan bu mekanizma hem yöntemi ölçeklenebilir hale getirmekte hem de yanlış etiketlemenin olumsuz etkisini azaltmaktadır.

3. BULGULAR VE İRDELEME

3.1. Tez Çalışmasında Kullanılan Veri Setleri

Çoklu-odaklı görüntü birleştirme için hazırlanan veri setleri genellikle sıg veri setleridir. Bu veri setleri içerisinde sadece birleştirebilecek iki kaynak görüntü bulunmaktadır ve görüntü setleri sayısı oldukça sınırlıdır. Literatürde yaygın olarak Lytro[51] veri seti ve Prasad[52] tarafından oluşturulan veri seti kullanılmaktadır.

M. Nejati ve ark.[51] tarafından 2015 yılında hazırlanan Lytro veri setinde birleştirmek için 20 adet renkli görüntü seti mevcuttur. Her bir görüntünün boyutu 520x520 pikseldir. Renkli görüntülerde birleştirme yapan yayınlarda bu veri seti sıklıkla kullanılmaktadır. Lytro veri setinden alınan örnek için farklı kaynak görüntüler Şekil 3.1.'de verilmektedir.




(a)

(b)

Şekil 3.1. Lytro veri setinden alınan örnekler a) Sol-odaklı görüntü, b) Sağ-odaklı görüntü


Literatürde kullanılan diğer bir veri seti Durga Prasad [52] tarafından hazırlanan ve 31 görüntü setinden oluşan veri setidir. Bu veri setinde görüntüler manuel olarak düzenlenmiştir. Görüntüler renkli ve gri seviye olmak üzere farklı seviyelerde ve boyutları farklıdır. Görüntü setlerinde görüntülerin orijinal biçimleri de bulunmaktadır. Durga Prasad veri setinden alınan farklı örnek görüntülere ait farklı kaynak görüntüler Şekil 3.2.'de verilmektedir.



Şekil 3.2. Durga Prasad veri setinden alınan örnekler a) Pepsi sol-odaklı görüntü, b) Pepsi sağ-odaklı görüntü, c) Book sağ-odaklı görüntü, d) Book sol-odaklı görüntü

3.2. Performans Ölçüm Metrikleri

Çoklu-odaklı görüntü birleştirme, kaynak görüntülerden doğru bilgilerin maksimum seviyede birleştirilmiş görüntüye aktarılması ve kaynak görüntülerdeki detay bilgilerin korunmasını amaçlamaktadır. Oluşturulan birleştirilmiş görüntü bulanık alanlar içermemeli ve incelenmesi kolay olmalıdır. Literatürde bu alanda kullanılan metrikler iki temel sınıfa ayrılmaktadır. Bu sınıflar objektif ve subjektif metriklerdir ve Şekil 3.3. ile verilmektedir [110].



Şekil 3.3. Performans ölçüm metrikleri

3.2.1. Sübjektif Metrikler

Subjektif değerlendirme, mutlak değerlendirme ve görelî değerlendirme olarak ikiye ayrılmaktadır. Subjektif değerlendirmenin en basit şekli insan gözüyle yapılan gözlemdir. İnsanlar, görüntü ayrıntılarını, kontrastı, görüntü bütünlüğünü ve bozulma derecesini gözlemleyerek farklı birleştirme yöntemlerini karşılaştırabilir. Öznel değerlendiriciler, kaynaşmış görüntü üzerinde niteliksel olarak puanlama yapmak için değerlendirme kriterlerini kullanabilmektedir. Yine de herkesin aynı görüntü için farklı değerlendirme kriterleri vardır, bu kriterler kişisel tercih, çevre ve diğer faktörlerden kolayca etkilenecek kaynaşmış görüntü için yanlış yorumlamalara yol açabilmektedir. Bunun sonucu olarak kaliteli bir değerlendirme yapılması zorlaşmaktadır.

Bu metrikler orijinal birleştirilmiş görüntü varsa bu görüntü ile yöntem sonucu oluşturulan birleştirilmiş görüntüyü karşılaştırmak amacıyla kullanılmaktadır. Genellikle orijinal görüntüye ulaşmak zor olduğundan literatürde tercih edilmemektedir [111].

3.2.1.1. Ortalama Karekök Hatası (RMSE) Metriği

Subjektif metrikler arasında en sık tercih edilen metriklerdendir. Orijinal görüntü ile yöntem sonucu oluşturulan birleştirilmiş görüntünün piksel piksel karşılaştırılması ile hesaplanmaktadır. Yani iki görüntünün birbirine benzerliğini ölçmektedir. Bu metrik sonucu ne kadar küçükse önerilen yöntem o kadar başarılıdır [110]. Metrik hesabı denklem 3.1 ile verilmektedir.

$$RMSE = \sqrt{\frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (I_R(i, j) - I_F(i, j))^2} \quad (3.1)$$

Denklemde görüntüdeki satır sayısı ve sütun sayısı sırasıyla M ve N ile temsil edilmektedir. $I_R(i, j)$ var olan orijinal görüntüdeki i ve j satır sütununa denk gelen piksel değerini gösterirken, $I_F(i, j)$ birleştirilmiş görüntüde aynı noktalara denk gelen gri seviye parlaklık değerini göstermektedir.

3.2.1.2. Yapısal Benzerlik (SSIM) Metriği

Yapısal Benzerlik İndeksi Yöntemi, algıya dayalı bir modeldir. Bu modelde görüntü bozulması, yapısal bilgilerdeki algı değişikliği olarak kabul edilir. Ayrıca parlaklık maskeleme, kontrast maskeleme vb. gibi diğer bazı önemli algı temelli yöntemlerle de beraber çalışabilmektedir. SSIM, görüntü ve videoların algılanan kalitesini tahmin etmekte kullanılmaktadır [112] ve iki görüntü arasındaki benzerliği ölçmektedir. Metriğe ait hesaplama denklem 3.2-3.6 ile verilmektedir.

$$I(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \quad (3.2)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2} \quad (3.3)$$

$$s(x, y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3} \quad (3.4)$$

$$c_3 = \frac{c_2}{2} \quad (3.5)$$

$$SSIM(x, y) = [I(x, y)^\alpha \cdot c(x, y)^\beta \cdot s(x, y)^\gamma] \quad (3.6)$$

Denklemden μ_x ve μ_y sırasıyla x ve y görüntülerindeki piksellerin ortalamalarını σ_x^2 ve σ_y^2 ise sırasıyla x ve y görüntülerinin varyansını ifade etmektedir. SSIM sonucu ne kadar 1'e yakınsa yöntem o kadar başarılı demektir.

3.2.1.3. Maksimum Sinyal Gücü (PSNR) Metriği

PSNR, maksimum sinyal gücü ile temsilinin kalitesini etkileyen bozulma gürültüsünün gücü arasındaki oranı hesaplamak için kullanılır. Bu metrik birleştirilmiş görüntünün orijinal görüntüye göre gürültüye ne kadar dayanıklı olduğunu göstermek için kullanılmaktadır. Metrik sonucu ne kadar büyükse önerilen yöntem o kadar başarılı demektir [110].

$$PSNR = 10 \log_{10} \left(\frac{L^2}{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (I_R(i,j) - I_F(i,j))^2} \right) \quad (3.7)$$

Denklemden görüntüdeki satır sayısı ve sütun sayısı sırasıyla M ve N ile temsil edilmektedir. $I_R(i,j)$ var olan orijinal görüntüdeki i ve j satır sütununa denk gelen piksel değerini gösterirken, $I_F(i,j)$ birleştirilmiş görüntüde aynı noktalara denk gelen gri seviye parlaklık değerini göstermektedir. Maksimum parlaklık seviyesi is L ile temsil edilmektedir.

3.2.2. Objektif Metrikler

Objektif değerlendirme metrikleri, subjektif değerlendirme metriklerinde var olan sorunları ortadan kaldıracak şekilde tasarlanmıştır. Araştırmacılar, objektif değerlendirme göstergeleri kullanarak nicel değerlendirme ve görüntü Birleştirme için doğru bir karşılaştırma yapabilmektedir. Bu nedenle literatürde birçok farklı objektif metrik bulunmaktadır. Objektif değerlendirme, insan görsel algı sistemini simüle ederek karşılık gelen bir matematiksel model oluşturmada ve her bir birleştirme yönteminin performansını istatistiksel verilerle karşılaştırmak olarak tanımlanmaktadır. Objektif görüntü kalitesi ölçümü, referans standart görüntülerin ve referans olmayan standart görüntülerin kullanımını içermektedir.

Objektif metrikler, subjektif metriklerin aksine orijinal görüntüye ihtiyaç duymazlar. Bu nedenle literatürde sıklıkla tercih edilmektedirler. Kaynak görüntülerden aktarılan doğru bilgi miktarı ve kenar bilgisi miktarı bu metrikler yardımıyla ölçülebilmektedir.

3.2.2.1. Standart Sapma (SD) Metriği

Standart sapma (Σ), görüntü gri seviyesi yoğunluklarının dağılımının bir ölçüsünü sağlamaktadır. Kameralar tarafından elde edilen alternatif sinyal bileşeninin güç seviyesinin bir ölçüsü olarak ifade edilmektedir. Ayrıca bu metrik görüntünün kontrast bilgisi hakkında bilgi vermektedir. Metrik sonucu ne kadar büyükse yöntem o kadar başarılı demektir [110]. Metrik denklem 1.26 kullanılarak hesaplanmaktadır.

$$SD = \sqrt{\sum_{x=0}^L (i - i')^2 x h_{I_f}(x)} \quad (3.8)$$

Denklemden $h_{I_f}(x)$ normalize edilmiş histogram bilgisini gösterilirken maksimum gri seviye parlaklık bilgisi L ile gösterilmektedir.

3.2.2.2. Uzamsal Frekans (SF) Metriği

Uzamsal frekanslar, bir uyarının görünümü hakkında farklı bilgiler içermektedir. Yüksek uzamsal frekanslar, kenarlar gibi görüntüdeki ani uzamsal değişiklikleri temsil eder ve genellikle özellik bilgilerine ve ince ayrıntılara karşılık gelir. Düşük uzamsal frekanslar ise, nesnenin şekli gibi genel bilgileri temsil etmektedir [110]. Metrik hesabı denklem 3.9 ile verilmektedir.

$$SF = \sqrt{CF^2 + RF^2} \quad (3.9)$$

Satır frekans bilgileri RF ile gösterilirken, sütun frekans bilgileri ise CF ile gösterilmektedir.

$$CF = \frac{1}{M \times N} \sqrt{\sum_{x=1}^M \sum_{y=2}^N (I_f(x, y) - I_f(x, y - 1))^2} \quad (3.10)$$

$$RF = \frac{1}{M \times N} \sqrt{\sum_{x=1}^M \sum_{y=2}^N (I_f(x, y) - I_f(x-1, y))^2} \quad (3.11)$$

Görüntüdeki satır ve sütun sayıları denklemde sırasıyla M ve N ile temsil edilmektedir. Tüm odaklı görüntüde x ve y piksellerine karşılık düşen parlaklık bilgisi ise $I_f(x, y)$ ile temsil edilmektedir.

3.2.2.3. Karşılıklı Bilgi (MI) Metriği

Karşılıklı Bilgi (MI), bir değişkenin diğeri hakkında içerdiği bilgi miktarını ölçen temel bir bilgi teorisi kavramıdır. Bu, görüntü birleştirme performansının ölçüsü olarak MI'yı kullanmak için bir motivasyondur. Bu metrik kaynak görüntülerin birleştirilmiş görüntüde ne oranda temsil edildiğini göstermektedir [113]. Metrik aşağıdaki denklemler kullanılarak hesaplanmaktadır.

$$I_{AF} = \sum_{a,f} P_{AF}(a, f) \log \frac{P_{AF}(a, f)}{P_A(a)P_F(f)} \quad (3.12)$$

$$I_{BF} = \sum_{b,f} P_{BF}(b, f) \log \frac{P_{BF}(b, f)}{P_B(b)P_F(f)} \quad (3.13)$$

A, B ve F görüntüleri aynı boyutta olup sırasıyla kaynak görüntüler ve birleştirilmiş görüntüyü temsil etmektedir. P_{AF} ve P_{BF} ise kaynak görüntüler ve birleştirilmiş görüntüler arasındaki ortak histogram değerlerinin tutulduğu diziyi ifade etmektedir. Denklem 3.12 ve 3.13 her bir kaynak görüntü ile birleştirilmiş görüntü arasındaki bağlantıyı hesaplamaktadır. Nihai metrik sonucu 3.14 denklemi ile hesaplanmaktadır.

$$MI = I_{AF} + I_{BF} \quad (3.14)$$

3.2.2.4. QAB/F Metriği

Xydeas ve Petrovic, A ve B kaynak görüntülerinden F kaynaşmış görüntüsüne aktarılan kenar bilgisinin göreceli miktarını ölçen nesnel bir performans metriği önermektedir. Bu yöntem, hem kaynak hem de birleştirilmiş görüntülerde her pikselde kenar

kuvveti ve yönünü birlikte hesaplamak amacıyla bir Sobel kenar detektörü kullanır. Metrik denklem 3.15 kullanılarak hesaplanmaktadır [113].

$$Q^{AB/F} = \frac{\sum_{i=1}^M \sum_{j=1}^N (Q^{AF}(i,j)w^A(i,j) + Q^{BF}(i,j)w^B(i,j))}{\sum_{i=1}^M \sum_{j=1}^N (w^A(i,j) + w^B(i,j))} \quad (3.15)$$

$w^A(i,j)$ ve $w^B(i,j)$ ağırlıkları $Q^{AF}(i,j)$ ve $Q^{BF}(i,j)$ için gerekli ağırlıkları temsil etmektedir. Q^{AF} , A kaynak görüntüsü ile F birleştirilmiş görüntüsü arasında kenar bilgilerini temsil etmektedir. $Q^{AB/F}$ değeri 0 ile 1 arasında değer alır ve bu değer ne kadar büyükse önerilen yöntem o kadar başarılı olmaktadır.

3.2.2.5. Ortalama Gradyan (AG) Metriği

AG, birleştirilmiş görüntünün dokusunu ve detayını ifade etme yeteneğini temsil etmede kullanılmaktadır [114]. Metriğe ait hesaplama denklem 3.16 ile verilmektedir.

$$AG = \frac{1}{M \times N} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \sqrt{\frac{\Delta I_x^2 + \Delta I_y^2}{2}} \quad (3.16)$$

Denklemde ΔI_x ve ΔI_y , x ve y görüntülerinin birinci dereceden türevini göstermektedir. Görüntülerin satır ve sütun sayıları sırasıyla M ve N ile temsil edilmektedir. Bu metrik değeri ne kadar büyük olursa yöntem o kadar başarılı demektir.

3.2.2.6. Korelasyon Katsayısı (CC) Metriği

CC, kaynaşmış bir görüntü ile kaynak görüntüler arasındaki doğrusal korelasyon derecesini ölçmektedir. Metriğin hesaplanması denklem 3.17 ile gösterilmektedir.

$$p = \sqrt{\frac{\sum_{i=1}^M \sum_{j=1}^N (F_s(i,j) - F_f(i,j))^2}{M \times N}} \quad (3.17)$$

Satır ve sütun sayıları sırasıyla M ve N ile gösterilmektedir. $F_s(i,j)$, $F_f(i,j)$ ise sırasıyla kaynak görüntü ve birleştirme edilmiş görüntüyü ifade etmektedir.

3.3. Gradyan-tabanlı Yeni Birleştirme Kuralı Kullanılarak Süper-çözünürlüklü Farklı Veri Setleri İçin Çoklu-odaklı Görüntü Birleştirme Sonuçları

Tez çalışması kapsamında çoklu-odaklı görüntü Birleştirme için yeni bir yaklaşım uygulanmaktadır. Görüntüleri ayrıştırmak için Sabit Dalgacık Dönüşümü (SWT), kaynak görüntülerin bilgilerini artırmak için bikübik interpolasyon tabanlı süper çözünürlük ve birleştirme kuralı olarak Sobel operatörü ile gradyan yöntemi kullanılarak çıkarılan ağırlık katsayıları matrisini içeren hibrit bir yaklaşımdır. Önerilen yöntem; literatürdeki yöntemlerin aksine bu alan için daha büyük seviyeler süper çözünürlük, yeni birleştirme kuralı ve yeni veri seti [115] içermektedir. Literatürdeki mevcut çalışmalar genellikle, kaynaşacak şekilde odaklanmamış kısımları olan iki kaynak görüntüyü içeren benzer veri setlerini kullanır. Bu durum, bu alan için bir sınırlamadır, çünkü odaklanmamış kısımları olan görüntüler gerçekte herhangi bir sayıda olabilir. Bu sınırlamayı aşmak için hazırlanan yeni veri seti, kaynaştırmak için ikiden fazla kaynak görüntüyü içermektedir. Bu kaynak görüntüler, özgür ve açık kaynak kodlu görüntü düzenleme yazılımı olan GIMP kullanılarak oluşturulur. GIMP kullanılarak kaynak görüntülerin bazı kısımları Gauss bulanıklaştırma yöntemiyle bulanıklaştırılır.

Bu çalışmada çoklu-odaklı görüntü Birleştirme için yeni veri seti ve popüler görüntüler kullanılmıştır. Ayrıca, renkli kaynak görüntüleri içeren Lytro [51] veri seti kullanılmıştır. Hazırladığımız veri seti yeni bir veri seti olması nedeniyle önerilen yöntemin literatürdeki yöntemlerle karşılaştırılmasında kullanılamamaktadır. Bu veri setlerinin hiçbir referans görüntü içermez, bu nedenle referans görüntülere ihtiyaç duyan öznel değerlendirmeler bu veri setleri için yapılamaz. Bu veri setlerinin yanı sıra hem kaynak görselleri hem de referans görselleri içeren veri seti de özneliği ölçmek için incelenmiştir.

Önerilen yöntemde Birleştirmen başarısını artırmak için birkaç yöntem etkili bir şekilde birleştirilir. Her yöntemin bu alana farklı katkıları vardır. SWT, kaynak görüntüleri alt bantlara ayırır ve bu alt bantlar bize görüntünün kaba özellikler, gürültüler, kenarlar vb. gibi farklı kısımlarını verir. Normalde bu parçaları doğrudan piksel yoğunluğu değerlerini kullanarak analiz etmek kolay değildir, bu nedenle analizi kolaylaştıran SWT kullanılır. Dalgacık dönüşümlerinin genellikle iki işlemi vardır; yukarı örnekleme ve aşağı örnekleme. Yukarı örnekleme işlemi sinyallerin boyutunu artırırken, aşağı örnekleme işlemleri sinyallerin bazı kısımlarını kaldırır. Literatürde aşağı örnekleme işleminin sinyallerde kaynaşmış görüntü için önemli olabilecek bilgi kaybına neden olduğu anlatılmaktadır. SWT yöntemi, diğer dalgacıkların aksine süzgeçlerde yalnızca yukarı örnekleme işlemi uygular,

bu nedenle SWT ile oluşturulan alt bantlar, kaynak görüntüler hakkında daha fazla bilgiye sahiptir. Ayrıca alt bantlar orijinal görüntü ile aynı boyuta sahip olduğundan, yeniden oluşturma hata oranı diğer dalgacık dönüşümlerinden daha azdır.

Kaynak görüntülerdeki bir pikselin kaynaşmış görüntü için ne kadar önemli olduğuna karar vermek için kullanılan birleştirme kuralı, birleştirme yöntemlerinin en önemli adımıdır. Bu çalışmada, Sobel operatörlü gradyan yöntemine dayalı yeni bir birleştirme kuralı tasarlanmıştır. Gradyan tabanlı yöntemler genellikle görüntü birleştirmede odaklanmış alanları çıkarmak için uygulanır.

Bu genel kullanımın aksine, önerilen yöntemde kaynaşmış görüntü için kaynak görüntülerde karşılık gelen her pikselin önem oranlarını belirleyen ağırlık katsayılarını hesaplamak için gradyan tabanlı yöntem uygulanmaktadır. Kaynak görüntülerin karşılık gelen piksel değerleri, kaynaşmış görüntü için aynı öneme sahip değildir. Kenar, köşe vb. noktalarda önem oranları daha yüksek iken bulanık, pürüzsüz vb. alanlarda daha düşüktür. Bu nedenle etkin birleştirme için bu piksellerin önem oranlarının belirtilmesi çok önemlidir. Önerilen birleştirme kuralı, hangi piksellerin önemli veya önemsiz olduğuna karar vermek için çok yararlı olan Sobel tabanlı gradyan yöntemini kullanarak her bir kaynak görüntü için önem oranlarını çıkarır. Çoklu-odaklı görüntü birleştirme yöntemleri, kaynak görüntünün kenarlar, köşeler vb. gibi önemli kısımlarını korumayı amaçlar, önerilen birleştirme kuralı bu amacı destekler ve iyi birleştirilmiş görüntüler oluşturmamıza yardımcı olur.

Önerilen yöntemde diğer bir yenilik ise biküçük interpolasyon tabanlı süper çözünürlük yöntemi uygulanmasıdır. Bu yöntem Photoshop'ta görüntüleri geliştirmek için de kullanılır. Yöntem, kaynak görüntülerin detaylarını artırarak kısa sürede yüksek çözünürlüklü görüntüler üretmektedir, bu nedenle önerilen yöntemde bilgiyi artırmak ve küçük detayları yakınlaştırmak için bu yöntem seçilmiştir. Çoklu-odaklı görüntü birleştirme yöntemleri, kenarları, köşeleri vb. korumanın yanı sıra kaynak görüntülerden kaynaşmış görüntüye maksimum bilgiyi aktarmayı da amaçlar. Kaynak görüntüler genellikle sınırlı bilgi ve ayrıntıya sahiptir. Bu çalışmadaki süper çözünürlük yöntemi, kaynak görüntülerin bilgi ve detaylarını artırdığından, çoklu-odaklı görüntü birleştirme yöntemlerinin amacına uygun olarak kaynak görüntülerden kaynaşmış görüntüye aktarılan bilgi miktarı artmıştır. Çözünürlüğün ne kadar artırılacağına karar veren sabit değerler süper-çözünürlük faktörü olarak adlandırılır. Bu yazıda, farklı çözünürlük faktörleri kullanılarak süper çözünürlük faktörlerinin birleştirme üzerindeki etkisi gösterilmeye çalışılmıştır. Deneysel sonuçlar, bu yöntemlerin kombinasyonunun, çoklu-odaklı görüntü birleştirmenin amaçlarını

gerçekleştirmek için çok yararlı olduğunu ve literatürdeki yöntemlerden daha üstün olduğunu göstermektedir.

Yöntemlerin performansını ölçmek için iki ana metrik kategorisi vardır; Objektif ve Subjektif kalite ölçütleri. Bunların her ikisi de bu çalışmada önerilen yöntemin performansını ölçmek için hesaplanmıştır. Objektif metrikler, kaynaşmış görüntüye ne kadar önemli bilginin aktarıldığını ve ayrıca kaynak görüntülerin kenarının ne kadar korunduğunu belirtir. Bu özellikler yöntemin başarısını belirlemede önemlidir, çünkü birleştirme yöntemlerinin iki temel amacı vardır; kaynak görüntülerin kenarlarının korunması ve kaynak görüntülerden kaynaşmış görüntüye daha fazla bilgi aktarılması. Subjektif metrikler ise, referans görüntü ile kaynaşmış görüntü arasındaki benzerlikleri ölçer. Önerilen yöntemin literatürdeki diğer yöntemlerle karşılaştırılmasında bu kalite ölçütlerinin yanı sıra zaman ölçütü de kullanılmaktadır.

Önerilen yöntem 2, 3 ve 4 olmak üzere üç farklı süper çözünürlük faktörü kaynak görüntülere uygulanmış ve bu yöntemlerin sonuçları ayrı ayrı değerlendirilmiştir. Kaynak görüntülerin uzamsal çözünürlüğü süper çözünürlük faktörleri kullanılarak 2, 3 ve 4 kez katlanmış, dolayısıyla bu katsayıların önerilen yöntemdeki etkileri de sonuçlara göre incelenmiştir. Performans değerlendirmeleri ve karşılaştırmaları alt bölümlerde verilmiştir.

3.3.1. Yeni Veri Seti İçin Objektif Değerlendirme Sonuçları


Önerilen yöntem hem geleneksel veri setleri hem de yeni veri seti için uygulanmıştır. Bu bölümde, yeni veri seti için önerilen yöntemin objektif kalite metriği sonuçları verilmiştir. Objektif metrikler bir referans görüntüye ihtiyaç duymaz, bu nedenle bu metrikler araştırmacılar tarafından daha çok tercih edilir. Ayrıca kaynak görüntülerden kaynaşmış görüntüye ne kadar doğru bilginin aktarıldığı ve kaynaşmış görüntü için kenar, yoğunluk, gradyan büyüklüğü vb. gibi önemli bilgilerin ne kadarının korunduğu nesnel değerlendirmeler kullanılarak çıkarılabilir. MI, Q_{AB}^F , AG, SD, SF ve CC objektif kalite metrikleri, yeni veri setindeki görüntüler için hesaplanmıştır. Yeni veri setindeki Lake (512x512), Livingroom (512x512), Truck (512x512), Astronaut (512x512), Jet (512x512), Boats (512x512) ve Street (512x512) görselleri için önerilen yöntemin sonuçları Tablo 3.3'te verilmiştir.

Tablo 3.1. Oluşturulan yeni veri seti için önerilen 1. çalışmanın objektif metrikler ile değerlendirme sonuçları

Görüntü	SR Factor	MI	QAB/F	AG	SD	SF	CC
Lake	2	15.99	0.93	20.43	67.33	36.48	0.99
	3	19.82	0.93	17.80	65.47	31.40	0.99
	4	21.90	0.94	16.20	64.67	28.26	0.99
Livingroom	2	13.66	0.94	18.88	61.24	31.63	0.98
	3	17.84	0.96	15.90	60.04	26.9	0.98
	4	19.83	0.96	14.33	59.22	24.01	0.98
Truck	2	8.9	0.96	19.26	63.32	25.63	0.96
	3	13.38	0.96	16.41	61.72	22.29	0.96
	4	15.44	0.97	14.74	60.99	19.87	0.97
Astronaut	2	18.39	0.91	17.04	86.22	37.89	0.98
	3	19.9	0.91	14.84	84.79	33.29	0.98
	4	21.07	0.91	13.54	84.08	30.25	0.98
Jet	2	15.39	0.92	11.12	61.77	24.87	0.99
	3	18.93	0.93	9.35	60.09	20.83	0.99
	4	20.84	0.94	8.64	59.47	18.88	0.99
Boats	2	19.81	0.93	9.78	59.15	22.13	0.98
	3	24.19	0.93	8.24	58	18.74	0.98
	4	26.03	0.95	7.55	57.51	16.85	0.99
Street	2	12	0.93	38.30	63.04	62.20	0.97
	3	11.39	0.95	34.22	60.28	56.67	0.97
	4	11.76	0.96	30.34	58.25	50.44	0.97


Tablo 3.1 tez çalışması için oluşturulan veri setine ait objektif sonuçları içermektedir. SR faktörü ile, kaynak görüntü çözünürlüğün ne kadar katlandığı ifade edilmektedir. Bu doğrultuda, sonuçlar incelendiğinde süper-çözünürlük katsayısı arttıkça yöntemin başarısının da arttığı açık olarak görülmektedir. Sonuçlar alınırken literatürde kullanılan popüler görüntüler kullanılmıştır. Bu görüntüler farklı boyutlara ve genellikle gri seviyeye sahiptir. Değerlendirme için kullanılan metrikler kaynak görüntülerden birleştirilmiş görüntüye odak bilgisinin ne kadar doğrulukla aktarıldığını hesaplamaktadır. Bu doğrultuda sonuçlar incelendiğinde önerilen yaklaşımın kaynak görüntülerden doğru odak bilgisini aktarmada oldukça başarılı olduğu görülmektedir. Ayrıca süper-çözünürlük katsayısı arttıkça yöntemin başarısının da arttığı tablodan görülmektedir.

Önerilen yöntemin görsel sonuçları sırasıyla Şekil 3.4-3.7' de verilmiştir. Şekil 3.4, yeni veri setinden alınan Livingroom görüntüsünü göstermektedir. Her figürün boyutu 512x512'dir. (a-d), kaynaştırmak için farklı odaklanmış kısımlara sahip dört kaynak görüntüyü gösterirken (e-g), sırasıyla 2, 3 ve 4 süper çözünürlük faktörleri ile önerilen yöntemin uygulanmasından sonraki kaynaşmış görüntüyü gösterir.




Şekil 3.4. Çoklu-odaklı Livingroom görüntüsü (512x512): (a) Kaynak görüntü 1(512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) 2 SR faktörü ile birleştirilmiş görüntü (512x512), (f) 3 SR faktörü ile birleştirilmiş görüntü (512x512), (g) 4 SR faktörü ile birleştirilmiş görüntü (512x512)

Şekil 3.5, yeni veri setinden alınan astronot görüntüsünü göstermektedir. Her figürün boyutu 512x512'dir. (a-d), birleştirmek için farklı odaksız ve bulanık kısımlara sahip dört kaynak görüntüyü sunar. (e-g), sırasıyla 2, 3ve 4 süper çözünürlük faktörleriyle önerilen yöntemin uygulanmasından sonraki son birleştirilmiş görüntüyü göstermektedir.




Şekil 3.5. Çoklu-odaklı Astronaut görüntüsü (512x512): (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) 2 SR faktörü ile birleştirilmiş görüntü (512x512), (f) 3 SR faktörü ile birleştirilmiş görüntü (512x512), (g) 4 SR faktörü ile birleştirilmiş görüntü (512x512)

Şekil 3.6, yeni veri setinden alınan Truck görüntüsünü göstermektedir. Her figürün boyutu 512x512'dir. (a-d), birleştirmek için farklı odaksız ve bulanık kısımlara sahip dört kaynak görüntüyü sunar. (e-g), sırasıyla 2, 3 ve 4 süper çözünürlük faktörleri ile önerilen yöntemin uygulanmasından sonraki son birleştirilmiş görüntüyü göstermektedir.



Şekil 3.6. Çoklu-odaklı Trucks görüntüsü (512x512): (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) 2 SR faktörü ile birleştirilmiş görüntü (512x512), (f) 3 SR faktörü ile birleştirilmiş görüntü (512x512), (g) 4 SR faktörü ile birleştirilmiş görüntü (512x512)

Şekil 3.7, yeni veri setinden alınan Lake görüntüsünü göstermektedir. Her figürün boyutu 512x512'dir. (a-d), birleştirmek için farklı odaksız ve bulanık kısımlara sahip dört kaynak görüntüyü sunar. (e-g), sırasıyla 2, 3 ve 4 süper çözünürlük faktörleri ile önerilen yöntemin uygulanmasından sonraki son birleştirilmiş görüntüyü göstermektedir.



Şekil 3.7. Çoklu-odaklı Lake görüntüsü (512x512): (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) 2 SR faktörü ile birleştirilmiş görüntü (512x512), (f) 3 SR faktörü ile birleştirilmiş görüntü (512x512), (g) 4 SR faktörü ile birleştirilmiş görüntü (512x512)

3.3.2. Önerilen Çalışma İçin Subjektif Değerlendirme Sonuçları


Öznel kalite ölçütleri, nesnel ölçütlerin aksine yöntemin performansını ölçmek için referans görüntüyü kullanır. Referans görüntü orijinal görüntüdür. Orijinal görüntüyü bulmak kolay olmadığı için; öznel metrikler araştırmacılar tarafından tercih edilmemektedir. Bu metrikler, tüm odaklı görüntü ile orijinal görüntü arasındaki benzerliği ölçer. RMSE ve PSNR en çok kullanılan subjektif kalite ölçütleridir. Değerlendirmeler için farklı boyutlarda

farklı görüntüler kullanılmıştır. Bu resimler Lab (480x640), Flower (384x512), Leopard (360x480), Desk (480x640), Book (240x320) ve Oscar'dır (512x512x3). Bu görüntüler için elde edilen metrik sonuçları Tablo 3.2'de verilmiştir.


Tablo 3.2. Önerilen 1. çalışma için subjektif metrikler ile değerlendirme sonuçları

Görüntüler	SR Faktör	RMSE	PSNR
Lab	2	2.01	42.06
	3	1.94	42.37
	4	1.96	42.28
Flower	2	2.46	40.31
	3	2.17	41.40
	4	2.57	39.93
Leopard	2	3.48	37.29
	3	3.21	38.01
	4	2.97	38.67
Desk	2	3.39	37.52
	3	3.01	38.55
	4	3.03	38.50
Book	2	4.53	35.00
	3	2.38	40.55
	4	1.91	42.51
Oscar	2	9.32	28.74
	3	7.33	30.82
	4	6.75	31.54

Tablo 3.2'de, SR faktörü, kaynak görüntülerin çözünürlüğünün ne kadar katlandığını temsil eder. Şekil 3.8 ve 3.9 sırasıyla, Saras (512x512) ve Flower (384x512) görüntüleri için görsel sonuçları göstermektedir. Bu şekillerde (a) sol odaklı görüntüyü temsil etmektedir. Yani, görüntünün sol kısmı odaklı iken sağ kısmı odaksızdır. (b) görüntüsü sol odaklı görüntünün tam tersi olan sağ odaklı görüntüyü temsil eder. (c) görüntüsü ise referans görüntüyü gösterir. (d) - (f) sırasıyla 2, 3 ve 4 süper çözünürlük faktörleri ile önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü temsil etmektedir. Öznel sonuçlar bize referans görüntü ile kaynaşmış görüntüler arasındaki görselliği karşılaştırma şansı verir.



Şekil 3.8. Çoklu-odaklı Saras görüntüsü (512x512): (a) Sol odaklı kaynak görüntü (512x512), (b) Sağ odaklı kaynak görüntü (512x512), (c) Referans görüntü (512x512), (d) 2 SR faktörü ile birleştirilmiş görüntü (512x512), (e) 3 SR faktörü ile birleştirilmiş görüntü (512x512), (f) 4 SR faktörü ile birleştirilmiş görüntü (512x512)



Şekil 3.9. Çoklu-odaklı Flower görüntüsü (384x512): (a) Sol odaklı kaynak görüntü (384x512), (b) Sağ odaklı kaynak görüntü (384x512), (c) Referans görüntü (384x512), (d) 2 SR faktörü ile birleştirilmiş görüntü (384x512), (e) 3 SR faktörü ile birleştirilmiş görüntü (384x512), (f) 4 SR faktörü ile birleştirilmiş görüntü (384x512)

3.3.3.Önerilen Çalışmanın Literatürdeki Çalışmalar ile Objektif Metrikler Kullanılarak Karşılaştırılması

Önerilen yöntem, nesnel kalite ölçütleri ve öznel kalite ölçütleri kullanılarak literatürdeki yöntemlerle karşılaştırılmıştır. Kaynak görüntülerin çözünürlüklerinin ne kadar katlanacağını belirleyen sabit değere süper çözünürlük faktörü adı verilir. Bu çalışmada süper-çözünürlük faktörü 2, 3, 4 olarak seçilmiş ve önerilen yöntemi literatürdeki yöntemlerle karşılaştırmak için kullanılan nicel sonuçlar bu faktörler kullanılarak ayrı ayrı hesaplanmıştır. Böylece çözünürlük faktörünün birleştirme üzerindeki etkisi de net bir şekilde gözlemlenmektedir. Önerilen yöntemin literatürdeki yöntemlerle karşılaştırılmasında literatürde sıklıkla tercih edilen MI ve Q_{AB}^F kullanılmaktadır. Bu metrikler, birleştirilmiş görüntüye ne kadar önemli bilginin aktarıldığını ve kaynak görüntülerin kenar bilgisinin ne kadar korunduğunu ölçer. Bu özelliğinden dolayı bu metriklerin yöntemin kalitesini ölçmek için önemli olduğu söylenebilir. Önerilen yöntem


literatürdeki 10 farklı yöntemle karşılaştırılmıştır. Objektif metrikler kullanılarak yapılan karşılaştırmalar Tablo 3.3 ile verilmektedir.

Tablo 3.3. Durga Prasad veri seti için önerilen 1. çalışma ve literatürdeki çalışmaların objektif metrikler ile karşılaştırma sonuçları

	Görüntüler Metrikler	Book	Clock	Pepsi	Lab	Disk	Leopard	Grass	Balloon
Chen ve ark. [117]	MI QAB/F	8,61 0.71	X X	7,42 0.75	8,10 0.73	7,66 0.71	X X	X X	X X
Hua ve ark. [120]	MI QAB/F	9,24 0.73	8,29 0.73	7,80 0.76	8,50 0.74	8,00 0.73	X X	X X	X X
Zhang ve ark. [121]	MI QAB/F	X X	7,83 0.71	7,09 0.78	8,04 0.73	6,49 0.68	X X	X X	X X
Li ve ark. [125]	MI QAB/F	9,63 0.71	8,52 0.68	8,83 0.76	8,78 0.73	X X	X X	X X	X X
Nejati ve ark. [124]	MI QAB/F	9,44 0.73	8,58 0.72	8,87 0.78	8,70 0.74	8,29 0.73	X X	X X	8,19 0.78
Jiang ve ark. [119]	MI QAB/F	8,96 0.73	8,38 0.71	8,25 0.78	8,78 0.73	7,75 0.72	X X	X X	X X
Abdipour ve ark.[118]	MI QAB/F	9,27 0.73	7,16 0.65	8,90 0.79	8,69 0.75	X X	X X	X X	X X
Chaudhary ve ark. [122]	MI QAB/F	X X	X X	7,07 0.76	6,26 0.68	6,45 0.71	X X	5,48 0.73	X X
Yang ve ark. [123]	MI QAB/F	9,34 0.76	8,65 0.74	X X	X X	8,38 0.73	10,90 0.83	X X	X X
Aymaz ve ark. [116]	MI QAB/F	10,87 0.92	8,62 0.9	9,27 0.93	9,37 0.89	8,32 0.88	X X	X X	X X
SR-2 ile Önerilen Yaklaşım	MI QAB/F	10,14 0.9	10,70 0.87	10,48 0.91	10,89 0.88	8,74 0.87	12,49 0.92	6,38 0.84	14.23 0.91
SR-3 ile Önerilen Yaklaşım	MI QAB/F	11,12 0.91	11,69 0.88	12,41 0.92	12,41 0.89	9,21 0.88	12,62 0.92	6,45 0.86	15.23 0.92
SR-4 ile Önerilen Yaklaşım	MI QAB/F	11,69 0.93	11,70 0.89	13.25 0.93	13,10 0.90	9,65 0.89	12,97 0.93	6,29 0.88	15.44 0.94

Karşılaştırmalarda çoklu-odaklı görüntü birleştirme yöntemleri için popüler olan sekiz farklı görüntü kullanılmıştır. Bunlar Book (384x512), Clock (512x512), Pepsi (512x512), Lab (480x640), Disk (480x640), Leopard (360x480), Grass (256x256) ve Balloon (480x64) resimleridir. Tablo 3.3'te önerilen yöntem 3 farklı formda tabloya eklenmiştir. Bunlar SR-2 ile Önerilen Yaklaşım, SR-3 ile Önerilen Yaklaşım ve SR-4 ile Önerilen Yaklaşım'dır. Tabloda süper çözünürlük yöntemi, SR olarak temsil edilmektedir. Ayrıca 2,3 ve 4 kaynak görüntülerin çözünürlüğünün kaç kat artırıldığını göstermektedir. Yani süper çözünürlük faktörü 2 olarak seçildiğinde kaynak görüntülerin uzamsal çözünürlüğü iki katına çıkmaktadır. Belirtilen görüntülerde metriklerin en iyi sonuçları kalın olarak gösterilmiştir. Ayrıca, tabloda ilgili görüntüler için yöntemlere ait sonuçlar olmadığında bu durum X ile temsil edilmiştir. Sonuçlar, önerilen yöntemin her bir süper çözünürlük faktörü ile literatürdeki yöntemlere kıyasla bu alanda daha başarılı olduğunu kanıtlamıştır. MI ve Q_{AB}^F metrikleri, araştırmacılar tarafından çoğunlukla tercih edilen objektif kalite metrikleridir, bu nedenle, önerilen yöntemi literatürdeki yöntemlerle karşılaştırmak için bu metrikler seçilmiştir. MI metriği, ilgili verilerin kaynak görüntülerden kaynaşmış görüntüye aktarılma miktarını ölçerken, Q_{AB}^F , birleştirme işlemlerinden sonra kaynak görüntülerin kenar bilgisinin ne kadar korunduğunu ölçer. Buna göre, MI ve Q_{AB}^F metrik sonuçları incelendiğinde, önerilen yöntemin kaynak görüntülerin daha fazla kenarını koruduğu ve kaynak görüntülerden daha fazla bilgiyi odaklanmış görüntüye aktardığı söylenebilir. Ayrıca önerilen yöntemin süper çözünürlük faktörü artırıldığında daha iyi sonuçlar verdiği görülmektedir.

Ayrıca veri setlerinden alınan bazı görüntüler için görsel sonuçlar sırasıyla Şekil 3.10 ve 3.11' de verilmiştir. Şekil 3.10 ve 3.11, bu alanda çok popüler olan görüntülerin görsel sonuçlarını göstermektedir. Bu şekillerde (a) sol odaklı görüntüyü temsil etmektedir. Yani, görüntünün sol kısmı odaklı iken sağ kısmı odaksızdır. (b) görüntüsü sol odaklı görüntünün tam tersi olan sağ odaklı görüntüyü temsil etmektedir. Önerilen yöntem, üç farklı süper çözünürlük faktöründe uygulanmaktadır. (c) - (e) görüntüleri sırasıyla 2, 3 ve 4 süper çözünürlük faktörleri ile önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü göstermektedir. Görüntüler bu faktörlerle katlanır ve yöntemin sonunda biküçük interpolasyon tabanlı yeniden boyutlandırma yöntemi kullanılarak kaynaştırılan görüntü orijinal boyutuna getirilir. Görsel sonuçlar, önerilen yöntemin iyi görsel algı ile yüksek kaliteli görüntüler oluşturduğunu göstermektedir.



(a)

(b)




(c)

(d)


(e)

Şekil 3.10. Çoklu-odaklı Clock görüntüsü (512x512): (a) Sol-odaklı kaynak görüntü (512x512), (b) Sağ-odaklı kaynak görüntü (512x512), (c) 2 SR faktörü ile birleştirilmiş görüntü (512x512), (d) 3 SR faktörü ile birleştirilmiş görüntü (512x512), (e) 4 SR faktörü ile birleştirilmiş görüntü (512x512)




Şekil 3.11. Çoklu-odaklı balloon görüntüsü (480x640): (a) Sol-odaklı kaynak görüntü (480x640), (b) Sağ-odaklı kaynak görüntü (480x640), (c) 2 SR faktörü ile birleştirilmiş görüntü (512x512), (d) 3 SR faktörü ile birleştirilmiş görüntü (512x512), (e) 4 SR faktörü ile birleştirilmiş görüntü (512x512)


Şekil 3.12 – 3.14, sırasıyla çözünürlükleri bikübik interpolasyon tabanlı süper çözünürlük yöntemiyle 2,3,4 kat artırılan Clock (512 x 512), Balloon (480 x 640) ve Lytro02 (520 x 520) kaynak görüntülerini göstermektedir. Şekillerde (a) – (c) sırasıyla 2, 3 ve 4 süper çözünürlük faktörleriyle çözünürlüğü artırılmış sola odaklanmış yüksek çözünürlüklü görüntüleri sunar. (d) – (f) görüntüleri ise çözünürlükleri süper çözünürlük faktörleri 2, 3 ve 4 ile artırılan sağa odaklanmış yüksek çözünürlüklü kaynak görüntüleri gösterir. Bu kaynak görüntüler, orijinal kaynak görüntülerden daha fazla bilgi ve ayrıntıya sahiptir. Sonuçlar incelendiğinde süper çözünürlük faktörü arttıkça önerilen yöntemin başarısı ve kaynaşmış görüntüden birleştirilmiş görüntüye aktarılan doğru bilginin de arttığı görülmektedir.



Şekil 3.12. Çoklu-odaklı Clock görüntüsü (512x512): (a) 2 SR faktörü ile sol-odaklı kaynak görüntü (1024x1024), (b) 3 SR faktörü ile sol odaklı kaynak görüntü (1536x1536), (c) 4 SR faktörü ile sol-odaklı kaynak görüntü (2048x2048), (d) 2 SR faktörü ile sağ-odaklı kaynak görüntü (1024x1024), (e) 3 SR faktörü ile sağ-odaklı kaynak görüntü (1536x1536), (f) 4 SR faktörü ile sağ-odaklı kaynak görüntü (2048x2048)




Şekil 3.13. Çoklu-odaklı Balloon görüntüsü (480x640): (a) 2 SR faktörü ile sol-odaklı kaynak görüntü (960x1280), (b) 3 SR faktörü ile sol-odaklı kaynak görüntü (1440x1920), (c) 4 SR faktörü ile sol-odaklı kaynak görüntü (1920x2560), (d) 2 SR faktörü ile sağ-odaklı kaynak görüntü (960x1280), (e) 3 SR faktörü ile sağ-odaklı kaynak görüntü (1440x1920), (f) 4 SR faktörü ile sağ-odaklı kaynak görüntü (1920x2560)




Şekil 3.14. Çoklu-odaklı Lytro-02 Görüntüsü (520x520): (a) 2 SR faktörü ile sol-odaklı kaynak görüntü (1040x1040), (b) 3 SR faktörü ile sol-odaklı kaynak görüntü (1560x1560), (c) 4 SR faktörü ile sol-odaklı kaynak görüntü (2080x2080), (d) 2 SR faktörü ile sağ-odaklı kaynak görüntü (1040x1040), (e) 3 SR faktörü ile sağ-odaklı kaynak görüntü (1560x1560), (f) 4 SR faktörü ile sağ-odaklı kaynak görüntü (2080x2080)

Şekil 3.15 ve Şekil 3.16, Lytro [51] veri setinden alınan kaynak görüntülerin görsel sonuçlarını göstermektedir. Bu veri seti genellikle 520 x 520 boyutundaki renkli görüntüleri içermektedir. Görsel sonuçlar yorumlandığında önerilen yöntemin daha başarılı sonuçlar oluşturduğu görülmektedir.



Şekil 3.15. Çoklu-odaklı Lytro-01 görüntüsü (520x520): (a) Sol-odaklı kaynak görüntü (520x520), (b) Sağ-odaklı kaynak görüntü (520x520), (c) 2 SR faktörü ile birleştirilmiş görüntü (520x520), (d) 3 SR faktörü ile birleştirilmiş görüntü (520x520), (e) 4 SR faktörü ile birleştirilmiş görüntü (520x520)



Şekil 3.16. Çoklu-odaklı Lytro-02 görüntüsü (520x520): (a) Sol-odaklı kaynak görüntü (520x520), (b) Sağ-odaklı kaynak görüntü (520x520), (c) 2 SR faktörü ile birleştirilmiş görüntü (520x520), (d) 3 SR faktörü ile birleştirilmiş görüntü (520x520), (e) 4 SR faktörü ile birleştirilmiş görüntü (520x520)

3.3.4.Önerilen Çalışmanın Literatürdeki Çalışmalar ile Subjektif Metrikler Kullanılarak Karşılaştırılması


Öznel kalite metrikleri, her şey dâhil odaklı görüntü ile referans görüntü arasındaki benzerliği ölçer, ancak bu metrikler, referans görüntü bulmak zor olduğundan araştırmacılar tarafından nadiren tercih edilir. Önerilen yönteme ait karşılaştırma sonuçları Tablo 3.4’te verilmektedir.

Tablo 3.4. Durga Prasad veri seti için önerilen 1. çalışma ve literatürdeki çalışmaların subjektif metrikler ile karşılaştırma sonuçları

	BOOK		CLOCK		LAB		FLOWER		SARAS	
Yöntemler	RMSE	PSNR	RMSE	PSNR	RMSE	PSNR	RMSE	PSNR	RMSE	PSNR
Moushmi ve ark. [126]	7.04	31.17	4.51	35.04	X	X	X	X	2.85	X
Li ve ark. [127]	X	X	X	X	4.65	34.78	7.84	30.24	X	X
Aymaz ve ark. [116]	5.28	33.67	0.95	48.57	2.92	38.82	4.99	34.16	2.76	39.31
SR-2 ile Önerilen Çalışma	4.53	35	1.22	46.40	2.01	42.06	2.46	40.31	2.73	39.40
SR-3 ile Önerilen Çalışma	2.38	40.6	0.98	48.30	1.94	42.37	2.17	41.40	1.90	42.55
SR-4 ile Önerilen Çalışma	1.91	42.51	0.87	49.34	1.96	42.28	2.57	39.93	1.54	44.38

Book (240x320), Clock (512x512), Lab (480x640), Flower (384x512) ve Saras (512x512) görüntüleri, önerilen yöntemi RMSE ve PSNR subjektif metrikleri kullanılarak literatürdeki yöntemlerle karşılaştırmak için kullanılmıştır. Tablo 3.4 incelendiğinde, kaynak görüntünün uzamsal çözünürlüğünün ne kadar katlanacağına karar vermek için kullanılan süper çözünürlük faktörü arttıkça, önerilen yöntemin başarısı artmaktadır. Kaynak görüntüler için metriklerin en iyi sonuçları kalın harflerle gösterilmiştir. Önerilen yöntemin subjektif sonuçları, birleştirilmiş görüntü ile referans görüntü arasında ne kadar benzerlik olduğunu ve önerilen yöntemin gürültüye ne kadar dayanıklı olduğunu ortaya koymaktadır. Tablo 3.4' teki sonuçlar, önerilen yöntemin literatürdeki yöntemlerden daha iyi bir birleştirme elde etmede daha başarılı olduğunu kanıtlamaktadır.

Lab (480x640) ve Book (384x512) görüntüleri için görsel sonuçlar sırasıyla Şekil 3.17 ve Şekil 3.18'de verilmiştir. (a) ve (b), bu şekillerde 512x512 boyutunda hem sol odaklı hem de sağ odaklı kaynak görüntüyü göstermektedir. Subjektif metrikleri hesaplamak için gerekli olan referans görüntü (c) ile gösterilir. (d), (e) ve (f) sırasıyla SR Faktörü 2, 3 ve 4 ile önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüleri göstermektedir.



Şekil 3.17. Çoklu-odaklı Lab görüntüsü (512x512): (a) Sol-odaklı kaynak görüntü (512x512), (b) Sağ-odaklı kaynak görüntü (512x512), (c) referans görüntü (512x512), (d) 2 SR faktörü ile birleştirilmiş görüntü (512x512), (e) 3 SR faktörü ile birleştirilmiş görüntü (512x512), (f) 4 SR faktörü ile birleştirilmiş görüntü (512x512)



Şekil 3.18. Çoklu-odaklı Book görüntüsü (384x512): (a) Sol-odaklı kaynak görüntü (384x512), (b) Sağ-odaklı kaynak görüntü (384x512), (c) referans görüntü (384x512), (d) 2 SR faktörü ile birleştirilmiş görüntü (384x512), (e) 3 SR faktörü ile birleştirilmiş görüntü (384x512), (f) 4 SR faktörü ile birleştirilmiş görüntü (384x512)

3.4. Çoklu-odaklı Görüntü Birleştirmede Dinamik Karar Mekanizmalı Yeni Bir Yaklaşım İçin Sonuçlar

Tez kapsamında önerilen diğer yöntemde, çok odaklı görüntü Birleştirme için yeni bir yaklaşım önerilmiştir. Bu yöntem, yeni bir veri seti kullanılması, eğitim için yeni bir ağ önermesi ve birleştirme aşamasında uygulanan iyileştirme mekanizmaları ile literatürdeki diğer yöntemlerden ayrılmaktadır. Genellikle literatürdeki yöntemler, sınırlı sayıda kaynak görüntü içeren Lytro veri setini kullanır. Bu veri setini kullanan yöntemler, iki kaynak görüntüyü birleştirmeye odaklanır ve bu görüntülerdeki odaklanılan bölgeler birbirinin tam tersidir. Başka bir deyişle, kaynak görüntüler tek bir karar haritası ile birleştirilebilir. Bu durumun aksine gerçek hayattaki görüntüleme cihazlarıyla alınan kaynak görüntüler ikiden fazla olabilir ve bu görüntülerde odaklanılan bölgeler rastgeledir. Bu nedenle gerçek hayata uygun yeni ve büyük bir veri seti hazırlanarak bu çalışmada kullanılmıştır. Bu veri seti, rastgele odak bölgelerine sahip iki veya daha fazla kaynak görüntü içerir. Literatürde

kullanılan yöntemler bu veri setini birleştirmek için yeterli değildir çünkü bu yöntemler görüntüleri tek bir karar haritası ile birleştirir ve önerilen veri seti buna uygun değildir.

Aynı zamanda, eğitim için yeni bir ağ tasarlanmıştır. Bu ağ 21 katmandan oluşmaktadır, bu ağ diğerlerinden ayıran özelliği maksimum-havuzlama katmanının kaldırılarak detaylı bilgilerin korunmasıdır. Literatürdeki yöntemlerden bir diğer farkı da eğitilecek görüntü yamalarına uygulanan prosedürlerdir. Diğer yöntemler döndürme ve öteleme gibi dönüşümleri kullanırken, önerilen yöntemde bunlara ek olarak kontrast iyileştirme de uygulanmaktadır. Böylece hem eğitim başarısı hem de test başarısı artırılmaktadır.


Önerilen yöntemdeki diğer önemli noktalar, nihai karar haritaları bulunurken uygulanan odak ölçüm metriklerine dayalı iyileştirme ve önerilen yöntemin son aşamasında nihai karar haritalarının kesişiminde uygulanan gradyan tabanlı birleştirme kuralıdır. Bu iki iyileştirme yöntemi, ikiden fazla kaynak görüntü içeren veri setlerinin kaynaşmasına ve literatürdeki bir boşluğun giderilmesine önemli ölçüde katkıda bulunmaktadır. Tüm bu aşamalardan sonra önerilen yöntemin performansı objektif metrikler kullanılarak ölçülür ve literatürdeki diğer yöntemlerle karşılaştırılır.

Performans ölçümü için objektif metrikler kullanılmıştır. Bu metrikler Q_{AB}^F , MI vb. literatürde sıklıkla kullanılan metriklerdir. Bu metrikler, kaynaşmış görüntüde kaynak görüntülerin ne kadar temsil edildiğini ölçer. Diğer bir deyişle, bu metriklere bakarak kaynak görüntülerde kenar, köşe gibi önemli kısımların önerilen yöntemde ne kadar korunabildiği söylenebilir. Bu çalışmada sonuçlar üç farklı veri seti için verilmiştir. Bunlar, tarafımızca oluşturulan yeni veri seti, literatürdeki yöntemlerin çoğunda kullanılan görüntülerden oluşan geleneksel veri seti ve Lytro veri seti'dir. Her bir veri seti için görsel ve nicel sonuçlar alt bölümlerde verilmiştir.

3.4.1. Yeni Veri Seti İçin Önerilen Çalışmanın Görsel ve Sayısal Sonuçları

Yeni veri seti, 155 setten oluşmaktadır. Bu Veri Setinde her bir set farklı sayıda (2, 3, 4, 5, 6) görüntü içermekte olup toplamda 715 renkli görüntü bulunmaktadır. Bu çalışmada ilk kez kullanılan bu Veri Seti için sadece görsel ve nicel sonuçlar verilmiş olup, herhangi bir karşılaştırma yapılamamıştır. Şekil 3.19-3.29, yeni veri setini kullanarak önerilen yöntemin görsel sonuçlarını vermektedir. Şekillerde hem iki görüntü hem de ikiden fazla kaynak görüntü için birleştirme sonuçları verilmiştir. Bu durum literatür için ilktir çünkü


literatürde bulunan çalışmalar sadece iki adet kaynak görüntü birleştirmeye odaklanmış ve buna uygun olarak sonuçlar vermiştir. Bu bölümde sonuçları verilen görseller veri setinden rastgele seçilmiş görüntülerden oluşmaktadır.



Şekil 3.19. Yeni veri seti GOODS görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) Kaynak görüntü 1 için nihai karar haritası (512x512), (f) Kaynak görüntü 2 için nihai karar haritası (512x512), (g) Kaynak görüntü 3 için nihai karar haritası (512x512), (h) Kaynak görüntü 4 için nihai karar haritası (512x512), (i) Tüm-odaklı görüntü (512x512)


Şekil 3.19, yeni veri setindeki GOODS görselinin sonuçlarını içerir. (a-d) birleştirme için kullanılacak farklı odak alanlarına sahip kaynak görüntüleri verir, (e-h) görüntüleri

önerilen yöntemden sonra oluşturulan nihai karar haritalarını verir ve sonuncusu (i) görüntüsü, önerilen yöntemden sonra hepsi bir arada odaklanmış görüntüyü verir. Yöntem her kaynak görüntü için ayrı karar haritası oluşturmakta ve bunları kaynak görüntülerden daha ayrıntılı birleştirilmiş bir görüntü oluşturmak için kullanmaktadır.




Şekil 3.20. Yeni veri seti HORSEANDCOW görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) Kaynak görüntü 1 için nihai karar haritası (512x512), (f) Kaynak görüntü 2 nihai karar haritası (512x512), (g) Kaynak görüntü 3 için nihai karar haritası (512x512), (h) Kaynak görüntü 4 için nihai karar haritası (512x512), (i) Tüm-odaklı görüntü (512x512)

Şekil 3.20, yeni veri setindeki HORSEANDCOW görüntüsü için sonuçları içerir. (a-d) görüntüleri, birleştirme için kullanılacak farklı odak alanlarına sahip kaynak görüntüleri verir, (e-h) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını verir ve sonuncusu (ı) görüntüsü, önerilen yöntemden sonra hepsi bir arada odaklanmış görüntüyü verir. Bu şekil, dört farklı kaynak görüntünün birleştirilmesinin sonuçlarını verir. Önerilen yöntem kullanılarak oluşturulan görüntü, kaynak görüntülerden daha net ve ayrıntılıdır.



Şekil 3.21. Yeni veri seti DOG görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 1 için nihai karar haritası (512x512), (d) Kaynak görüntü 2 için nihai karar haritası (512x512), (e) Tüm-odaklı görüntü (512x512)


Şekil 3.21, yeni veri setindeki görüntü DOG için sonuçları içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak alanlarına sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra kaynak görüntüler için nihai karar haritalarını gösterir ve (e) görüntüsü birleştirilmiş görüntüyü verir. Bu şekil, iki farklı kaynak görüntü için önerilen yöntemin sonuçlarını göstermektedir. Karar haritaları ve birleştirilmiş görüntü, yöntemin ayrıntıları ne kadar iyi koruduğunu göstermektedir.




Şekil 3.22. Yeni veri seti JETS görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) Kaynak görüntü 1 için nihai karar haritası (512x512), (f) Kaynak görüntü 2 için nihai karar haritası (512x512), (g) Kaynak görüntü 3 için nihai karar haritası (512x512), (h) Kaynak görüntü 4 için nihai karar haritası (512x512), (i) Tüm-odaklı görüntü (512x512)

Şekil 3.22, yeni veri setindeki görüntü JETS sonuçlarını içerir. (a-d) görüntüleri, birleştirme için kullanılacak farklı odak alanlarına sahip kaynak görüntüleri verir, (e-h) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını verir ve sonuncusu (i) görüntüsü, önerilen yöntemden sonra hepsi bir arada odaklanmış görüntüyü verir. Bu şekilde 4 adet kaynak görüntü vardır ve görüntülerdeki her nesnenin ayrı bir odak noktası

vardır. Önerilen yöntem, odaklanmış ve odaklanmamış nesneleri başarılı bir şekilde algılayarak kaynaşmış bir görüntü oluşturur.




Şekil 3.23. Yeni veri seti KNIFEANDBANANA görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) Kaynak görüntü 1 için nihai karar haritası (512x512), (f) Kaynak görüntü 2 için nihai karar haritası (512x512), (g) Kaynak görüntü 3 için nihai karar haritası (512x512), (h) Kaynak görüntü 4 için nihai karar haritası (512x512), (i) Tüm-odaklı görüntü (512x512)




Şekil 3.24. Yeni veri seti APPLE görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 3 (512x512), (d) Kaynak görüntü 4 (512x512), (e) Kaynak görüntü 1 için nihai karar haritası (512x512), (f) Kaynak görüntü 2 için nihai karar haritası (512x512), (g) Kaynak görüntü 3 için nihai karar haritası (512x512), (h) Kaynak görüntü 4 için nihai karar haritası (512x512), (i) Tüm-odaklı görüntü (512x512)

Şekil 3.23-3.24, sırasıyla yeni veri setindeki KNIFEANDBANANA ve APPLE görüntüleri için sonuçları içermektedir. Bu görsellerde, (a-d) görselleri, birleştirme için kullanılacak farklı odak alanlarına sahip kaynak görsellerini, (e-h) görselleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve (i) görseli, önerilen yöntemden sonra hepsi bir arada odaklanmış görseli vermektedir. Şekiller incelendiğinde önerilen yöntemin kaynak görüntülerdeki farklı nesneleri tespit etmede başarılı olduğu görülmektedir. Önerilen


yöntem kullanılarak oluşturulan birleştirilmiş görüntülerin kaynak görüntülere oranla çok daha çok detay içerdiği açıkça görülmektedir.




Şekil 3.25. Yeni veri seti ELEPHANT görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 1 için nihai karar haritası (512x512), (d) Kaynak görüntü 2 için nihai karar haritası (512x512), (e) Tüm-odaklı görüntü (512x512)




Şekil 3.26. Yeni veri seti BIKER görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 1 için nihai karar haritası (512x512), (d) Kaynak görüntü 2 için nihai karar haritası (512x512), (e) Tüm-odaklı görüntü (512x512)



Şekil 3.27. Yeni veri seti ROSE görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 1 için nihai karar haritası (512x512), (d) Kaynak görüntü 2 için nihai karar haritası (512x512), (e) Tüm-odaklı görüntü (512x512)



Şekil 3.28. Yeni veri seti MOTORCYCLE görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 1 için nihai karar haritası (512x512), (d) Kaynak görüntü 2 için nihai karar haritası (512x512), (e) Tüm-odaklı görüntü (512x512)



Şekil 3.29. Yeni veri seti MINICAT görseli: (a) Kaynak görüntü 1 (512x512), (b) Kaynak görüntü 2 (512x512), (c) Kaynak görüntü 1 için nihai karar haritası (512x512), (d) Kaynak görüntü 2 için nihai karar haritası (512x512), (e) Tüm-odaklı görüntü (512x512)

Şekil 3.25-3.29, yeni veri setinde iki kaynak görüntüye sahip kümeler için önerilen yöntemin görsel sonuçlarını vermektedir. Bu şekillerde, (a-b) görüntüleri, birleştirme için kullanılacak farklı odak alanlarına sahip kaynak görüntüleri vermektedir. (c-d) görüntüleri, önerilen yöntemden sonra kaynak görüntüler için nihai karar haritalarını gösterir ve (e) görüntüsü birleştirilmiş görüntüyü verir. Bu şekiller, karar haritaları ve birleştirilmiş görüntüler incelendiğinde önerilen yöntemin detayları ne kadar iyi sakladığını göstermektedir. Bu görseller, yeni veri setinden seçilen birkaç örnekten oluşmaktadır.

Oluşturulan yeni veri seti, bu görüntüler gibi farklı özelliklere sahip birçok örneğe sahiptir. Bu nedenle ileriki çalışmalarda yöntemlerin başarısını ölçmek için önemli olacağı düşünülmektedir. Tüm şekillerde görüldüğü gibi hem iki kaynak görüntü hem de ikiden fazla kaynak görüntü için önerilen yöntem başarılı sonuçlar vermektedir. Bu çalışmada literatürden farklı olarak her görüntü için bir karar haritası oluşturulmuş ve görüntüleri şekillerle verilmiştir.

Ayrıca yeni veri setindeki 13 görüntü için nicel sonuçlar Tablo 3.5’ de verilmiştir. Sonuçlar Q_{AB}^F , Ortalama Gradyan (AG), Standart Sapma (SD) ve Yapısal Benzerlik (SSIM)

metrikleri hesaplanarak alınmıştır. Tabloda verilen görüntüler, sayısı 2 ile 4 arasında değişen kaynak görüntülerin kaynaştırılmasıyla elde edilmektedir.

Tablo 3.5. Oluşturulan yeni veri seti için önerilen 2. çalışmanın objektif ve subjektif metrikler ile değerlendirme sonuçları


Image	$Q^{AB/F}$	AG	SD	SSIM
WALLCLOCK	0,933601	10,96519	59,36694	0,974091
ELEPHANT	0,936588	13,94278	53,75363	0,976955
BASEBALL	0,977726	14,83936	59,80712	0,993941
DOG	0,949241	16,65958	76,39733	0,991114
TRAFFICTABLE	0,893894	16,39537	65,63501	0,985051
BIKER	0,924265	11,26721	84,73571	0,99008
DOGINBEACH	0,966518	11,00734	65,52608	0,986906
COOKIE	0,964454	20,57043	50,21136	0,995772
CATS	0,912745	12,21992	93,67405	0,994186
ZEBRA	0,970527	24,11568	46,12044	0,993215
STOPSIGN	0,937506	19,52018	78,16658	0,993382
STATUE	0,933824	11,93802	67,42037	0,982335
JUMPER	0,913127	11,63854	56,13581	0,943463

Tablo 3.5, yeni veri seti için nesnel ve öznel değerlendirme sonuçlarını göstermektedir. SSIM, birleştirilmiş görüntü ile referans görüntü arasındaki benzerlik oranını veren öznel bir ölçümdür. Kalan metrikler objektiftir ve kaynak görüntülerden birleştirilmiş görüntüye aktarılan verilerin doğruluğunu ölçer. SSIM ve $Q(AB/F)$ 0 ile 1 arasında değerler alır. Bu metriklerin sonuçları ne kadar büyükse, önerilen yöntem o kadar başarılı olacaktır. Metrik sonuçlara bakıldığında önerilen yöntemin kaynaşmış görüntüdeki kaynak görüntüleri temsil etmede oldukça başarılı olduğu görülmektedir. Veri seti ilk kez bu çalışmada kullanıldığı için bu veri seti kullanılarak karşılaştırma yapılmamıştır.


3.4.2. Durga Prasad Veri Seti İçin Görsel ve Sayısal Sonuçlar

Durga Prasad tarafından oluşturulan geleneksel veri seti literatürdeki yöntemlerde sıklıkla kullanılmaktadır. Genellikle görüntü kümeleri birleştirilecek iki görüntüden oluşur ve gri seviyelidir. Diğer veri setlerine ek olarak, geleneksel veri seti de önerilen çalışmada


kullanılmaktadır. Bu çalışmada geleneksel veri setinde bulunan Flower, Leopard, Leaf, Cameraman ve Hoed görüntüleri için görsel sonuçlar verilmiştir. Ayrıca geleneksel veri seti için objektif değerlendirme sonuçlarına göre literatürdeki 16 farklı yöntemle karşılaştırmalar yapılmıştır. Karşılaştırma için literatürdeki yeni yöntemler seçilmiş ve karşılaştırma sonuçları Tablo 3.6'da verilmiştir.




Şekil 3.30. Çoklu-odaklı Flower görüntüsü: (a) Kaynak görüntü 1 (480x640), (b) Kaynak görüntü 2 (480x640), (c) Kaynak görüntü 1 için nihai karar haritası (480x640), (d) Kaynak görüntü 2 için nihai karar haritası (480x640), (e) Tüm-odaklı görüntü (480x640)




Şekil 3.31. Çoklu-odaklı Leopard görüntüsü: (a) Kaynak görüntü 1 (360x480), (b) Kaynak görüntü 2 (360x480), (c) Kaynak görüntü 1 için nihai karar haritası (360x480), (d) Kaynak görüntü 2 için nihai karar haritası (360x480), (e) Tüm-odaklı görüntü (360x480)



Şekil 3.32. Çoklu-odaklı Leaf görüntüsü: (a) Kaynak görüntü 1 (204x268), (b) Kaynak görüntü 2 (204x268), (c) Kaynak görüntü 1 için nihai karar haritası (204x268), (d) Kaynak görüntü 2 için nihai karar haritası (204x268), (e) Tüm-odaklı görüntü (204x268)



Şekil 3.33. Çoklu-odaklı Cameraman görüntüsü: (a) Kaynak görüntü 1 (256x256), (b) Kaynak görüntü 2 (256x256), (c) Kaynak görüntü 1 için nihai karar haritası (256x256), (d) Kaynak görüntü 2 için nihai karar haritası (256x256), (e) Tüm-odaklı görüntü (256x256)



Şekil 3.34. Çoklu-odaklı Hoed görüntüsü: (a) Kaynak görüntü 1 (256x256), (b) Kaynak görüntü 2 (256x256), (c) Kaynak görüntü 1 için nihai karar haritası (256x256), (d) Kaynak görüntü 2 için nihai karar haritası (256x256), (e) Tüm-odaklı görüntü (256x256)

Şekil 3.30-3.34 literatürde sıklıkla kullanılan görsellerden oluşmaktadır. Bu şekillerde (a-b) görüntüleri birleştirme için kullanılacak kaynak görüntüleri vermekte, c-d görüntüleri önerilen yöntem sonrası kaynak görüntüler için nihai karar haritalarını göstermektedir. Son olarak, € görüntüsü hepsi bir arada odaklanmış görüntüyü verir. Şekillerde görüldüğü gibi, birleştirilmiş görüntüler kaynak görüntülerden daha fazla ayrıntıya sahiptir.

Ayrıca objektif ölçümlere dayalı olarak ölçümler yapılmakta ve literatürde bulunan 16 farklı yöntemle karşılaştırılmaktadır. Karşılaştırmalar yapılırken son yıllarda literatürde bulunan yöntemler seçilmeye çalışılmıştır. Önerilen yöntemi literatürdeki yöntemlerle karşılaştırmak için Book, Clock, Pepsi, Lab, Disk, Leaf ve Flower kaynak görüntüler seçilmiştir. Tablo 3.6, önerilen yöntem için objektif karşılaştırma sonuçlarını ve bu görüntüler için karşılaştırılan yöntemleri vermektedir.

Tablo 3.6. Durga Prasad veri seti için önerilen 2. çalışma ve literatürdeki çalışmaların objektif metrikler ile karşılaştırma sonuçları

	Görüntüler Metrikler	BOOK	CLOCK	PEPSİ	LAB	DİSK	LEAF	FLOWER
Yin ve ark. [3]	MI	X	5,49	5,16	X	X	4,75	X
	QAB/F	X	0.71	0.78	X	X	0.73	X
Nejati ve ark. [124]	MI	9,44	8,58	8,87	8,70	8,29	X	X
	QAB/F	0.73	0.72	0.78	0.74	0.73	X	X
Chen ve ark. [117]	MI	8,61	X	7,42	8,10	7,66	X	X
	QAB/F	0.71	X	0.75	0.73	0.71	X	X
He ve ark [129]	MI	9,39	X	8,10	X	7,88	X	X
	QAB/F	0.76	X	0.78	X	0.7299	X	X
Hua ve ark. [120]	MI	9,24	8,29	7,80	8,50	8,00	X	X
	QAB/F	0.73	0.73	0.76	0.74	0.73	X	X
Panigrahy ve ark.[130]	MI	X	X	X	X	X	X	X
	QAB/F	0.9145	0.8968	X	0.8996	0.8958	0.8874	0.8869
Zhang ve ark. [121]	MI	X	7,83	7,09	8,04	6,49	X	X
	QAB/F	X	0.71	0.78	0.73	0.68	X	X
Wen ve ark.[131]	MI	X	X	X	8,69	8,40	7,69	X
	QAB/F	X	X	X	0.76	0.74	0.74	X
Du ve ark.[128]	MI	8,87	X	X	8,83	X	X	8,58
	QAB/F	0.72	X	X	0.75	X	X	0.71
Yang ve ark.[132]	MI	X	X	8,23	7,84	7,04	X	X
	QAB/F	X	X	0.73	0.7458	0.6972	X	X
Amin-Naji ve ark. [133]	MI	8,92	X	X	8,85	X	X	8,54
	QAB/F	0.726	X	X	0.7588	X	X	0.7182
Jiang ve ark. [119]	MI	8,96	8,38	8,25	8,78	7,75	X	X
	QAB/F	0.73	0.71	0.78	0.73	0.72	X	X
Liu ve ark.[134]	MI	9,62	8,58	8,66	8,58	8,17	X	X
	QAB/F	0.8005	0.7306	0.7931	0.7691	0.7352	X	X
Li ve ark. [135]	MI	9,57	9,07	9,03	8,68	8,50	7,65	8,74
	QAB/F	0.7982	0.7512	0.7574	0.7661	0.7266	0.7367	0.7252
Yang ve ark.[136]	MI	8,97	X	8,42	X	7,76	X	8,27
	QAB/F	0.7468	X	0.7490	X	0.7156	X	0.7201
GFF[137]	MI	8,96	8,05	8,31	8,31	7,62	5,65	8,23
	QAB/F	0.7985	0.7426	0.7534	0.7640	0.7228	0.7341	0.7233

Tablo 3.6'nın devamı

Önerilen	MI	9,98	9,36	9,27	11,23	8,63	6,23	10,66
Çalışma	QAB/F	0.95	0.8872	0.91	0.9073	0.9021	0.8912	0.89

Objektif metrikler, kaynak görüntülerden kaynaşmış görüntüye aktarılan bilgi miktarını ve yöntemlerin kaynak görüntülerin ayrıntı bileşenlerini ne kadar iyi koruduğunu ölçer, bu nedenle çoklu-odaklı görüntü birleştirme yöntemlerinde sıklıkla kullanılırlar. Karşılıklı Bilgi (MI), kaynak görüntülerden birleştirilmiş görüntüye ne kadar önemli bilgi aktarıldığını gösterir. QAB/F , kaynak görüntülerdeki kenar bilgilerinin kaynaşmış görüntüde ne kadar temsil edildiğini gösterir. Nicel sonuçlar, önerilen yöntemin nesnel olarak literatürdeki diğer yöntemlerden daha başarılı olduğunu göstermektedir. Tabloda metrik sonuçları en iyi olan yöntemler kalın yapılırken ilgili yöntemin görüntü için sonucu olmadığında bu durum X ile temsil edilmektedir. Sonuç olarak kaynak görüntülerde yer alan kenar, köşe vb. bilgi ve detayların literatürdeki diğer yöntemlere göre daha fazla korunduğu kanıtlanmaktadır.

Ayrıca literatürde sıklıkla kullanılan bazı geleneksel görüntüler için de öznel değerlendirmeler yapılmıştır. Literatürde referans görüntü veri setlerini bulmak zor olduğundan, bu metriklere yönelik sonuçlar daha sınırlıdır. Bu tez çalışmasında, önerilen yöntem, Moushmi ve diğerleri [126] ile Li ve diğerleri [127] tarafından önerilen yöntemler ile Ortalama Kare Hatası (RMSE) ve PSNR subjektif metriği kullanılarak karşılaştırılmaktadır. Bu metrikler, kaynaşmış görüntünün ve veri setinden alınan referans görüntünün ne kadar benzer olduğunu ölçer. Diğer bir deyişle, kaynak görüntülerden önemli bilgilerin kaynaştırılmış görüntüye aktarılmasında önerilen yöntemin başarısını vermektedir.

Subjektif karşılaştırma için Book, Clock, Saras, Lab ve Flower görüntüleri kullanılmıştır. Moushmi ve ark. [126] önerdiği yöntem sonuçları verilirken Book, Clock ve Saras görüntüleri kullanılmış ve bu görüntüler için RMSE ve PSNR metrik sonuçları karşılaştırmaları Tablo 3.7 ile gösterilmektedir.

Tablo 3.7. Önerilen 2. çalışma ile Moushmi ve ark. çalışması subjektif metrikler ile karşılaştırma sonuçları

Görüntüler	Book		Clock		Saras	
Metrikler	RMSE	PSNR	RMSE	PSNR	RMSE	PSNR
Moushmi ve ark. [126]	7,04	31,17	4,51	35,04	2,85	39,03
Önerilen Çalışma	0,36	57,00	1,50	44,60	0,94	48,66

Ayrıca Li ve ark. [127] önerdiği yöntemin sonuçları verilirken Lab ve Flower görüntüleri kullanılmıştır. Bu görüntüler için RMSE ve PSNR metrik sonuçları kullanılarak önerilen yöntem ve Li ve ark. yöntemi için yapılan karşılaştırmalar Tablo 3.8 ile gösterilmektedir.

Tablo 3.8. Önerilen 2. çalışma ile Li ve ark. yöntemi subjektif metrikler ile karşılaştırma sonuçları


Görüntüler	Lab		Flower	
Metrikler	RMSE	PSNR	RMSE	PSNR
Li ve ark.[127]	4,65	34,78	7,84	30,24
Önerilen Çalışma	1,11	47,22	1,24	46,26

Sonuçlar incelendiğinde önerilen yöntemin subjektif olarak karşılaştırılan yöntemlere göre daha iyi sonuçlar verdiği ve kaynak görüntülerden önemli bilgileri birleştirilmiş görüntüye aktarmada daha başarılı olduğu söylenebilir.

3.4.3. Lytro Veri Seti İçin Görsel ve Sayısal Sonuçlar

Lytro veri seti [51] bu alanda kullanılan nadir renkli veri setlerinden biridir. Genellikle literatürdeki diğer yöntemlerde sıklıkla kullanılmaktadır. Bu veri seti, 520x520 boyutlarında 20 çift farklı görüntü içerir. Diğer veri setlerindeki görüntüler gibi bu görüntüler de birbirine zıttır ve tek bir karar haritası ile temsil edilebilir. Önerilen yöntem için görsel sonuçlar Şekil 3.35-3.42'da verilmiştir. Ayrıca önerilen yöntem bu veri seti kullanılarak literatürdeki 9 farklı yöntemle [41, 79, 81, 137-142] karşılaştırılmıştır. Referans görüntü Lytro veri setinde sağlanmadığı için karşılaştırma için objektif metrikler seçilmiştir. Bu metrikler, bir referans


görüntü kullanmadan yöntemin başarısını ölçer. Önerilen yöntemi literatürdeki yöntemlerle karşılaştırmak için Karşılıklı Bilgi(MI), Q_{CB} , Q_{AB}^F ve Standart Sapma(SD) objektif kalite metrikleri seçilmiştir. Bu metrikler, kaynak görüntülerden kaynaşmış görüntüye aktarım miktarını daha iyi belirleyebildikleri için literatürde sıklıkla tercih edilmektedir. Q_{CB} , Chen ve diğerleri tarafından önerilen kontrast duyarlılığına dayalı bir ölçümdür. Q_{AB}^F , kaynak görüntülerden kaynaşmış görüntüye aktarılan kenarları ölçer, piksel dağılımı STD kullanılarak hesaplanır ve kaynak görüntüler ile kaynaşmış görüntü arasındaki doğru veri aktarımı MI kullanılarak hesaplanır. Tüm bu metriklerin temel amacı, kaynak görüntülerin kaynaşmış görüntüdeki temsil başarısını ölçmektir.



Şekil 3.35. Çoklu-odaklı Lytro-14 görüntüsü: (a) Kaynak görüntü 1 (520x520), (b) Kaynak görüntü 2 (520x520), (c) Kaynak görüntü 1 için nihai karar haritası (520x520), (d) Kaynak görüntü 2 için nihai karar haritası (520x520), (e) Tüm-odaklı görüntü (520x520)


Şekil 3.35, Lytro veri setindeki Lytro 14 görüntüsünün sonuçlarını içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak değerlerine sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve son olarak (e) görüntüsü, önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü verir.

Bu çalışmada, her bir kaynak görüntü için bir karar haritası oluşturularak başarının artırılmasına çalışılmaktadır.




Şekil 3.36. Çoklu-odaklı Lytro-13 görüntüsü: (a) Kaynak görüntü 1 (520x520), (b) Kaynak görüntü 2 (520x520), (c) Kaynak görüntü 1 için nihai karar haritası (520x520), (d) Kaynak görüntü 2 için nihai karar haritası (520x520), (e) Tüm-odaklı görüntü (520x520)

Şekil 3.36, Lytro veri setindeki Lytro 13 görüntüsünün sonuçlarını içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak değerlerine sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve son olarak (e) görüntüsü, önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü verir.




Şekil 3.37. Çoklu-odaklı Lytro-12 görüntüsü: (a) Kaynak görüntü 1 (520x520), (b) Kaynak görüntü 2 (520x520), (c) Kaynak görüntü 1 için nihai karar haritası (520x520), (d) Kaynak görüntü 2 için nihai karar haritası (520x520), (e) Tüm-odaklı görüntü (520x520)

Şekil 3.37, Lytro veri setindeki Lytro 12 görüntüsünün sonuçlarını içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak değerlerine sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve son olarak (e) görüntüsü, önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü verir.




Şekil 3.38. Çoklu-odaklı Lytro-11 görüntüsü: (a) Kaynak görüntü 1 (520x520), (b) Kaynak görüntü 2 (520x520), (c) Kaynak görüntü 1 için nihai karar haritası (520x520), (d) Kaynak görüntü 2 için nihai karar haritası (520x520), (e) Tüm-odaklı görüntü (520x520)

Şekil 3.38, Lytro veri setindeki Lytro 11 görüntüsünün sonuçlarını içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak değerlerine sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve son olarak (e) görüntüsü, önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü verir.




Şekil 3.39. Çoklu-odaklı Lytro-10 görüntüsü: (a) Kaynak görüntü 1 (520x520), (b) Kaynak görüntü 2 (520x520), (c) Kaynak görüntü 1 için nihai karar haritası (520x520), (d) Kaynak görüntü 2 için nihai karar haritası (520x520), (e) Tüm-odaklı görüntü (520x520)

Şekil 3.39, Lytro veri setindeki Lytro 10 görüntüsünün sonuçlarını içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak değerlerine sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve son olarak ϵ görüntüsü, önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü verir.




Şekil 3.40. Çoklu-odaklı Lytro-03 görüntüsü: (a) Kaynak görüntü 1 (520x520), (b) Kaynak görüntü 2 (520x520), (c) Kaynak görüntü 1 için nihai karar haritası (520x520), (d) Kaynak görüntü 2 için nihai karar haritası (520x520), (e) Tüm-odaklı görüntü (520x520)

Şekil 3.40, Lytro veri setindeki Lytro 03 görüntüsünün sonuçlarını içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak değerlerine sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve son olarak (e) görüntüsü, önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü verir.



Şekil 3.41. Çoklu-odaklı Lytro-01 görüntüsü: (a) Kaynak görüntü 1 (520x520), (b) Kaynak görüntü 2 (520x520), (c) Kaynak görüntü 1 için nihai karar haritası (520x520), (d) Kaynak görüntü 2 için nihai karar haritası (520x520), (e) Tüm-odaklı görüntü (520x520)

Şekil 3.41, Lytro veri setindeki Lytro 01 görüntüsünün sonuçlarını içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak değerlerine sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve son olarak (e) görüntüsü, önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü verir.



Şekil 3.42. Çoklu-odaklı Lytro-08 görüntüsü: (a) Kaynak görüntü 1 (520x520), (b) Kaynak görüntü 2 (520x520), (c) Kaynak görüntü 1 için nihai karar haritası (520x520), (d) Kaynak görüntü 2 için nihai karar haritası (520x520), (e) Tüm-odaklı görüntü (520x520)

Şekil 3.42, Lytro veri setindeki Lytro-08 görüntüsünün sonuçlarını içerir. (a-b) görüntüleri, birleştirme için kullanılacak farklı odak değerlerine sahip kaynak görüntüleri verir. (c-d) görüntüleri, önerilen yöntemden sonra oluşturulan nihai karar haritalarını ve son olarak (e) görüntüsü, önerilen yöntem kullanılarak oluşturulan birleştirilmiş görüntüyü verir.

Şekillerde görüldüğü gibi önerilen yöntem bu veri seti için görsel olarak iyi sonuçlar vermektedir. Yöntem genel olduğu için kaynak görüntü sayısı artsa bile sonuç üretebilmektedir. Tablo 3.9, bu veri seti için derin öğrenmeye dayalı 9 farklı yöntemle karşılaştırma sonuçlarını göstermektedir. Bunlar iki aşamalı öğrenme yöntemi [138], derin evrişimli sinir ağı tabanlı bir yöntem [81], genel çekişmeli ağ tabanlı bir yöntem [79], CNN tabanlı bir yöntem [41], seyrek temsil tabanlı bir yöntem [137] ve evrişimli sinir ağı tabanlı [138] bir yöntem, çoklu-ölçekli ayrıştırma ve seyrek temsil tabanlı bir yöntem [140], dörtlü ağaç tabanlı bir yöntem [141] ve sınır bulma tabanlı bir yöntemdir [142]. Bu çalışmada kullanılan metrikler, kaynak görüntülerden kaynaşmış görüntüye aktarılan verilerin hesaplanmasında sıklıkla tercih edilen metriklerdir. Bunlar Karşılıklı Bilgi (MI), Chen-Blum Metrik (Q_{CB}), Petrovic Metrik ($Q^{AB/F}$) ve Standart Sapmadır (SD). Bu metrikler, kaynak

görüntülerdeki önemli bilgilerin ne kadarının kaynaşmış görüntüye aktarıldığını gösterir. Metrik sonuçları ne kadar büyük olursa, yöntem o kadar başarılı sayılmaktadır.

Tablo 3.9. Önerilen 2. çalışma ile literatürdeki çalışmaların Lytro veri seti için objektif metrikler ile karşılaştırma sonuçları

Method		MI	Q_{CB}	$Q^{AB/F}$	SD
DCNN[81]	Mean	5.96	0.8084	0.76	57.46
	Variance	0.31	0.0014	8.43×10^{-4}	77.49
FusionGAN[79]	Mean	3.50	0.5088	0.37	48.35
	Variance	0.32	0.0016	7.76×10^{-3}	57.42
ECNN[41]	Mean	6.15	0.8072	0.75	57.51
	Variance	0.29	0.0014	9.27×10^{-4}	77.63
ASR[137]	Mean	4.91	0.7207	0.74	56.84
	Variance	0.60	0.0035	1.13×10^{-3}	77.31
IFCNN[138]	Mean	4.87	0.7292	0.7296	57.55
	Variance	0.45	0.0021	9.91×10^{-4}	76.01
TWOSTAGE[139]	Mean	6.12	0.8094	0.7621	57.57
	Variance	0.28	0.0013	7.38×10^{-4}	74.86
MST-SR[140]	Mean	5.15	0.7654	0.7483	57.42
	Variance	0.42	0.0019	1.17×10^{-3}	76.89
QB[141]	Mean	5.50	0.7827	0.7446	57.53
	Variance	0.41	0.0015	1.1×10^{-3}	77.80
BF[142]	Mean	6.07	0.8065	0.7583	57.29
	Variance	0.29	0.0015	9.60×10^{-4}	76.26
Proposed	Mean	9.55	0.8232	0.90	60.11
	Variance	0.22	0.0015	2×10^{-3}	55.04

Tablo 3.9’ da verilen yöntemler bu alanda yapılan son çalışmalardan oluşmaktadır. Kullanılan metrikler, yöntemlerin çoklu-odaklı görüntü Birleştirmende ne kadar başarılı olduğunu göstermektedir. Bu metrikler, kaynaşmış görüntü için kaynak görüntülerin temsil yeteneklerini ölçmektedir. Kaynak görüntülerde doğru bilgi ne kadar iyi temsil edilirse, yöntemlerin başarısı o kadar yüksek olur. Lytro veri setindeki 20 çift görüntü için sonuçlar

elde edilmiş olup, bu sonuçların ortalama ve varyans hesaplamaları Tablo 3.9’ da verilmiştir. Tabloda metrik sonuçları en iyi olan yöntemler koyu renklidir. Bu tabloya bakıldığında önerilen yöntemin literatürdeki yöntemlerden daha başarılı olduğu görülmektedir. Bu veri seti için önerilen yöntemin kaynak görüntülerdeki doğru bilgileri diğer yöntemlere göre kaynaştırılmış görüntüye daha iyi aktardığı söylenebilir.

3.4.4.Önerilen Çalışmanın Farklı Ağ Girişi Boyutları İçin Değerlendirme Sonuçları

Önerilen CNN mimarisi, küçük boyutlu görüntüleri odaklı veya odaksız olarak sınıflandırmak için tasarlanmıştır. Literatürde genellikle 32x32 görüntü yamalarının sınıflandırılmasına yönelik ağlar tasarlanmaktadır. Bu çalışmada ağın girdi boyutlarının yöntemin başarısına etkisini göstermek amacıyla 8x8, 16x16 ve 32x32 görüntü yamaları için ayrı ayrı metrik hesaplamaları yapılmıştır. Bu hesaplamalar literatürdeki popüler 8 farklı görüntü için yapılmıştır. Ayrıca ağ girdi boyutlarının etkisini göstermek amacıyla dört farklı objektif metrik kullanılmıştır. Bu metrikler MI, QAB/F, AG ve SD’dir. Seçilen metrikler kaynak görüntülerin birleştirilmiş görüntüdeki doğru temsil kabiliyetini ölçmektedir. Farklı ağ girdileri için sonuçlar Tablo 3.10’da verilmektedir.

Tablo 3.10. Önerilen 2. çalışmanın farklı ağ girişi boyutları için değerlendirme sonuçları

Görüntüler	Blok Boyutu	MI	$Q^{AB/F}$	AG	SD
Lytro-01	8x8	0,903205	10,35912	7,730566	39,48458
	16x16	0,89686	10,29273	7,653627	39,46563
	32x32	0,887234	10,19456	7,570189	39,30889
Lytro-02	8x8	0,902984	17,0263	8,2637	49,15829
	16x16	0,901265	16,60465	8,201348	49,16776
	32x32	0,897494	16,89742	8,163744	49,0993
Lytro-03	8x8	0,894873	13,67902	8,320296	48,52895
	16x16	0,887556	13,65723	8,255088	48,51957
	32x32	0,877365	13,637	8,146485	48,49874
Lytro-04	8x8	0,890401	18,24075	7,714704	59,52592
	16x16	0,887058	18,20859	7,685201	59,47716
	32x32	0,881699	18,11637	7,607571	59,43948
Lytro-05	8x8	0,827415	13,30719	8,500881	62,39922
	16x16	0,833336	13,26216	8,41539	61,94933
	32x32	0,824308	13,21147	8,374295	61,35692
Lytro-06	8x8	0,882186	18,39647	10,13042	68,50868
	16x16	0,847462	17,07328	9,106011	68,11129
	32x32	0,843871	17,71983	9,458361	68,28158
Source05-3	8x8	0,892908	11,52597	10,83436	37,91442
	16x16	0,862429	11,18195	10,80147	37,89315
	32x32	0,858602	11,43323	10,7538	37,8745
Source08-3	8x8	0,886239	12,19188	7,688848	46,71524
	16x16	0,882209	12,49967	7,656488	46,77591
	32x32	0,875973	12,23077	7,584373	46,6976

Tablo 3.10’da her bir görüntü için görüntü yama boyutlarının etkisi gösterilmektedir. Görüntü yamaları boyutu için alınan en iyi sonuçlar koyu ile belirtilmektedir. Tablo incelendiğinde daha küçük boyutlu ağ girdileri için yöntem daha başarılı sonuçlar

üretmektedir. Küçük boyutlu pencereler odaklı bölgelerden odaksız bölgelere geçişleri daha iyi tahmin edebildiğinden bu sonuçlar oluşmaktadır. Görüntü yamaları boyutları arttıkça geçiş bölgelerindeki alanların tespiti zorlaştığından yöntemlerin başarısı düşmektedir.

3.5. Tez Kapsamında Önerilen Çalışmaların Birbirleri ve Literatürdeki Çalışmalar ile Karşılaştırılması

Bu bölümde tez çalışması için önerilen yöntemlerin birbirleri ve literatürdeki diğer yöntemlerle olan karşılaştırma sonuçları verilecektir. Karşılaştırma yapılırken literatürde bulunan geleneksel veri setlerinden alınan görüntüler ve oluşturulan yeni veri setinde bulunan görüntüler kullanılmaktadır. Bu görüntüler kullanılarak objektif ve subjektif değerlendirmeler yapılmıştır.

İlk olarak metrik hesaplamasında referans görüntülere ihtiyaç duyan ve önerilen yöntemler sonrası oluşturulan birleştirilmiş görüntü ile referans görüntü arasındaki benzerliği ölçmede kullanılan subjektif metriklere dayalı karşılaştırmalar yapılmıştır. Literatürde yer alan veri setlerinde referans görüntüye ulaşmak zor olduğundan subjektif metrikler çok fazla tercih edilmemektedir. Tez çalışması için önerilen yöntemlerin subjektif olarak Moushmi ve ark [126], Li ve ark. [127] ve Aymaz ve ark. [116] yöntemleriyle karşılaştırma sonuçları Tablo 3.11’de verilmektedir.

Tablo 3.11. Önerilen yaklaşımların birbirleri ve literatürdeki yaklaşımlar ile subjektif metrikler kullanılarak karşılaştırma sonuçları

Yöntemler	Book Görüntüsü		Clock Görüntüsü		Lab Görüntüsü		Flower Görüntüsü		Saras Görüntüsü	
	RMSE	PSNR	RMSE	PSNR	RMSE	PSNR	RMSE	PSNR	RMSE	PSNR
Moushmi ve ark. [126]	7,04	31.17	4,51	35.04	X	X	X	X	2,85	39.03
Li ve ark. [127]	X	X	X	X	4,65	34.78	7,84	30.24	X	X
Aymaz ve ark. [116]	5,28	33.67	0.95	48.57	2,92	38.82	4,99	34.16	2,76	39.31
SR-2 ile Önerilen Yaklaşım	4,53	35,00	1,22	46.40	2,01	42.06	2,46	40.31	2,73	39.40
SR-3 ile Önerilen Yaklaşım	2,38	40.6	0.98	48.30	1,94	42.37	2,17	41.40	1,90	42.55
SR-4 ile Önerilen Yaklaşım	1,91	42.51	0.87	49.34	1,96	42.28	2,54	39.93	1,54	44.38
Önerilen 2. Yaklaşım	0.36	57,00	1,50	44.60	1,11	47.22	1,24	46.26	0.94	48.66

Tablo 3.11’ de subjektif metriklerden RMSE ve PSNR metrikleri, literatürde sıklıkla kullanılan Book, Clock, Lab, Flower ve Saras görüntüleri için hesaplanmaktadır. Tez çalışması için önerilen birinci yöntemin sonuçları üç farklı süper çözünürlük katsayısı için ayrı ayrı verilmektedir. Tablo incelendiğinde tez çalışmasında önerilen yöntemlerin diğer yöntemlere göre daha başarılı olduğu görülmektedir. Ayrıca tez çalışması için önerilen iki yöntem birbirleriyle kıyaslandığında öğrenmeye dayalı olan ikinci yöntemin birinci yöntemle göre daha başarılı olduğu görülmektedir. Öğrenmeye dayalı Çoklu-odaklı görüntü birleştirme yöntemleri odaklı alanlardaki piksel parlaklık değerlerini belirli bir oranda değil de doğrudan birleştirmiş görüntüye aktardığından, başarılı sınıflandırma yapabilen öğrenmeye dayalı yöntemler uzamsal ve dönüşüm tabanlı yöntemlere göre daha detaylı birleştirilmiş görüntüler oluşturabilmektedir.

Subjektif değerlendirmelerin yanında tez çalışmasında önerilen çalışmalar için objektif değerlendirmeler de yapılmaktadır. Objektif değerlendirmeler kaynak görüntülerin doğru odak bilgisinin birleştirilmiş görüntüde ne kadar temsil edildiğini ölçmektedir. Literatürde objektif değerlendirmeler yapılırken MI ve QAB/F metrikleri sıklıkla kullanılmaktadır. Bu nedenle yapılan değerlendirmeler bu metrikler kullanılarak

yapılmaktadır. MI metriği, kaynak görüntülerdeki doğru bilgilerin birleştirilmiş görüntüdeki temsilini, QAB/F metriği ise kaynak görüntülerdeki önemli bilgilerin (kenar, köşe vb.) ne kadarının korunduğunu ölçmektedir. Bu bölümde geleneksel veri setlerinden alınan Clock, Lab ve Disk görüntüleri için önerilen yöntemler ve literatürdeki yöntemler arasındaki objektif karşılaştırma sonuçları verilecektir.

Clock görüntüsü için karşılaştırma sonuçları Tablo 3.12’ de verilmektedir. Tabloda önerilen çalışmalar ve literatürdeki 6 farklı yöntem için sonuçlar yer almaktadır. Önerilen birinci çalışma için sonuçlar üç farklı süper çözünürlük katsayısı için verilmektedir. Tablo incelendiğinde önerilen birinci çalışmanın 4 süper çözünürlük katsayısı için QAB/F metriğinde en yüksek değeri verdiği, önerilen ikinci çalışmanın ise MI metriği için en yüksek değeri verdiği görülmektedir. Bu nedenle önerilen çalışmaların birleştirilmiş görüntü oluşturmada daha iyi olduğu ifade edilebilmektedir.

Tablo 3.12. Clock görüntüsü için önerilen yaklaşımların birbirleri ve literatürdeki yaklaşımlar ile objektif metrikler kullanılarak karşılaştırma sonuçları

Yöntemler	Clock Görüntüsü	
	MI	$Q^{AB/F}$
Yin ve ark. [3]	5,49	0,71
Nejati ve ark. [124]	8,58	0,72
Jiang ve ark. [119]	8,38	0,71
Hua ve ark. [120]	8,29	0,73
Liu ve ark. [134]	8,58	0,73
Li ve ark. [135]	9,07	0,75
SR-2 ile Önerilen 1. Yaklaşım	10,7	0,87
SR-3 ile Önerilen 1. Yaklaşım	11,69	0,88
SR-4 ile Önerilen 1. Yaklaşım	11,7	0,89
Önerilen 2. Yaklaşım	14,18	0,88

Bir diğer karşılaştırma Lab görüntüsü için yapılmaktadır. Lab görüntüsü için önerilen yöntemler ve literatürdeki yedi yöntem için objektif metrik sonuçları Tablo 3.13’ de verilmektedir. Tablo incelendiğinde, önerilen ikinci çalışmanın bu görüntü için daha başarılı sonuçlar verdiği görülmektedir.

Tablo 3.13. Lab görüntüsü için önerilen yaklaşımların birbirleri ve literatürdeki yaklaşımlar ile objektif metrikler kullanılarak karşılaştırma sonuçları

Yöntemler	Lab Görüntüsü	
	MI	$Q^{AB/F}$
Nejati ve ark. [124]	8,7	0,74
Chen ve ark. [117]	8,1	0,73
Hua ve ark. [120]	8,5	0,74
Wen ve ark. [131]	8,69	0,76
Du ve ark. [128]	8,83	0,75
Liu ve ark. [134]	8,58	0,77
Li ve ark. [135]	8,86	0,76
SR-2 ile Önerilen 1. Yaklaşım	10,89	0,88
SR-3 ile Önerilen 1. Yaklaşım	12,41	0,89
SR-4 ile Önerilen 1. Yaklaşım	13,1	0,9
Önerilen 2. Yaklaşım	14,95	0,91

Son olarak Disk görüntüsü için objektif değerlendirmeler yapılmaktadır. Bu görüntü için önerilen çalışmalar ve literatürdeki 8 farklı yöntem için objektif metrik ölçümleri yapılmıştır. Tablo 3.14 incelendiğinde önerilen ikinci çalışmanın bu görüntüyü birleştirmede daha başarılı sonuçlar verdiği görülmektedir.

Tablo 3.14. Disk görüntüsü için önerilen yaklaşımların birbirleri ve literatürdeki yaklaşımlar ile objektif metrikler kullanılarak karşılaştırma sonuçları

Yöntemler	Disk Görüntüsü	
	MI	$Q^{AB/F}$
Nejati ve ark. [124]	8,29	0,73
Chen ve ark. [117]	7,66	0,71
He ve ark. [129]	7,88	0,73
Hua ve ark. [120]	8	0,73
Wen ve ark. [131]	8,4	0,74
Yang ve ark. [132]	7,04	0,69
Liu ve ark. [134]	8,17	0,73
Li ve ark. [135]	8,5	0,72
SR-2 ile Önerilen 1. Yaklaşım	8,74	0,87
SR-3 ile Önerilen 1. Yaklaşım	9,21	0,88
SR-4 ile Önerilen 1. Yaklaşım	9,65	0,89
Önerilen 2. Yaklaşım	12,36	0,9

Literatürdeki çalışmalar iki kaynak görüntüyü birleştirmeye odaklanmaktadır. Bu nedenle bu çalışmalarda sadece iki kaynak görüntüyü birleştirmedeki başarılar ölçülmektedir. Fakat gerçekte odaklı veya odaksız parçalar içeren görüntü setleri ikiden fazla kaynak görüntü içerebilir. Bu durum literatürdeki bir eksiklik olarak görülebilir. Tüm bunlar göz önüne alınarak önerilen çalışmalarda ikiden fazla kaynak görüntü içeren yeni veri setleri oluşturulmuştur. Birinci çalışmada oluşturulan veri seti gri görüntülerden oluşurken, ikinci çalışma için üretilen veri seti renkli görüntülerden oluşmaktadır. Bu bölümde oluşturulan yeni veri seti için, önerilen çalışmaların karşılaştırma sonuçları verilmektedir. Önerilen veri setinden alınan dört farklı görüntü için MI, QAB/F ve SD metriklerine ait sonuçlar Tablo 3.15 ile verilmektedir. Tablo incelendiğinde önerilen ikinci çalışmanın ikiden fazla görüntüyü birleştirmede daha başarılı olduğu görülmektedir. Dolayısıyla ikinci çalışma sonrası oluşturulan birleştirilmiş görüntünün birinci çalışmaya oranla kaynak görüntülerin önemli bilgilerini korumada daha başarılı olduğu söylenebilir.

Tablo 3.15. Önerilen yaklaşımların ikiden fazla görüntüyü birleştirmede performans karşılaştırma sonuçları

Görüntüler	Yöntemler	MI	QABF	SD
Astronaut	Sr 2 ile Önerilen 1. Yaklaşım	18,39	0,91	86,22
	Sr 3 ile Önerilen 1. Yaklaşım	19,9	0,91	84,79
	Sr 4 ile Önerilen 1. Yaklaşım	21,9	0,92	84,08
	Önerilen 2. Yaklaşım	22,96	0,9455	88,01
Truck	Sr 2 ile Önerilen 1. Yaklaşım	8,9	0,96	63,32
	Sr 3 ile Önerilen 1. Yaklaşım	13,38	0,96	61,72
	Sr 4 ile Önerilen 1. Yaklaşım	15,44	0,97	60,99
	Önerilen 2. Yaklaşım	20,52	0,9838	69,78
Lake	Sr 2 ile Önerilen 1. Yaklaşım	15,99	0,93	67,33
	Sr 3 ile Önerilen 1. Yaklaşım	19,82	0,93	65,47
	Sr 4 ile Önerilen 1. Yaklaşım	21,9	0,94	64,67
	Önerilen 2. Yaklaşım	27,34	0,9587	65,52
Livingroom	Sr 2 ile Önerilen 1. Yaklaşım	13,66	0,94	61,24
	Sr 3 ile Önerilen 1. Yaklaşım	17,84	0,96	60,04
	Sr 4 ile Önerilen 1. Yaklaşım	19,83	0,96	59,22
	Önerilen 2. Yaklaşım	27,37	0,9873	64,18

Sonuç olarak, önerilen çalışmaların objektif ve subjektif değerlendirmelerine bakıldığında literatürdeki diğer yöntemlere göre daha başarılı olduğu görülmektedir. Her iki metrik grubu da birleştirilmiş görüntünün ne kadar iyi oluşturulduğunu ölçmek için kullanılmaktadır. Dolayısıyla önerilen çalışmaların detaylı birleştirilmiş görüntü oluşturmada oldukça başarılı olduğu söylenebilir. Ayrıca önerilen birinci ve ikinci çalışma genel olarak incelendiğinde öğrenmeye dayalı olan ikinci çalışmanın birinci çalışmaya göre hem iki kaynak görüntüyü birleştirmede hem de ikiden fazla kaynak görüntüyü birleştirmede daha başarılı olduğu görülmektedir. Öğrenmeye dayalı yöntemlerde odaklı piksel bilgisi doğrudan birleştirilmiş görüntüye aktarılırken, diğer yöntemlerde odaklı piksel bilgisi belirli bir oranla birleştirilmiş görüntüye aktarılmaktadır. Bu durum öğrenmeye dayalı yöntemlerin başarısını olumlu yönde etkilemektedir.

4. SONUÇLAR VE TARTIŞMA

Çoklu-odaklı görüntü birleştirme, görüntüleme cihazlarının sınırlı derinlikteki nesnelere odaklanmasından kaynaklanan problemleri ortadan kaldırmak amacıyla kullanılmaktadır. Görüntüleme cihazlarındaki bu eksiklikten dolayı, kaynak görüntülerde bazı nesneler odaklı olurken bazı nesneler odaksız olmaktadır. Bu durum görüntülerin anlaşılabilirliğini olumsuz yönde etkilemektedir. Çoklu-odaklı görüntü birleştirme yöntemleri, aynı sahneye ait iki veya daha fazla odaksız nesne içeren görüntünün birleştirilerek tüm-odaklı detaylı, anlaşılır bir birleştirilmiş görüntü oluşturulmasını amaçlamaktadır. Bu amacı gerçekleştirirken kaynak görüntülerdeki odak bilgisinin birleştirilmiş görüntüye en doğru şekilde aktarılması ve kaynak görüntülerdeki kenar, köşe vb. gibi önemli noktaların maksimum seviyede birleştirilmiş görüntüye aktarılması kullanılan yöntemlerin ana amacıdır. Bu tez çalışmasında, bu amaçlara uygun olarak iki farklı yaklaşım önerilmektedir.

Önerilen ilk çalışma, bu alanda yenilikler içeren hibrit bir çalışmadır. Literatürdeki yöntemler, veri setlerinin sığ olmasından dolayı sadece iki kaynak görüntü için birleştirme yapmaktadır, fakat günlük hayatta bulanıklık içeren görüntü sayısı ikiden fazla olabilmektedir. Bu nedenle bu çalışmada ikiden fazla gri seviye kaynak görüntü içeren yeni bir veri seti önerilerek literatürdeki bu boşluk doldurulmuştur. Önerilen çalışmada, bu alanda ilk kez kullanılan bikübik-tabanlı süper-çözünürlük yöntemi yardımıyla kaynak görüntülerdeki detay bilgileri artırılmıştır. Bu ön işlem sayesinde birleştirilmiş görüntüye aktarılan doğru bilgi miktarı da artmış olmaktadır. Daha sonra süper-çözünürlüklü kaynak görüntülerin daha detaylı analizi için görüntüler Sabit Dalgacık Dönüşümü ile detay ve yaklaşım frekans bileşenlerine ayrılmıştır. Çoklu-odaklı görüntü birleştirme yöntemlerinin en önemli aşaması kaynak görüntülerdeki bilgilerin birleştirilmiş görüntüdeki temsil oranını belirleyen birleştirme kurallarıdır. Bu çalışmada gradyan-tabanlı özgün bir birleştirme kuralı tasarlanmış ve gradyan operatörünün özellikleri sayesinde detaylı birleştirme edilmiş frekans bileşenleri oluşturulmuştur. Sonuç olarak yapılan objektif ve subjektif değerlendirmelerle de önerilen yaklaşımın hem iki kaynak görüntüyü hem de ikiden fazla kaynak görüntüyü birleştirmede oldukça başarılı olduğu görülmektedir.

Tez çalışmasında önerilen diğer yaklaşım öğrenmeye dayalı olan ve yöntem adımlarında literatürdeki açıklıkları gidermek için iyileştirmeler içeren yenilikçi bir yaklaşımdır. Bu çalışmada önerilen birinci çalışmadaki veri setini zenginleştirecek ikiden

fazla renkli kaynak görüntü içeren yeni bir veri seti hazırlanmıştır. Önerilen yaklaşımda, kaynak görüntülerden çıkarılan 8x8 örtüşen yamaları odaklı veya odaksız olarak sınıflandırabilecek yeni bir ağ tasarlanmıştır. Bu ağ yapısı çok küçük görüntü parçalarını bile sınıflandırabilecek şekilde tasarlanmıştır. Kaynak görüntülerden çıkarılan görüntü yamaları ayrı ayrı önerilen ağa verilmiş ve bu ağın sınıflandırma sonuçları ilk karar haritalarına iletilmiştir. İlk karar haritalarında, görüntü boyutlarının küçük olmasından dolayı önerilen ağın karar veremediği (ilgili görüntü yamalarının tamamının odaklı veya odaksız olması) durumlarda literatürde ilk kez kullanılan odak metriklerine dayalı yeni bir iyileştirme mekanizması kullanılarak ilk karar haritaları iyileştirilmiştir. İyileştirilen karar haritalarında kalan bozulmalar ise morfolojik işlemlerle onarılarak son karar haritaları elde edilmiştir. Önerilen yaklaşımda literatürden farklı olarak her bir kaynak görüntü için karar haritaları oluşturulduğundan daha esnek birleştirme kuralları uygulanabilmekte bu da ikiden fazla kaynak görüntünün kolaylıkla birleştirilmesine olanak sağlamaktadır. Bu çalışmada tasarlanan dinamik birleştirme kuralı ile kaynak görüntüler birleştirilmiş ve tüm-odaklı detaylı bir birleştirilmiş görüntü oluşturulmuştur. Önerilen çalışma için yapılan değerlendirmelere bakıldığında, bu yaklaşımın çoklu-odaklı görüntü birleştirme amaçlarına diğer yöntemlerden daha uygun olduğu görülmektedir.

Ayrıca tez çalışmasında önerilen iki yaklaşım birbirleri ile de karşılaştırılmıştır. Yapılan karşılaştırmalarda öğrenmeye dayalı olarak oluşturulan ikinci yaklaşımın birinci yaklaşımdan daha başarılı olduğu performans ölçüm metrikleriyle kanıtlanmıştır. Uzamsal veya dönüşüm alan tekniklerine dayalı olan birinci yaklaşımda odak bilgisi, belirli bir katsayı ile birleştirilmiş görüntüye aktarılmaktadır. Kullanılan katsayıların doğru olarak belirlenmesi birinci yaklaşımdaki sınırlamadır. Öğrenmeye dayalı olan ikinci yaklaşımda ise odak bilgisi doğrudan birleştirilmiş görüntüye aktarıldığından kaynak görüntülerdeki odak bilgisi daha doğru belirlenmiş olur. Odaklı alanlardan odaksız alanlara geçiş bölgeleri, yöntemlerin genellikle hatalı kararlar verdikleri bölgelerdir. Önerilen ikinci çalışmada birinci çalışmanın aksine bu geçiş bölgeleri CNN mimarisi ve önerilen iyileştirme mekanizması kullanılarak doğru olarak tespit edilmektedir. Tüm bu farklılıklar ikinci yaklaşım ile yapılan çoklu-odaklı görüntü birleştirmenin daha başarılı sonuçlar vermesini sağlamaktadır.

Sonuç olarak, önerilen yaklaşımların literatüre yenilikler kazandırdığı ve iki veya ikiden fazla kaynak görüntüyü birleştirmede başarılı olduğu yapılan değerlendirmelerle kanıtlanmaktadır.

5. ÖNERİLER

Tez çalışmasında, iki veya ikiden fazla kaynak görüntüyü kusursuza yakın şekilde birleştirebilen iki farklı yaklaşım önerilmiştir. Önerilen birinci yaklaşım süper-çözünürlük yöntemi uygulanmış kaynak görüntülerin, önerilen füzyon kuralı ile birleştirilmesine dayanmaktadır. Önerilen ikinci yaklaşım ise derin öğrenmeye dayalı ve temel görüntü birleştirme adımlarında yenilikler içeren bir yaklaşımdır. Bu bölümde, bu yaklaşımlara ek olarak gelecek çalışmalarda yapılabilecek iyileştirmeler aktarılacaktır.

Çoklu-odaklı görüntü birleştirme yöntemlerinde kullanılabilecek veri setleri sığ ve sayıca çok azdır. Tez kapsamında önerilen yaklaşımlarda literatüre katkı sağlayabilecek yenilikçi zengin veri setleri oluşturulmaktadır. Oluşturulan veri setleri ve literatürdeki veri setlerinin ortak bir yönü bulanıklaştırma ile görüntülerin oluşturulmasıdır. Literatürde kaynak görüntülere eklenebilecek gürültü bozulmalarının çoklu-odaklı görüntü birleştirme yöntemlerinin başarılarına etkisi ile ilgili bir çalışma bulunmamaktadır. Literatürdeki bu eksikliği gidermek için bulanıklaştırmanın yanı sıra farklı gürültüler de içeren kaynak görüntüler kullanılarak yeni veri setleri oluşturulabilir.

Tez çalışmasında önerilen birinci yaklaşımda, kaynak görüntülerin detaylarının arttırılabilmesi amacıyla süper-çözünürlük ön işlemi uygulanmıştır. Uygulanan ön işlemin sonuçlara etkisinin pozitif yönde olduğu görülmüştür. Literatürde, kaynak görüntülere ön işlem uygulanması konusu göz ardı edilmektedir. Uygulanan ön işlemin pozitif katkısı, sonraki çoklu-odaklı görüntü birleştirme yöntemlerinde de farklı ön işlemlerin getirebileceği katkıların araştırılmasına örnek teşkil edecektir.

Tez çalışmasında önerilen ikinci yaklaşımda görüntülerdeki odaklı veya odaksız bölgeleri sınıflandırabilecek yeni bir CNN mimarisi tasarlanmıştır. Tasarlanan mimarinin çoklu-odaklı görüntü birleştirme amaçlarını gerçekleştirmede oldukça başarılı olduğu görülmektedir. Gelecek çalışmalar için aynı veya farklı ağ yapıları için tasarlanan yeni ağ mimarilerinin çoklu-odaklı görüntü birleştirme alanına etkisi araştırılabilir.

Çoklu-odaklı görüntü birleştirme işlemlerinde yöntemin başarılı bir birleştirme yapması kadar işlemlerin gerçek zamanlı olması da bir o kadar önemlidir. Farklı yaklaşımlar kullanılarak çalışmaların gerçek-zamanlı olması sağlanabilir.

Performans ölçümü, yöntemlerin karşılaştırılabilmesi için büyük bir öneme sahiptir. Literatürdeki çalışmalar, performans ölçümü için belirli metriklere odaklanmaktadır. Bu

durum performans karşılaştırmalarında ölçüm yapılacak metriklerin sınırlanması demektir. Performans ölçüm metriklerinin çeşitlendirilmesi literatüre sağlanacak katkılar arasında yer almaktadır.



6. KAYNAKLAR

1. Du, C. ve Gao, S., Multi-focus image fusion algorithm based on pulse coupled neural network modified decision map, Optik, 157 (2018) 1003-1015.
2. Liu, C., Long, Y. ve Mao, J., Energy efficient multi-focus image fusion based on neighbour distance and morphology, Optik, 127 (2016) 11354-11363.
3. Yin, H., Li, Y., Chai, Y., Liu, Z. ve Zhu, Z., A novel sparse-representation-based multi-focus image fusion approach, Neurocomputing, 216 (2016) 216-229.
4. Liu, Y., Wang, Lei., Cheng, J., Li, C. ve Chen, X., Multi-focus image fusion: A survey of the state of the art, Information Fusion, 64 (2020) 71-91.
5. Thomas, C., Ranchin, T., Wald, L. ve Chanussot, J., Synthesis of multispectral images to high spatial resolution: A critical review of fusion methods based on remote sensing physics, IEEE Transactions on Geoscience and Remote Sensing, 46,5 (2008) 1301–1312.
6. Simone, G., Farina, A., Morabito, F., Serpico, S. ve Bruzzone, L., Image fusion techniques for remote sensing applications, Information Fusion, 3,1 (2002) 3–15.
7. Li, S., Kang, X., Fang, L., Hu, J. ve Yin, H., Pixel-level image fusion: a survey of the state of the art, Information Fusion, 33 (2017) 100–112.
8. Heijmans, H. ve Goutsias, J., Nonlinear multiresolution signal decomposition schemes, II. Morphological wavelets, IEEE Transactions on Image Processing, 9,11 (2000) 1897–1913.
9. Zhou, F., Li, X., Li, J., Wang, R. ve Tan, H., Multifocus image fusion based on fast guided filter and focus pixels detection, IEEE Access, 7 (2019) 50780–50796.
10. Li, S., Kang, X., Fang, L., Hu, J. ve Yin, H., Pixel-level image fusion: A survey of the state of the art, Information Fusion, 33 (2017) 100-112.
11. Burt, P., J. ve Adelson, E., H., Merging images through pattern decomposition, Applications of Digital Image Processing VIII, 0575 (1985) 173–181.
12. Burt, P. ve Adelson, E., The Laplas pyramid as a compact image code, IEEE Transactions on Communications, 31,4 (1983) 532–540.
13. Burt, P., J. ve Kolcznski, R., J., Enhanced image capture through fusion, (4th) International Conference on Computer Vision (ICCV), Haziran 1993, Berlin, Germany, Bildiriler Kitabı, 173–182.
14. Bogoni, L. ve Hansen, M., Pattern-selective color image fusion, Pattern Recognition, 34 (2001) 1515–1526.

15. Petrovic, V. ve Xydeas, C., Gradient-based multiresolution image fusion, IEEE Transactions on Image Processing, 13,2 (2004) 228–237.
16. Yang, B., Li, S. ve Sun, F., Image fusion using nonsubsampling contourlet transform, Fourth International Conference on Image and Graphics (ICIG), Ağustos 2007, Chengdu, China, Bildiriler Kitabı, 719–724.
17. Qu, X., Yan, J., Xiao, H. ve Zhu, Z., Image fusion algorithm based on spatial frequency–motivated pulse coupled neural networks in nonsubsampling contourlet transform domain, Acta Automatic Sinica, 34,12 (2008) 1508–1514.
18. Yang, B. ve Li, S., Multifocus image fusion and restoration with sparse representation, IEEE Transactions on Instrumentation and Measurement, 59,4 (2010) 884–892.
19. Chen, L., Li, J. ve Chen, C., Regional multifocus image fusion using sparse representation, Optics Express, 21,4 (2013) 5182–5197.
20. Li, S., Kwok, J. ve Wang, Y., Combination of images with diverse focuses using the spatial frequency, Information Fusion, 2,3 (2001) 169–176.
21. Huang, W. ve Jing, Z., Evaluation of focus measures in multi-focus image fusion, Pattern Recognition Letters, 28,4 (2007) 493–500.
22. Li, M., Cai, W. ve Tan, Z., A region-based multi-sensor image fusion scheme using pulse–coupled neural network, Pattern Recognition Letters, 27,16 (2006) 1948–1956.
23. Li, S. ve Yang, B., Multifocus image fusion using region segmentation and spatial frequency, Image and Vision Computing, 26,7 (2008) 971–979.
24. Hao, X., Zhao, H. ve Liu, J., Multifocus color image sequence fusion based on mean shift segmentation, Applied Optics, 54,30 (2015) 8982–8989.
25. Yang, B. ve Li, S., Multi-focus image fusion based on spatial frequency and morphological operators, Chinese Optics Letters, 5,8 (2007) 452–453.
26. Liu, Y., Jin, J., Wang, Q., Shen, Y. ve Dong, X., Novel focus region detection method for multifocus image fusion using quaternion wavelet, Journal of Electronic Imaging, 22,2 (2013) 23017.
27. Liu, Y., Jin, J., Wang, Q., Shen, Y. ve Dong, X., Region level based multi-focus image fusion using quaternion wavelet and normalized cut, Signal Processing, 97 (2014) 9–30.
28. Wang, H., Multi-focus image fusion algorithm based on focus detection in spatial and NSCT domain, PLoS One, 13,9 (2018) e0204225.
29. Li, H., Qiu, H., Yu, Z. ve Li, B., Multifocus image fusion via fixed window technique of multiscale images and non-local means filtering, Signal Processing, 138 (2017) 71–85.

30. Bouzos, O., Andreadis, I. ve Mitianoudis, N., Conditional random field model for robust multi-focus image fusion, IEEE Transactions on Image Processing, 28,11 (2019) 5636–5648.
31. Nejati, M., Samavi, S. ve Shirani, S., Multi-focus image fusion using dictionary-based sparse representation, Information Fusion, 25,1 (2015) 72–84.
32. Yan, X., Qin, H. ve Li, J., Multi-focus image fusion based on dictionary learning with rolling guidance filter, Journal of the Optical Society of America A: Optics, Image Science, and Vision, 34,3 (2017) 432–440.
33. Zhang, Q., Shi, T., Wan, F., Blum, R., S. ve Han, J., Robust sparse representation based multi-focus image fusion with dictionary construction and local spatial consistency, Pattern Recognition, 83 (2018) 299–313.
34. Li, Q., Yang, X., Wu, W., Liu, K. ve Jeon, G., Multi-focus image fusion method for vision sensor systems via dictionary learning with guided filter, Sensors, 18,7 (2018) 2143.
35. Yang, Y., Yang, M., Huang, S., Ding, M. ve Sun, J., Robust sparse representation combined with adaptive pcnn for multifocus image fusion, IEEE Access, 6 (2018) 20138–20151.
36. Li, H., Chai, Y. ve Li, Z., A new fusion scheme for multifocus images based on focused pixels detection, Machine Vision and Applications, 24,6 (2013) 1167–1181.
37. Yang, Y., Tong, S., Huang, S. ve Lin, P., Dual-tree complex wavelet transform and image block residual-based multi-focus image fusion in visual sensor networks, Sensors, 14,12 (2014) 22408–22430.
38. Yang, Y., Tong, S., Huang, S. ve Lin, P., Multifocus image fusion based on nsct and focused area detection, IEEE Sensors Journal, 15,5 (2015) 2824–2838.
39. Zhang, B., Lu, X., Pei, H., Liu, H., Zhao, Y. ve Zhou, W., Multi-focus image fusion algorithm based on focused region extraction, Neurocomputing, 174 (2016) 733–748.
40. Liu, Y., Chen, X., Peng, H. ve Wang, Z., Multi-focus image fusion with a deep convolutional neural network, Information Fusion, 36 (2017) 191–207.
41. Amin-Naji, M., Aghagolzadeh, A. ve Ezoji, M., Ensemble of cnn for multi-focus image fusion, Information Fusion, 51 (2019) 201–214.
42. Yang, Y., Nie, Z., Huang, S., Lin, P. ve Wu, J., Multilevel features convolutional neural network for multifocus image fusion, IEEE Transactions on Computational Imaging, 5,2 (2019) 262–273.
43. Tang, H., Xiao, B., Li, W. ve Wang, G., Pixel convolutional neural network for multi-focus image fusion, Information Sciences, 433-434 (2018) 125–141.

44. Mao, X., Li, Q., Xie, H., Lau, R., Wang, Z. ve Smolley, S., Least squares generative adversarial networks, IEEE International Conference on Computer Vision (ICCV), Nisan 2017, Venice, Italy, Bildiriler Kitabı, 2794-2802.
45. Xu, K., Qin, Z., Wang, G., Zhang, H., Huang, K. ve Ye, S., Multi-focus image fusion using fully convolutional two-stream network for visual sensors, KSII Transactions on Internet and Information Systems, 12,5 (2018) 2253–2272.
46. Zhao, W., Wang, D. ve Lu, H., Multi-focus image fusion with a natural enhancement via a joint multi-level deeply supervised convolutional neural network, IEEE Transactions on Circuits and Systems for Video Technology, 29,4 (2019) 1102–1115.
47. Li, H., Nie, R., Cao, J., Guo, X., Zhou, D. ve He, K., Multi-focus image fusion using u-shaped networks with a hybrid objective, IEEE Sensors Journal, 19,21 (2019) 9755–9765.
48. Lai, R., Li, Y., Guan, J. ve Xiong, A., Multi-scale visual attention deep convolutional neural network for multi-focus image fusion, IEEE Access, 7 (2019) 114385–114399.
49. Li, J., Guo, X., Lu, G., Zhang, B., Xu, Y., Wu, F. ve Zhang, D., Drpl: deep regression pair learning for multi-focus image fusion, IEEE Transactions on Image Processing, 29 (2020) 4816–4831.
50. Li, J., Yuan, G. ve Fan, H., Multifocus image fusion using wavelet-domain-based deep cnn, Computational Intelligence and Neuroscience, 2019 (2019) 1-23.
51. Nejati, M., Samavi, S. ve Shirani, S., Multi-focus image fusion dataset, <http://mansournejati.ece.iut.ac.ir/content/lytro-multi-focus-dataset>, 10 Nisan 2018.
52. Prasad, D., Multi-focus image fusion dataset, <https://drive.google.com/drive/folders/0BzXT0LnoyRqlRDJRZ0VnUG9pUk0?resourcekey=0-Ofj0Njyzo4muONUHdedSqA>, 10 Nisan 2018.
53. <http://www.owl.net.rice.edu/~elec539/Projects99/BACH/proj2/Wiener.html>, Wiener Filtering, 12 Ekim 2018.
54. Ni, K., S. ve Nguyen, T., Q., Image Superresolution Using Support Vector Regression, IEEE Transactions on Image Processing, 16,6 (2007) 1596-1610.
55. Zhao, J., Hu, H. ve Cao, F., Image Super-Resolution via Adaptive Sparse Representation, Knowledge-Based Systems, 124 (2017), 23-33.
56. Shinde, A. ve Ruikar, S., Nearest Neighbor and Interpolation Based Super-Resolution, International Journal of Control Theory and Applications, 10 (2017) 745-753.
57. Gupta, C. ve Gupta, P., A Study and Evaluation of Transform Domain based Image Fusion Techniques for Visual Sensor Networks, International Journal of Computer Applications, 116 (2015) 26-30.

58. Zheng, Y., ed., Image Fusion and Its Applications, BoD–Books on Demand, 2011.
59. Sharma, M. ve Khandelwal, S., Image Fusion on Coloured and Gray Scale Multi Focus Images by Using Hybrid DWT-DCT, International Journal of Computer Applications, 152,9 (2016) 30-34.
60. Kaur, P. ve Sharma, R., A Study of Various Multi-Focus Image Fusion Techniques, International Journal of Computer Science and Mobile Computing, 4,6 (2015) 1139 – 1146.
61. Mertens, T., Kautz, J. ve Reeth, F., V., Exposure fusion, 15th Pacific Conference on Computer Graphics and Applications, Ekim 2007, Maui, HI, USA, Bildiriler Kitabı, 382–390.
62. Zhang, Z. ve Blum, R., S., A categorization of multiscale-decomposition-based image fusion schemes with a performance study for a digital camera application, Proceedings of the IEEE, 87,8 (1999) 1315–1326.
63. Ben Hamza, A., He, Y., Krim, H. ve Willsky, A., A multiscale approach to pixel-level image fusion, Integrated Computer Aided Engineering, 12,2 (2005) 135–146.
64. Li, S., Kwok, J., T. ve Wang, Y., Using the discrete wavelet frame transform to merge landsat TM and SPOT panchromatic images, Information Fusion, 3,1 (2002) 17–23.
65. Krizhevsky, A., Sutskever, I. ve Hinton, G., E., ImageNet classification with deep convolutional neural networks, Advances in Neural Information Processing Systems, 25,2 (2012) 1097–1105.
66. Long, J., Shelhamer, E. ve Darrell, T., Fully convolutional networks for semantic segmentation, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Haziran 2015, Boston, MA, USA, Bildiriler Kitabı, 3431–3440.
67. Dong, C., Loy, C., He, K. ve Tang, X., Image super-resolution using deep convolutional networks, IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI), 38,2 (2016) 295–307.
68. Aymaz, S., Köse, C. ve Aymaz, Ş., Multi-focus image fusion for different datasets with super-resolution using gradient-based new fusion rule, Multimedia Tools and Applications, 79,20 (2020) 13311–13350.
69. Zhang, Y., Wei, W. ve Yuan, Y., Multi-focus image fusion with alternating guided filtering, Signal Image and Video Processing, 13 (2019) 727-735.
70. Zhou, Z., Li, S. ve Wang, B., Multi-scale weighted gradient-based fusion for multi-focus image fusion, Information Fusion, 26 (2014) 60-72.
71. Anbarjafari, G. ve Demirel, H., Image Super-resolution Based on Interpolation of Wavelet Domain High Frequency Subbands and the Spatial Domain Input Image, ETRI Journal, 32,3 (2010) 390-394.

72. Kannan, K., Perumal, S., A. ve Arulmozhi, K., Performance Comparison of Various Levels of Fusion of Multi-Focused Images Using Wavelet Transform, International Journal of Computer Applications, 1 (2010) 71-78.
73. Lu, J., Liu, H., P. ve Hsu, C., Y., Discrete Meyer Wavelet Transform Features For online Hangul Script Recognition, Research Journal of Applied Sciences, Engineering and Technology, 4,20 (2012) 3905-3910.
74. Vijitha, B. ve Reddy, K., S., Image Reconstruction with Super-Resolution, International Journal of Research in Computer Applications and Robotics, 4,9 (2016) 36-40.
75. Tuna, C., Unal, G. ve Sertel, E., Single-frame super resolution of remote-sensing images by convolutional neural network, International Journal of Remote Sensing, 39,28 (2018) 2463-2478.
76. Mirulanni, K. ve Geethalashmi, S., N., Enhanced Interpolation Method for Enlargement of Mammogram Images, International Conference on Advanced Computing and Communication Systems (ICACCS-2017), Ocak 2017, Coimbatore, India, Bildiriler Kitabı, 1-8.
77. Zhang, H., Xu, H., Tian, X., Jiang, J. ve Ma, J., Image fusion meets deep learning: A survey and perspective, Information Fusion, 76 (2021) 323-336.
78. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. ve Bengio, Y., Generative Adversarial Nets, In Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2 (NIPS'14), Aralık 2014, Cambridge, MA, USA, Bildiriler Kitabı, 2672–2680.
79. Ma, J., Yu, W. ve Liang, P., FusionGAN: a generative adversarial network for infrared and visible image fusion, Information Fusion, 48 (2019) 11–26.
80. Duan, Z., Zhang, D., Tan, J. ve Luo, X., Non-local Multi-focus Image Fusion with Recurrent Neural Networks, IEEE Access, 8 (2020) 135284-135295.
81. Liu, Y., Chen, X., Peng, H. ve Wang, Z., Multi-focus image fusion with a deep convolutional neural network, Information Fusion, 36 (2017) 191–207.
82. Du, C. ve Gao, S., Image segmentation-based multi-focus image fusion through multiscale convolutional neural network, IEEE Access, 5 (2017) 15750–15761.
83. Liu, Y., Chen, X., Cheng, J. ve Peng, H., A medical image fusion method based on convolutional neural networks, 20th International Conference on Information Fusion, Temmuz 2017, Xi'an, China, Bildiriler Kitabı, 1–7.
84. Tran, D., Bourdev, L., Fergus, R., Torresani, L. ve Paluri, M., Learning spatiotemporal features with 3d convolutional networks, Proceedings of International Conference on Computer Vision (ICCV), Aralık 2015, Santiago, Chile, Bildiriler Kitabı, 4489–4497.

85. Bezdan, T. ve Dzacula, N., B., Convolutional Neural Networks and Architectures, Sinteza 2019 - International Scientific Conference on Information Technology and Data Related Research, Ocak 2019, Belgrade, Singidunum University, Serbia, Bildiriler Kitabı, 445-451.
86. Nwankpa, C., E., Ijomah, W., Gachagan, A., ve Marshall, S., Activation Functions: Comparison of Trends in Practice and Research for Deep Learning, 2nd International Conference on Computational Sciences and Technologies (INCCST 20), Aralık 2020, MUET Jamshoro, Bildiriler Kitabı, 124-133.
87. Turian, J., Bergstra, J. ve Bengio, Y., Quadratic features and deep architectures for chunking, Human Language Technologies: Conference of the North American Chapter of the Association of Computational Linguistics, Ocak 2009, Boulder, Colorado, USA, Bildiriler Kitabı, 245–248.
88. Neal, R., M., Connectionist learning of belief networks, Artificial Intelligence, 56,1 (1992) 71–113.
89. Goodfellow, I., Yoshua, B. ve Aaron, C., Deep Learning, MIT press, 2016.
90. Maas, A., Hannun, A. ve Ng, A., Rectifier Nonlinearities Improve Neural Network Acoustic Models, International Conference on Machine Learning (ICML), Haziran 2013, Atlanta, Georgia, USA, Bildiriler Kitabı, 1-6.
91. Krizhevsky, A., Nair, V. ve Hinton, G., The CIFAR-10 dataset, <https://www.cs.toronto.edu/~kriz/cifar.html>, 8 Ağustos 2020.
92. Deng, L., The mnist database of handwritten digit images for machine learning research, IEEE Signal Processing Magazine, 29,6 (2012) 141–142.
93. Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., ve Fei-Fei, L, Imagenet: A large-scale hierarchical image database, 2009 IEEE conference on computer vision and pattern recognition, Haziran 2009, Miami, FL, USA, Bildiriler Kitabı, 248–255.
94. Zhao, H., Gallo, O., Frosio, I. ve Kautz, J., Loss functions for image restoration with neural networks, IEEE Transactions on Computational Imaging, 3,1 (2017) 47–57.
95. Li, P., He, X., Song, D., Ding, Z., Qiao, M., Cheng, X., ve Li, R., Improved categorical cross-entropy loss for training deep neural networks with noisy labels, Pattern Recognition and Computer Vision, (2021) 78–89.
96. Ruder, S., An overview of gradient descent optimization algorithms, ArXiv, abs/1609.04747 (2016) 1–14.
97. Nemirovsky, A., S. ve Yudin, D., B., Problem Complexity and Method Efficiency in Optimization, SIAM Review, 27,2 (1985) 264–265.

98. Agarwal, A., Bartlett, P., L., Ravikumar, P. ve Wainwright, M., J., Information-Theoretic Lower Bounds on the Oracle Complexity of Stochastic Convex Optimization, IEEE Transactions on Information Theory, 58, 5 (2012) 3235-3249.
99. Robbins, H. ve Monro, S., A stochastic approximation method, Ann. Math. Statist., 22,3 (1951) 400–407.
100. Duchi, J., Hazan, E. ve Singer, Y., Adaptive subgradient methods for online learning and stochastic optimization, Journal of Machine Learning Research, 12 (2011) 2121–2159.
101. McMahan, H. ve Streeter, M., Adaptive bound optimization for online convex optimization, COLT 2010 - The 23rd Conference on Learning Theory, Temmuz 2010, Haifa, Israel, Bildiriler Kitabı, 1-19.
102. Kingma, D., P. ve Ba, J., Adam: A method for stochastic optimization, 3rd International Conference on Learning Representations (ICLR), Mayıs 2015, San Diego, CA, USA, Bildiriler Kitabı, 1-15.
103. Huang, W. ve Jing, Z., Evaluation of focus measures in multi-focus image fusion, Pattern Recognition Letters, 28,4 (2007) 493-500.
104. Eltoukhy, H., A. ve Kavusi, S., A Computationally Efficient Algorithm for Multi-Focus Image Reconstruction, Proceedings of SPIE - The International Society for Optical Engineering, Mayıs 2003, Santa Clara, CA, United States, Bildiriler Kitabı, 332–341.
105. Nayar, S., K. ve Nakagawa, Y., Shape from focus, IEEE Transactions on Pattern Analysis and Machine Intelligence, 16,8 (1994) 824–831.
106. Li, S., Kwok, J., T. ve Wang, Y., Combination of images with diverse focuses using the spatial frequency, Information Fusion, 2 (2001) 169–176.
107. Boomgaard, Rein van den ve Balen, Richard van, Methods for Fast Morphological Image Transforms Using Bitmapped Binary Images, CVGIP: Graphical Models and Image Processing, 54,3 (1992) 252–258.
108. <https://cocodataset.org/>, COCO dataset, 5 Mayıs 2020.
109. Aymaz, S., Çoklu-odaklı Görüntü Birleştirme Veri Seti, <https://drive.google.com/file/d/1t28bbxOxO2m7l9p-Kbq-jrjZxt1CPBpf/view>, 15 Ağustos 2020.
110. Pa, J. ve Hegde, A., V., A Review of Quality Metrics for Fused Image, International Conference on Water Resources, Coastal and Ocean Engineering (ICWRCOE), Mart 2015, Karnataka, India, Bildiriler Kitabı, 133-142.
111. Li, S., Kang, X., Fang, L., Hu, J. ve Yin, H., Pixel-Level Image Fusion: A Survey of The State of The Art, Information Fusion, 33 (2017) 100-112.

112. Wang, Z., Bovik, A., C., Sheikh, H., R. ve Simoncelli, E., P., Image quality assessment: from error visibility to structural similarity, IEEE Transactions on Image Processing, 13,4 (2004) 600–612.
113. Zhang, X., Li, X. ve Feng, Y., A New Multi-Focus Image Fusion Based on Spectrum Comparison, Signal Processing, 123 (2016) 127-142.
114. Fu, W., Huang, S., Li, Z., Shen, H., Li, J. ve Wang, P., The Optimal Algorithm for Multi-Source RS Image Fusion, MethodsX, 3 (2016) 87–101.
115. Aymaz, S., Çoklu-odaklı Görüntü Birleştirme Veri Seti, [https://github.com/sametaymaz/Multi-focus-Image-Fusion Dataset/blob/master/MF_Dataset.rar](https://github.com/sametaymaz/Multi-focus-Image-Fusion-Dataset/blob/master/MF_Dataset.rar), 10 Ocak 2019.
116. Aymaz, S. ve Köse, C., A novel image decomposition-based hybrid technique with super-resolution method for multi-focus image fusion, Information Fusion, 45 (2019) 113-127.
117. Chen, C. H., Geng, P. ve Lu, K., Multifocus image fusion based on multiwavelet and DFB, Chemical Engineering Transactions, 46 (2015) 277-282.
118. Abdipour, M. ve Nooshyar, M., Multi-focus image fusion using sharpness criteria for visual sensor networks in wavelet domain, Computers and Electrical Engineering, 51 (2016) 74-88.
119. Jiang, Q., Jin, X., Lee, S. ve Yao, S., A Novel Multi-Focus Image Fusion Method Based on Stationary Wavelet Transform and Local Features of Fuzzy Sets, Neurocomputing, 174 (2016) 733-748.
120. Hua, K., L., Wang, H., C., Rusdi, A., H. ve Jiang, S., Y., A novel multi-focus image fusion based on random walks, Journal of Visual Communication and Image Representation, 25 (2014) 951-962.
121. Zhang, B., Lu, X., Pei, H., Liu, H., Zhao, Y. ve Zhou, W., Multi-focus Image fusion algorithm based on focused region extraction, Neurocomputing, 174 (2015) 733-748.
122. Chaudhary, V. ve Kumar, V., Block-based image fusion using multi-scale analysis to enhance depth of field and dynamic range, Signal, Image and Video Processing, 12 (2018) 271-279.
123. Yang, Y., Tong, S., Huang, S., Lin, P. ve Fang, Y., A Hybrid Method for Multi-Focus Image Fusion Based on Fast Discrete Curvelet Transform, IEEE Access, 5 (2017) 14898-14913.
124. Nejati, M., Samavi, S., Karimi, N., Soroushmehr, S., M., R., Shirani, S., Roosta, I. ve Najarian, K., Surface-area based focus criterion for multi-focus image fusion, Information Fusion, 36 (2017) 284-295.

125. Li, L., Ma, H., Jia, Z. ve Si, Y., A novel multiscale transform decomposition-based multi-focus image fusion framework, Multimedia Tools and Applications, 80 (2021) 12389-12409.
126. Moushmi, S., Sowmya, V. ve Soman, K., P., Empirical Wavelet Transform for Multi-focus Image Fusion, Proceedings of the International Conference on Soft Computing Systems, Ocak 2016, India, Bildiriler Kitabı, 257-263.
127. Li, H., Chai, Y., Yin, H. ve Liu, G., Multi-focus image fusion and denoising scheme based on homogeneity similarity, Optics Communications, 285 (2012) 91–100.
128. Du, C., Gao, S., Liu, Y. ve Gao, B., Multi-focus image fusion using deep support value convolutional neural network, Optik, 176 (2019) 567-578.
129. He, K., Zhou, D., Zhang, X. ve Nie, R., Multi-focus: Focused region finding and multi-scale transform for image fusion, Neurocomputing, 320 (2018) 157-170.
130. Panigrahy, C., Seal, A. ve Mahato, N., K., Fractal dimension based parameter adaptive dual-channel PCNN for multi-focus image fusion, Optics and Lasers in Engineering, 133 (2020) 106141.
131. Wen, Y., Yang, X., Celik, T., Sushkova, O. ve Albertini, M., K., Multi-focus image fusion using convolutional neural network, Multimedia Tools and Applications, 79 (2020) 34531–34543.
132. Yang, Y., Que, Y., Huang, S. ve Lin, P., Technique for multi-focus image fusion based on fuzzy-adaptive pulse-coupled neural network, Signal Image and Video Processing, 11,3 (2017) 439-446.
133. Amin-Naji, M., Aghagolzadeh, A. ve Ezoji, M., CNN's hard voting for multi-focus image fusion, Journal of Ambient Intelligence and Humanized Computing, 11 (2020) 1749-1769.
134. Liu, S., Lu, Y., Wang, J., Hu, S., Zhao, J. ve Zhu, Z., A new focus evaluation operator based on max-min filter and its application in high-quality multi-focus image fusion, Multidimensional Systems and Signal Processing, 31,2 (2020) 569-590.
135. Li, H., Li, X., Yu, Z. ve Mao, C., Multi-focus image fusion by combining with mixed-order structure tensors and multiscale neighborhood, Information Sciences, 349 (2016) 25-49.
136. Yang, Y., Zhang, Y., Huang, S. ve Wu, J., Multi-focus image fusion via NSST with non-fixed base dictionary learning, International Journal of Systems Assurance Engineering and Management, 11,6 (2019) 849-855.
137. Liu, Y. ve Wang, Z., Simultaneous image fusion and denoising with adaptive sparse representation, IET Image Processing, 9,5 (2014) 347–357.

138. Zhang, Y., Liu, Y. ve Sun, P., IFCNN: a general image fusion framework based on convolutional neural network, Information Fusion, 54 (2020) 99–118.
139. Gai, D., Shen, X., Chen, H. ve Su, P., Multi-focus image fusion method based on two-stage of convolutional neural network, Signal Processing, 176 (2020) 107681.
140. Liu, Y., Liu, S. ve Wang, Z., A general framework for image fusion based on multi-scale transform and sparse representation, Information Fusion, 24 (2015) 147–164.
141. Bai, X., Zhang, Y. ve Zhou, F., Quadtree-based multi-focus image fusion using a weighted focus-measure, Information Fusion, 22 (2015) 105–118.
142. Zhang, Y., Bai, X. ve Wang, T., Boundary finding based multi-focus image fusion through multi-scale morphological focus-measure, Information Fusion, 35 (2017) 81–101.



ÖZGEÇMİŞ

İlkokulu ve ortaokulu Mustafa Kemal İlköğretim Okulu'nda ve liseyi Bafra Anadolu Lisesi'nde tamamlamıştır. Lisans öğrenimini Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü'nden 2012 yılında tamamlamıştır. 2013 yılında Milli Eğitim Bakanlığı'na Mühendis olarak atanmıştır. 2015 yılında Sağlık Bakanlığı Kanuni Eğitim ve Araştırma Hastanesi'ne Mühendis olarak atanmıştır. 2020 yılından itibaren Trabzon İl Sağlık Müdürlüğünde Bilişim Uzmanı olarak görevine devam etmektedir. 2016-2017 eğitim-öğretim yılının güz döneminde Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda tezli yüksek lisans programını tamamlamış ve takip eden bahar dönemi doktora programına başlamıştır. İyi derecede İngilizce bilmektedir. Evli ve bir çocuk babasıdır.

Uluslararası hakemli dergilerde yayınlanan makaleler (SCI/SCI-E)

1. Aymaz, S. ve Köse, C., A novel image decomposition-based hybrid technique with super-resolution method for multi-focus image fusion, Information Fusion, 45 (2019) 113-127.
2. Aymaz, S., Köse, C. ve Aymaz, Ş., Multi-focus image fusion for different datasets with super-resolution using gradient-based new fusion rule, Multimedia Tools and Applications, 79,20 (2020) 13311–13350.

Uluslararası hakemli dergilerde süreci devam eden makaleler (SCI/SCI-E)

1. Aymaz, S., Köse, C. ve Aymaz, Ş., A Novel Approach with the Dynamic Decision Mechanism (DDM) in Multi-focus Image Fusion, Multimedia Tools And Applications (Minor revizyon sonrası hakem değerlendirmesinde)
2. Aymaz, S., Aymaz, Ş. ve Köse, C., A New Classification-based Approach for Multi-focus Image Fusion, Sigma Journal of Engineering and Natural Sciences (Editörde)

Ulusal ve uluslararası konferanslarda sözlü sunumu yapılan bildiriler

1. Aymaz, S. ve Köse, C., Multi-focus image fusion using Stationary Wavelet Transform (SWT) with Principal Component Analysis (PCA), 2017 10th International Conference on Electrical and Electronics Engineering (ELECO), Kasım 2017, Bursa, Türkiye, Bildiriler Kitabı, 1176-1180.

2. Aymaz, S., Dizdaroğlu, B., Köse, C. ve Aymaz, Ş., A New Hybrid Approach with Perona-Malik Improvement for Multi-focus Image Fusion, 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), Eylül 2018, Malatya, Türkiye, Bildiriler Kitabı, 1-6.
3. Aymaz, Ş., Çavdar, T., Aymaz, S. ve Öztürk, E., An Analysis of Load Balancing Strategies with Wireshark in Software Defined Networks, 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), Eylül 2018, Malatya, Türkiye, Bildiriler Kitabı, 1-5.
4. Aymaz, Ş., Çavdar, T. ve Aymaz, S., Load Balancing with a New Approach for Dynamic Server Selection in Software Defined Network, 1st International Conference on Electrical-Electronics and Computer Engineering, Temmuz 2021, Trabzon, Türkiye, Bildiriler Kitabı, 85-91.

