

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ÖĞRENME TABANLI TEK GÖRÜNTÜ SÜPER ÇÖZÜNÜRLÜĞÜ
YAKLAŞIMLARININ GELİŞTİRİLMESİ VE UYGULANMASI**

DOKTORA TEZİ

Bil. Yük. Müh. Selen AYAS

**HAZİRAN 2019
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ÖĞRENME TABANLI TEK GÖRÜNTÜ SÜPER ÇÖZÜNÜRLÜĞÜ YAKLAŞIMLARININ
GELİŞTİRİLMESİ VE UYGULANMASI**

Selen AYAS

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

Tezin Enstitüye Verildiği Tarih : 20 / 05 / 2019

Tezin Savunma Tarihi : 18 / 06 / 2019

Tez Danışmanı : Prof. Dr. Murat EKİNCİ

Trabzon 2019

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

Bilgisayar Mühendisliği Anabilim Dalında

Selen AYAS Tarafından Hazırlanan

**ÖĞRENME TABANLI TEK GÖRÜNTÜ SÜPER ÇÖZÜNÜRLÜĞÜ
YAKLAŞIMLARININ GELİŞTİRİLMESİ VE UYGULANMASI**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 28 /05/2019 gün ve 1806 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

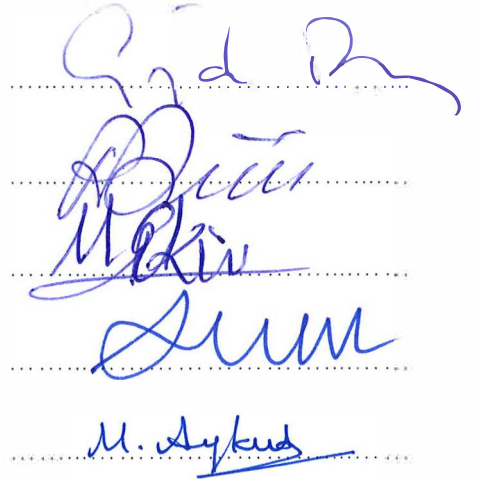
Başkan : Prof. Dr. Gözde BOZDAĞI AKAR

Üye : Prof. Dr. Recep DEMİRCİ

Üye : Prof. Dr. Murat EKİNCİ

Üye : Prof. Dr. Ali GANGAL

Üye : Dr. Öğr. Üyesi Murat AYKUT



Prof. Dr. Asim KADIOĞLU

Enstitü Müdürü

ÖNSÖZ

Tek bir düşük çözünürlüklü görüntüden yüksek çözünürlüklü bir görüntü oluşturmayı ifade eden tek görüntü süper çözünürlüğü, görüntüleme sisteminden kaynaklanan çözünürlük kısıtlamalarının üstesinden gelmek amacıyla tercih edilmektedir. Son yıllarda pratik uygulamalarda da yüksek fayda sağlayan öğrenme tabanlı tek görüntü süper çözünürlüğü, düşük çözünürlüklü ve yüksek çözünürlüklü görüntüler arasında doğrusal olmayan eşleşme fonksiyonunun öğrenilmesini içermektedir. Bu tez çalışması kapsamında var olan öğrenme tabanlı tek görüntü süper çözünürlüğü problemlerinin iyileştirilmesi için yeni yaklaşımlar geliştirilmiş ve farklı görüntüler üzerinde süper çözünürlük uygulamaları gerçekleştirilmiştir.

Bu çalışmada danışmanlığımı üstlenen değerli hocam Prof. Dr. Murat EKİNCİ'ye ilgi, alaka ve yardımlarından dolayı teşekkürlerimi sunarım. Akademisyenlik hayatım boyunca bana her türlü desteği sağlayan hocam Dr. Öğr. Üyesi Murat AYKUT'a ve tez sürecinde fikirlerinden yararlandığım tez jürime teşekkür ederim. Tez çalışmam süresince BİDEB 2228-B Yurt İçi Doktora Burs Programı ve BİDEB 2214-A Yurt Dışı Araştırma Burs Programı kapsamında maddi olarak beni destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK)'a ve bu araştırmada yer alan kısmi nümerik hesaplamalar TÜBİTAK ULAKBİM, Yüksek Başarım ve Grid Hesaplama Merkezi'nde (TRUBA kaynaklarında) gerçekleştirildiğinden TÜBİTAK ULAKBİM'e teşekkür etmeyi bir borç bilirim. Doktora eğitimimin başlamasında ve her aşamasında yanımda olan eşime, kızıma, hoşgörülerinden ötürü sevgili aileme şükranlarımı sunarım.

Selen AYAS
Trabzon 2019

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “Öđrenme Tabanlı Tek Görüntü Süper Çözünürlüđü Yaklaşımlarının Geliştirilmesi ve Uygulanması” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Murat EKİNCİ'nin sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdıđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 18/06/2019

Selen AYAS

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	IX
SUMMARY	X
ŞEKİLLER DİZİNİ	XI
TABLolar DİZİNİ.....	XVI
SEMBOLLER DİZİNİ	XVIII
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Süper Çözünürlük	3
1.2.1. Görüntü Oluşum Modeli	3
1.2.2. Süper Çözünürlük Teknikleri.....	5
1.2.2.1. Ara Değerleme Tabanlı Yöntemler.....	8
1.2.2.2. Oluşturma Tabanlı Yöntemler	9
1.2.2.3. Öğrenme Tabanlı Yöntemler	10
1.3. Tezin Kapsamı	15
1.4. Seyrek Gösterim Tabanlı Süper Çözünürlük	16
1.4.1. Seyrek Kodlama.....	17
1.4.1.1. Konveks Optimizasyon Yöntemleri.....	19
1.4.1.2. Açgöz Arama Yaklaşımları.....	19
1.4.2. Sözlük Öğrenmesi	22
1.4.3. Sentetik Görüntülerde Seyrek Gösterim Tabanlı Süper Çözünürlük.....	24
1.4.3.1. Seyrek Gösterim Tabanlı Süper Çözünürlükte Kullanılan Görüntü Veritabanları	24
1.4.3.2. Seyrek Gösterim Tabanlı Görüntü Süper Çözünürlüğünde Güncel Yaklaşımlar.....	25
1.4.4. Uydu Görüntülerinde Seyrek Gösterim Tabanlı Süper Çözünürlük.....	28
1.4.4.1. Bileşen Yerine Koyma Tabanlı Yaklaşımlar	29
1.4.4.2. Çoklu Çözünürlük Analizi Tabanlı Yaklaşımlar	31
1.4.4.3. Sıkıştırılmış Algılama Tabanlı Yaklaşımlar	31

1.5.	Konvolüsyonel Sinir Ağları Tabanlı Süper Çözünürlük.....	33
1.5.1.	Konvolüsyonel Sinir Ağları	34
1.5.1.1.	Konvolüsyon Katmanı	35
1.5.1.2.	Aktivasyon Fonksiyonu	37
1.5.1.3.	Havuzlama Katmanı.....	38
1.5.1.4.	Tam Bağlantılı Katman.....	39
1.5.2.	Konvolüsyonel Sinir Ağlarının Eğitimi	40
1.5.2.1.	Verilerin ve Modelin Kurulması	40
1.5.2.2.	İleri Yayılım.....	41
1.5.2.3.	Kayıp Fonksiyonu	41
1.5.2.4.	Geri Yayılım	43
1.5.2.4.1.	Olasılıksal Gradyan İniş Algoritması.....	44
1.5.2.4.2.	Momentumlu Olasılıksal Gradyan İniş Algoritması.....	45
1.5.2.4.3.	Adam Algoritması.....	46
1.5.3.	Sentetik Görüntülerde Konvolüsyonel Sinir Ağları Tabanlı Süper Çözünürlük	48
1.5.3.1.	Konvolüsyonel Sinir Ağları Tabanlı Süper Çözünürlükte Kullanılan Görüntü Veritabanları	48
1.5.3.2.	Konvolüsyonel Sinir Ağları Tabanlı Görüntü Süper Çözünürlüğünde Güncel Yaklaşımlar	49
1.5.4.	Medikal Görüntülerde Konvolüsyonel Sinir Ağları Tabanlı Süper Çözünürlük	54
1.6.	Süper Çözünürlükte Performans Ölçümü	55
1.6.1.	Sentetik ve Medikal Görüntülerde Performans Ölçümü.....	55
1.6.2.	Uydu Görüntülerinde Performans Ölçümü	57
2.	YAPILAN ÇALIŞMALAR	60
2.1.	Ayrık Dalgacık Dönüşümüne Dayalı Tek Görüntü Süper Çözünürlüğü	62
2.1.1.	Sözlüklerin Öğrenilmesi	63
2.1.1.1.	Dalgacık Dönüşümü.....	64
2.1.1.2.	Temel Bileşen Analizi.....	66
2.1.1.3.	Sözlük Öğrenmesi	67
2.1.2.	Yüksek Çözünürlüklü Görüntü Oluşturma	68
2.2.	Çok Ölçekli ve Çok Yönlü Gabor Özellik Temsiliyetine Dayalı Tek Görüntü Süper Çözünürlüğü	70
2.2.1.	Sözlük Çiftinin Öğrenilmesi	70
2.2.1.1.	Gabor Dalgacıkları.....	72
2.2.1.2.	Sözlük Öğrenmesi	74

2.2.2.	Yüksek Çözünürlüklü Görüntü Oluşturma	75
2.3.	Yoğun Atlamalı Bağlantılı Konvolüsyonel Sinir Ağlarına Dayalı Tek Görüntü Süper Çözünürlüğü	77
2.3.1.	Konvolüsyonel Sinir Ağlarına Dayalı Mevcut Yaklaşımların Analizi	78
2.3.2.	Konvolüsyonel Sinir Ağlarında Eğitim Veri Kümesinin Analizi	84
2.3.3.	Yoğun Atlamalı Konvolüsyonel Sinir Ağ Yapısı	85
2.3.3.1.	Ağ Mimarisi	87
2.3.3.1.1.	Düşük Seviyeli Özellikler ve Yoğun Atlamalı Bağlantılı Bloklar.....	88
2.3.3.1.2.	Atlamalı Bağlantı ile Özellik Birleştirme	89
2.3.3.1.3.	Büyütme ve Oluşturma Katmanı.....	90
2.3.3.2.	Ağ Modelinin Eğitimi	90
2.4.	Sözlük Öğrenmesi ve Seyrek Temsiliyete Dayalı Pan Keskinleştirme	91
2.4.1.	Görüntü Bozunma Modeli	92
2.4.2.	Örnek Azaltımı ve Sözlük Öğrenmesi	94
2.4.3.	Yüksek Çözünürlüklü Görüntü Oluşturma	96
2.4.4.	İteratif Geri İzdüşürme.....	97
2.5.	Derin Konvolüsyonel Sinir Ağlarına Dayalı Mikroskobik Görüntü Süper Çözünürlüğü.....	97
2.5.1.	Veri Ön İşleme	98
2.5.2.	Ağ Mimarisi	100
2.5.3.	Ağ Modelinin Eğitimi	101
3.	BULGULAR VE İRDELEME	103
3.1.	Veritabanlarının Analizi.....	103
3.1.1.	Sentetik Görüntülerden Oluşan Veritabanları.....	103
3.1.2.	Uzaktan Algılama Görüntülerinden Oluşturulan Veritabanları	106
3.1.3.	Mikroskobik Görüntülerden Oluşturulan Veritabanları.....	107
3.2.	Ayrık Dalgacık Dönüşümüne Dayalı Tek Görüntü Süper Çözünürlüğü Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar.....	109
3.2.1.	Seyrek Temsiliyet Parametrelerinin Etkisi	109
3.2.2.	Deneysel Sonuçlar ve Analizler.....	110
3.3.	Çok Ölçekli ve Çok Yönlü Gabor Özellik Temsiliyetine Dayalı Tek Görüntü Süper Çözünürlüğü Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar	113
3.3.1.	Özellik Tanımlayıcısı Parametrelerinin Etkisi	113
3.3.2.	Seyrek Temsiliyet Parametrelerinin Etkisi	115
3.3.3.	Deneysel Sonuçlar ve Analizler.....	116

3.4.	Yoğun Atlamalı Bağlantılı Konvolüsyonel Sinir Ağlarına Dayalı Tek Görüntü Süper Çözünürlüğü Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar	120
3.4.1.	Yoğun Blok Sayısı ve Blok İçerisindeki Katman Sayısının Etkisi.....	121
3.4.2.	Transpoze Konvolüsyon Filtre Sayısının Etkisi.....	122
3.4.3.	Küçük Grup Boyutunun Etkisi.....	123
3.4.4.	Başlangıç Öğrenme Katsayısının Etkisi.....	124
3.4.5.	Atlamalı Bağlantı ile Özellik Birleştirmenin Etkisi.....	125
3.4.6.	Deneysel Sonuçlar ve Analizler.....	126
3.5.	Sözlük Öğrenmesi ve Seyrek Temsiliyete Dayalı Pan Keskinleştirme Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar.....	131
3.5.1.	Kullanıcı Tanımlı Parametrelerin Etkisi	131
3.5.2.	Quickbird Verisi ile Yapılan Deneyler	135
3.5.3.	IKONOS Verisi ile Yapılan Deneyler	138
3.5.4.	Zaman Karmaşıklığı.....	141
3.6.	Derin Konvolüsyonel Sinir Ağlarına Dayalı Mikroskobik Görüntü Süper Çözünürlüğü Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar.....	144
3.6.1.	Çoklu Ölçekler İçin Tek Model	144
3.6.2.	Renk Değişimine Karşı Dayanıklılık	148
3.6.3.	Zaman Karmaşıklığı.....	151
4.	SONUÇLAR	153
5.	ÖNERİLER VE TARTIŞMA	155
6.	KAYNAKLAR	157
7.	EKLER.....	171
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

ÖĞRENME TABANLI TEK GÖRÜNTÜ SÜPER ÇÖZÜNÜRLÜĞÜ
YAKLAŞIMLARININ GELİŞTİRİLMESİ VE UYGULANMASI

Selen AYAS

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Murat EKİNCİ
2019, 170 Sayfa, 7 Sayfa Ek

Tez çalışması kapsamında, literatürde süper çözünürlükte görüntü oluşturma olarak adlandırılan düşük çözünürlüklü bir görüntünün uzamsal çözünürlüğünü artırmak için yeni yaklaşımlar önerilmektedir. Literatüre yapılan katkıların ilki Dalgacık dönüşümünden yararlanarak görüntüdeki kenar, köşe ve sınır yapılarını koruyan yeni bir seyrek gösterim tabanlı süper çözünürlük yaklaşımının sunulmasıdır. Tezin literatüre ikinci katkısı, Gabor Dalgacıkları yönteminin görüntülerden özellik çıkarılması amacıyla kullanılmasıdır. Sentetik görüntüler üzerinde yapılan deneyler önerilen yöntemin literatürdeki derin öğrenme hariç öğrenme tabanlı yöntemlere kıyasla daha iyi sonuç verdiğini göstermektedir. Tezin literatüre üçüncü katkısı, öğrenme tabanlı süper çözünürlük için literatürdeki konvolüsyonel sinir ağları tabanlı süper çözünürlük yaklaşımlarının analizlerinin yapılması ve yoğun atlamalı bağlantılar içeren yeni bir konvolüsyonel sinir ağ yapısının önerilmesidir. Bu ağ yapısı ile sentetik görüntülerin süper çözünürlük kaliteleri iyileştirilmiştir. Tezin literatüre dördüncü katkısı olarak, süper çözünürlük uygulanacak görüntülerin mikroskobik görüntü olması durumu yeni bir konvolüsyonel sinir ağ yapısı ile değerlendirilmiştir. Önerilen çalışma, literatürdeki mikroskobik görüntülerin süper çözünürlüğünü sağlayan ilk ve tek çalışmanın kısıtlamalarını ortadan kaldırmaktadır. Son olarak uzaktan algılama görüntüleri üzerinde yeni bir seyrek temsiliyet tabanlı pan keskinleştirme yaklaşımı önerilerek yüksek başarı elde edilmiş ve literatürde ilk kez detaylı bir karşılaştırma gerçekleştirilmiştir.

Anahtar Kelimeler: Tek görüntü süper çözünürlüğü, Öğrenme tabanlı süper çözünürlük, Seyrek temsiliyet, Konvolüsyonel sinir ağları, Mikroskobik görüntü süper çözünürlüğü, Pan-keskinleştirme.

PhD. Thesis

SUMMARY

DEVELOPMENT AND IMPLEMENTATION OF LEARNING BASED SINGLE
IMAGE SUPER RESOLUTION APPROACHES

Selen AYAS

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Murat EKİNCİ
2019, 170 Pages, 7 Pages Appendix

In the thesis work, novel methods are proposed to increase the spatial resolution of a low resolution image which the process is referred to as super resolution image reconstruction in the literature. The first contribution to the literature is to present a novel edge, corner and boundary preserving sparse representation based super resolution approach by using Wavelet transform. The second contribution of the thesis to the literature is the use of Gabor Wavelets method for the purpose of feature extraction. The experiments conducted on synthetic images show that the proposed method gives better results compared to learning-based method except for deep learning in the literature. The third contribution of the thesis to the literature is to analyze the convolutional neural network based super resolution approaches in the literature and to propose a novel convolutional neural network structure with deep skip-connections for learning-based super-resolution. With this network structure, the super resolution qualities of synthetic images have been improved. As the fourth contribution of the thesis to the literature, the microscopic image super resolution is examined with a novel convolutional neural network structure. The proposed study eliminates the limitations of the first and only study that provides the super resolution of microscopic images in the literature. Finally, high quality images are obtained with the proposed sparse representation based pan sharpening approach in remote sensing images and a detailed comparison is made for the first time in the literature.

Key Words: Single image super resolution, Learning based super resolution, Sparse representation, Convolutional neural network, Microscopic image super resolution, Pan sharpening

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Süper çözünürlük görüntü oluşum modeli	3
Şekil 2. Süper çözünürlük algoritma türleri	6
Şekil 3. Çoklu görüntü süper çözünürlüğü için çakıştırma süreci.....	7
Şekil 4. 1 ve 2 boyutlu ara değerlendirme fonksiyonlarının karşılaştırılması	9
Şekil 5. Oluşturma tabanlı yöntemlerde kullanılan önsel çeşitleri	10
Şekil 6. Öğrenme tabanlı tek görüntü süper çözünürlüğü yaklaşımlarının (a) eğitim süreci ve (b) YÇ görüntü oluşturma süreci	11
Şekil 7. Tez içeriğinin genel yapısı	16
Şekil 8. Pan keskinleştirme süreci	28
Şekil 9. Aktivasyon fonksiyonlarının biçimleri ve matematiksel ifadeleri	37
Şekil 10. Maksimum havuzlamanın değişmezlik özelliği [114].	39
Şekil 11. Ayrık dalgacık dönüşümüne dayalı önerilen yaklaşımın sözlük öğrenmesi süreci	63
Şekil 12. Ayrık dalgacık dönüşümüne dayalı önerilen yaklaşımın yüksek çözünürlüklü görüntü oluşturma süreci.....	69
Şekil 13. Gabor özellik temsiliyetine dayalı önerilen yaklaşımın sözlük öğrenmesi süreci	71
Şekil 14. Uzamsal domende (üst satır, sadece reel kısımlar) ve frekans domeninde (alt satır) 2 boyutlu Gabor filtre fonksiyonları [155].	73
Şekil 15. Gabor özellik temsiliyetine dayalı önerilen yaklaşımın yüksek çözünürlüklü görüntü oluşturma süreci.....	76
Şekil 16. Basit veri artırımı tekniklerinin 291 veri kümesindeki ‘tt19’ görüntüsüne uygulanması; (a) 0° döndürme, (b) 90° döndürme, (c) 180° döndürme, (d) 270° döndürme, (e, f, g, h) sırasıyla (a, b, c, d) görüntülerinin dikey çevirmeleri	80
Şekil 17. Konvolüsyonel sinir ağlarına dayalı mevcut yaklaşımlarda ağın karmaşıklık ve başarı analizi.....	82
Şekil 18. Eğitim veri kümesindeki görüntü sayısının süper çözünürlük performansına etkisi.....	85
Şekil 19. VDSR ağ mimarisinin derinliğinin süper çözünürlük performansına etkisi	86
Şekil 20. Önerilen yoğun atlamalı konvolüsyonel sinir ağı mimarisi	87

Şekil 21. Şekil 20’de verilen ağ yapısındaki önerilen yoğun alt blok yapısı.....	88
Şekil 22. Pan keskinleştirme görüntü bozunma modeli	93
Şekil 23. Mikroskobik görüntüleme için veri ön işleme akışı.....	98
Şekil 24. Örnek eşleşen mikroskobik görüntüler üzerinde 2B NCC fonksiyonun sonuç görüntüleri, (a) 10× objektifinde mikroskoptan alınan görüntü (600×300), (b) 40× objektifinde mikroskoptan alınan görüntü (600×300), (c) 2B NCC yönteminin çıkışında elde edilen DÇ görüntü (150×75), (d) 2B NCC yönteminin çıkışında elde edilen YÇ görüntü (600×300)	99
Şekil 25. Mikroskobik görüntüleme için derin CNN mimarisi	100
Şekil 26. 91 görüntüden oluşan veri kümesindeki farklı sınıflara ait örnek eğitim görüntüleri: (a) t4, (b) t36, (c) t53, (d) tt2, (e) tt26, (f) tt18	104
Şekil 27. Set5 veri kümesindeki test görüntüleri: (a) baby, (b) bird, (c) butterfly, (d) head, (e) woman.....	104
Şekil 28. Set14 veri kümesindeki test görüntüleri: (a) baboon, (b) barbara, (c) bridge, (d) coastguard, (e) comic, (f) face, (g) flowers, (h) foreman, (i) lenna, (j) man, (k) monarch, (l) pepper, (m) ppt3, (n) zebra	104
Şekil 29. DIV2K veri kümesindeki örnek görüntüler: (a) 0007, (b) 0058, (c) 0089, (d) 0158, (e) 0690	105
Şekil 30. B100 veri kümesindeki örnek görüntüler: (a) 3096, (b) 69015, (c) 102061, (d) 145086, (e) 351093	105
Şekil 31. Urban100 veri kümesindeki örnek görüntüler: (a) img_011, (b) img_049, (c) img_085, (d) img_089, (e) img_091	105
Şekil 32. Quickbird veritabanında bulunan eğitim MS ve PAN görüntülerinden bir örnek	106
Şekil 33. IKONOS veritabanında bulunan eğitim MS ve PAN görüntülerinden bir örnek	107
Şekil 34. Mikroskobik veritabanındaki (a) <i>mamic_57551</i> ve (b) <i>mamic_57552</i> yaymalarına ait örnek görüntüler	108
Şekil 35. Set14 veri kümesi üzerinde ×2 büyütme faktöründe sözlük boyutunun süper çözünürlük performansına etkisi.....	110
Şekil 36. Set5 veri kümesinden ‘Butterfly’ görüntüsünün ×2 büyütme faktöründe süper çözünürlük sonuçları.....	111
Şekil 37. Set14 veri kümesinden ‘PPT3’ görüntüsünün ×2 büyütme faktöründe süper çözünürlük sonuçları.....	111
Şekil 38. Set14 veri kümesi üzerinde ×3 büyütme faktöründe η ve γ parametrelerinin süper çözünürlük performansına etkisi	114
Şekil 39. Set14 veri kümesi üzerinde ×3 büyütme faktöründe sözlük boyutunun süper çözünürlük performansına etkisi.....	115

Şekil 40. Set5 veri kümesinden ‘Bird’ görüntüsünün $\times 3$ büyütme faktöründe süper çözünürlük sonuçları	117
Şekil 41. Set14 veri kümesinden ‘Lenna’ görüntüsünün $\times 3$ büyütme faktöründe süper çözünürlük sonuçları	117
Şekil 42. Transpoze konvolüsyon filtre sayısının ağın performansına etkisi (PSNR (dB) ve zaman (saat)).....	122
Şekil 43. Küçük grup boyutunun ağın performansına etkisi (PSNR (dB) ve zaman (saat))	124
Şekil 44. Başlangıç öğrenme katsayısının ağın performansına etkisi a) Kayıp fonksiyonu ve b) RMSE.....	124
Şekil 45. Atlamalı bağlantı kullanımının ağın performansına etkisi a) PSNR (dB) ve b) zaman (saat).....	125
Şekil 46. DIV2K veri kümesinden ‘0828’ görüntüsünün $\times 4$ büyütme faktöründe süper çözünürlük sonuçları	127
Şekil 47. Urban100 veri kümesinden ‘img039’ görüntüsünün $\times 4$ büyütme faktöründe süper çözünürlük sonuçları	127
Şekil 48. DIV2K veri kümesinden ‘0853’ görüntüsünün $\times 4$ büyütme faktöründe süper çözünürlük sonuçları	127
Şekil 49. Set5 veri kümesinden ‘butterfly’ görüntüsünün $\times 3$ büyütme faktöründe farklı bozunma parametrelerine bağlı oluşturulan DÇ Y kanalı görüntüleri: (a) orijinal YÇ görüntü, (b) Çekirdek genişliği (ÇG) = 1.0, Gürültü seviyesi (GS) = 0; (c) ÇG = 1.0, GS = 15; (d) ÇG = 1.0, GS = 50; (e) ÇG = 2.6, GS = 0; (f) ÇG = 2.6, GS = 15; (g) ÇG = 2.6, GS = 50.	129
Şekil 50. Set5 veri kümesinden ‘butterfly’ görüntüsünün $\times 3$ büyütme faktöründe farklı bozunma parametrelerine bağlı (a,b,c) çift kübik ara değerlendirme yönteminin ve (d,e,f) önerilen yaklaşımın süper çözünürlük sonuçları; (a, d) ÇG = 1.0, GS = 15; (b, e) ÇG = 2.6, GS = 0; (c,f) ÇG = 2.6, GS = 50.....	130
Şekil 51. Farklı β parametreleri ile önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi	132
Şekil 52. Farklı sözlük boyutları ile önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi	134
Şekil 53. İteratif geri izdüşürme adımının kullanılmasına bağlı olarak önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi (mavi: kullanılmamış, kırmızı: kullanılmış)	134
Şekil 54. Doku tabanlı sözlük kullanılmasına bağlı olarak önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi (mavi: normal, kırmızı: doku tabanlı sözlük)	135

- Şekil 55. Örnek azaltımı uygulanmasına bağlı olarak önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi (mavi: orijinal, kırmızı: örnek azaltılmış) 135
- Şekil 56. Kaynak Quickbird görüntüleri (kıyı boyu) ve pan keskinleştirme sonuçları 137
- Şekil 57. Kaynak Quickbird görüntüleri (otoyol) ve pan keskinleştirme sonuçları 137
- Şekil 58. Kaynak IKONOS görüntüleri (nehir) ve pan keskinleştirme sonuçları 140
- Şekil 59. Kaynak IKONOS görüntüleri (dağ) ve pan keskinleştirme sonuçları..... 141
- Şekil 60. Tek ölçekli model kullanılarak Veri Kümesi 1 test kümesinden bir görüntünün $\times 2$ büyütme faktörü ile eğitilip $\times 2$ büyütme faktörü ile test edilmesinin süper çözünürlük sonuçları; (a) $20\times$ giriş görüntüsüne karşılık gelen derin CNN çıkış görüntüsü, (b,e) DÇ giriş görüntüsünün büyütülmüş ilgi bölgeleri ($20\times$), (c,f) çift kübik ara değerlendirme sonucunun büyütülmüş ilgi bölgeleri (PSNR: 24.9961 dB, SSIM: 0.7844), (d,g) derin CNN sonucunun büyütülmüş ilgi bölgeleri (PSNR: 26.7010 dB, SSIM: 0.8380).... 147
- Şekil 61. Tek ölçekli model kullanılarak Veri Kümesi 2 test kümesinden bir görüntünün $\times 4$ büyütme faktörü ile eğitilip $\times 4$ büyütme faktörü ile test edilmesinin süper çözünürlük sonuçları; (a) $10\times$ giriş görüntüsüne karşılık gelen derin CNN çıkış görüntüsü, (b,e) DÇ giriş görüntüsünün büyütülmüş ilgi bölgeleri ($10\times$), (c,f) çift kübik ara değerlendirme sonucunun büyütülmüş ilgi bölgeleri (PSNR: 28.4036 dB, SSIM: 0.7967), (d,g) derin CNN sonucunun büyütülmüş ilgi bölgeleri PSNR: 29.7667 dB, SSIM: 0.8406)..... 147
- Şekil 62. Çoklu ölçekli model kullanılarak Veri Kümesi 1 test kümesinden bir görüntünün $\times 2,4$ büyütme faktörü ile eğitilip $\times 2$ büyütme faktörü ile test edilmesinin süper çözünürlük sonuçları; (a) $20\times$ giriş görüntüsüne karşılık gelen derin CNN çıkış görüntüsü, (b,e) DÇ giriş görüntüsünün büyütülmüş ilgi bölgeleri ($20\times$), (c,f) çift kübik ara değerlendirme sonucunun büyütülmüş ilgi bölgeleri (PSNR: 28.2829 dB, SSIM: 0.8494), (d,g) derin CNN sonucunun büyütülmüş ilgi bölgeleri (PSNR: 29.7518 dB, SSIM: 0.8856).... 148
- Şekil 63. Çoklu ölçekli model kullanılarak Veri Kümesi 2 test kümesinden bir görüntünün $\times 2,4$ büyütme faktörü ile eğitilip $\times 4$ büyütme faktörü ile test edilmesinin süper çözünürlük sonuçları; (a) $10\times$ giriş görüntüsüne karşılık gelen derin CNN çıkış görüntüsü, (b,e) DÇ giriş görüntüsünün büyütülmüş ilgi bölgeleri ($10\times$), (c,f) çift kübik ara değerlendirme sonucunun büyütülmüş ilgi bölgeleri (PSNR: 23.5932 dB, SSIM: 0.6053), (d,g) derin CNN sonucunun büyütülmüş ilgi bölgeleri (PSNR: 25.3092 dB, SSIM: 0.6846).... 148
- Şekil 64. Renk değişimine karşı dayanıklılık modelinin süper çözünürlük sonuçları; (a) Veri Kümesi 1 görüntüleri ile eğitilmiş ağın $\times 2$ büyütme faktöründe Veri Kümesi 1 görüntüsüyle test edilmesinin süper çözünürlük sonucu, (b) Veri Kümesi 2 görüntüleri ile eğitilmiş ağın $\times 2$ büyütme faktöründe Veri Kümesi 1 görüntüsüyle test edilmesinin süper çözünürlük sonucu, (c) DÇ giriş görüntüsünün büyütülmüş ilgi bölgesi ($20\times$), (d) (a)'da verilen süper

özünürlük sonucunun büyütmüş ilgi bölgesi (PSNR: 26.0249 dB, SSIM: 0.8288), (e) (b)'de verilen süper özünürlük sonucunun büyütmüş ilgi bölgesi (PSNR: 25.9976 dB, SSIM: 0.8186), (f) orijinal YÇ görüntünün büyütmüş ilgi bölgesi..... 150

Şekil 65. Renk deęişimine karşı dayanıklılık modelinin süper özünürlük sonuçları; (a) Veri Kümesi 2 görüntüleri ile eğitilmiş aęın $\times 2$ büyütme faktöründe Veri Kümesi 2 görüntüsüyle test edilmesinin süper özünürlük sonucu, (b) Veri Kümesi 1 görüntüleri ile eğitilmiş aęın $\times 2$ büyütme faktöründe Veri Kümesi 2 görüntüsüyle test edilmesinin süper özünürlük sonucu, (c) DÇ giriş görüntüsünün büyütmüş ilgi bölgesi ($20\times$), (d) (a)'da verilen süper özünürlük sonucunun büyütmüş ilgi bölgesi (PSNR: 29.7103 dB, SSIM: 0.8516), (e) (b)'de verilen süper özünürlük sonucunun büyütmüş ilgi bölgesi (PSNR: 30.9416 dB, SSIM: 0.8795), (f) orijinal YÇ görüntünün büyütmüş ilgi bölgesi..... 151

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Dahili ve harici öğrenme odaklı tekniklerin öğrenme fonksiyonlarının karşılaştırılması	12
Tablo 2. Bileşen yerine koyma tabanlı yaklaşımlar için spektral ağırlıklar ve enjekte kazançları (k =çıkış bandı, i =giriş bandı)	30
Tablo 3. Çoklu çözünürlük analizi tabanlı yaklaşımların filtre türleri ve enjekte kazançları	31
Tablo 4. Konvolüsyonel sinir ağlarına dayalı mevcut yaklaşımların analizi	79
Tablo 5. Farklı ölçek faktörlerinin süper çözünürlük performansına etkisi (PSNR (dB)) ..	83
Tablo 6. Set5 veri kümesi üzerinde $\times 2$ büyütme faktöründe önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları	111
Tablo 7. Set14 veri kümesi üzerinde $\times 2$ büyütme faktöründe önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları	112
Tablo 8. Set5 veri kümesi üzerinde $\times 3$ büyütme faktöründe önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları	118
Tablo 9. Set14 veri kümesi üzerinde $\times 3$ büyütme faktöründe önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları	119
Tablo 10. Set5 ve Set14 veri kümesi üzerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları	120
Tablo 11. Blok sayısı (M) ve konvolüsyon katman sayısının (N) ağırlık performansına etkisi (PSNR (dB) ve zaman (saat))	121
Tablo 12. Set5, Set14, B100, Urban100 ve DIV2K validasyon veri kümesi üzerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları	128
Tablo 13. Set5 veri kümesi üzerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde önerilen yöntemin farklı bozunma modelleri kullanıldığında elde edilen PSNR (dB) sonuçları	130
Tablo 14. Quickbird_1 veri kümesi ile gerçekleştirilen temsili deneylerin sayısal değerlendirme sonuçları	138
Tablo 15. Quickbird_2 veri kümesi ile gerçekleştirilen temsili deneylerin sayısal değerlendirme sonuçları	139

Tablo 16. IKONOS_1 veri kümesi ile gerçekleştirilen temsili deneylerin sayısal değerlendirme sonuçları	142
Tablo 17. IKONOS_2 veri kümesi ile gerçekleştirilen temsili deneylerin sayısal değerlendirme sonuçları	143
Tablo 18. MaMic veri kümeleri için çift kübik interpolasyon ile tek ölçekli ve çoklu ölçekli modellerde derin CNN sonuçlarının ortalama PSNR (dB) ve SSIM değerleri	145
Tablo 19. MaMic veri kümeleri için çift kübik interpolasyon ile tek ölçekli ve çoklu ölçekli modellerde veri kümesi 1 ile eğitilmiş ağız veri kümesi 2 test görüntülerine ya da tam tersi uygulanmasının derin CNN sonuçlarının ortalama PSNR (dB) ve SSIM değerleri	150
Tablo 20. Farklı veri kümelerinde süper çözünürlük yöntemlerinin test edilmesi için sn cinsinden geçen süre	152

SEMBOLLER DİZİNİ

AdaGrad	: Adaptif Eğim (Adaptive Gradient)
Adam	: Adaptif Moment Tahmini (Adaptive Moment Estimation)
AFD	: Ayırık Fourier Dönüşümü (Discrete Fourier Transform)
AKD	: Ayırık Kosinüs Dönüşümü (Discrete Cosine Transform)
ATWT	: Toplamsal Dalgacık Dönüşümü (Additive A Trous Wavelet Transform)
AWLP	: ATWT Oransal Luminans Yöntemi (Additive Wavelet Luminance Proportional)
BDS	: Bant Bağımlı Uzamsal Detay (Band Dependent Spatial Detail)
BP	: Taban Arayış (Basis Pursuit)
CBD	: Doku Tabanlı Karar (Context Based Decision)
CC	: Korelasyon Katsayısı (Correlation Coefficient)
CNN	: Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
CS	: Bileşen Yerine Koyma (Component Substitution)
DÇ	: Düşük Çözünürlüklü
DWT	: Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform)
FIHS	: Hızlı Parlaklık Ton Doygunluk Dönüşümü (Fast Intensity-Hue-Saturation)
GA	: Genetik Algoritmalar (Genetic Algorithms)
GLP	: Genelleştirilmiş Laplacian Piramidi (Generalized Laplacian Pyramid)
GPU	: Grafik İşleme Ünitesi (Graphics Processing Unit)
GS	: Gram-Schmidt
GSA	: Adaptif <i>Gram-Schmidt</i> (Adaptive <i>Gram-Schmidt</i>)
HH	: Yüksek-Yüksek alt bant
HL	: Yüksek-Alçak alt bant
HPF	: Yüksek Geçiren Filtreleme (High-Pass Filtering)
IHS	: Parlaklık Ton Doygunluk Dönüşümü (Intensity-Hue-Saturation)
ILSVRC	: Büyük Ölçekli Görsel Tanıma Yarışması (Large Scale Visual Recognition Challenge)
LARS	: En Küçük Açısız Regresyon (Least Angle Regression)
LH	: Alçak-Yüksek alt bant
LL	: Alçak-Alçak alt bant

MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MOS	: Fikir Skorlarının Ortalaması (Mean Opinion Scores)
MP	: Uyumlu Arayış (Matching Pursuit)
MRA	: Çoklu Çözünürlük Analizi (Multiresolution Analysis)
MS	: Çoklu Spektral (Multispectral)
MSE	: Ortalama Karesel Hata (Mean Squared Error)
MTF	: Modülasyon Transfer Fonksiyonu (Modulation Transfer Function)
NCC	: Normalize Edilmiş Çapraz İlişki (Normalized Cross Correlation)
NIR	: Yakın Kızılötesi
NP	: Çok fazla gerekirci olmayan polinomial zaman (Non-deterministic polynomial time hard)
NTIRE	: Görüntü Restorasyonu ve İyileştirmesinde Yeni Trendler Yarışması (New Trends in Image Restoration and Enhancement)
OMP	: Ortogonal Uyumlu Arayış (Orthogonal Matching Pursuit)
PAN	: Pankromatik (Panchromatic)
PSNR	: Tepe Sinyal-Gürültü Oranı (Peak Signal to Noise Ratio)
RMSE	: Ortalama Karesel Hatanın Karekökü (Root Mean Square Error)
RMSProp	: Ortalama Karesel Yayılımın Karekökü (Root Mean Square Propagation)
SAM	: Spektral Açılı Haritalama (Spectral Angle Mapper)
SGD	: Olasılıksal Gradyan İniş (Stochastic Gradient Descent)
SSIM	: Yapısal Benzerlik İndeksi Ölçümü (Structural Similarity Index Measure)
SVD	: Tekil Değer Ayrıştırması (Singular Value Decomposition)
SVT	: Destek Vektör Dönüşümü (Support Value Transform)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
VOS	: Fikir Skorlarının Varyansı (Variance Opinion Scores)
YÇ	: Yüksek Çözünürlüklü

1. GENEL BİLGİLER

1.1. Giriş

Sayısal görüntü uygulamalarında, yüksek çözünürlüklü (YÇ) görüntü veya videolar genellikle sonraki aşamalarda uygulanacak olan görüntü işleme ve analizi için düşük çözünürlüklü (DÇ) görüntü ve videolara nazaran daha çok ilgi görmektedir. Görüntü çözünürlüğü, bir görüntünün içerdiği detaylar olarak tanımlanmakta olup görüntü çözünürlüğünün yüksek olması daha fazla görüntü detayı anlamına gelmektedir. Sayısal bir görüntüdeki çözünürlük birkaç farklı biçimde sınıflandırılabilir ve sayısal görüntü uygulamalarında daha çok uzamsal çözünürlükten bahsedilmektedir [1].

Sayısal bir görüntü piksel adı verilen küçük görüntü parçalarından oluşmaktadır. Uzamsal çözünürlük bir görüntüdeki piksel yoğunluğunu ifade eder ve birim alan başına düşen piksel sayısı ile ölçülür ve görüntü çözünürlüğü öncelikle görüntüleme aygıtı ya da sensörü tarafından sınırlanır. Görüntüleme aygıtından alınan görüntüler, aygıtın üretim hatası veya kısıtlaması ve nesnenin hareketi veya aygıtın sarsıntısından kaynaklanan gözlemlenen nesnenin dengesizliği gibi birçok faktörden etkilenmektedir. Sonuçta oluşan görüntülerde gürültü, bulanıklık ve zayıf çözünürlük gibi problemlerle karşı karşıya kalmaktadır [2].

Görüntü çözünürlüğünü başka bir ifade ile birim alan başına düşen piksel sayısını artırma sorununun çözümü için mümkün donanım tabanlı yaklaşımlar piksel boyutunu azaltma ve sensör boyutunu artırma gibi çözümleri içermektedir [3]. Piksel boyutunu azaltmak faydalı bir çözüm olmasına karşın günümüz teknolojilerinin ulaşabildiği belirli bir eşik değerinden daha fazla azaltmak sensördeki ilgili piksel hücrelerine ulaşan ışık miktarını da azaltacaktır. Bu da görüntü kalitesini oldukça fazla bozan saçma gürültüsü (shot noise) üretecektir. Ayrıca küçük boyutlu pikseller, büyük boyutlu piksellerle karşılaştırıldığında kırınım etkisine (diffraction effects) karşı daha hassastır. Bir diğer çözüm olan sensör boyutunu artırmak sistem kapasitesini artıracak ve yüksek kapasitanslar ise yük aktarım oranının hızlanmasını zorlaştıracaktır. Diğer taraftan yüksek hassasiyetli optik ve görüntü sensörlerinin yüksek maliyeti YÇ görüntülemeye ilişkin birçok ticari uygulamada önemli bir problemdir. Bu yüzden uzamsal çözünürlüğü artırmak için sensör ve optik üretim teknolojilerinin sınırlarının üstesinden gelen yeni bir yaklaşım gerekmektedir [3,4]. Bu

problemin çözümü için önerilen yaklaşım görüntü bozulmalarını kabul edip görüntüleme aygıtından elde edilen görüntüleri hesaplama maliyetini donanım maliyetiyle dengeleyerek sinyal işleme ve makine öğrenmesi teknikleri ile sonradan işlemektir. Bu teknikler süper çözünürlük olarak adlandırılır [1].

Süper çözünürlük, DÇ kameranın görüntüleme sürecinden kaynaklı bozulmaları kaldırarak ve yüksek frekans bileşenlerini artırarak bir ya da daha fazla DÇ gözlemden bir ya da daha fazla YÇ görüntü elde etme sürecidir. Başka bir deyişle, bir görüntüdeki birim alan başına düşen piksel sayısını artırarak görüntüleme aygıtının örnekleme ızgarasından daha iyi detaylar sağlamayı amaçlayan bir yaklaşımdır [5]. Süper çözünürlük ara değerlendirme ve restorasyon gibi benzer tekniklerle karıştırılmaktadır. Genellikle tek bir görüntüye uygulanan ara değerlendirme, bilinmeyen konumlardaki değerleri tahmin etmek için bilinen verileri kullanma süreci olarak tanımlanmaktadır. Ara değerlendirme literatürde kapsamlı bir şekilde çalışılmış olmasına rağmen basit fonksiyonlar kullanıldığı için DÇ görüntüden elde edilen görüntünün kalitesi oldukça sınırlıdır. Öyle ki DÇ örnekleme süreci boyunca bozulan ya da kaybolan yüksek frekans detaylarını iyileştirmez [2,6]. Bulanıklık kaldırma, keskinleştirme ve benzer tekniklerle elde edilen görüntü restorasyonunda, görüntü kalitesi iyileşirken giriş ve çıkış görüntü boyutları aynı kalmaktadır. Süper çözünürlükte ise çıkış görüntüsünün kalitesi iyileştirilirken görüntüdeki birim alan başına düşen piksel sayısı yani boyut artırılmaktadır [3].

Süper çözünürlük son yıllarda görüntüleme sisteminden kaynaklanan çözünürlük kısıtlamalarının üstesinden geldiği ve birçok görüntü işleme uygulamalarının performansını geliştirdiği için etkin bir çalışma alanı haline gelmiştir. Süper çözünürlüğün faydalı olduğu uygulamaları şu şekilde sıralayabiliriz [4]:

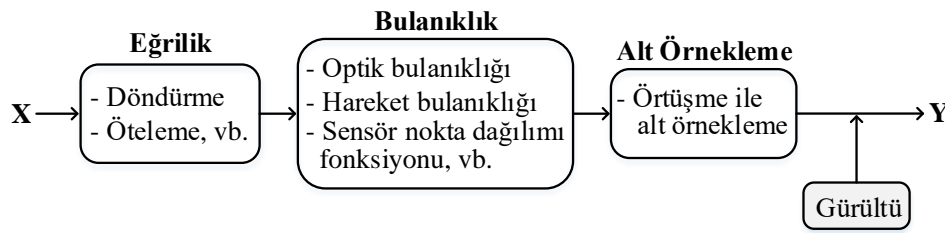
1. Medikal görüntüleme: Çözünürlük kalitesi sınırlı olan birçok görüntü elde edilebilir ve süper çözünürlük teknikleri çözünürlüğü geliştirmek için kullanılabilir.
2. Uzaktan algılama: Aynı alana ait birçok görüntü elde edilir ve geliştirilmiş çözünürlüklü görüntü elde edilebilir.
3. Gözetleme videosu: İnsan algılama için videodaki ilgili çerçeve dondurulur ve ilgi bölgesi yaklaştırılır; otomatik hedef tanıma için çözünürlük geliştirilir.
4. Video dönüşümü: Örneğin NTSC video sinyalinden HDTV sinyaline dönüşüm yapılabilir.
5. Kişisel fotoğrafları genişletmek, videoları yaklaştırmak için kullanılabilir.

1.2. Süper Çözünürlük

Süper çözünürlük, 1984 yılında Tsai ve Huang'ın [7] gerçekleştirdiği öncü çalışmadan sonra en etkin araştırma konularından biri olmuştur. Bu tarihten itibaren frekans domeninden uzamsal domene ve sinyal işleme alanından makine öğrenmesi alanına yaklaşımları temsil eden birçok yöntem önerilmiştir. Son yıllarda genellikle tüm görüntü bozulmalarını modelleme esnekliğine sahip uzamsal domendeki problemlere değinilen çalışmalar üzerinde durulmaktadır. Mevcut süper çözünürlük algoritmalarının çeşitlerinin incelenmesinden önce görüntü oluşum modelinin kurulması gerekmektedir.

1.2.1. Görüntü Oluşum Modeli

Sayısal görüntüleme sistemleri donanım kısıtlamalarından dolayı çeşitli türde bozulmalara sahip görüntüler üretmektedir. Bu sebeple süper çözünürlük problemini analiz etmenin ilk adımı, orijinal YÇ görüntüyü gözlemlenen DÇ görüntülerle ilişkilendiren bir görüntü oluşum modelinin kurulmasıdır. Literatürde birçok oluşum modeli önerilmiş ve bu modeller durağan görüntüler için modeller ve video dizileri için modeller olmak üzere kabaca ikiye ayrılmaktadır. Durağan görüntüler için Şekil 1'de gösterildiği gibi oluşturulmuş görüntü oluşum modelleri basitçe video dizisi modeline genişletilebilmektedir.



Şekil 1. Süper çözünürlük görüntü oluşum modeli

Şekil 1, YÇ görüntü, X , ile DÇ görüntüleri, Y_k , ilişkilendiren genel oluşum modelini göstermektedir. Gözlemlenen DÇ görüntü, YÇ görüntüde gerçekleştirilen eğrilik, bulanıklık ve alt örnekleme işlemlerinden sonra elde edilen görüntüye gürültü eklenmesiyle elde edilmektedir. X ve Y_k arasındaki matematiksel ilişkiyi kolay ifade etmek için görüntülerin sözlüksel (lexicographical) temsiliyeti kullanılmaktadır. Bu temsiliyette görüntünün tüm

satırlar birbirine eklenerek uzun bir kolon vektörü oluşturulmaktadır. Böylece $M \times N$ boyutundaki bir DÇ Y görüntüsü $MN \times 1$ boyutlu kolon vektörü olarak temsil edilmektedir. Benzer biçimde X YÇ görüntüsü ise l_1 ve l_2 'nin sırasıyla dikey ve yatay yönlerde alt örnekleme faktörünü ifade ettiği $l_1 M l_2 N \times 1$ boyutlu bir vektördür.

İstenen YÇ görüntü X ve kameradan alınan k . DÇ gözlem Y_k ile gösterilsin. Kameranın K tane DÇ çerçeve yakaladığı farzedilirse, YÇ sahne ile ilişkili DÇ gözlemler (1) eşitliği ile ifade edilmektedir.

$$Y_k = DH_k F_k X + V_k, k = 1, 2, \dots, K, \quad (1)$$

Burada F_k k . çerçeve için eğrilik bilgisini, H_k bulanıklık etkisini, V_k gürültü terimini ve D alt örnekleme operatörünü göstermektedir. Alt örnekleme operatörü, YÇ görüntünün alt örneklenecek boyutunun azaltılmasını ifade eden $MN \times l_1 M l_2 N$ boyutlu bir matristir. Örneğin; bir YÇ görüntüde q^2 piksel boyutluk her bir pencere, q^2 piksel değerinin ortalamasının alınmasıyla DÇ gözlemlenen görüntüde sadece tek bir piksele karşılık düşer. Bulanıklık fonksiyonu, optik sistem (lens ya da sensör) ya da atmosferik etkilerden kaynaklı DÇ gözlemlenen görüntünün etkilendiği herhangi bir bulanıklık fonksiyonunu ifade eden $l_1 M l_2 N \times l_1 M l_2 N$ boyutlu bir matristir. Eğrilik fonksiyonu ise DÇ gözlemlenen görüntü ile YÇ görüntü arasındaki herhangi bir dönüşüme karşılık gelmektedir ve yine $l_1 M l_2 N \times l_1 M l_2 N$ boyutlu bir matris ile ifade edilmektedir. V gürültü terimi ise $MN \times 1$ boyutlu bir vektördür. 4×4 boyutlu örnek bir görüntü için alt örnekleme D , bulanıklık H ve eğrilik F işlemleri sözlüksel temsiliyette Ek 1'de açık bir şekilde verilmektedir. Aksi durum belirtilmedikçe tezin tamamında tüm eşitlikler için sözlüksel temsiliyet kullanılmıştır.

Genel olarak görüntü oluşum modellerinde önce eğrilik ardından bulanıklık uygulanmasına rağmen bazı araştırmacılar önce bulanıklık ardından eğrilik uygulayarak fonksiyonların sırasını değiştirmişlerdir [3]. Verilen doğrusal eşitlikler geniş bir doğrusal sistem olarak (2)'deki gibi yeniden düzenlenebilir.

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_K \end{bmatrix} = \begin{bmatrix} DH_1 F_1 \\ DH_2 F_2 \\ \vdots \\ DH_K F_K \end{bmatrix} X + \underline{V} \quad (2)$$

(2) eşitliği ise daha genel biçimde (3) ile ifade edilmektedir.

$$\underline{Y} = M\underline{X} + \underline{V} \quad (3)$$

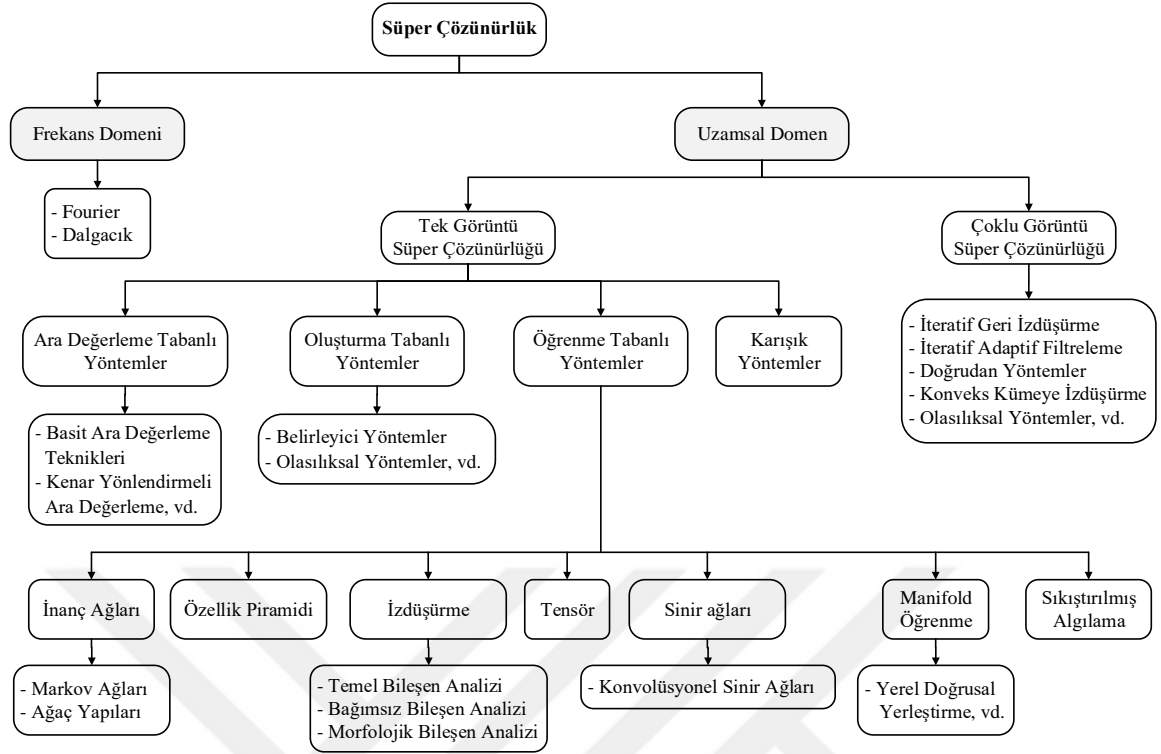
Eşitlik (1)'de verilen eşitliğin içerdiği D , H_k , F_k matrisleri ya da Eşitlik (3)'te verilen M matrisi oldukça seyrek ve bu doğrusal sistem genel anlamda kötü konumlanmıştır. Ayrıca, gerçek görüntüleme sistemlerinde bu matrisler bilinmemekte ve mevcut DÇ gözlemlerden tahmin edilmektedir. Bu da problemi daha kötü koşullu yapmaktadır. Eşitlik (1)'de verilen görüntü oluşum modeline bağlı kalındığında, süper çözünürlüklü görüntü oluşturmanın amacı, Y_k DÇ gözlemlerden X YÇ görüntüsünün tahmin edilmesidir. Bir sonraki bölümde problemin çözümü için literatürde önerilen temel süper çözünürlük teknikleri detaylı olarak anlatılacaktır.

1.2.2. Süper Çözünürlük Teknikleri

Son yıllarda süper çözünürlüklü görüntü oluşturma için çeşitli yöntemler araştırmacılar tarafından önerilmiştir. Önerilen çalışmalar incelendiğinde süper çözünürlük algoritmaları süper çözünürlüğün uygulandığı uzay, kullanılan DÇ görüntü sayısı ve oluşum metodu gibi faktörlere bağlı olarak sınıflandırılmaktadır. Şekil 2'de, literatürde var olan süper çözünürlük algoritmalarının türleri gösterilmiştir [3].

Süper çözünürlüğün gerçekleştirildiği uzaya dayandırıldığında literatürdeki mevcut yaklaşımlar frekans ve uzamsal uzayda yapılan çalışmalar olarak ikiye ayrılmaktadır. İlk süper çözünürlük yaklaşımları frekans uzayında sinyal işleme tekniklerinin kullanılmasıyla ortaya atılsa da önerilen yaklaşımların büyük bir kısmının uzamsal uzayda geliştirildiği görülmektedir. Kullanılan DÇ görüntü sayısı bakımından süper çözünürlük yaklaşımları tek görüntü ve çoklu görüntü süper çözünürlüğü olarak iki sınıfa ayrılmaktadır [3].

Frekans uzayında gerçekleştirilen çalışmalarda, süper çözünürlük probleminin formüle edilmesi ve çözümü frekans uzayında gerçekleşmektedir. Ayrıca, bu alandaki algoritmaların büyük bir kısmı çoklu DÇ görüntü kullanmaktadır. YÇ görüntü oluşturma için Ayrık Fourier Dönüşümü (AFD) [7], Ayrık Kosinüs Dönüşümü (AKD) [8] ve Dalgacık dönüşümleri [9,10] araştırmacılar tarafından kullanılmıştır.

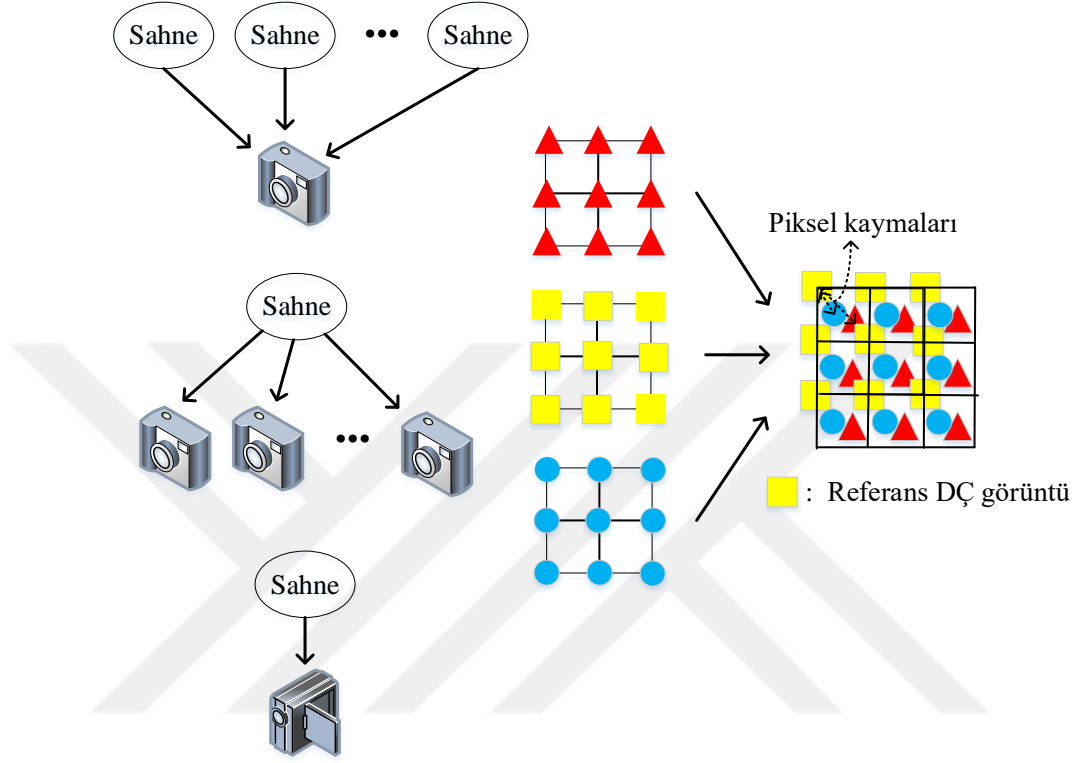


Şekil 2. Süper çözünürlük algoritma türleri

Fakat gerçek zamanlı uygulamalarda görüntü oluşum modelinin ve devinim kestiriminin modellenmesinde esnek olmaması, hataya duyarlı olması, yetersiz önsel modeller ve karmaşık matematiksel formüller gibi sınırlamalara sahiptir. Bu eksikliklerin üstesinden gelmek için araştırmacılar uzamsal uzaydaki teknikler üzerinde çalışmaya başlamışlardır [11].

Uzamsal uzayda, süper çözünürlüklü görüntü oluşturma süreci piksel değerlerini güncelleyerek görüntü uzayında gerçekleştirilir. Kullanılan giriş görüntü sayısına bağlı olarak teknikler tek görüntü ve çoklu görüntü süper çözünürlüğü olmak üzere ikiye ayrılmaktadır. Çoklu görüntü süper çözünürlüğünde birden fazla DÇ görüntü giriş olarak alınmaktadır. Aynı sahnede farklı görünüşler elde etmek için çoklu sahne ya da video dizisi aracılığıyla çerçeveden çerçeveye değişen bağıl sahne hareketleri gerekmektedir. Çoklu sahneler bir kameradan birkaç sahne çekimi ile ya da farklı pozisyonlarda konumlandırılmış çoklu kameralardan elde edilebilir. Buradaki mevcut sahne hareketleri, görüntüleme sistemindeki kontrollü hareketlerden meydana gelmektedir. Aynı durum kontrolsüz hareket denilen nesnenin hareketi ya da görüntüleme aygıtının titreşimi gibi hareketlerden de meydana gelebilir. Çoklu görüntü süper çözünürlüğünde hedef, YÇ bir ızgara üzerindeki DÇ

görüntülerin piksel kaymalarını birleştirmek için hareketleri tahmin etmektir. Bu sahne hareketleri bilinir veya tahmin edilebilirse ve bu DÇ görüntüler birleştirilirse süper çözünürlüklü görüntü oluşumu Şekil 3'teki gibi gösterilebilir [2].



Şekil 3. Çoklu görüntü süper çözünürlüğü için çakıştırma süreci

Çoklu görüntü süper çözünürlüğünün verimliliği çoğunlukla gözlemlenen farklı DÇ görüntüler arasındaki hareketin tahmini olarak ifade edilen çakıştırma hatasına bağlıdır. Pratik uygulamalarda aynı çerçevede bulunan nesnelere hareketleri ve yönlerinde birbirlerinden farklı olduklarından hareket tahmini kararsız ve karmaşık bir süreçtir. Bu problemlerin üstesinden gelmek için YÇ görüntü oluşumu için tek bir DÇ görüntünün kullanıldığı tek görüntü süper çözünürlüğü kullanılmaktadır [11].

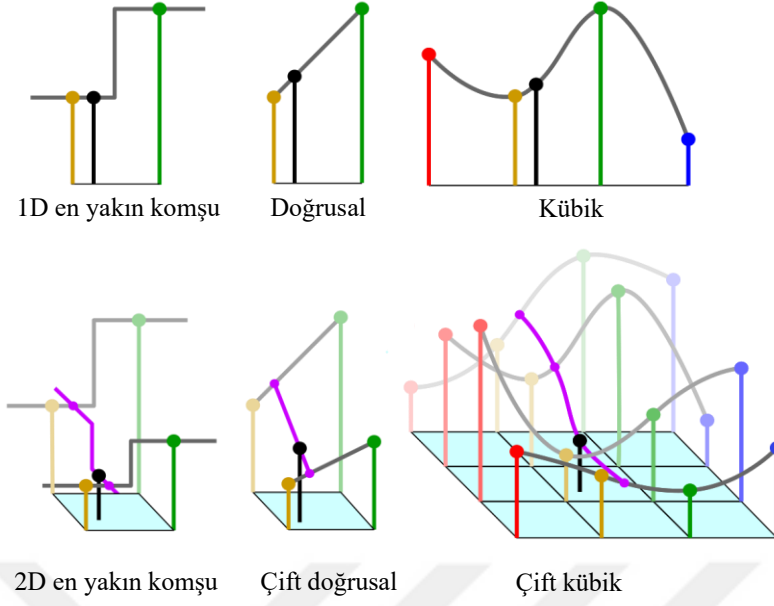
Tek görüntü süper çözünürlüğü pratik uygulamalarda da yüksek fayda sağladığından dolayı son yıllarda en çok araştırılan alanlardan biridir. Yapılan çalışmalar tek görüntü süper çözünürlüğü algoritmalarının performansını artırmak için geliştirilen ve iyileştirilen teknikler üzerinedir. YÇ görüntüyü oluşturma sürecine bağlı olarak algoritmalar ara değerlendirme tabanlı, oluşturma tabanlı, öğrenme tabanlı ve bu üç yöntemin birleştirilmesiyle oluşturulmuş karışık yöntemler olarak kategorize edilebilir.

1.2.2.1. Ara Değerleme Tabanlı Yöntemler

Ara değerlendirme tabanlı tek görüntü süper çözünürlüğünde hedef komşu pikseller yardımıyla kayıp piksellerin değerlerini tahmin ederek DÇ görüntüyü YÇ görüntüye dönüştürmektir. İlk olarak DÇ görüntünün çözünürlüğünü artırmak için sinyal işlemenin ara değerlendirme tekniklerinden yararlanılmıştır. Ara değerlendirme teknikleri basit ara değerlendirme ve kenar yönlendirmeli ara değerlendirme teknikleri olarak sınıflandırılmaktadır.

Basit ara değerlendirme teknikleri doğrusal ya da doğrusal olmayan teknikler olarak ikiye ayrılır. Doğrusal ara değerlendirme, çift doğrusal ve en yakın komşu gibi tek boyutlu ara değerlendirme tekniklerinde kullanılan doğrusal eşitliğin benzerini kullanmaktadır. Doğrusal olmayan ara değerlendirme ise kübik, çift kübik, bağlayıcı (spline), çokterimli ve diğer çeşitlerini içermektedir. 1 ve 2 boyutlu bazı ara değerlendirme fonksiyonlarının karşılaştırılması Şekil 4'te gösterilmektedir. Burada siyah nokta ara değerlendirilmiş noktaya karşılık düşerken kırmızı, sarı, yeşil ve mavi noktalar komşu örnekleri göstermektedir. Basit ara değerlendirme teknikleri uygulamada hızlı olmalarına rağmen bilinen piksellerden yararlanarak YÇ bir ızgara üzerinde bilinmeyen pikselleri hesapladıklarından yumuşak geçişlerde iyi çalışırken kenar ve köşe bölgeler gibi süreksizliğin olduğu yerlerde salınım ve bulanıklığa sebep olurlar [1].

Basit ara değerlendirme tekniklerinin olumsuz etkilerinin üstesinden gelmek için kenar yönlendirmeli ara değerlendirme teknikleri kullanılarak YÇ görüntü kalitesi artırılmıştır. Kenar yönlendirmeli yöntemler, ara değerlendirme yapılacak noktanın etrafındaki geniş bölgede kenar özelliklerini karakterize ederek ara değerlemenin doğruluğunu geliştirmeye çalışmaktadır. Bu sebeple öncelikle görüntüdeki yüksek doku ve kenar bölgeleri belirlenir ve bulanıklığı önlemek için yüksek doku ve kenarlar boyunca ara değerlendirme yapılarak genellikle daha keskin kenar bilgisine sahip görüntüler üretilmektedir. Yöntemlerin performansı yüksek doku bölgesini görüntüden ayırma performansına bağlı olarak değişmektedir. Benzer şekilde uzamsal adaptif tekniklerde de öncelikle kenar ve diğer doku bölgeleri yapılarına göre farklı kategorilere gruplandırılır ve ardından ara değerlendirme teknikleri bu gruplara uygulanmaktadır.



Şekil 4. 1 ve 2 boyutlu ara değerlendirme fonksiyonlarının karşılaştırılması

Genel olarak mevcut kenar yönlendirmeli ve uzamsal adaptif ara değerlendirme tekniklerinin temel problemi, görüntüdeki yeni bilginin ve yüksek frekans bileşenlerinin üretilmesi ve kenar özelliklerin korunmasıdır. Diğer süper çözünürlük yaklaşımlarına göre hızlı ve uygulanmaları kolay olmalarına rağmen sonuç görüntülerinde bulanıklığa ve tırtıklı yapıya sebep olduklarından birçok süper çözünürlük uygulaması için uygun değildir.

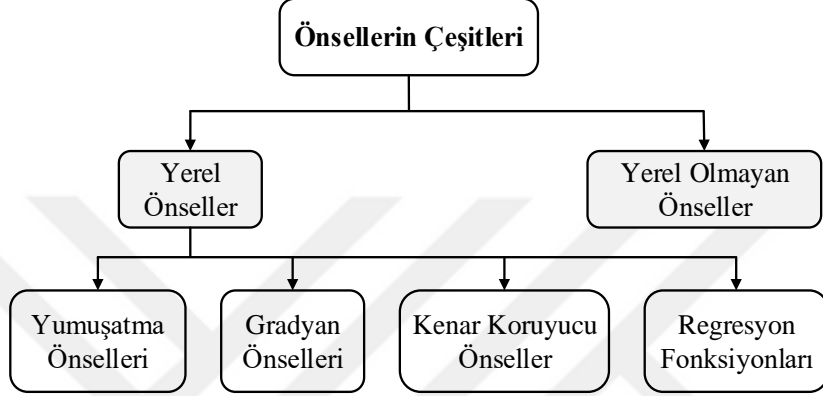
1.2.2.2. Oluşturma Tabanlı Yöntemler

Ara değerlendirilmiş görüntünün eksikliklerinin ve bozucu etkilerinin üstesinden gelmek için farklı düzenleme ya da oluşturma tabanlı teknikler YÇ görüntü oluşumu için DÇ görüntüye uygulanmıştır. Oluşturma tabanlı tek görüntü süper çözünürlüğünde yöntemler mümkün çözüm sayısını sınırlandırmak için kısıtlama olarak kullanılan farklı önsel bilgilerden yararlanırlar [1]. Önseller genellikle bulanıklık ve basamak etkisini azaltmak için tasarlanır ve kötü konumlanmış ters probleme düzenleme terimi kullanılarak eklenir. Böylece problem (4)'te verildiği gibi düzenlenebilir.

$$\hat{X} = \underset{X}{\operatorname{argmin}} \|Y - DHFX\|_2^2 + \lambda\rho(X) \quad (4)$$

Burada $\lambda\rho(\mathbf{X})$ düzenleme terimi, λ veri uygunluğu ile düzenleme terimini dengeleyen parametre ve $\rho(\mathbf{X})$ önselinden oluşmaktadır [12].

Düzenleme terimi olarak eklenecek önsel sayısı yöntemin gerekliliğine bağlı olarak birden fazla olabilir. Önselin seçimi görüntünün özelliklerine bağlıdır ve önseller Şekil 5'teki gibi yerel ve yerel olmayan önseller olarak ikiye ayrılmaktadır.



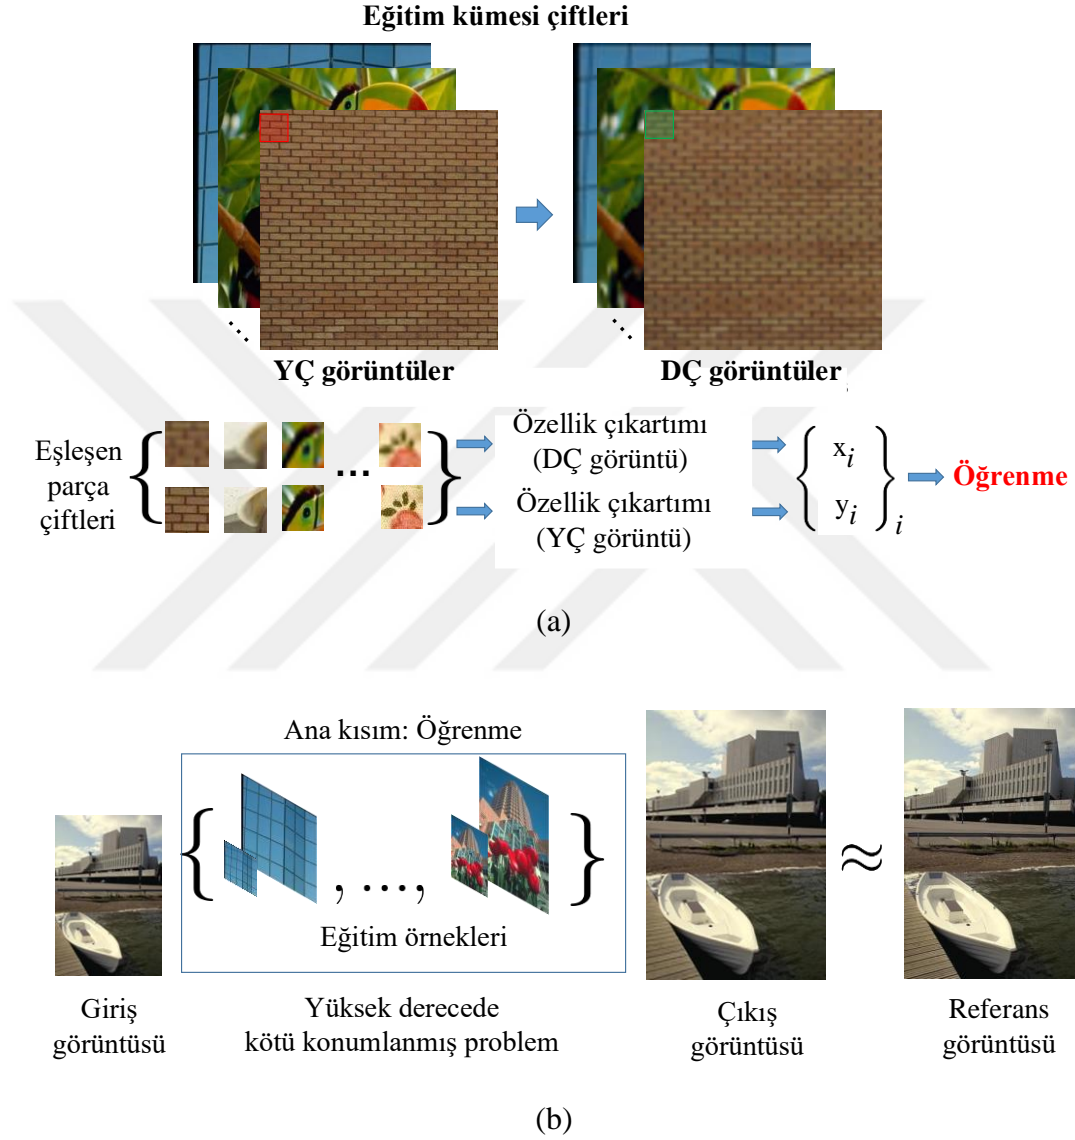
Şekil 5. Oluşturma tabanlı yöntemlerde kullanılan önsel çeşitleri

Yerel önseller, görüntünün istatistik ve yerel özelliklerinden yararlanılarak ters problemi çözmek için kısıtlama olarak kullanılırlar. Bu alanda farklı önsel terimleri önerilmiştir. Yerel olmayan önsellerde görüntüde var olan yerel olmayan benzerlikler ters problemi düzenleştirmek için kullanılır. Oluşturma tabanlı süper çözünürlük yaklaşımları çok fazla sayıda matematiksel hesaplama gerektirmektedir, fakat ara değerlendirme tabanlı yöntemlerden daha iyi sonuç vermektedir. Önseller gürültüyü bastırmada ve kenar bilgisini korumada verimli olmasına rağmen YÇ görüntü oluşturmada görüntüye yapaylık katmaktadır. Bunun yanında oluşturulan YÇ görüntünün başarısı yüksek oranda kullanılan önselle bağlı olduğundan ve yeni bir önselin önerilmesi büyük bir sorun oluşturduğundan son yıllarda öğrenme tabanlı yöntemler kullanılarak çalışmalar yapılmaktadır.

1.2.2.3. Öğrenme Tabanlı Yöntemler

Öğrenme tabanlı tek görüntü süper çözünürlüğü tekniklerinin amacı görüntüdeki yüksek frekans bilgisini korumak ve aynı zamanda istenen çözünürlüğe kadar görüntüyü

büyütmektir. Öğrenme tabanlı süper çözünürlük yaklaşımları çoğunlukla DÇ ve YÇ görüntülerden doğrusal olmayan eşleşme fonksiyonunu öğrenmek için örnek çiftleri kullanmaktadır [13].



Şekil 6. Öğrenme tabanlı tek görüntü süper çözünürlüğü yaklaşımlarının (a) eğitim süreci ve (b) YÇ görüntü oluşturma süreci

Öğrenme tabanlı tek görüntü süper çözünürlüğü yaklaşımları Şekil 6'da gösterildiği gibi iki aşamadan oluşmaktadır: eğitim süreci ve YÇ görüntü oluşturma süreci. Eğitim sürecinde standart bir veritabanı kullanılarak sistem eğitilmekte ve bu aşamayı YÇ görüntü oluşturma süreci takip etmektedir. Burada öğrenme analitik ve sentetik olabilmektedir.

Analitik öğrenme Fourier, Dalgacık, Curvelet, Contourlet, Bandlet gibi tanımlı fonksiyonlar kullanılarak gerçekleştirilmektedir. Analitik öğrenme gerçekleştirilmesi hızlı olmasına karşın yüksek boyutlu veriler için tasarlanması zordur. Sentetik öğrenmede ise DÇ ve YÇ görüntü parçaları kullanılmaktadır. Bu alandaki çalışmalar harici ve dâhili öğrenme odaklı teknikler olmak üzere iki yönde geliştirilmektedir.

DÇ ve YÇ parça çifti verildiğinde geleneksel harici öğrenme odaklı teknikler sözlük öğrenmesi, regresyon, rastgele ormanlar ve konvolüsyonel sinir ağları gibi yöntemler kullanarak eşleşme fonksiyonunu eğitmektedir. Diğer bir deyişle, görüntü çiftlerinden oluşan geniş harici bir kümedeki DÇ ve YÇ görüntü parçaları arasındaki eşleşmeyi öğrenmektedir. Buna karşın, dâhili öğrenme tabanlı yöntemler görüntü ölçeğini artırarak YÇ görüntüyü oluştururlar. Oluşturma yaklaşımı kendine benzeme özelliğine dayandırılmaktadır; yani doğal görüntülerdeki küçük parçalar görüntünün kendisinde ya da farklı ölçeklerinde kendini tekrarlamaktadır [14]. Her bir yöntemin kendine göre güçlü ve zayıf olduğu yanlar bulunmaktadır. Dâhili ve harici öğrenme odaklı tekniklerin öğrenme fonksiyonlarının karşılaştırılması Tablo 1’de verilmektedir.

Tablo 1. Dahili ve harici öğrenme odaklı tekniklerin öğrenme fonksiyonlarının karşılaştırılması

Harici Öğrenme Odaklı Teknikler	Dahili Öğrenme Odaklı Teknikler
Standart görüntü kümesi gereklidir	Harici veritabanına ihtiyaç yoktur
Giriş görüntüsünden farklı olarak çevrimdışı öğrenme süreci	Giriş görüntüsü yardımıyla çevrimiçi öğrenme süreci
Geniş bellek ihtiyacı	Az bellek ihtiyacı
Giriş görüntüsüne benzer dokuda görüntüler veritabanında bulunduğu performans artar	Giriş görüntüsü içerisindeki benzerlik derecesi arttığında performans artar
Sabit ve giriş görüntüsüne adapte edilemez	Görüntünün kendisinden oluşturulduğu için çeşitlendirilebilir

Öğrenme tabanlı yöntemlerin çeşitleri, dâhili ya da harici öğrenme odaklı teknikleri kullanılmaktadır. Bu yöntemler Şekil 2’de gösterildiği üzere yedi kısma ayrılmaktadır.

- Özellik Piramidi tabanlı yöntemler: Özellik piramitlerinde, Gauss, Laplace gibi bazı belirli özellikler tabanlı piramitler görüntünün bulanıklaştırılması ve alt örneklenmesiyle iteratif olarak oluşturulur. Bu süreç eğitim için kullanılır ve ardından YÇ görüntü, DÇ görüntünün ona eşleştirilmesiyle oluşturulmaktadır. Bu alanda Gradyan piramit tabanlı tahmin [15], döndürülebilir piramit yapısı [16], Laplacian

piramidi [17] gibi farklı teknikler kullanılmaktadır. Görüntüden benzerliğin çıkarılması için bu teknikler sıklıkla kullanılmaktadır, fakat görüntülerin dönme ve ötelenmeden kaynaklı kaymasıyla meydana gelen görüntülerde bazı sınırlandırmalara sahiptir.

- İnanç Ağları tabanlı yöntemler: İnanç Ağları, eğitim sürecinde bileşik olasılık dağılımını çarpanlarına ayırmak (factorize) için bayesçi yaklaşım kullanan modellerdir. Bunun için genellikle ağaç yapısı [18] ya da Markov ağı [19, 20] kullanılır. Markov ağlarında, geçiş fonksiyonu YÇ görüntüdeki komşu parçalar arasındaki ilişkiyi tahmin etmek için kullanılır. Gözlem fonksiyonu ise eşleşme amacıyla DÇ ve YÇ çiftlerin yardımıyla hesaplanmaktadır. Yüksek hesaplama gerektirmektedir. Ağaç yapısı da benzer şekilde eğitim sürecindeki görüntülerin DÇ ve YÇ parçalarındaki ilişkiyi formülize etmek ve gözlemlemek için kullanılır ve arama algoritmasını hızlandırmaya yardım etmektedir.
- İzdüşürme tabanlı yöntemler: İzdüşürmeler global önselleri matematiksel eşitliklere dahil etmek için süper çözünürlüklü görüntü oluşturmada yerel kısıtlamalarla birlikte kullanılır. Temel Bileşen Analizi (PCA) [21,22], Bağımsız Bileşen Analizi [23], Morfolojik Bileşen Analizi [24] yöntemleri tercih edilmektedir. Doğrusal olmayan problemler için ise Çekirdek PCA [25], Maximum A Posteriori yönteminde önsel olarak kullanılmıştır. Doğrusal olmayan yaklaşımlar karmaşık korelasyona sahip görüntüleri temsil etmeye yardımcı olmaktadır. Radyal temelli fonksiyonlar [26], Gabor filtresi [27] gibi farklı teknikler ile birlikte kullanılırlar.
- Sinir Ağları tabanlı yöntemler: Sinir ağları yapay zekâ tabanlıdır ve öğrenme tabanlı yaklaşımlarda eğitim sürecinde kullanılmaktadır. Bu sınıfa giren algoritmalarından Rastgele Ormanlar [28, 29] ve Konvolüsyonel Sinir Ağları [30] bu alanda kullanılan en son yaklaşımlardandır. Birçok yöntem yüksek boyut gerektirmektedir. Bu problem derin bir yapı ile birlikte seyrek kodlama tabanlı ağların uzantısı olarak düşünülen derin konvolüsyonel sinir ağları kullanılarak DÇ ve YÇ görüntüler arasındaki uçtan uca ilişkinin öğrenilmesiyle çözülmüştür. Bu yöntemlerin hesaplama karmaşıklıkları yüksektir.

- **Manifold tabanlı yöntemler:** Manifold tabanlı yöntemler, doğal görüntülerdeki komşuluklarda var olan benzerliklerden yararlanarak süper çözünürlük sürecinde boyut azaltımı olarak kullanılmaktadır. Genellikle PCA ve Doğrusal Ayırtaç Analizi yöntemlerinin, Öklid olmayan yapılarından dolayı başarısız olduğu durumlarda manifold teknikler kullanılmaktadır. Bu algoritmalarda görsel ilkeler (visual primitives) özellik çıkarma olarak kullanılır. Süper çözünürlük probleminin çözümü için Komşu Yerleştirme (Neighbor Embedding) [31], genel manifold teknikleri [32,33], Yerel Doğrusal Yerleştirme tekniği (Locally Linear Embedding Technique) [34], Ortogonal Yerelliği Koruma İzdüşümü (Orthogonal Locality Preserving Projections) [35], Yerelliği Koruma İzdüşümü (Locality Preserving Projection) [36] teknikleri gibi yöntemler kullanılmıştır. Önerilen çalışmalarda; kullanılan parça sayısı, parçaların boyutları, parçalar arasındaki örtüşme, özellik seçimi gibi faktörler süper çözünürlüğün performansını etkilemektedir. Yerleştirme işlemi ve analizi geniş parça boyutlarında karmaşık olurken küçük parça boyutu kullanıldığında görüntünün genel özelliklerinden yararlanılamaz.
- **Tensör tabanlı yöntemler:** Tensör tabanlı yöntemlerde, DÇ ve YÇ çiftler arasındaki eşleşmeyi sağlamak amacıyla yüksek dereceden matrisler ve vektörler verinin çok kipli uzaya dağılması için kullanılmaktadır. Yüz sanrısı (face hallucination) olarak bilinen yüze uygulanan süper çözünürlük tekniklerinde sıklıkla tensör tabanlı yöntemler tercih edilmektedir [37-39].
- **Sıkıştırılmış Algılama tabanlı yöntemler:** Sıkıştırılmış algılama sinyal işleme tabanlıdır ve undetermined problemin çözümünü bularak süper çözünürlüklü görüntü oluşturmaya yardım etmektedir. Bilinen seyrek dönüşüm uzayında görüntünün uygunluk terimini küçültme ve seyrekliğini büyütme üzerinde durmaktadır. Genellikle eğitim süreci biri YÇ ve biri DÇ olmak üzere iki sözlüğün eğitilmesini kapsamaktadır. Sıkıştırılmış algılama sinyallerin fazlalığından yararlanmaktadır. Bu teknikler daha gürbüz ve kararlı sonuçlar vermekte ve DÇ-YÇ çiftler arasındaki doğrusal olmayan ilişkiyi yararına kullanabilmektedir.

1.3. Tezin Kapsamı

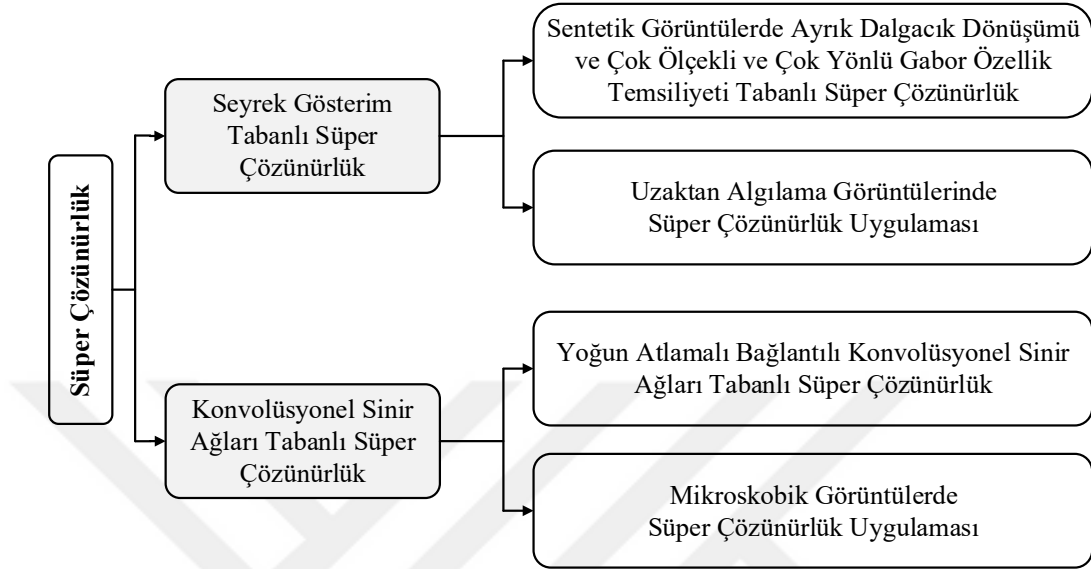
Süper çözünürlüğün önemi, YÇ görüntülerin birçok görüntü işleme uygulamasının performansını geliştirdiği ve süper çözünürlüğün faydalı olduğu uygulama alanları düşünülerek bu tez çalışmasında DÇ görüntülerden YÇ görüntülerin yüksek başarı oranı ile oluşturulması hedeflenmiştir. Bu kapsamda sentetik görüntüler üzerinde farklı öğrenme tabanlı yaklaşımlar önerilmiş ve uzaktan algılama ile medikal görüntüler üzerinde benzer yaklaşımların uygulamaları gerçekleştirilmiştir.

Sentetik görüntüler üzerinde gerçekleştirilen öğrenme tabanlı yaklaşımlarda literatürdeki süper çözünürlük alanında kullanılan ortak veri setleri üzerinde eğitimler yapılmıştır. YÇ görüntü oluşturma sürecinde Dalgacık ve Gabor dalgacıklarına dayalı seyrek gösterim tabanlı yaklaşımlar önerilerek süper çözünürlüğün performansı artırılmış ve literatürde süper çözünürlük alanında daha başarılı sonuçlar vererek yeni bir yöntem olarak kullanılan konvolüsyonel sinir ağları tabanlı yaklaşımlarda da farklı ağ yapılarının süper çözünürlüğün performansına etkisi analiz edilmiştir. Önerilen yaklaşımlar yine literatürde var olan ortak veri setleri üzerinde test edilerek mevcut önerilmiş çalışmalarla sayısal ve görsel karşılaştırmalar yapılmıştır.

Süper çözünürlüğün gerçek görüntüler üzerinde başarısını incelemek için seyrek gösterim tabanlı bir yaklaşım önerilerek uydudan alınan çoklu spektral (MS) görüntülerin içerdiği düşük çözünürlüğe sahip renkli bantların yüksek çözünürlüğe sahip pankromatik (PAN) bantlar kullanılarak çözünürlüğü artırılmıştır. Farklı bir uygulama alanı olarak düşük büyütme faktörlerinde mikroskoptan alınan görüntülerin konvolüsyonel sinir ağları tabanlı süper çözünürlük yaklaşımı kullanılarak çözünürlüğü artırılmış ve yüksek büyütme faktörlerinde alınan görüntülerle karşılaştırılması yapılarak önerilen yaklaşımın performansı incelenmiştir. Tez içeriğinin genel yapısını oluşturan şema Şekil 7'de gösterilmektedir.

Tezin genel bilgiler bölümünde Şekil 7'de verilen her bir süper çözünürlük yaklaşımı için ayrı ayrı konu tanıtımı, literatür taraması ve literatürde kullanılan yöntemlerin kısaca tanımlamaları yapılacaktır. Yapılan çalışmalar bölümünde ise süper çözünürlük problemi için gerçekleştirdiğimiz çalışmalar deney ve sonuçlardan bağımsız olarak özetlenecek ve seyrek gösterim ve konvolüsyonel sinir ağları tabanlı süper çözünürlük alanında önerilen yöntemler açıklanacaktır. Bulgular ve irdeleme bölümünde de elde edilen sayısal ve görsel sonuçlar irdelenip yorumlanacak ve literatürde bu alanlarda yapılmış süper çözünürlük

çalışmalarıyla karşılaştırılacaktır. Çalışmanın son kısmında ise bu tez kapsamında ve gelecekte yapılabilecek diğer çalışmalar için bazı öneriler sunulmaktadır.



Şekil 7. Tez içeriğinin genel yapısı

1.4. Seyrek Gösterim Tabanlı Süper Çözünürlük

Seyrek sinyal gösterimi, yüksek boyutlu sinyalleri elde etme, temsil etme ve sıkıştırmada oldukça güçlü bir araçtır. Bu başarısının başlıca sebebi ise ses ve görüntü gibi önemli sinyallerin bazı sabit temellere (Fourier, dalgacık gibi) ya da bunların birleşimlerine göre seyrek temsiliyetlere sahip olmalarıdır. Ayrıca, bu temsiliyetleri yüksek uygunlukla hesaplamak için konveks optimizasyon ya da açgöz arama (greedy pursuit) tabanlı etkili algoritmalar mevcuttur. Seyrek gösterimi başarılı bir şekilde bilgisayarla görü alanına uygulamada veriyi temsil etmek için temelin nasıl doğru bir şekilde seçileceği problemi çözmek gerekmektedir. Klasik sinyal işlemede kullanımından farklı olarak bilgisayarla görüde verilen örnek görüntülerden overcomplete bir sözlüğün öğrenilmesi gerekmektedir [40]. Bu yüzden seyrek gösterim teorisi seyrek kodlama ve sözlük öğrenmesi arasında değişimli olarak gerçekleştirilen iteratif bir şema sunmaktadır. Seyrek kodlama ve sözlük öğrenmesi alt başlıklarda detaylı olarak anlatılacaktır.

1.4.1. Seyrek Kodlama

$\mathbf{X} \in \mathbb{R}^{m \times N}$, N kolondan oluşan $\mathbf{x}_j \in \mathbb{R}^m$ veri vektörlerinin (görüntü parçalarının) bir kümesi ve $\mathbf{D} \in \mathbb{R}^{m \times K}$, $\mathbf{d}_k \in \mathbb{R}^m$ kolonları olarak ifade edilen K atomlu bir sözlük olarak verilsin. Her bir \mathbf{x}_j veri vektörü ona karşılık düşen $\boldsymbol{\alpha}_j \in \mathbb{R}^K$ katsayılarından oluşan bir vektöre sahiptir ve her bir vektör (5)'te gösterildiği gibi matrisin bir kolonunu oluşturmaktadır.

$$\mathbf{A} = [\boldsymbol{\alpha}_1, \dots, \boldsymbol{\alpha}_N] \in \mathbb{R}^{K \times N} \quad (5)$$

Seyrek gösterimin amacı, $\mathbf{X} \simeq \mathbf{DA}$ eşitliğini tüm ya da çoğu \mathbf{x}_j veri örneği için $\|\boldsymbol{\alpha}_j\|_0$ 'nin yeterince küçük olması şartıyla sağlayan bir \mathbf{D} sözlüğü tasarlamaktır. Sabit bir \mathbf{D} sözlüğü için \mathbf{A} 'nın hesaplanması seyrek kodlama olarak adlandırılmaktadır. Burada \mathbf{X} 'in temsiliyeti kesin olarak $\mathbf{X} = \mathbf{DA}$ ya da $\|\mathbf{X} - \mathbf{DA}\|_p \leq \epsilon$ şartını sağlayarak yaklaşık olarak $\mathbf{X} \simeq \mathbf{DA}$ ifadesine eşit olmaktadır. Yaklaşıklık yöntemlerinde sapmayı ölçmek için kullanılan genel normlar ℓ^0 -norm, ℓ^p -norm, ℓ^1 -norm, $\ell^{2,1}$ -norm ve ℓ^2 -normlardır [41].

Seyrek kodlama probleminin ℓ^0 -norm minimizasyonu ile çözümü (6) eşitliği ile verilmektedir.

$$\hat{\mathbf{A}} = \arg \min \|\mathbf{A}\|_0 \text{ öyle ki } \mathbf{X} = \mathbf{DA} \quad (6)$$

Burada $\|\cdot\|_0$ ile ifade edilen vektördeki sıfırdan farklı elemanların sayısıdır ve seyrekliğin ölçüsü olarak ifade edilmektedir. Gerçek veriler her zaman gürültü içerdiklerinden, temsiliyet gürültüsü de çoğu durumda kaçınılmaz olmaktadır. Gürültünün varlığı ile orijinal model küçük mümkün gürültüye bağlı olarak $\mathbf{X} = \mathbf{DA} + \mathbf{s}$ ile ifade edildiğinde gürültü $\|\mathbf{s}\|_2 \leq \epsilon$ olarak sınırlandırılmaktadır ve problem (7) ya da (8) eşitliği ile çözülmektedir.

$$\hat{\mathbf{A}} = \arg \min \|\mathbf{A}\|_0 \text{ öyle ki } \|\mathbf{X} - \mathbf{DA}\|_2^2 \leq \epsilon \quad (7)$$

$$\hat{\mathbf{A}} = \arg \min \|\mathbf{X} - \mathbf{DA}\|_2^2 \text{ öyle ki } \|\mathbf{A}\|_0 \leq \epsilon \quad (8)$$

Lagrange çarpanları teoremine göre de uygun bir λ sabiti ile (7) ve (8) eşitlikleri (9) eşitliğindeki sınırlandırılmamış minimizasyon problemine eşittir.

$$\hat{\mathbf{A}} = L(\mathbf{A}, \lambda) = \arg \min \|\mathbf{X} - \mathbf{DA}\|_2^2 + \lambda \|\mathbf{A}\|_0 \quad (9)$$

Burada λ parametresi $\|\mathbf{A}\|_0$ ile ilişkili olan Lagrange çarpanını göstermektedir.

ℓ^0 -norm minimizasyonu ile seyrek gösterim, \mathbf{D} matrisi üzerinde temel bir \mathbf{A} seyrek çözümü elde etse de problem çok fazla gerekirci olmayan polinomial zaman (NP) gerektirmekte ve çözümün yakınsaması güç olmaktadır [42]. Literatürde seyreklik şartı ve yeterli seyreklik ile ℓ^1 -norm minimizasyon sınırlandırması kullanılarak elde edilen temsiliyet çözümünün ℓ^0 -norm minimizasyonu ile elde edilen çözüme eşit olduğunu gösteren çalışmalar mevcuttur. Ayrıca, ℓ^1 -norm optimizasyon problemi analitik çözüme sahiptir ve polinomial zaman içerisinde çözülebilmektedir. Bu nedenle, ℓ^1 -norm minimizasyonu ile seyrek gösterim yöntemleri seyrek gösterim teorisini zenginleştirmek için önerilmiştir. ℓ^1 -norm minimizasyonu ile seyrek temsiliyet ℓ^0 -norm ile seyrek temsiliyet yapısına benzemektedir ve problem (10) ya da (11) eşitliği ile çözülmektedir.

$$\hat{\mathbf{A}} = \arg \min \|\mathbf{A}\|_1 \text{ öyle ki } \|\mathbf{X} - \mathbf{DA}\|_2^2 \leq \epsilon \quad (10)$$

$$\hat{\mathbf{A}} = \arg \min \|\mathbf{X} - \mathbf{DA}\|_2^2 \text{ öyle ki } \|\mathbf{A}\|_1 \leq \tau \quad (11)$$

ℓ^0 -norm minimizasyonuna benzer biçimde Lagrange çarpanları teoremine göre de (10) ve (11) eşitlikleri (12) eşitliğindeki sınırlandırılmamış minimizasyon problemine eşittir.

$$\hat{\mathbf{A}} = L(\mathbf{A}, \lambda) = \arg \min \frac{1}{2} \|\mathbf{X} - \mathbf{DA}\|_2^2 + \lambda \|\mathbf{A}\|_1 \quad (12)$$

ℓ^0 -norm ve ℓ^1 -norm minimizasyonuna ek olarak, bazı araştırmacılar seyrek temsiliyet problemini ℓ^p -norm minimizasyonu ($0 < p < 1$) ile de çözmeye çalışmışlardır. Fakat ℓ^p -norm minimizasyonu yöntemleri seyrek temsiliyet probleminin çözümünü elde etmek için temel yöntemler olmadığından dolayı tez kapsamında detaylandırılmayacaktır [41].

Seyrek temsiliyette optimizasyon probleminin çözümü için çeşitli yöntemler bulunmaktadır. Mevcut yaklaşımlardan en sık kullanılanları alt başlıklarda detaylandırılacaktır.

1.4.1.1. Konveks Optimizasyon Yöntemleri

Taban Arayış (BP) yaklaşımı [43], overcomplete sözlükler üzerinden sinyal temsiliyetini, temsiliyetteki katsayıların ℓ^1 -normunu (13) ile minimize ederek konveks optimizasyon ile bulmaktadır.

$$\hat{A} = \arg \min \|A\|_1 \text{ öyle ki } X = DA \quad (13)$$

BP yaklaşımının en büyük avantajı, uygun bir hassasiyetle birlikte hızlı bir yakınsamaya sahip olmasıdır. Dezavantajı ise hesaplama karmaşıklığının yüksek olmasıdır. BP yaklaşımı doğrusal programlamayla yakından ilgilidir. Bu yüzden geniş ölçekli doğrusal programlamadaki gelişmeler BP yöntemine uygulanmakta ve doğrusal zaman içerisinde BP optimizasyon problemi çözülmektedir [44].

Diğer bir yöntem olan Lasso yaklaşımı [45] ise karesel programlama ile (14)'teki gibi optimizasyon problemini çözmektedir.

$$\hat{A} = \arg \min \|X - DA\|_2^2 \text{ öyle ki } \|A\|_1 < c \quad (14)$$

Lasso problemlerinin çözmek için mevcut problemlerden en popüler ve iyi olanı En Küçük Açısız Regresyon (LARS) yöntemidir [46]. Kısıtlı biçimde verilen (14) eşitliğindeki c parametresinin $c = 0$ başlangıç koşulu ile başlayarak adım adım ilerleyen ve c arttıkça en etkili değişkenleri belirleyen iteratif bir algoritmadır.

1.4.1.2. Açgöz Arama Yaklaşımları

Açgöz arama algoritma stratejilerinin esas düşüncesi, veri vektörü ile seyrek katsayılar arasındaki ilişki temelinde pozisyonu belirlemek ve sonra genlik değerini değerlendirmek için en küçük kareleri kullanmaktır. Açgöz arama algoritmaları, problemin çözümü için her

bir adımda yerel optimum çözümü elde etmektedir. Böylece her zaman tüm çözüme yaklaşık ya da genel optimum çözümü üretmektedirler. Aslında açgöz arama yaklaşımları doğrudan optimizasyon problemini çözmezler, sadece (6) eşitliğindeki problem için yaklaşık çözüm aramaktadırlar [41].

Uyumlu Arayış (MP) algoritması [47] açgöz arama yaklaşımını kullanan ilk yöntemdir. Algoritma yaklaşık seyrek çözümü elde etmek için belirli benzerlik ölçüsü tabanında sözlükten en iyi atomu iteratif olarak seçmektedir. Her bir iterasyonda, korelasyonun ortogonal izdüşümün uzunluğu olarak ölçüldüğü, yakınsama hatası ile yüksek korelasyona sahip olan atomu bulmaktadır. Ardından ilişkilendirilmiş parça yakınsama hatasından çıkarılır ve algoritma yeni elde edilen yakınsama hatası ile iterasyona devam etmektedir. Sonuç seyrek çözümü ise ilişkili korelasyon değerleri ile ağırlıklandırılmış seçili atomların birleştirilmesiyle elde edilmektedir [48].

$\mathbf{x}_j \in \mathbb{R}^m$ örneğinin \mathbf{D} sözlüğü üzerinden seyrek gösterimi problemi ele alındığında algoritma şu şekilde çalışmaktadır. Sözlük $\mathbf{D} = [\mathbf{d}_1, \dots, \mathbf{d}_i, \dots, \mathbf{d}_K] \in \mathbb{R}^{m \times K}$ olarak verilsin ve \mathbf{D} 'deki her bir atomun ℓ^2 -normu birim vektör yani $\|\mathbf{d}_i\| = 1$ olsun. MP algoritması j .iterasyonda (15) eşitliğindeki verilen şartı sağlayan atomu aramaktadır.

$$\mathbf{d}_j^{opt} = \underset{\mathbf{d}_i \in \mathbf{D}}{\operatorname{argmax}} |\langle \mathbf{R}_{j-1}, \mathbf{d}_i \rangle| \quad (15)$$

Burada \mathbf{R}_{j-1} , $(j-1)$. iterasyonda temsiliyet artığı ya da yakınsama hatasını ve $\langle \cdot, \cdot \rangle$, $\langle \mathbf{u}, \mathbf{v} \rangle = \mathbf{u}^t \mathbf{v}$ olarak tanımlanan iç çarpım işlemini göstermektedir. İterasyon başlangıcında yakınsama hatası verilen giriş vektörüne eşittir ve dolayısıyla $\mathbf{R}_0 = \mathbf{x}$ 'dir. Seçilen \mathbf{d}_j^{opt} atomunun ağırlığı ya da katsayısı $\langle \mathbf{R}_{j-1}, \mathbf{d}_j^{opt} \rangle$ 'ye eşittir ve bu ifade c_j ile gösterildiğinde algoritma artığı (16) eşitliği ile güncellemektedir.

$$\mathbf{R}_j = \mathbf{R}_{j-1} - c_j \mathbf{d}_j^{opt} \quad (16)$$

Algoritma artığın normunun istenen bir yakınsama hata sınırının altına düştüğünde ya da yakınsamadaki atom sayısının istenen limite eşit olması durumunda sonlanmaktadır. Aksi durumda, algoritma bir sonraki iterasyonla devam etmektedir. j .iterasyondaki yakınsama ise (17) eşitliği ile ifade edilmektedir.

$$\mathbf{x}_j = \sum_{k=1}^j c_k \mathbf{d}_k^{opt} = [d_1 d_2 \dots d_j] [c_1 c_2 \dots c_j]^T \quad (17)$$

MP algoritması her iterasyonda azalan bir yakınsama hatasına sahiptir. Bu yüzden algoritma yakınsamayı garanti etmemektedir; fakat hala tam uygun çözümü bulamamaktadır. Her bir iterasyonda elde edilen artık sadece seçilen atoma ortogondur, önceki adımlarda seçilen tüm atomlara ise ortogond olmayabilir. Sonuç olarak, önceki iterasyonlarda seçilen atomlar tekrar seçilebilmektedir. Bu da yavaş yakınsamaya sebep olmaktadır. Ortogonal Uyumlu Arayış (OMP) algoritması [49] önceki adımlarda seçilen tüm atomların katsayılarını güncelleyerek bu problemi ortadan kaldırmaktadır. Böylece yeni elde edilen artık sadece o anki atoma değil önceki iterasyonlarda da seçilen tüm atomlara ortogondur. Sonuç olarak bir atom bir kez seçildiğinde sonraki iterasyonlarda asla seçilmeyecektir.

MP algoritmasında olduğu gibi j . iterasyonda algoritma ilk olarak (18) eşitliğini hesaplamaktadır.

$$\mathbf{d}_j^{opt} = \underset{\mathbf{d}_i \in \mathbf{D}/\mathbf{D}_{j-1}}{\operatorname{argmax}} |\langle \mathbf{R}_{j-1}, \mathbf{d}_i \rangle| \quad (18)$$

Burada \mathbf{R}_{j-1} , $(j-1)$. iterasyonda temsiliyet artığını, \mathbf{D}_{j-1} , $(j-1)$. iterasyona kadar seçilen atomların kümesini ve ‘/’, küme fark işlecini göstermektedir. j . iterasyonda yakınsama, seçilen atomlar tarafından kapsanan alt uzaya orijinal giriş vektörünün izdüşürülmesiyle elde edilmektedir. $\mathbf{D}_j \equiv \mathbf{D}_{j-1} \cup \{\mathbf{d}_j^{opt}\}$ olarak verilirse j . iterasyondaki yakınsama (19) ile ifade edilmektedir.

$$\mathbf{x}_j = \mathbf{D}_j (\mathbf{D}_j^T \mathbf{D}_j)^{-1} \mathbf{D}_j^T \mathbf{x} \equiv \mathbf{D}_j \mathbf{c}_j \quad (19)$$

Burada \mathbf{c}_j , j . iterasyondaki katsayı vektörünü göstermektedir. İkinci adımda algoritma artıkları (20) eşitliğini kullanarak güncellemektedir.

$$\mathbf{R}_j = \mathbf{x} - \mathbf{D}_j \mathbf{c}_j \quad (20)$$

Algoritma MP algoritmasındaki gibi sonlandırma şartları sağlanana kadar iteratif biçimde devam etmektedir. OMP algoritması basit gibi gözükmesine rağmen oldukça güçlü

bir algoritmadır. Literatürde MP ve OMP dışında bu yöntemler tabanlı birçok açgöz arama algoritması, arayış algoritmalarını geliştirmek için önerilmiştir.

1.4.2. Sözlük Öğrenmesi

Seyrek kodlama verilen bir \mathbf{x} giriş vektörü ve \mathbf{D} sözlüğü üzerinden \mathbf{A} temsiliyet katsayılarını hesaplama sürecidir. Bu süreç aynı zamanda atom ayrıştırma olarak da adlandırılmakta ve yaklaşık çözümü bulan bir arayış algoritmasıyla gerçekleştirilmektedir. Seyrek gösterime yol açan overcomplete bir \mathbf{D} sözlüğü ise fonksiyonların önceden tanımlı bir kümesi olarak seçilebileceği gibi içeriğinin verilen giriş örnekleri kümesine uydurulmasıyla da tasarlanabilmektedir [50].

Seyrek temsiliyete neden olan overcomplete bir sözlük genellikle dönüşüm fonksiyonlarının önceden tanımlı kümesinden yararlanarak (dönüşüm domeni yöntemleri) ya da öğrenme ile (sözlük öğrenmesi yöntemleri) elde edilmektedir. Dönüşüm domeni ve sözlük öğrenmesi tabanlı yöntemler, görüntü örneklerini farklı domene dönüştürmekte ve dönüşüm benzerliklerinin katsayılarını kullanmaktadırlar. Aralarındaki fark ise dönüşüm domeni yöntemleri görüntü örneklerini temsil etmede sabit dönüşüm fonksiyonları grubundan yararlanırken sözlük öğrenmesi yöntemleri artık bilgiyle seyrek temsiliyeti overcomplete bir sözlük üzerinde uygulamaktadırlar. Önceden tanımlı dönüşüm matrislerini kullanmak hızlı ve basit olduklarından dolayı daha çok ilgi çekmektedir. Bu yöntemler genellikle görüntü parçalarını curvelet, contourlet, bandelet, wavelet, complex wavelet, shearlet ve grouplet gibi dönüşümler kullanarak temsil etmektedir [51]. Fakat seyrek temsiliyetten yararlanan sözlük öğrenmesi yöntemleri dönüşüm fonksiyonları tabanlı önceden tanımlı sözlüklerden daha iyi performans göstermektedirler [50].

Sözlük öğrenmesi, sözlük tasarımında en yeni yaklaşımdır ve aslında seyrek temsiliyet teorisi ve algoritmalarındaki son gelişmelerden de etkilenmektedir. En yeni eğitim yöntemleri genellikle ℓ^0 , ℓ^1 ve ℓ^2 norm üzerinde odaklanmaktadır. Mevcut güncel sözlük öğrenmesi yaklaşımları Method of Optimal Directions (MOD), Union-of-Orthobases, Genelleştirilmiş PCA, K-SVD ve parametrik eğitim yöntemlerini kapsamaktadır. Bunların arasında en popüler olanı K-SVD yöntemi olduğundan ve tez çalışmasında kullanıldığından dolayı tez kapsamında bu yöntem detaylandırılacaktır. Diğer yöntemlerin detayları [51] çalışmasında verilmektedir.

K-SVD algoritması, ismini sözlükteki atom sayısı olarak verilen K kez tekrarlanan atom güncelleme adımının özünü oluşturan Tekil Değer Ayrıştırması (SVD) sürecinden almaktadır. K-SVD algoritmasının amaç fonksiyonu (21) eşitliği ile verilmektedir.

$$\arg \min_{\mathbf{D}, \mathbf{A}} \|\mathbf{X} - \mathbf{DA}\|_F^2 \text{ öyle ki } \|\mathbf{A}\|_0 \leq T_0 \quad (21)$$

Burada T_0 , sabit ve önceden tanımlı sıfırdan farklı girişlerin sayısını gösteren bir parametredir ve seyrekliğin ölçüsü olarak ifade edilmektedir. Problem \mathbf{D} ve \mathbf{A} 'ya bağlı ortak bir optimizasyon problemidir ve çözümü için doğal yöntem herhangi birini sabit tutarak karşılıklı olarak \mathbf{D} ve \mathbf{A} 'yı iteratif bir biçimde optimize etmektir. Seyrek kodlama adımında \mathbf{D} 'nin sabit tutulduğu farzedilir ve optimizasyon problemi \mathbf{A} matrisindeki katsayılarla seyrek temsiliyeti arama problemine dönüşmektedir ve problem (22) eşitliği ile çözülmektedir.

$$\arg \min_{\alpha_i} \|\mathbf{x}_i - \mathbf{D}\alpha_i\|_2^2 \text{ öyle ki } \|\alpha_i\|_0 \leq T_0, i = 1, 2, \dots, N \quad (22)$$

(22) eşitliğindeki problem seyrek kodlama problemidir. K-SVD algoritması esnek olduğundan herhangi bir arayış algoritması ile birlikte çalışabilir. Dolayısıyla, (22) eşitliğinin çözümü için 1.4.1 bölümünde verilen herhangi bir arayış algoritması kullanılmaktadır. Burada verilen k değeri yeterince küçük olduğunda çözüm ideal çözüme yaklaşmaktadır. Sıfırdan farklı katsayılar ile sözlük güncellemesi sürecinde \mathbf{D} ve \mathbf{A} 'nın sabit tutulduğu farzedilir. Sözlüğün her bir kolonu \mathbf{d}_k ve ona karşılık gelen katsayılar yani \mathbf{A} 'daki k .satur α_T^k ile ifade edilirse (21) eşitliğindeki terim yeniden yazılarak (23) eşitliği ile ifade edilir.

$$\begin{aligned} \|\mathbf{X} - \mathbf{DA}\|_F^2 &= \|\mathbf{X} - \sum_{j=1}^K \mathbf{d}_j \alpha_T^j\|_F^2 \\ &= \|(\mathbf{X} - \sum_{j \neq k} \mathbf{d}_j \alpha_T^j) - \mathbf{d}_k \alpha_T^k\|_F^2 \\ &= \|\mathbf{E}_k - \mathbf{d}_k \alpha_T^k\|_F^2 \end{aligned} \quad (23)$$

Burada öncelikle \mathbf{E}_k hesaplanır ve ardından \mathbf{d}_k ve α_T^k güncellenir. Bu adımda α_T^k 'nin seyrekliğini korumak için α_T^k 'nin sadece sıfırdan farklı elemanları korunmalı ve \mathbf{E}_k 'nin sadece sıfırdan farklı elemanları, yani \mathbf{E}_k^R , $\mathbf{d}_k \alpha_T^k$ 'den saklanmalıdır. Ardından SVD

algoritması E_k^R 'yi $E_k^R = U\Delta V^T$ biçiminde ayrıştırarak d_k sözlüğünü güncellemektedir. SVD ayrıştırması d_k 'yi U 'nun ilk kolonu ile ve α_R^k 'yi $\Delta(1,1)$ 'in V 'nin ilk kolonuyla çarpımının sonucu ile güncellemektedir [41].

Eşitliklerden de görüldüğü üzere K-SVD yönteminin asıl katkısı diğer sözlük öğrenmesi yöntemlerinde uygulanan matris tersini kullanmak yerine sözlük öğrenmesinin basit ve verimli bir süreç olarak her bir atom için gerçekleştirilmesidir. Hızlandırmanın daha da artması o anki atomun ve ilgili seyrek katsayının eş zamanlı güncellenmesiyle sağlanmaktadır [51].

1.4.3. Sentetik Görüntülerde Seyrek Gösterim Tabanlı Süper Çözünürlük

1.4.3.1. Seyrek Gösterim Tabanlı Süper Çözünürlükte Kullanılan Görüntü Veritabanları

Sentetik görüntüler olarak da adlandırılan doğal görüntüler (natural images), kendine özgü istatistiksel özelliklere sahiptirler [52, 53]. Bu özelliklerden en çok bilineni, görüntülere türev alıcı filtreler uygulandığında ağır kuyruklu (heavy-tailed) dağılım göstermeleridir. Sezgisel olarak doğal görüntüler yerel olarak pürüzsüz (smooth) görüntülerdir; böylece yerel farklar küçüktür. Diğer taraftan, doğal görüntüler çok fazla sayıda kenar gibi yapısal detaylara sahip olduklarından türev cevapları büyük olmaktadır. Bu önsel bilgi gürültü arındırma, netleştirme ve süper çözünürlük gibi geniş uygulama alanlarında başarılı bir şekilde uygulanmaktadır [54]. Seyrek gösterim tabanlı süper çözünürlük probleminde sıklıkla kullanılan veri kümeleri de sentetik görüntülerden oluşmaktadırlar. Literatürde seyrek gösterim tabanlı süper çözünürlük probleminde kullanılan sentetik veri kümesi aşağıda detayları ile birlikte verilmektedir.

- Timofte veritabanı [55]: Tek görüntü süper çözünürlüğü amacıyla sıklıkla kullanılan veri kümesidir. 91 eğitim görüntüsü [56] ile 5 ve 14 görüntüden oluşan Set5 [57] ve Set14 [58] test veri kümesinden oluşmaktadır.

1.4.3.2. Seyrek Gösterim Tabanlı Görüntü Süper Çözünürlüğünde Güncel Yaklaşımlar

Yang vd. [56, 59] sözlük öğrenmesi kullanımı ile birlikte seyrek kodlamayı ilk kez görüntü süper çözünürlüğü problemine uygulayarak ScSR (Sparse Coding Super Resolution) ismini verdikleri bir süper çözünürlük yaklaşımı önermişlerdir. Literatürde öğrenme tabanlı süper çözünürlük yaklaşımlarında DÇ parçalardan özellik çıkarılması için çeşitli yaklaşımlar önerilmiştir: Freeman vd. [60] DÇ parçalardan özellik olarak kenar bilgisini çıkarmak için yüksek geçiren bir filtre kullanmışlardır. Sun vd. [61] sınır bilgisini çıkarmak için Gauss türev alıcı filtreleri kullanmışlardır. Chang vd. [31] ise temsiliyet için parçaların birinci ve ikinci dereceden türev bilgilerini kullanmışlardır. Yang vd. önerdikleri yaklaşımda [59], [31] çalışmasından esinlenerek basit ve verimli olduklarından dolayı birinci ve ikinci dereceden türev bilgilerini kullanmışlardır. Diğer öğrenme tabanlı süper çözünürlük yaklaşımlarıyla karşılaştırıldığında önerdikleri yaklaşım geniş bir eğitim parçalarından oluşan veritabanı kullanmak yerine sadece iki öz öğrenilmiş sözlük gerektirmektedir. Seyrek temsiliyetin elde edilmesi için sadece DÇ sözlük kullanılmaktadır ve seyrek kodlama problemi Lasso yaklaşımı ile çözülmüştür. DÇ sözlük ve YÇ sözlük oluşturma süreci ise olasılıksal bir yaklaşımla çözülmüştür [62]. DÇ giriş ve karşılık gelen YÇ çıkışın aynı seyrek katsayıları paylaştığı varsayımıyla YÇ görüntü, DÇ görüntünün seyrek katsayıları ve eğitilmiş YÇ sözlük ile oluşturulmaktadır. Eğitimde 91 görüntüden oluşan Timofte veri kümesini kullanmışlardır. Önerdikleri yaklaşımı ise farklı sentetik görüntülerde $\times 3$ büyütme faktöründe değerlendirerek çift kübik ara değerlendirme ve NE [31] yöntemleriyle karşılaştırmışlardır.

Wang vd. [63] SCDL (Semi-Coupled Dictionary Learning) ismini verdikleri çalışmalarında DÇ ve YÇ parçaların aynı seyrek temsiliyete sahip olmaları varsayımını süper çözünürlük problemi için rahatlatmışlardır ve seyrek domende daha kararlı süper çözünürlük eşleşmesi öğrenmişlerdir. Bunun için sözlük çiftini ve eşleşme fonksiyonunu aynı anda öğrenmişlerdir. Sözlük çifti, iki görüntünün yapısal domenini karakterize etmeyi amaçlarken eşleşme fonksiyonu iki görüntü arasındaki ilişkiyi açığa çıkarmaktadır. Seyrek kodlama problemini verimliliğinden ve kararlılığından dolayı LARS algoritması ile ve sözlük çiftlerini ise birer birer güncelleme stratejisi [64] ile çözmüşlerdir. Önerilen çalışmada iki sözlük tam olarak birleştirilmiş değildir; böylece görüntüler arası doğru dönüşüm için eşleşme fonksiyonunun daha esnek olması sağlanmaktadır. Eğitimde Kodak

PhotoCD veri kümesini kullanmışlardır. Önerilen yaklaşım farklı sentetik görüntüler üzerinde $\times 2$ ve $\times 3$ büyütme faktörlerinde çift kübik ara değerlendirme ve ScSR [59] yöntemiyle karşılaştırılmıştır. Verilen görüntüler üzerinde ScSR yönteminden daha başarılı sonuçlar elde edilmiştir.

Zeyde vd. [58], Yang vd. [56, 59]'nin önerdikleri yaklaşım tabanlı, bir görüntüdeki kenar bilgilerini ve küçük detayları koruyarak süper çözünürlüklü görüntü oluşturan bir yaklaşım önermişlerdir. Sözlük çiftini öğrenmeyi K-SVD algoritmasıyla gerçekleştirirken YÇ görüntüyü OMP algoritması kullanarak oluşturmuşlardır. Önerdikleri yaklaşım, Yang vd.'nin önerdikleri yaklaşıma göre birkaç önemli değişiklik içermektedir: sözlük çiftinin eğitilmesi için farklı bir eğitim yaklaşımı kullanılması, seyrek kodlama algoritması olarak OMP algoritmasının kullanılarak seyrek kodlamanın ℓ^1 optimizasyon tabanlı yöntemlerden daha hızlı gerçekleşmesi, son işlem olarak kullanılan iteratif geri izdüşürme gibi gereksiz adımların kaldırılarak önerilen yöntemin basitleştirilmesi. Eğitimde 91 görüntüden oluşan Timofte veri kümesini kullanmışlardır. Önerilen yaklaşım Set14 veri kümesi üzerinde $\times 3$ büyütme faktöründe çift kübik ara değerlendirme ve ScSR [59] yöntemiyle karşılaştırılmıştır. Verilen görüntüler üzerinde ScSR yönteminden daha başarılı sonuçlar elde edilmiştir.

He vd. [65], ortak özellik uzayında sözlük öğrenme problemi için beta süreci modeli ortak sözlük öğrenme algoritması önermişlerdir. Önerdikleri yaklaşım, bahsedilen seyrek gösterim tabanlı çalışmalarda olduğu gibi her bir özellik uzayına uyarlanan sözlük öğrenmesi yöntemleri sağlarken iki özellik uzayı arasında daha tutarlı ve doğru eşleşme de sağlamaktadır. Bu da seyrek gösterimin değerlerine ve sözlük atomlarına ayrıştırılabildiği beta süreç modelinin özgün özelliğinden kaynaklanmaktadır. Çalışmalarında, sözlük atomları için aynı beta süreç önselini fakat iki özellik uzayındaki değerler için farklı önselleri kullanmışlardır. Böylece önerilen algoritma birleştirilmiş özellik uzayında aynı sözlük atomlarına aynı seyreklikle fakat farklı değerle karşılık gelen seyrek temsiliyeti öğrenmektedir. Bunun yanında, literatürdeki diğer sözlük öğrenmesi yöntemlerinde sözlük boyutu bilinmeyen bir parametredir ve büyük boyutlu sözlükler daha iyi görüntü oluşturma doğruluğu için gerekmektedir. Önerilen yaklaşım ile sözlük boyutunun sonuç üzerindeki etkisi parametrik değildir ve küçük sözlük boyutlarıyla aynı ya da daha iyi öğrenme doğrulukları üretilmektedir. Önerilen yaklaşım farklı sentetik görüntüler üzerinde $\times 2$ ve $\times 3$ büyütme faktöründe çift kübik ara değerlendirme, ScSR[59], Zeyde vd. [58], SCDL [63] ve

Bilevel [66] yöntemleriyle karşılaştırılmıştır. Verilen görüntüler üzerinde tüm yöntemlerden daha başarılı sonuçlar elde edilmiştir.

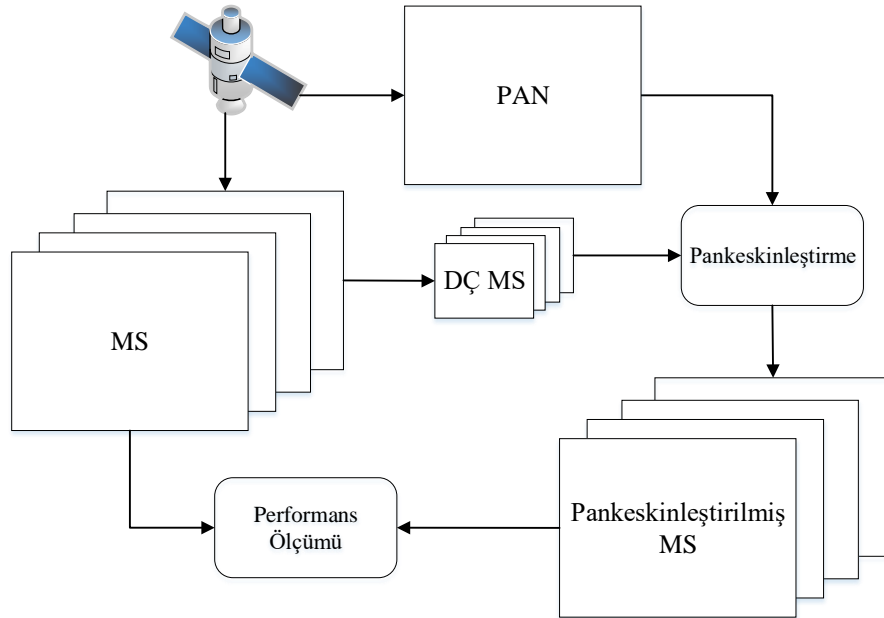
Yang vd. [66] çalışmalarında genel iki seviyeli seyrek kodlama modelini birleştirilmiş sinyal uzayları üzerinden sözlüklerin öğrenilmesi için ilk kez önermişlerdir. İki uzaydaki sinyalleri, sinyallerin seyrek temsiliyetleri ve sözlükleri ile ilişkilendiren genel seyrek kodlama modeli sunmuşlardır. Öğrenme algoritması birinci dereceden olasılıksal gradyan iniş yöntemi kullanılarak etkili biçimde çözülen iki seviyeli optimizasyon problemi olarak formülize edilmektedir. Çalışmalarında genel model sıkıştırılmış algılama ve tek görüntü süper çözünürlüğünde sözlük öğrenmesi için kullanılmıştır. Önerilen yaklaşım farklı sentetik görüntüler üzerinde çift kübik ara değerlendirme ve yazarın ilk çalışması olan ScSR [59] yöntemleriyle karşılaştırılmıştır. Verilen görüntüler üzerinde ilgili çalışmalardan daha başarılı sonuçlar elde edilmiştir.

[58], [59], [63] ve [65] çalışmaları temelde sözlük öğrenmesi üzerinde değişiklik yapmaya odaklanmaktadır. Bunların yanında, çeşitli önsel bilgilerden yararlanma da etkin bir araştırma alanıdır. Dong vd. [67] adaptif seyrek domen seçimi şemasını (Adaptive Sparse Domain Selection-ASDS) süper çözünürlük problemine uygulamışlardır. Süper çözünürlüklü görüntünün kalitesi büyük ölçüde seyrek domenin görüntüyü iyi temsil edip etmeyeceğine bağlı olduğundan ve içerik farklı görüntülerde veya tek bir görüntüdeki parçalarda önemli bir biçimde değişeceğinden dolayı görüntü parçalarından çeşitli kümeler öğrenmeyi önermişlerdir. YÇ görüntü oluşturma sürecinde herhangi bir görüntü parçası verildiğinde, yerel seyrek domeni nitelendirmek için kümelerden biri adaptif olarak seçilmiştir. Ayrıca iki adaptif düzenleme terimini seyrek temsiliyet yapısına eklemişlerdir. Bunlardan ilki görüntü parçaları kümesinden öğrenilen özbağlanımlı (autoregressive) modelin kümesi, diğeri ise yerel olmayan özbenzeşliktir (nonlocal self-similarity). Bunun dışında çalışmalarında seyrek düzenleme parametresi de adaptif biçimde tahmin edilmektedir. Önerilen yöntemin dayanıklılığını göstermek için içerikleri birbirinden farklı olan, her birinde 5 farklı görüntü içeren 2 farklı eğitim veri kümesi kullanmışlardır. Önerilen yaklaşım farklı sentetik görüntüler üzerinde $\times 3$ büyütme faktöründe bazı önsel bilgilerin kullanıldığı ve düzenleme terimi içeren çalışmaların yanında ScSR [59] yöntemiyle karşılaştırılmıştır. Verilen görüntüler üzerinde tüm yöntemlerden daha başarılı sonuçlar elde edilmiştir.

1.4.4. Uydu Görüntülerinde Seyrek Gösterim Tabanlı Süper Çözünürlük

Tüm pratik uzaktan algılama uygulamalarına basit, etkin ve hızlı çözümler sağladıklarından dolayı uydu görüntülerine rağbet günümüzde artmaktadır. Bu artış araştırmacıların yüksek spektral ve uzamsal çözünürlüğe sahip daha iyi görüntü elde etmeleri için yeni teknolojiler üzerinde çalışmalarına neden olmaktadır. Fakat sensör teknolojilerindeki yeni gelişmelere rağmen uydu sensörlerinin sağladıkları spektral ve uzamsal çözünürlükler arasında hala bir ödünleşme mevcuttur [68]. Sensörlerden alınan yüksek bant yoğunluğuna sahip MS görüntüler, ona karşılık düşük bantlı PAN aygıttan elde edilen tek renkli görüntüden daha kaba uzamsal çözünürlüğe sahiptir [68, 69]. Bu yüzden, sırasıyla yüksek spektral ve uzamsal çözünürlüğe sahip MS ve PAN görüntülerinin her ikisinin de avantajlarından yararlanmak için pan keskinleştirmeden yararlanılmaktadır. Pan keskinleştirme yüksek spektral çözünürlüğe sahip MS görüntünün uzamsal detaylarının yüksek uzamsal çözünürlüğe sahip PAN görüntü kullanılarak zenginleştirilmesi sürecidir.

Pan keskinleştirme teknikleri, Şekil 8’de görüldüğü gibi YÇ MS görüntü elde etmek için DÇ MS ve YÇ PAN görüntüyü birleştirmeyi amaçlamaktadır.



Şekil 8. Pan keskinleştirme süreci

Pan keskinleştirme teknikleri sınıflandırma, hedef tanıma, sahne yorumlama benzeri birçok pratik uzaktan algılama uygulamalarında genellikle ilk adım olarak uygulanmaktadır [70, 71]. Genel olarak incelendiğinde şimdiye kadar literatürde önerilmiş olan pan keskinleştirme yaklaşımları spektral ve uzamsal olarak da adlandırılan bileşen yerine koyma (CS) ve çoklu çözünürlük analizi (MRA) yaklaşımları olarak iki gruba ayrılmaktadır. Bunların dışında Bayes yaklaşımı tabanlı çalışmalar da veri kaynaştırma için önerilmiştir. Fakat mevcut MS ve PAN görüntü ile pan keskinleştirilmiş sonucu ortak karakterize eden uygun bir istatistiksel yöntem bulmanın zorluğu, Bayes yaklaşımının pan keskinleştirme için kullanımını sınırlandırmaktadır. Fakat yine de Bayes tahmin teorisine dayalı literatürde birçok katkı yapılan çalışma mevcuttur. Bazı çalışmalar da Toplam Değişinti ya da Sıkıştırılmış Algılama tabanlıdır. Bunların arasında en özgün çalışmalar birçok görüntü işleme ve bilgisayarla görü uygulamalarında sıklıkla kullanılan süper çözünürlük tekniklerinin uygulanmasıyla elde edilen iyileştirmelerin sağlandığı çalışmalardır [72]. Bileşen yerine koyma, çoklu çözünürlük analizi ve sıkıştırılmış algılama tabanlı çalışmalar alt bölümlerde detaylandırılacaktır.

1.4.4.1. Bileşen Yerine Koyma Tabanlı Yaklaşımlar

Bileşen yerine koyma tabanlı yaklaşımlar, yapılacak olan dönüşümün farklı bileşenlerdeki uzamsal yapının spektral bilgiden ayrıştırılabileceğini farzederek MS görüntünün farklı bir uzaya izdüğürlmesini gerektirmektedir. Dönüştürülen MS görüntü, uzamsal yapıyı içeren bileşenin PAN görüntü ile birleştirilmesiyle zenginleştirilebilir. Bu sebeple yerleştirme işleminden önce PAN görüntünün seçili bileşene histogram eşleştirmesi (histogram matching) gerçekleştirilir. Böylece histogram eşleştirilmiş PAN görüntü yer değiştirilecek bileşenle aynı ortalama ve varyansa sahip olacaktır. Son olarak da, pan keskinleştirme süreci ters dönüşüm aracılığıyla veriyi orijinal uzaya geri getirerek tamamlanır [72, 73].

Bileşen yerine koyma yöntemlerinin genel formülü (24) eşitliği ile verilmektedir.

$$\widehat{X}_k = \widehat{Y}_k + g_k(\mathbf{P} - \mathbf{I}_L), \quad k = 1, \dots, N \quad (24)$$

Burada $\widehat{\mathbf{X}}_k$, tahmin edilen YÇ MS çözünürlüklü hedef görüntünün k . bandını ve $\widehat{\mathbf{Y}}_k$ ise PAN görüntünün ölçeğine ara değerlenmiş DÇ MS görüntüyü göstermektedir.

$\mathbf{g} = [g_1 \dots, g_N]^T$, enjekte kazançlarını (injection gain) içeren bir vektördür ve \mathbf{I}_L (25) eşitliği ile ifade edilmektedir.

$$\mathbf{I}_L = \sum_{i=1}^N w_i \widehat{\mathbf{Y}}_i \quad (25)$$

Burada $\mathbf{w} = [w_1 \dots, w_N]^T$ ağırlıkları spektral bantlar ve PAN görüntü \mathbf{P} arasındaki spektral örtüşmeyi ölçmektedir [74,75]. Bileşen yerine koyma tabanlı yaklaşımlar (24) eşitliğinde kullanılan MS görüntünün izdüşürülmesinde birbirinden ayrılan PCA [76], Gram-Schmidt (GS) [77], Parlaklık Ton Doygunluk Dönüşümü (IHS) [78], Brovey dönüşümü [79], adaptif GS (GSA) [80], Bant Bağımlı Uzamsal Detay (BDSD) [81] gibi popüler yaklaşımları içermektedir. Her bir yaklaşımda kullanılan, (24) ve (25) eşitlikleri ile verilen $w_{k,i}$ spektral ağırlıkların ve g_k enjekte kazançlarının değerleri Tablo 2’de verilmektedir.

Tablo 2. Bileşen yerine koyma tabanlı yaklaşımlar için spektral ağırlıklar ve enjekte kazançları (k =çıkış bandı, i =giriş bandı)

Yöntem	$w_{k,i}$	g_k
PCA	$\mathbf{X}_{1,i}$	$\mathbf{X}_{1,k}$
GS	$1/N$	$\frac{cov(\mathbf{I}_L, \widehat{\mathbf{Y}}_k)}{var(\mathbf{I}_L)}$
IHS	$1/N$ (N=3)	1
Brovey	$1/N$	$\frac{\widehat{\mathbf{Y}}_k}{\mathbf{I}_L}$
GSA	$\mathbf{P}_L = \sum_{k=1}^N w_k \widehat{\mathbf{Y}}_k$ Eşitliğin minimum MSE çözümüyle hesaplanır.	$\frac{cov(\mathbf{I}_L, \widehat{\mathbf{Y}}_k)}{var(\mathbf{I}_L)}$
BDSD	$\gamma_{k,i} = \begin{cases} g_k & \text{if } i = N + 1 \\ -g_k \cdot w_{k,i} & \text{otherwise} \end{cases}$ $\widehat{\mathbf{X}}_k = \widehat{\mathbf{Y}}_k + \mathbf{H}\boldsymbol{\gamma}_k$, $\mathbf{H} = [\widehat{\mathbf{Y}}_1, \dots, \widehat{\mathbf{Y}}_N, \mathbf{P}]$, $\boldsymbol{\gamma}_k = [y_{k,1}, \dots, y_{k,N+1}]^T$ $\widehat{\mathbf{Y}}_k = (\mathbf{H}_d^t \mathbf{H}_d)^{-1} \mathbf{H}_d^t (\widehat{\mathbf{Y}}_k - \widehat{\mathbf{Y}}_k^{LP})$, LP: Alçak geçiren filtre	$w_{k,i}$ ile aynı

1.4.4.2. Çoklu Çözünürlük Analizi Tabanlı Yaklaşımlar

Pan keskinleştirme yöntemlerinin bir diğer türü olan çoklu çözünürlük analizi tabanlı yaklaşımlarda, PAN görüntüye uzamsal bir filtre uygulanarak MS görüntüye yerleştirilecek detaylar elde edilmektedir. Detay görüntüsü olarak isimlendirilen PAN görüntünün pan keskinleştirilmiş görüntüye olan katkısı PAN görüntü \mathbf{P} ile alçak geçiren filtre uygulanmış görüntüsü \mathbf{P}_L arasındaki fark hesaplanarak elde edilir. Yani YÇ MS görüntü (26) ile tanımlanır.

$$\widehat{\mathbf{X}}_k = \widehat{\mathbf{Y}}_k + g_k(\mathbf{P} - \mathbf{P}_L), \quad k = 1, \dots, m\lambda \quad (26)$$

Çoklu çözünürlük analizi tabanlı yaklaşımlar (26) eşitliğinde kullanılan PAN görüntünün filtrelenmesinde uygulanan filtre türüne göre birbirinden ayrılan Yüksek Geçiren Filtreleme (HPF) [82], ATWT Oransal Luminans Yöntemi (AWLP) [83], Toplamsal Dalgacık Dönüşümü (ATWT) [84], Modülasyon Transfer Fonksiyonu (MTF) eşleşmiş filtre ve Doku Tabanlı Karar (CBD) ile Genelleştirilmiş Laplacian Piramidi (MTF-GLP-CBD) [85] gibi popüler yaklaşımları içermektedir. Tablo 3, çoklu çözünürlük analizi tabanlı yaklaşımlarda filtre türlerini ve enjekte kazanç formüllerini özetlemektedir.

Tablo 3. Çoklu çözünürlük analizi tabanlı yaklaşımların filtre türleri ve enjekte kazançları

Yöntem	Çoklu çözünürlük analizi türü ve filtresi	g_k kazancı
HPF	Kutu filtre ile ATWT	1
AWLP	Starck ve Murtagh filtreli ATWT	$\frac{\widehat{\mathbf{Y}}_k}{\frac{1}{N} \sum_{i=1}^N \widehat{\mathbf{Y}}_k}$
ATWT	Starck ve Murtagh filtreli ATWT	1
MTF-GLP-CBD	MTF filtreli GLP	$\frac{cov(\mathbf{P}_L, \widehat{\mathbf{Y}}_k)}{var(\mathbf{P}_L)}$

1.4.4.3. Sıkıştırılmış Algılama Tabanlı Yaklaşımlar

Son yıllarda popüler bir yaklaşım olarak, orijinal YÇ MS görüntüyü bozulmuş örneklerinden yani DÇ MS ve PAN görüntülerinden oluşturmak için ters problem tabanlı yöntemler kullanılmaktadır. Bozulma sürecinde çok fazla bilgi kaybolduğu için problem

kötü konumlanmış ters bir problemdir ve çözüm tek değildir. Bu demektir ki bozulma sürecine bağlı olarak, aynı YÇ PAN ve DÇ MS görüntüden çok fazla sayıda YÇ MS görüntü üretilebilir. Bu nedenle çeşitli oluşturma tabanlı yaklaşımlar kötü konumlanmış ters problemi çözmek için önerilmiştir. Fakat önerilen yöntemlerin performansı kullanılacak olan önsele bağlı olmakta ve yeterli sayıda eğitim görüntüsü olmadığında performans azalmaktadır. Bunun sonucu olarak son yıllarda, sıkıştırılmış algılama teorisine dayalı çalışmalar önerilmektedir.

Sıkıştırılmış algılama teorisi, birçok görüntü işleme uygulamasında kullanılan, küçük bir doğrusal izdüşüm kümesinden bilinmeyen seyrek sinyallerin elde edilmesini sağlamaktadır [86-88]. Diğer bir deyişle sıkıştırılmış algılama, geleneksel yöntemlerin kullandığı ölçüm ya da örnek sayısından çok daha az örnek ya da ölçümden bazı sinyal ve görüntülerin elde edilebileceğini ileri sürmektedir ve görüntü işleme [89], görüntü restorasyonu [90], gürültü arındırma [91] ve yüz tanıma [92] gibi birçok görüntü işleme probleminde uygulanmaktadır.

Sıkıştırılmış algılama tabanlı öncü pan keskinleştirme yöntemlerinin ilki Li vd. tarafından önerilmiştir [70]. Görüntü oluşum modeli DÇ MS ve YÇ PAN görüntülerinin doğrusal dönüşümleriyle formülize edilmiştir. Sözlük, YÇ MS görüntülerden alınan rastgele örneklenmiş ham görüntü parçalarından oluşturulmuştur. Seyrek gösterimin elde edilmesini amaçlayan seyrek gösterim problemi BP yaklaşımı ile çözülmüştür. Böylece, pan keskinleştirilmiş YÇ MS görüntü seyrek vektör ve sözlük kullanılarak oluşturulmuştur. Önerilen yaklaşım Genelleştirilmiş IHS [78], GS [77], Destek Vektör Dönüşümü (SVT) [93], CBD [94], AWLP [83], Genetik Algoritmalar (GA) ile ATWT tabanlı yöntem [95] ile karşılaştırılmıştır. Birçok kalite metriğinde karşılaştırılan yöntemlerden başarılı sonuçlar üretmiştir.

Jiang vd. [68], [70]'dan farklı olarak, üst örneklenen DÇ MS görüntü ile YÇ PAN görüntünün ikisinden K-SVD sözlük öğrenmesi algoritmasıyla ortak bir sözlük oluşturmuşlardır. [70] çalışmasında olduğu gibi seyrek kodlama problemi BP algoritması ile çözülmüştür. Pan keskinleştirilmiş görüntünün oluşturulmasında DÇ MS ile YÇ PAN görüntünün katkısını kontrol eden bir β ödünleşme parametresi önerilmiştir. Önerilen yaklaşım Hızlı IHS (FIHS) [75], GS [77] ve AWLP [83] yöntemleri ile karşılaştırılmıştır. Tüm kalite metriklerinde karşılaştırılan yöntemlerden başarılı sonuçlar üretmiştir.

Zhu vd. [96], sadece DÇ ve YÇ PAN görüntülerden eğitilmiş sözlük kullanmayı önermişlerdir. DÇ MS görüntü ve ona karşılık gelen oluşturulacak olan YÇ görüntü, aynı zamanda aynı alanı gözlemlediklerinden dolayı oluşturulan sözlükte aynı seyrek katsayılara sahiptir. Seyrek katsayılar ise SLIMMER algoritması [97, 98] kullanılarak tahmin edilmiştir. Önerilen yöntemin verimliliğinin gösterilmesi için, yöntemin çoklu çözünürlük analizi tabanlı yaklaşımlarla da karşılaştırılması gerekmesine rağmen sadece bileşen yerine koyma tabanlı yaklaşımlarla başka bir deyişle IHS [78], adaptif IHS, PCA [76] ve Brovey dönüşümü [79] yöntemleriyle karşılaştırma yapılmıştır. Ayrıca yöntem adaptif IHS yönteminin sonuçlarına benzer kalitede pan keskinleştirilmiş görüntü sağladığından dolayı performans diğer yöntemlerden daha iyi değildir. Bunun yanında, yazarlar tarafından da belirtildiği üzere önerilen yaklaşım genellikle görüntü füzyonuna uygulanabilmektedir.

Li vd. [99] DÇ MS ve PAN görüntüleri için sözlükleri ortak öğrenme stratejisi ile eğitim veri setinden K-SVD algoritması kullanarak öğrenmeyi önermişlerdir. OMP algoritması sözlük öğrenme sürecinin seyrek kodlama aşamasında kullanılmıştır. Sözlükler arasındaki matematiksel ilişkilerden yararlanılarak, YÇ MS görüntü için farklı bir sözlük DÇ MS ve PAN sözlüklerinden optimizasyon problemi çözülerek elde edilmiştir. Pan keskinleştirilmiş MS görüntü ise elde edilen katsayılar ve YÇ sözlük kullanılarak elde edilmiştir. Önerilen yaklaşım GS [77], FIHS [75], SVT [93], CBD [94] ve AWLP [83] yöntemleri ile karşılaştırılmıştır. Birçok kalite metriğinde karşılaştırılan yöntemlerden başarılı sonuçlar üretmiştir.

1.5. Konvolüsyonel Sinir Ağları Tabanlı Süper Çözünürlük

Son yıllarda görüntü sınıflandırma, nesne algılama, bilgi çıkarımı gibi birçok bilgisayarla görü alanındaki başarılarından dolayı derin konvolüsyonel sinir ağları görüntü süper çözünürlüğü [17, 30, 100-110], içboyama [111] ve gürültü arındırma [111-113] gibi görüntü restorasyonu alanında da kullanılmaya başlanmıştır. Görüntü süper çözünürlüğündeki geleneksel öğrenme tabanlı yaklaşımlardan farklı olarak, konvolüsyonel sinir ağları (CNN) DÇ giriş ile YÇ çıkış arasındaki uçtan uca eşleşmeyi doğrudan öğrenmektedir. Bu sebeple de CNN tabanlı süper çözünürlük yaklaşımları öğrenme tabanlı yaklaşımlar arasında diğer yöntemlere nazaran önemli biçimde ilerleme sağlamaktadır.

Bu bölümde öncelikle konvolüsyonel sinir ağlarına değinilecek, ardından süper çözünürlük probleminde konvolüsyonel sinir ağlarının kullanımını anlatılacaktır. Literatürdeki sentetik görüntülerde ve medikal görüntülerde süper çözünürlük problemi üzerine önerilen yaklaşımlar ayrı ayrı alt başlıklarda incelenecektir.

1.5.1. Konvolüsyonel Sinir Ağları

Konvolüsyonel sinir ağları, standart çok katmanlı sinir ağlarında olduğu gibi öğrenilebilir ağırlıklara ve sapmalara sahip olan nöronlardan oluşmaktadır. Her bir nöron bazı girişler alarak bir iç çarpım gerçekleştirmektedir ve bu işlemi genellikle bir doğrusalsızlık takip etmektedir. Aslında tüm ağ tek bir türevlenebilir skor fonksiyonunu ifade etmektedir; yani bir uçta ham görüntü pikselleri bulunurken diğer uçta sınıf skorları bulunmaktadır. Yine yapay sinir ağlarında olduğu gibi son katmanda da bir kayıp fonksiyonu bulunmaktadır. CNN'i sıradan bir yapay sinir ağından farklı kılan, ağ yapısının bir giriş görüntüsünün 2D yapısından ya da konuşma sinyali gibi farklı bir 1D girişten yararlanmak için tasarlanmış olmasıdır. Bu da ileri fonksiyonun gerçekleştirilmesinin daha verimli olmasını sağlamakta ve ağdaki parametre sayısını da büyük ölçüde azaltmaktadır.

Bir CNN mimarisi genellikle 3 katman türünden oluşmaktadır: konvolüsyon katmanları, havuzlama katmanları, tam bağlantılı katmanlar. Bu katmanlar art arda eklenerek tam bir CNN mimarisi oluşturulabilir. Konvolüsyon ve tam bağlantılı katmanlar sadece girişteki aktivasyonların değil aynı zamanda nöronların ağırlık ve sapmaları olan parametrelerinde fonksiyonu olan dönüşümleri gerçekleştirmektedir. Diğer taraftan aktivasyon fonksiyonu ve havuzlama katmanı ise sabit bir fonksiyonu gerçekleştirmektedir. Konvolüsyon ve tam bağlantılı katmanlardaki parametreler gradyan iniş ile eğitilmekte ve böylece CNN ağının hesapladığı sınıf skorları eğitim kümesinden her bir görüntünün etiket bilgisiyle tutarlı olmaktadır. CNN mimarisini oluşturan konvolüsyon katmanı, aktivasyon fonksiyonu, havuzlama katmanı ve tam bağlantılı katman alt bölümlerde detaylandırılacaktır.

1.5.1.1. Konvolüsyon Katmanı

Konvolüsyon katmanı CNN yapısını oluşturan temel bloklar içerisinde hesaplamaların en ağır yükünü çeken bloğudur. Genel olarak konvolüsyon gerçek değerli argüman içeren iki fonksiyon üzerinde yapılan bir işlemdir. Herhangi bir t zamanında konvolüsyon işlemi (27)'de olduğu gibi yıldız imi (*) ile gösterilmektedir.

$$s(t) = (x * w)(t) \quad (27)$$

CNN terminolojisinde, x ilk terim girişini, w çekirdeği (filtre) ve s çıkışı ise özellik haritasını göstermektedir. Makine öğrenmesi uygulamalarında, giriş genellikle çok boyutlu veri dizisine ve filtre ise öğrenme algoritmaları tarafından adapte edilen parametrelerin çok boyutlu dizisine karşılık düşmektedir. Pratikte konvolüsyon işlemi gerçekleştirilirken sonlu sayıda dizi elemanları üzerinden sonsuz bir toplam kümülatif bir biçimde gerçekleştirilmektedir. Konvolüsyon işlemi herhangi bir zamanda birden fazla eksen üzerinde gerçekleştirilmektedir. Giriş olarak herhangi bir iki boyutlu I görüntüsü ve iki boyutlu bir K çekirdeği kullanıldığında özellik haritası (28) eşitliği ile oluşturulmaktadır [114].

$$S(i, j) = (K * I)(i, j) = \sum_m \sum_n I(i - m, j - n)K(m, n) \quad (28)$$


Konvolüsyon katmanlarının parametreleri, öğrenilebilir filtre kümesinden oluşmaktadır. Her bir filtre genişlik ve yükseklik boyunca yani uzamsal olarak küçük olmasına rağmen, girişin derinliğine göre genişletilebilir. İleri yayılım boyunca, her bir filtre girişin genişliği ve yüksekliği boyunca kaydırılarak herhangi bir pozisyondaki giriş ile filtre girişleri arasındaki iç çarpım (28) eşitliğindeki gibi hesaplanmaktadır. Filtrenin girişin genişliği ve yüksekliği boyunca kaydırılmasıyla filtrenin her bir uzamsal pozisyondaki cevabını veren 2 boyutlu bir özellik haritası üretilmektedir. Eğer her bir konvolüsyon katmanında filtre kümesi bulunuyorsa filtrelerin her biri ayrı 2 boyutlu özellik haritası üretmektedir. Bu özellik haritaları ise yığılarak derinlik boyutu oluşturulmaktadır [115].

Konvolüsyon, makine öğrenmesi sisteminin geliştirilmesine yardım etmek için üç önemli özelliği kullanmaktadır: seyrek ilişkiler, uzamsal düzenleme ve parametre paylaşımı.

- **Seyrek İlişkiler:** CNN genellikle yerel bağlantı, seyrek bağlantı olarak da adlandırılan seyrek ilişkilere sahiptir. Yüksek boyutlu görüntüler işlenirken nöronları bir önceki katmandaki tüm nöronlara bağlamak yerine her bir nöron bir önceki katmandaki yerel bir bölgeye bağlanmaktadır. Bu bağlantı uzamsal anlamda, boyutu filtre boyutuna eşit olan, nöronun alıcı alanı (receptive field) olarak adlandırılan hiperparametresine karşılık düşmektedir. Bu sebeple seyrek ilişki çekirdeğin uzamsal boyutunu girişten daha küçük yaparak gerçekleştirilir. Fakat derinlik boyutu giriş katmanının derinliğine eşit olmaktadır. Seyrek ilişkiler ile daha az parametre bellekte tutularak modelin bellek gereksinimi azaltılırken istatistiksel verimliliği de artırılmaktadır. Ayrıca çıkışı hesaplamak da daha az işlem gerektirmektedir [114, 115].
- **Uzamsal Düzenleme:** CNN'deki her bir konvolüsyon katmanının giriş katmanına bağlantısının nasıl olacağı dışında çıkışta kaç tane nöron olacağı ya da bu nöronların nasıl düzenleneceği CNN'in uzamsal düzenleme özelliğine girmektedir. Çıkışın boyutunu kontrol eden 3 tane parametre bulunmaktadır: derinlik, atlama ve sıfır doldurma (zero-padding). Derinlik parametresi kullanılan filtre sayısını ifade etmektedir. Burada her bir filtre girişin farklı bir özelliğini öğrenmektedir. İkinci parametre olan atlama, filtrenin kaydırılmasında herhangi bir zamanda kaç piksel hareket edeceğini göstermektedir. Atlama parametresinin seçimi uzamsal anlamda çıkışın boyutunun girişten daha küçük olmasını sağlamaktadır. Sıfır doldurma, giriş kenarları boyunca sıfırla doldurma anlamına gelmektedir. Bu parametrenin en önemli özelliği çıkışın uzamsal boyutunu kontrol etmeye izin vermesidir [115].
- **Parametre Paylaşımı:** Parametre paylaşımı, bir modeldeki birden fazla fonksiyon için aynı parametreleri kullanmak anlamına gelmektedir. CNN yapısında, filtrenin her bir elemanı girişin her bir pozisyonunda kullanılmaktadır. Konvolüsyon işleminin kullandığı parametre paylaşımı her bir konum için ayrı bir parametre kümesi öğrenmek yerine tek bir küme öğrenmek anlamına gelmektedir. Aslında bu işlem ileri yayılımın koşum zamanını etkilemezken modelin saklama gereksinimini azaltmaktadır [114].

1.5.1.2. Aktivasyon Fonksiyonu

Her bir konvolüsyon ya da tam bağlantılı katmandan sonra genellikle doğrusal olmayan bir aktivasyon fonksiyonu uygulanmaktadır. Her bir aktivasyon fonksiyonu ya da doğrusalsızlık tek bir değeri giriş olarak alarak üzerinde belirli bir matematiksel işlem gerçekleştirmektedir [116]. Konvolüsyonel sinir ağlarında sıklıkla kullanılan aktivasyon fonksiyonlarının biçimleri ve matematiksel ifadeleri Şekil 9’da gösterilmektedir.



Şekil 9. Aktivasyon fonksiyonlarının biçimleri ve matematiksel ifadeleri

Konvolüsyonel sinir ağlarında genellikle ReLU (Rectified Linear Unit) [117] aktivasyon fonksiyonu kullanılmaktadır. Bu fonksiyon pozitif kısmının birim fonksiyon olduğu ve negatif kısmının sifıra eşit olduğu parçalı bir doğrusal fonksiyondur. ReLU aktivasyon fonksiyonu (29) ile ifade edilmektedir.

$$y_i = \begin{cases} x_i & \text{eğer } x_i \geq 0 \\ 0 & \text{eğer } x_i < 0 \end{cases} \quad (29)$$

Burada x_i i . giriş örneğini ve y_i aktivasyon fonksiyonundan geçtikten sonraki karşılık gelen çıkışı göstermektedir. ReLU ile karşılaştırıldığında Leaky ReLU (LReLU) [118] negatif kısma küçük ve önceden tanımlı bir eğim vermektedir. LReLU, (30) ile hesaplanmaktadır.

$$y_i = \begin{cases} x_i & \text{eğer } x_i \geq 0 \\ \frac{x_i}{a_i} & \text{eğer } x_i < 0 \end{cases} \quad (30)$$

Burada α_i , $(1, +\infty)$ aralığında sabit bir parametredir. Orijinal çalışmada yazarlar α_i değerinin 100 gibi büyük bir sayıya eşitlenmesini önermektedirler. Rastgeleleştirilmiş ReLU (RReLU) [116], LReLU'nun rastgeleleştirilmiş biçimidir. Eğitim sürecinde α_{ji} rastgele sayısı, $U(l, u)$ tekdüze dağılımdan örneklenmektedir. Matematiksel olarak RReLU (31) ile ifade edilmektedir.

$$y_i = \begin{cases} x_{ji} & \text{eğer } x_{ji} \geq 0 \\ \alpha_{ji} x_{ji} & \text{eğer } x_{ji} < 0 \end{cases}, \quad \alpha_{ji} \sim U(l, u), l < u \text{ ve } l, u \in [0, 1) \quad (31)$$

Test aşamasında aktivasyon fonksiyonu kullanılırken eğitim aşamasında belirlenen α_{ji} 'lerin ortalaması alınmaktadır.

PReLU (Parametrik ReLU), He vd. [119] tarafından önerilmiştir ve yazarlar geniş ölçekte görüntü sınıflandırmada PReLU'nun performansının ReLU'dan daha iyi olduğunu rapor etmişlerdir. (30) eşitliğinde verilen LReLU denklemleri ile aynı ifadeye sahiptir. Fakat PReLU'da α_i geri yayılımla eğitim sürecinde öğrenilmektedir.

LReLU ve PReLU'nun negatif kısmındaki doğrusallığın tersine, ELU (Exponential Linear Unit) [120], önceden tanımlı ve sabit bir eşik değerinden üssel olarak eğimi 0'a azaltmaktadır ve model öğrenmesini hızlandırmak için yararlıdır. ELU, (32) ile tanımlanmaktadır.


$$y_i = \begin{cases} x_i & \text{eğer } x_i \geq 0 \\ \alpha(e^{x_i} - 1) & \text{eğer } x_i < 0 \end{cases} \quad (32)$$

1.5.1.3. Havuzlama Katmanı

Havuzlama fonksiyonu, belirli bir konumdaki ağırlık çıkışını kendine yakın çıkışların belirli istatistiklerine bağlı olarak elde edilen çıkışlarla yer değiştirir. Örneğin, maksimum havuzlama [121] dikdörtgensel komşuluk içerisinde maksimum çıkışı almaktadır. Diğer popüler havuzlama fonksiyonları dikdörtgensel komşuluğun ortalaması, ℓ^2 normu ya da merkezi pikselden olan uzaklığının ağırlıklı ortalamasını içermektedir.

Havuzlama, girişin küçük ötelenmelerine karşı temsiliyeti yaklaşık olarak değişmez yapmaya yardımcı etmektedir. Burada ötelenmeye karşı değişmezlik, girişi az miktarda ötelediğimizde havuzlanan çıkışların çoğunun değerinin değişmemesidir. Şekil 10, bu

özelliğin herhangi bir giriş dizisi için nasıl çalıştığını göstermektedir. Her iki alt şekilde de alt satır doğrusalsızlığın çıkışını gösterirken üst satır maksimum havuzlamanın çıkışını vermektedir. Burada havuzlama bölgesinin genişliği 3 piksel ve havuzlama bölgeleri arasında atlama genişliği 1 pikseldir. Şekil 10 (b)'de giriş 1 piksel sağa kaydırılmıştır. Alt satırdaki her bir pikselin değeri değişirken üst satırda sadece değerlerin yarısı değişmiştir. Çünkü maksimum havuzlama sadece komşuluklardaki maksimum değere karşı duyarlıdır, konumuna duyarlı değildir. Bu örnekten yola çıkılarak yerel ötelemelere değişmezlik, bazı özelliklerin nerede olduğundan daha çok varlığıyla ilgilenildiğinde yararlı bir özellik olmaktadır [114].



Şekil 10. Maksimum havuzlamanın değişmezlik özelliği [114].

Genellikle havuzlama katmanı, giriş temsiliyeti olan özellik haritasının boyutuna daha küçük yaparak ağıdaki parametre sayısını ve hesaplamaları azaltır ve böylece aşırı uyuma problemi önlenmiş olmaktadır.

1.5.1.4. Tam Bağlantılı Katman

Birkaç konvolüsyon ve havuzlama katmanından sonra, konvolüsyonel sinir ağlarında yüksek seviyeli tümevarım tam bağlantılı katmanlar ile yapılmaktadır. Tam bağlantılı katmandaki nöronlar, sıradan sinir ağlarında olduğu gibi önceki katmandaki tüm aktivasyonlara tam bağlantı içermektedir. Aktivasyonları ise matris çarpımı biçiminde hesaplanır ve onu bir sapma ötelemesi takip etmektedir. Genellikle sınıflandırma amaçlı kullanılmaktadır. Tam bağlantılı katmanın girişi bir özellik haritası iken çıkışı N 'nin sınıf sayısını ifade ettiği N boyutlu bir vektördür. Vektördeki her bir sayıda belirli sınıfın olasılığını göstermektedir.

1.5.2. Konvolüsyonel Sinir Ağlarının Eğitimi

1.5.2.1. Verilerin ve Modelin Kurulması

Mevcut problem için uygun bir ağ yapısının kurulmasının ardından verilerin gerekiyorsa ön işlenmesi ve ağda bulunan tüm ağırlıkların ve sapmaların öncelikle başlangıç değerine ayarlanması gerekmektedir.

Veri ön işlemenin ortalama çıkarma ve normalizasyon olmak üzere farklı çeşitleri bulunmaktadır.

- Ortalama Çıkarma: En bilinen ön işlem türüdür. Verideki her bir özellikten ortalaması çıkartılır ve böylece veri kümesinin her bir boyutta orijin etrafında kümelenmesi sağlanır.
- Normalizasyon: Veri boyutlarını normalize ederek yaklaşık olarak aynı ölçekte olmalarını sağlamaktır. Çeşitli normalize türleri bulunmaktadır. Bunlardan biri verinin her bir boyutunu verinin standart sapmasına bölerek sıfır merkezli yapmaktır. Diğer bir türü her bir boyutu normalize ederek minimum ve maksimum değerleri olan -1 ile 1 arasında olmasını sağlamaktır. Bu genellikle farklı giriş özelliklerinin farklı ölçeklerde ya da birimlerde olduğu ve öğrenme algoritmasına etkisinin yaklaşık olarak eşit olduğunun düşünüldüğü durumlarda yapılmaktadır.

Ağırlıkların başlangıç değerlerine ayarlanmaları için genellikle 0 'a yakın küçük rastgele sayılar kullanılmaktadır. Böylece ağırlıkların hepsi başlangıçta rastgele ve eşsiz olarak ayarlanıp ağınc güncellenmesi aşamasında birbirlerinden farklı güncellemeler yapılarak ağınc farklı parçaları olarak ağınc oluşturmaktadırlar. Genellikle ağırlıklara küçük rastgele sayı olarak başlangıç değerlerinin atanması için ortalaması 0 ve standart sapması 0.01 olan bir Gauss dağılımı kullanılmaktadır. Bu yaklaşımda ortaya çıkan problem rastgele başlangıç değerlerine atanmış filtrelerin çıkışları giriş sayısı ile birlikte artan bir varyansa sahip olmaktadır. Bu sebeple her bir filtrenin çıkışını 1 değerine normalize etmek için giriş sayısının kareköküyle ağırlık vektörünü ölçeklendirme de yapılmaktadır. Böylece ağdaki tüm filtrelerin başlangıçta yaklaşık olarak aynı çıkış dağılımına sahip oldukları garantilenmektedir ve deneysel olarak yakınsama hızı geliştirilmektedir.

Sapmalar başlangıç değeri olarak genellikle 0'a ayarlanmaktadır. ReLU doğrusalsızlığı kullanıldığında bazen 0.01 gibi küçük sabit değerlerde kullanılmaktadır.

He vd. [119], ReLU doğrusalsızlığı kullanıldığında ağda kullanılan filtrelerin varyanslarının $2.0/n$ olması gerektiği sonucuna varmıştır. Böylece rastgele değerler $\sqrt{2.0/n}$ ile çarpılarak başlangıç değeri ataması yapılmaktadır ve bu önerilen yaklaşım pratikte ReLU doğrusalsızlığı kullanıldığında tercih edilmektedir.

1.5.2.2. İleri Yayılım

Kurulan ağ giriş olarak bir görüntü alır ve bu görüntü ileri yayılım yaparak tüm katmanlardan (konvolüsyon, doğrusalsızlık, havuzlama, tam bağlı katman) geçmektedir. Bilinen giriş değerleri için her bir katmanın aktivasyonu hesaplanmaktadır. Bu aktivasyonla da sonraki katmanın girişi hesaplanmaktadır. Bu işlemler çıkış katmanına ulaşıncaya ve çıkış değerlerini elde edinceye kadar devam etmektedir. Sınıflandırma ağlarında çıkışta her bir sınıf için çıkış olasılıkları hesaplanırken regresyon ağlarında ise sürekli bilgi tahmin edilmektedir.

1.5.2.3. Kayıp Fonksiyonu

Konvolüsyonel sinir ağlarının eğitilmesi için optimizasyonun özel bir durumu kullanılmaktadır. Amaç bir ağın $J(\theta)$ kayıp fonksiyonunu önemli ölçüde azaltacak θ parametrelerini bulmaktır. Kayıp fonksiyonu da genellikle tüm veri seti üzerinde ek düzenleştirme terimleriyle birlikte bir performans ölçümü değerlendirmesini içermektedir [114].

Danışmanlı öğrenme problemlerinde hesaplanan kayıp fonksiyonu, tahmin ile kesin doğru etiket ya da sürekli bilgi arasındaki uyumluluğu ölçmektedir. Kayıp fonksiyonu her bir tek örnek için kayıp fonksiyonlarının ortalamasının alınmasıyla hesaplanmaktadır ve genel olarak (33) eşitliği ile ifade edilmektedir.

$$J(\theta) = \mathbb{E}_{(x,y) \sim \hat{p}_{veri}} L(f(x; \theta), y) \quad (33)$$

Burada, L örnek başına hesaplanan kayıp fonksiyonunu, $f(\mathbf{x}; \boldsymbol{\theta})$, giriş \mathbf{x} olduğunda tahmin edilen çıkış değerini ve \hat{p}_{veri} deneysel dağılımı göstermektedir. Danışmanlı öğrenme probleminde y hedef çıkışı vermektedir.

Pratikte farklı problemler için farklı kayıp fonksiyonları kullanılmaktadır. Sınıflandırma problemlerinde örneklerden oluşan bir veri kümesi ve her bir örnek için tek bir doğru etiket olduğu farzedilmektedir. En sık kullanılan iki kayıp fonksiyonundan biri Destek Vektör Makineleri'dir [122] ve (34) eşitliği ile hesaplanmaktadır.

$$L_i = \sum_{j \neq y_i} \max(0, f_j - f_{y_i} + 1) \quad (34)$$

Bazı araştırmacılar ise çalışmalarında (34) eşitliğindeki kayıp fonksiyonu yerine karesi alınmış hinge kaybı (squared hinge loss) $(\max(0, f_j - f_{y_i} + 1))^2$ ile daha iyi performans elde edildiğini raporlamışlardır. Diğer bir kayıp fonksiyonu ise çapraz entropi kaybını kullanan (35) eşitliği ile ifade edilen Softmax sınıflandırıcısıdır.

$$L_i = -\log \left(\frac{e^{f_{y_i}}}{\sum_j e^{f_j}} \right) \quad (35)$$

Regresyon problemleri, gerçek değerli nicelikleri tahmin etmek için kullanılmaktadır. Bunun içinde tahmin edilen nicelik ile kesin doğru cevap arasındaki kayıp hesaplanmakta ve farkın ℓ^2 karesel normu Ortalama Karesel Hata (MSE) kaybı ya da ℓ^1 normu Ortalama Mutlak Hata (MAE) kaybı hesaplanmaktadır. Tek bir örneğin ℓ^2 karesel normu (36) ile hesaplanmaktadır.

$$L_i = \|f - y_i\|_2^2 \quad (36)$$

ℓ^1 normu ise her bir boyut boyunca mutlak değerlerin toplamı olarak (37) ile ifade edilmektedir.

$$L_i = \|f - y_i\|_1 = \sum_j |f_j - (y_i)_j| \quad (37)$$

Burada eğer tahmin edilecek birden fazla nicelik varsa \sum_j istenen tahminin tüm boyutları boyunca toplanmaktadır.

1.5.2.4. Geri Yayılım

Kayıp fonksiyonuyla hatayı hesaplamamanın amacı; hatayı minimum yapacak ağırlıkları optimize etmektir. Bu süreç ağın öğrenmesi olarak adlandırılır ve ağ ise geri yayılım adı verilen algoritmayla öğrenmektedir. Geri yayılım algoritması, gradyanın hesaplanması için bilginin kayıp fonksiyonundan ağ aracılığıyla girişe doğru ilerlemesine izin vermektedir [114].

Geri yayılım terimi genellikle gradyanların hesaplanması için bir yöntemdir, diğer taraftan bu gradyanları kullanarak öğrenmenin gerçekleştirilmesi için farklı optimizasyon yöntemleri kullanılmaktadır. Bunun yanında geri yayılımın sadece çok katmanlı sinir ağlarına özgü olduğu düşünülse de aslında türevinin tanımlanmadığı herhangi bir fonksiyonun türevini hesaplayabilmektedir. Öğrenme algoritmalarında gradyan, kayıp fonksiyonunun parametrelere göre gradyanını, $\nabla_{\theta} J(\theta)$, ifade etmektedir. Ağ aracılığıyla bilginin yayılması ile türevlerin hesaplanması genellikle zincir kuralı ile gerçekleştirilmektedir.

Zincir kuralı türevleri bilinen diğer fonksiyonların birleşimi ile biçimlenen fonksiyonların türevleri ile hesaplanmaktadır. Geri yayılım da belirli sırada işlemlerle birlikte zincir kuralını hesaplayan bir algoritmadır.

x , bir gerçel sayı olarak ifade edilsin ve f ve g gerçel sayılardan gerçel sayılara eşleşmeyi sağlayan fonksiyon olsun. $y = g(x)$ ve $z = f(g(x)) = f(y)$ olduğu farzedilirse zincir kuralı (38) ile ifade edilebilir.

$$\frac{dz}{dx} = \frac{dz}{dy} \frac{dy}{dx} \quad (38)$$

Eşitlik skaler olarak da genelleştirilebilir. $\mathbf{x} \in \mathbb{R}^m$, $\mathbf{y} \in \mathbb{R}^n$ olduğu ve g , \mathbb{R}^m 'den \mathbb{R}^n 'e eşlemeyi ve f , \mathbb{R}^n 'den \mathbb{R} 'ye eşlemeyi sağladığı farzedilsin. Eğer $\mathbf{y} = g(\mathbf{x})$ ve $z = f(\mathbf{y})$ ise zincir kuralı (39) ile ifade edilebilir.

$$\frac{\partial z}{\partial x_i} = \sum_j \frac{\partial z}{\partial y_j} \frac{\partial y_j}{\partial x_i} \quad (39)$$

Vektör gösteriminde ise (39), (40) eşitliği ile yazılabilir.

$$\nabla_{\mathbf{x}}Z = \left(\frac{\partial \mathbf{y}}{\partial \mathbf{x}}\right)^T \nabla_{\mathbf{y}}Z \quad (40)$$

Burada $\left(\frac{\partial \mathbf{y}}{\partial \mathbf{x}}\right)$, g 'nin $n \times m$ boyutlu Jacobian matrisidir. Bu eşitliklerden \mathbf{x} değişkeninin gradyanının $\left(\frac{\partial \mathbf{y}}{\partial \mathbf{x}}\right)$ Jacobian matrisinin $\nabla_{\mathbf{y}}Z$ gradyanıyla çarpımıyla elde edilebileceği görülmektedir. Geri yayılım algoritması da graf üzerindeki her bir operasyon için Jacobian-gradyan çarpımını gerçekleştirmeyi içermektedir. Konvolüsyonel sinir ağlarında en sık kullanılan optimizasyon algoritmaları alt başlıklarda detaylandırılacaktır.

1.5.2.4.1. Olasılıksal Gradyan İniş Algoritması

Çoğu derin öğrenme algoritmaları gradyan tabanlı optimizasyon tekniklerini kullanmaktadır. Burada optimizasyon $J(\boldsymbol{\theta})$ fonksiyonunu minimum yapmayı ifade etmektedir. Türev, bir fonksiyonu minimum yapmak için çok yararlıdır; çünkü fonksiyon çıkışında küçük bir değişim yapmak için fonksiyon girdisinin nasıl değişeceğini göstermektedir. Herhangi bir fonksiyonu, girdiyi türevin karşıt yönünde küçük adımlar ile değiştirerek azaltmaya gradyan iniş yöntemi adı verilmektedir. Gradyan iniş yöntemi, tüm veri setinin gradyanını azaltmayı sağlamaktadır. Olasılıksal Gradyan İniş (SGD) yöntemi [123] ile ise tüm veri setinden rastgele seçilmiş küçük grupların (mini batch) gradyanının azaltılması sağlanarak gradyan iniş yöntemi hızlandırılmaktadır.

SGD ve türevleri makine öğrenmesi ve özellikle derin öğrenmede en sık kullanılan optimizasyon algoritmasıdır. SGD algoritması için çok önemli olan parametre öğrenme oranıdır. Genellikle pratikte öğrenme oranı, zamanla yavaş yavaş azaltılmaktadır. Bu sebeple öğrenme oranı ϵ ile ifade edilirse, k . iterasyonda öğrenme oranı ϵ_k ile gösterilmektedir. SGD yönteminin akışı Algoritma 1'de verilmektedir.

SGD algoritması, Algoritma 1'de görüldüğü üzere gradyan hesaplaması ve parametre güncellemeleri eğitim veri kümesinin bir alt grubu olan küçük grup üzerinde yapmaktadır. Her bir hesaplama k ile ifade edilen bir iterasyonu göstermektedir. Her bir iterasyonda algoritma kayıp fonksiyonunu minimum yaparak bir adım ilerlemektedir. Tüm eğitim kümesinin eğitim algoritmasıyla eğitilmesine ise bir devir (epoch) adı verilmektedir.

Algoritma 1. Olasılıksal Gradyan İniş (SGD) güncellemesi
<p>Giriş: Öğrenme katsayıları $\epsilon_1, \epsilon_2, \dots$ ve başlangıç parametresi θ</p> <p>$k \leftarrow 1$</p> <p>while durdurma kriteri karşılanmadığında do</p> <p> eğitim veri kümesinden m örnekle küçük grubu $\{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(m)}\}$ karşılık gelen çıkışla $\mathbf{y}^{(i)}$ birlikte örnekle</p> <p> gradyan tahminini hesapla: $\hat{\mathbf{g}} \leftarrow \frac{1}{m} \nabla_{\theta} \sum_i L(f(\mathbf{x}^{(i)}; \theta), \mathbf{y}^{(i)})$</p> <p> güncelleme yap: $\theta \leftarrow \theta - \epsilon_k \hat{\mathbf{g}}$</p> <p> $k \leftarrow k + 1$</p> <p>end while</p>

1.5.2.4.2. Momentumlu Olasılıksal Gradyan İniş Algoritması

SGD yöntemi popüler bir optimizasyon yöntemi olsa da öğrenme bazen yavaş olabilmektedir. Momentum yöntemi [124], öğrenmeyi hızlandırmak için tasarlanmıştır. Momentum algoritması geçmiş gradyanların üssel azalan hareketli ortalamasını toplar ve o yönde ilerlemeye devam eder. Momentum algoritması, parametrelerin parametre uzayında ilerlediği hızı ve yönü ifade eden \mathbf{v} hız parametresi kullanmaktadır. Bu parametre, negatif gradyanların üssel azalan ortalamasına ayarlanmaktadır ve momentum olarak da kabul edilmektedir. $\alpha \in [0,1)$ hiperparametresi de önceki gradyanların üssel azalmasının katkısının ne kadar çabuk olacağını belirlemektedir. Yani ϵ 'a bağlı olarak büyük α seçimi önceki gradyanların şimdiki yönü daha çok etkileyecekleri anlamına gelmektedir. Momentumlu SGD yönteminin akışı Algoritma 2'de verilmektedir.

α parametresi genel olarak pratikte 0.5, 0.9 ve 0.99 olarak kullanılmaktadır. Öğrenme oranı gibi α parametresi de zamanla uyarlanabilmektedir. Genellikle başlangıçta küçük değerlere ayarlanmakta ve sonradan artırılmaktadır. Fakat α parametresinin zamanla uyarlanması ϵ parametresinin zamanla azaltılmasından daha az önemlidir.

Öğrenme oranı ayarlanması en zor olan hiperparametredir, çünkü model performansını etkilemektedir. Kayıp parametre uzayında bazı yönler karşı daha hassasken, diğer yönler karşı daha az hassas olmaktadır. Momentum algoritması bu problemlerle az da olsa başa çıkabilmektedir, fakat bu yöntemde başka hiperparametreleri ortaya çıkarmaktadır. Bazı parametrelere karşı olan hassaslık bilindiğinde her bir parametre için ayrı bir öğrenme oranı

kullanılmakta ve otomatik olarak öğrenme boyunca bu öğrenme oranı adapte edilmektedir. Son zamanlarda model parametrelerinin öğrenme oranlarını adapte eden küçük yığın tabanlı birçok yöntem mevcuttur. Bu yöntemler içerisinde en yaygın olanları Adaptif Eğitim (AdaGrad) [125], Ortalama Karesel Yayılımın Karekökü (RMSProp) [126] ve Adaptif Moment Tahmini (Adam) [127] yöntemleridir. CNN tabanlı süper çözünürlük yaklaşımlarında öğrenme oranının adapte edildiği yöntemler içerisinde daha çok Adam [127] yöntemi kullanıldığından ve tez kapsamında da bu yöntemden yararlanıldığından dolayı tez kapsamında adaptif öğrenme katsayılı algoritmalarından sadece Adam yöntemine yer verilecektir.

Algoritma 2. Momentumlu Olasılıksal Gradyan İniş (SGDM) güncellemesi

Giriş: Öğrenme katsayısı ϵ , momentum parametresi α , başlangıç parametresi θ ve başlangıç hızı v

while durdurma kriteri karşılanmadığında **do**

eğitim veri kümesinden m örnekle küçük grubu $\{x^{(1)}, \dots, x^{(m)}\}$ karşılık gelen çıkışla $y^{(i)}$ birlikte örnekle

gradyan tahminini hesapla: $g \leftarrow \frac{1}{m} \nabla_{\theta} \sum_i L(f(x^{(i)}; \theta), y^{(i)})$

hız güncellemesi hesapla: $v \leftarrow \alpha v - \epsilon g$

güncelleme yap: $\theta \leftarrow \theta + v$

end while

1.5.2.4.3. Adam Algoritması

Adam [127] yöntemi adaptif öğrenme katsayısı kullanan optimizasyon algoritmalarından biridir. Adam ismi ‘adaptive moments’ ifadesinden gelmektedir. Adam yönteminin akışı Algoritma 3’te verilmektedir. Yöntem RMSProp [126] ile momentum algoritmalarının önemli birkaç ayırım ile birlikte birleşimi olarak görülmektedir. Bu ayırımlardan ilki momentum gradyanın üssel ağırlıklı birinci dereceden momentinin tahmini olarak doğrudan hesaplanmaktadır. RMSProp [126] yöntemine momentum eklemenin en açık yolu yeniden ölçeklendirilen gradyanlara momentum uygulamaktır. İkincisi, Adam yöntemi orijinde başlangıç değerlerine atanması için birinci dereceden momentler

(momentum terimi) ve ikinci dereceden (merkezi olmayan) momentlerin hesabına sapma düzeltmeleri eklemektedir. RMSProp yöntemi de aslında ikinci dereceden (merkezi olmayan) momentlerin tahminini yapmaktadır; fakat düzeltme faktörüne sahip değildir. Bu yüzden Adam yönteminden farklı olarak RMSProp yönteminin ikinci dereceden moment tahmini ağırlık eğitiminin başlangıcında yüksek sapmalara sahip olabilir. Adam yöntemi genellikle hiperparametrelerin seçimine karşı oldukça dayanıklı olarak görülmektedir. Fakat öğrenme oranlarının bazen önerilen varsayılan değerlerinden değiştirilmesine ihtiyacı vardır.

Algoritma 3. Adam algoritması

Giriş: Adım boyutu ϵ , moment tahminleri için üssel bozulma oranları, $[0,1]$ aralığında ρ_1 ve ρ_2 (önerilen değerler: sırasıyla 0.9 ve 0.999), sayısal kararlılık için kullanılan küçük δ sabiti (önerilen değer: 10^{-8}), θ başlangıç parametreleri

Birinci ve ikinci dereceden moment değişkenlerini başlangıç değerine ata $\mathbf{s} = \mathbf{0}, \mathbf{r} = \mathbf{0}$

Zaman adımını başlangıç değerine ata $t = 0$

while durdurma kriteri karşılanmadığında **do**

eğitim veri kümesinden m örnekle küçük grubu $\{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(m)}\}$ karşılık gelen çıkışla $\mathbf{y}^{(i)}$ birlikte örnekle

gradyanı hesapla: $\mathbf{g} \leftarrow \frac{1}{m} \nabla_{\theta} \sum_i L(f(\mathbf{x}^{(i)}; \theta), \mathbf{y}^{(i)})$

$t \leftarrow t + 1$

sapmalı birinci moment tahminini güncelle: $\mathbf{s} \leftarrow \rho_1 \mathbf{s} + (1 - \rho_1) \mathbf{g}$

sapmalı ikinci moment tahminini güncelle: $\mathbf{r} \leftarrow \rho_2 \mathbf{r} + (1 - \rho_2) \mathbf{g} \odot \mathbf{g}$

birinci momentteki sapmayı düzenle: $\hat{\mathbf{s}} \leftarrow \frac{\mathbf{s}}{1 - \rho_1^t}$

ikinci momentteki sapmayı düzenle: $\hat{\mathbf{r}} \leftarrow \frac{\mathbf{r}}{1 - \rho_2^t}$

güncellemeyi hesapla: $\Delta \theta = -\epsilon \frac{\hat{\mathbf{s}}}{\sqrt{\hat{\mathbf{r}} + \delta}}$ (eleman eleman uygulanan işlem)

güncelleme yap: $\theta \leftarrow \theta + \Delta \theta$

end while

Derin modellerin optimize edilmesi problemini çözen birçok algoritma bulunmasına rağmen hangi algoritmaların seçilmesi gerektiği hakkında herhangi bir fikir birliği

bulunmamaktadır. Schaul vd. [128]'nin çok çeşitli öğrenme problemlerine karşın birçok sayıda optimizasyon algoritmasının karşılaştırmasını yaptığı çalışmalarında tek bir en iyi algoritma bulunmamasına karşın adaptif öğrenme katsayılarının kullanıldığı algoritmaların oldukça dayanıklı performans gösterdiği görülmektedir.

1.5.3. Sentetik Görüntülerde Konvolüsyonel Sinir Ağları Tabanlı Süper Çözünürlük

1.5.3.1. Konvolüsyonel Sinir Ağları Tabanlı Süper Çözünürlükte Kullanılan Görüntü Veritabanları

Konvolüsyonel sinir ağları tabanlı süper çözünürlük probleminde sıklıkla kullanılan veri kümeleri de seyrek gösterim tabanlı süper çözünürlük probleminde kullanılan sentetik görüntülerden oluşmaktadır. Bazı veri setleri öneren kişi tarafından eğitim, validasyon ve test kümeleri olarak bölünmüş olmalarına rağmen birçok çalışma kümeleri bu bölünme kısıtlamasına bağlı olmaksızın kullanmışlardır. Literatürde kullanılan veri kümeleri aşağıda detayları ile birlikte verilmektedir.

- Timofte veritabanı [55]: Tek görüntü süper çözünürlüğü amacıyla sıklıkla kullanılan veri kümesidir. 91 eğitim görüntüsü [56] ile 5 ve 14 görüntüden oluşan Set5 [57] ve Set14 [58] test veri kümesinden oluşmaktadır.
- ImageNet [129]: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) tarafından sağlanan 400,000 civarı görüntüden oluşan tanıma amaçlı kullanılan veri kümesidir.
- Berkeley segmentasyon veritabanı [130]: 200 görüntüden oluşan eğitim kümesi ve 100 görüntüden oluşan test kümesini içeren BSDS300 ve BSDS300 veri kümesinin genişletilmiş olan 300 görüntüden oluşan eğitim/validasyon kümesi ve 200 görüntüden oluşan test kümesini içeren BSDS500 veri kümelerini içermektedir.
- General-100 [101]: Dong vd. [101], JPEG formatından dolayı BSDS500 veri kümesinin süper çözünürlük problemleri için uygun olmadıklarını düşündüklerinden süper çözünürlük problemleri için daha uygun olan temiz kenarlara ve daha az

pürüzsüz bölgelere sahip yüksek kaliteden oluşan 100 tane sıkıştırılmamış .bmp dosya formatında görüntü içeren veritabanı oluşturmuşlardır.

- Urban 100 [131]: Gerçek dünyadaki bina gibi keskin kenarlara sahip yapılardan oluşan 100 YÇ görüntüden oluşmaktadır. Görüntüler birbirlerine benzerlikleriyle bilinmektedir.
- 291 veri kümesi [132]: BSD200 ve Timofte veritabanındaki eğitim veri kümesinin birleşiminden oluşmaktadır.
- DIV2K [133]: Görüntü Restorasyonu ve İyileştirmesinde Yeni Trendler Yarışması (NTIRE) 2017 mücadelesi için sunulan çeşitli 2K çözünürlüğe sahip görüntülerden oluşan veri kümesidir. Yüksek kaliteli veri kümesi 800 eğitim, 100 validasyon ve 100 test görüntüsü olarak parçalanmıştır.
- Manga 109 [134]: İçerisinde sayısız karikatür çizimi bulunan 109 Japon karikatür kitaplarının kapak görüntülerinden oluşan veri kümesidir.

1.5.3.2. Konvolüsyonel Sinir Ağları Tabanlı Görüntü Süper Çözünürlüğünde Güncel Yaklaşımlar

Kim vd. [100]'ne göre, süper çözünürlük ve gürültü arındırma gibi görüntü restorasyonu çalışmalarında CNN uygulanırken havuzlama ve alt örnekleme, önemli görüntü detaylarını attığından dolayı zarar verici olabilmektedir. Bu yüzden bu tür çalışmalarda havuzlama katmanlarından genellikle kaçınılmaktadır. Bu tür sebeplerden dolayı konvolüsyonel sinir ağlarına dayalı süper çözünürlük yaklaşımlarında ağ yapısı konvolüsyon katmanı ve aktivasyon fonksiyonundan oluşmaktadır.

Dong vd. SRCNN (Super Resolution Convolutional Neural Network) ismini verdikleri çalışmada [30], daha öncesinde yapmış oldukları SRCNN-Ex olarak isimlendirilen çalışmanın [102] daha geniş filtre boyutları ve ek eşleşme katmanları kullanılmasıyla geliştirilmesini sağlamışlardır. Literatürde ise SRCNN, tek görüntü süper çözünürlüğünde konvolüsyonel sinir ağlarının kullanıldığı ilk çalışma olarak geçmekte ve karşılaştırmalı değerlendirmelerde referans çalışmaların ilki olarak kullanılmaktadır.

SRCNN yönteminde DÇ giriş görüntüsü ile YÇ çıkış görüntüsü arasında derin CNN olarak temsil edilen uçtan uça eşleşme doğrudan öğrenilmiştir. Önerilen yöntem ön işlem adımı olarak çift kübik ara değerlendirme fonksiyonu kullanarak DÇ görüntünün istenen YÇ görüntü boyutuna getirilmesini sağlamaktadır. Ön işlem adımını konvolüsyon aracılığıyla örtüşen parçaların çıkarımı takip etmektedir. Böylece özellik haritası olarak yüksek boyutlu vektörler elde edilmektedir. Ardından vektörler doğrusal olmayan bir biçimde birbirlerine eşleşir ve parça biçimine sokularak YÇ görüntü oluşturulur. Burada oluşturulan YÇ görüntünün kesin referans görüntüsüne mümkün olduğunca yakın olması beklenmektedir. Önerilen yöntemin performansı Set5, Set14 ve BSDS200 veri kümelerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde değerlendirilmiştir. Önerilen yöntem ile tüm veri kümelerinde çift kübik ara değerlendirme fonksiyonu, ScSR [59], NE [31], KK [135], ANR [136] yöntemlerinden daha iyi PSNR ve SSIM değerleri elde edilirken A+ [55] yöntemiyle kıyaslanabilir sonuçlar elde edilmiştir.

SRCNN yöntemi önceki gelişmiş modellere göre SR kalitesinde üstün performans gösterse de yüksek zaman karmaşıklığı yöntemin gerçek zamanlı uygulamalarda kullanımını engellemektedir. Bu nedenle Dong vd. kendi önerdikleri SRCNN yöntemini hem hızlandıran hem de yöntemin süper çözünürlük performansını artıran FSRCNN (Fast SRCNN) [101] olarak isimlendirdikleri yeni bir yaklaşım önermişlerdir. FSRCNN, SRCNN yönteminin ön işlem adımı olarak kullanılan çift kübik ara değerlendirme adımını ters konvolüsyon biçiminde son işlem olarak uygulamıştır. Ters konvolüsyon dışında ağ yapısı özellik çıkarımı, daralma, eşleşme ve genişletme konvolüsyon katmanlarından oluşmaktadır. Yani eşleşmeden önce özellik boyutlarını daraltma katmanı gelmekte ve eşleşme katmanını genişletme katmanı takip etmektedir. Ayrıca, ek eşleşme katmanlarının eklenmesiyle birlikte filtre boyutları tekrardan düşürülmüştür. Yazarlar, teorik olarak açıklanmadığından dolayı literatürdeki diğer çalışmalar tarafından kuşkulu olarak değerlendirilen 40 kat hızlanma olduğunu iddia etmişlerdir.

Wang vd. [103], ortak benzerlikler için derin bir model uyarlamak için DJSR (Deep Joint Super Resolution) olarak isimlendirdikleri bir model önermişlerdir. Yazarlar, CNN modelinin klasik seyrek kodlama yöntemlerine açık bir biçimde benzediğini savunmuşlar ve çalışmalarında süper çözünürlüğün harici ve kendine benzerliğinden yararlanmışlardır. [104] çalışmasında rapor edilen SDCAE (Stacked Denoising Convolutional Auto-Encoder) yapısını kullanırken, önerilen model auto-encoder ve CNN yapısını birleştirerek veri artırma ile oluşturulmuş harici bir kümeden DÇ görüntüyü giriş ve YÇ görüntüyü çıkış olarak

almaktadır. SDCAE bu verilerle ön eğitilmiştir. Ardından giriş görüntüsünden alınan parçalarla ayarlamalar yapılmıştır. Önerilen yöntemin performansı Set5 ve Set14 veri kümelerinde $\times 2$ ve $\times 3$ büyütme faktörlerinde değerlendirilmiştir. Önerilen yöntem ile çift kübik ara değerlendirme fonksiyonu, ScSR [59] yöntemlerinden daha iyi PSNR ve SSIM değerleri elde edilirken A+ [55] ve SRCNN [30] yöntemiyle kıyaslanabilir sonuçlar elde edilmiştir.

CNN modelinin derin olmasıyla daha doğru sonuçların elde edilebileceği literatürde savunulan bir gerçektir. Bu yaklaşımdan yola çıkılarak Kim vd. [105] çalışmalarında, ImageNet sınıflandırması için kullanılan VGG-net ağından esinlenilerek VDSR (Very Deep Super Resolution) olarak isimlendirdikleri çok derin bir konvolüsyon ağı kullanmışlardır. Art arda bağlanmış derin ağda küçük filtrelerin çok kez kullanılmasını içeren 20 ağırlık katmanlı derinlik kullanarak geniş görüntü bölgelerindeki bilgilerden yararlanılmıştır. Derinliğin büyük olmasından kaynaklı yavaş yakınsama problemi çok yüksek öğrenme oranı kullanarak çözülmüştür. Çok yüksek öğrenme oranı da gradyan patlamasına neden olacağından bu problem de sadece artık bilgi öğrenilerek ve adaptif gradyan kesme yöntemi ile çözülmüştür. Ayrıca önerilen çalışma tek bir ağ üzerinden çok ölçekli süper çözünürlüğe genişletilmiştir. Rapor edilen sonuçlara göre VDSR yöntemi Set5, Set14, B100 ve Urban100 veri kümelerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde çift kübik ara değerlendirme, A+ [55], RFL [132], SelfEx [131], SRCNN [30] yöntemlerine göre üstün performans göstermektedir.

Derin ağlar yüksek doğruluklara sebep olurken beraberinde iki problem doğurmaktadır: aşırı uyuma problemi ve çok büyük modellerin oluşturulması. Bu görüşten yola çıkarak Kim vd. DRCN (Deeply-Recursive Convolutional Network) olarak isimlendirdikleri diğer çalışmalarında [100] aynı konvolüsyon katmanını 16 kez yinelemeli bir biçimde uygulamışlardır. Burada amaç, derinliği artırırken ek parametrelerin doğmasını engellemektir. Çalışmada gradyan patlaması/yok olması problemini rekürsif danışman stratejisi ve katmanların atlayarak geçmesi ile çözmüşlerdir. Parametreleri VDSR yönteminde kullandıkları gibi ayarlamışlardır. Çalışma VDSR sonuçlarını referans olarak içermemesine rağmen kullanılan veri kümeleri ve referans yöntemler aynı olduğundan karşılaştırma yapmak mümkündür. Rapor edilen sonuçlara göre DRCN yönteminin sonuçları VDSR ile kıyaslanabilmektedir; hatta DRCN yöntemi sadece Set5 veri kümesinde VDSR yönteminden daha iyi sonuçlar elde etmektedir.

Lai vd. [17] bir diğer derin öğrenme ile süper çözünürlük yaklaşımı olan LapSRN (Laplacian Pyramid Super Resolution Network) olarak adlandırdıkları çalışmalarında, YÇ

görüntülerin alt bant artıklarını aşamalı bir biçimde oluşturmaya çalışmışlardır. Her bir piramit seviyesinde, önerilen model kötü çözünürlüklü özellik haritasını giriş olarak alarak yüksek frekans artıklarını tahmin etmekte ve özellik haritalarını daha iyi seviyeye iletmek için üst örneklemede transpoz konvolüsyon kullanmaktadır. Önerilen yöntemin piramit yapısından dolayı $\times 2$, $\times 4$ ve $\times 8$ büyütme faktörlerinde Set5, Set14, BSDS100, Urban100 ve Manga109 veri kümeleri üzerinde performans değerlendirmesi yapılarak sonuçlar çift kübik ara değerlendirme, A+ [55], SRCNN [30], FSRCNN[101], RFL [132], SelfEx [131], SCN[106], VDSR[105], DRCN[100] yöntemleriyle karşılaştırılmıştır. Önerilen yöntem $\times 2$ büyütme faktöründe VDSR ve DRCN yöntemleriyle kıyaslamalı sonuçlar üretse de $\times 4$ ve $\times 8$ büyütme faktörlerinde bu yöntemlerden daha başarılı sonuçlar üretmektedir.

Ledig vd. [107] SRResNet olarak isimlendirdikleri çalışmalarında ResNets [137] ağını süper çözünürlük problemi için kullanmışlardır. Aynı çalışmada SRGAN (SR Generative Adversarial Network) olarak isimlendirdikleri yaklaşım da önerilmiştir. Önerilen yaklaşım gerçekçi fotoğraflarda $\times 4$ büyütme faktöründe uygulanan süper çözünürlük yaklaşımlarının ilki olma özelliğini taşımaktadır. Bunun için çekişmeli ve kavramsal kaybın birleşiminden oluşan algısal bir kayıp fonksiyonu önermişlerdir. Önerilen yaklaşımın $\times 4$ büyütme faktöründe Set5, Set14 ve BSDS100 veri kümeleri üzerinde performansı incelenerek sonuçlar en yakın komşu ve çift kübik ara değerlendirme ile SRCNN [30], SelfEx [131], DRCN [100], ESPCN [138] yöntemleriyle karşılaştırılmıştır. SRGAN yaklaşımı ile elde edilen sonuçlar SRCNN yönteminden sayısal olarak daha başarısız sonuçlar üretmesine karşın SRResNet yaklaşımı ile DRCN yönteminden daha iyi sonuçlar elde edilmiştir.

Lim vd. [108] SRResNet ağında bulunan ardışık katmanlardan Batch Normalizasyon (BN) katmanını kaldırarak EDSR (Enhanced Deep Super Resolution) ve MDSR (Multiscale Deep Super Resolution) isimlerini verdikleri ağ yapılarını önermişlerdir. Önerdikleri yaklaşımlarda BN katmanlarını kaldırarak elde ettikleri %40 daha az bellek ihtiyacını katman sayısını artırarak daha geniş model oluşturmada kullanmışlardır. EDSR 32 artık bloktan oluşan bir derinliğe, 256 filtreye (özellik kanalı), 43M parametreye sahiptir ve ağıın içerdiği blokların dışında herhangi bir aktivasyon fonksiyonu kullanmamaktadır. Aynı biçimde MDSR de aktivasyon fonksiyonu kullanmamaktadır. MDSR, süper çözünürlüğü çoklu ölçeklerde yapmaktadır ve 64 filtreli 80 blokluk derinliğe ve 8M parametreye sahiptir. Aynı çalışmada EDSR ve MDSR yaklaşımlarına ek olarak test aşamasında önerdikleri geometrik öz-topluluk (self-ensemble) yaklaşımı ile de EDSR+ ve MDSR+ çalışmalarıyla NTIRE2017 mücadelesinin birinci ve ikinci sırada kazananı olmuşlardır. Önerilen

yaklaşımların $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde Set5, Set14, B100, Urban100 ve DIV2K validasyon veri kümeleri üzerinde performansı incelenerek sonuçlar çift kübik ara değerlendirme, A+ [55], SRCNN [30], VDSR [105], SRResNet [107] yöntemleriyle karşılaştırılmıştır. Karşılaştırmalar incelendiğinde EDSR, MDSR, EDSR+ ve MDSR+ yaklaşımlarının çok üstün performans gösterdiği görülmektedir.

Chu vd. [109] EDSR yaklaşımından esinlenerek MCSR (Multiconnected Super Resolution) olarak isimlendirdikleri ağ yapısını önermişlerdir. Ağın derinliği arttıkça artık bloklar gradyan yok olması problemini ortadan kaldırırken düşük seviye özelliklerin kullanılmasında başarısız olmaktadır. SRResNet ve EDSR yaklaşımları ilk katmanın özellik haritasını sonraki belirli bir katmana ekleyen uzun bir atlamalı bağlantıyla birlikte başarılı performansa sahip olsa da diğer düşük seviyeli özellikler yerine sadece ilk katmanın özelliklerini yeniden kullanmaktadırlar. Bunun yanında mevcut yaklaşımların çoğu iyi performansı garantilemeyen ℓ^2 kayıp fonksiyonuyla ağı eğitmektedir. Benzer biçimde EDSR yöntemi de ℓ^1 kayıp fonksiyonuyla ağı eğitmekte ve başarılı sonuçlar üretmektedir. Fakat ℓ^1 ve ℓ^2 kayıp fonksiyonları çok basit olduklarından aykırı değerlerle baş edememektedir. Bu sebeple yazarlar birleştirme operatörüyle düşük ve yüksek seviyeli özellikleri birleştiren çoklu bağlantılı bloklardan oluşan bir yapı önermişlerdir. Aynı zamanda özellikler uzun bir atlamalı bağlantı ile de tekrar birleştirilmiştir. Ayrıca, daha dayanıklı ve esnek iki parametrelili bir kayıp fonksiyonu kullanmışlardır. Önerilen yaklaşımların $\times 2$, $\times 3$ ve $\times 4$ büyütme faktöründe DIV2K validasyon veri kümeleri üzerinde performansı incelenerek sonuçlar çift kübik ara değerlendirme, SRCNN [30], VDSR [105], SRResNet [107] ve EDSR [108] yöntemleriyle karşılaştırılmıştır. Karşılaştırmalar incelendiğinde farklı kayıp fonksiyonlarıyla ve alt bloklarla oluşturulan MCSR-B (ℓ^2 kayıp), MCSR-B (ℓ^1 kayıp), MCSR-B (iki parametrelili kayıp), MCSR-EB (iki parametrelili kayıp), MCSR-EB+ (iki parametrelili kayıp) yaklaşımlarının her birinin EDSR yönteminden daha başarılı performans gösterdiği görülmektedir.

Wen vd. [110], MCSR yaklaşımına benzer biçimde tüm seviyelerdeki özelliklerin kullanılmasını için DRNet (Densely Connected Residual Networks) olarak isimlendirdikleri bir ağ yapısı önermişlerdir. DRNet çok derin ve geniş bir ağ yapısı sunarken EDSR'ye nazaran daha az parametreye ihtiyaç duymaktadır. Ayrıca önerilen yaklaşım daha yoğun bağlantılı artık bloklardan oluşmaktadır. Her bir blok kendinden önceki katmandan bilgiyi alıp bir sonraki katmana iletmektedir ve kendinden önceki tüm katmanların özelliklerini birleştirip çıkışı oluşturmaktadır. Önerilen yaklaşımların $\times 2$, $\times 3$ ve $\times 4$ büyütme

faktörlerinde Set5, Set14, B100 ve Urban100 veri kümeleri üzerinde performansı incelenerek sonuçlar çift kübik ara değerlendirme, A+ [55], SRCNN [30], VDSR [105], SRResNet [107] ve EDSR [108] yöntemleriyle karşılaştırılmıştır. Karşılaştırmalar incelendiğinde farklı blok sayısı ve filtrelerin boyutlarını ayarlayan büyüme oranının farklı değerleriyle oluşturulan DRNet_S ve DRNet_L yaklaşımlarının her birinin EDSR yönteminden daha başarılı performans gösterdiği görülmektedir.

1.5.4. Medikal Görüntülerde Konvolüsyonel Sinir Ağları Tabanlı Süper Çözünürlük

CNN ağlarının gelişmesiyle birlikte, CNN tabanlı tek görüntü süper çözünürlüğü yaklaşımlarının öğrenme tabanlı modellerle karşılaştırıldığında süper çözünürlük performansını artırdığı görülmektedir. Fakat medikal görüntülere uygulanan CNN çalışmaları, sentetik görüntülerle karşılaştırıldığında zayıf performans göstermektedir [139]. Bu modellerin zayıf performans göstermesinin asıl sebebi yaygın bir şekilde uygulanan veri artırma tekniklerinin medikal görüntülerin istatistiğini korumak amacıyla medikal görüntülere uygulanamamasıdır. Literatürde medikal görüntü istatistiğini korumak için en iyi veri artırma tekniklerini araştıran çalışmalar mevcuttur [140, 141]. Ayrıca medikal yayma görüntüleri teşhis amaçlı kullanıldıklarından dolayı yüksek doğruluk gerektirmektedir. Bütünüyle ele alındığında medikal görüntüler için verimli bir CNN mimarisinin yüksek doğruluk elde edebilmek için iyi tasarlanmasına ihtiyaç vardır.

Bilindiği kadarıyla, mikroskobik görüntü süper çözünürlüğü sadece tek bir çalışmada incelenmiştir [142]. Rivenson vd. çalışmalarında bir optik mikroskobun tasarımını ya da donanımını değiştirmeden performansını önemli ölçüde geliştiren bir CNN yapısının kullanımını önermişlerdir. Önerilen ağ yapısı, standart bir mikroskop ile elde edilen tek bir görüntüyü giriş olarak kullanmakta ve aynı numunenin geliştirilmiş görüntüsünü çıkış olarak vermektedir. Giriş konvolüsyon katmanı 5 artık bloktan oluşmaktadır ve artık blokların her biri konvolüsyon katmanı ve artık blokların peşpeşe sıralandığı 4 katmandan oluşmaktadır. Geliştirdikleri piramit ağ kavramı ile birlikte her bir katmandaki kanal sayısını dereceli olarak artırarak her bir katmandaki öğrenilen özellik sayısını artırmışlardır. Önerilen derin öğrenme yaklaşımını, düşük çözünürlükte görüntülenen çeşitli doku örnekleri kullanarak test etmişlerdir. Sonuçlar mikroskopi araçlarını kullanan çeşitli alanlar için oldukça önemlidir ve çalışma önerilen modelin diğer görüntüleme aygıtlarına da uygulanabileceğini

göstermektedir. Fakat çalışmanın temel kısıtlaması, verimliliğinin yüksek derecede büyütme faktörüne ve doku türüne bağlı olmasıdır. Bahsedilen çalışmada istenen YÇ görüntüyü oluşturmak için tek bir büyütme faktörü incelenmiştir. Ayrıca farklı örnek ve boya türlerinin ağın eğitiminde kullanılması çıkış görüntülerinde renk bozulmalarına sebep olmaktadır.

1.6. Süper Çözünürlükte Performans Ölçümü

Süper çözünürlük yöntemleriyle elde edilmiş YÇ görüntünün performansının ölçümünde kullanılan metriklerin anlatılacağı bu bölümde sentetik ve medikal görüntülerde performans ölçümü için kullanılan metrikler ile uydu görüntülerinde performans ölçümü için kullanılan metrikler ayrı ayrı incelenecektir.

1.6.1. Sentetik ve Medikal Görüntülerde Performans Ölçümü

Sentetik görüntülerde süper çözünürlük algoritmalarının sonuçlarının değerlendirilmesi için öznel ve nesnel yöntemler kullanılmaktadır. Öznel yöntemlerde, genellikle gözlemciler üretilen sonuç görüntüsünün kalitesini değerlendirerek, Fikir Skorlarının Ortalaması (MOS) ve Fikir Skorlarının Varyansı (VOS)'ni içeren nicelenen skorlar öznel ölçüm olarak hesaplanırlar [143]. Nesnel yöntemlerde ise süper çözünürlük algoritmasının sonuçları genellikle MSE ve Tepe Sinyal-Gürültü Oranı (PSNR) gibi metrikler kullanılarak kesin referans görüntüsüyle karşılaştırılır. MSE metriği (41) ile ifade edilmektedir.

$$MSE = \frac{1}{m*n} \sum_{i=1}^m \sum_{j=1}^n (\hat{X}(i,j) - X(i,j))^2 \quad (41)$$

Burada X ve \hat{X} sırasıyla YÇ kesin referans görüntüsünü ve tahmin edilen görüntüyü temsil etmektedir. m ve n ise görüntü boyutlarını göstermektedir. MSE değerinin küçük olması tahmin edilen görüntünün kesin referans görüntüsüne daha çok yaklaştığını göstermektedir. PSNR metriği ise MSE kullanılarak (42)'deki gibi hesaplanmaktadır.

$$PSNR = 10 \log_{10} \left(\frac{(2^n - 1)^2}{MSE} \right) \quad (42)$$

MSE ve PSNR metrikleri süper çözünürlük arařtırmalarında sıklıkla kullanılmasına rađmen insan görsel sistemini iyi derecede temsil etmemektedir [144]. Bu sebeple Yapısal Benzerlik İndeksi Ölçümü (SSIM) [145] metriđi de süper çözünürlük algoritmalarında kullanılmaktadır [144, 146].

SSIM yerel görüntü yapısı, parlaklık ve zıtlığı tek bir yerel kalite metriđinde birleřtirerek görüntü benzerliđini ölçmektedir [145]. Parlaklık terimi $I(\mathbf{X}, \hat{\mathbf{X}})$, zıtlık terimi $c(\mathbf{X}, \hat{\mathbf{X}})$ ve yapısal terim $s(\mathbf{X}, \hat{\mathbf{X}})$ sırasıyla eřitlik (43), (44) ve (45) ile hesaplanmaktadır.

$$I(\mathbf{X}, \hat{\mathbf{X}}) = \frac{2\bar{X}\bar{\hat{X}} + C_1}{\bar{X}^2 + \bar{\hat{X}}^2 + C_1} \quad (43)$$

$$c(\mathbf{X}, \hat{\mathbf{X}}) = \frac{2\sigma_X\sigma_{\hat{X}} + C_2}{\sigma_X^2 + \sigma_{\hat{X}}^2 + C_2} \quad (44)$$

$$s(\mathbf{X}, \hat{\mathbf{X}}) = \frac{\sigma_{X\hat{X}} + C_3}{\sigma_X\sigma_{\hat{X}} + C_3} \quad (45)$$

Burada $\sigma_X, \sigma_{\hat{X}}$ ve $\sigma_{X\hat{X}}$ standart sapmaları ve çapraz kovaryansı ifade etmektedir. C_1, C_2 ve C_3 sabit deđerlerdir. Üç terim (46)'daki gibi birleřtirildiđinde \mathbf{X} ve $\hat{\mathbf{X}}$ arasındaki SSIM benzerlik ölçütü elde edilmektedir.

$$SSIM(\mathbf{X}, \hat{\mathbf{X}}) = [I(\mathbf{X}, \hat{\mathbf{X}})]^\alpha \cdot [c(\mathbf{X}, \hat{\mathbf{X}})]^\beta \cdot [s(\mathbf{X}, \hat{\mathbf{X}})]^\gamma \quad (46)$$

Burada $\alpha > 0, \beta > 0$ ve $\gamma > 0$ parametreleri, üç bileřenin bađlı önemini ayarlamak için kullanılmaktadır. Verilen eřitliđi basitleřtirmek için $\alpha = \beta = \gamma = 1$ ve $C_3 = C_2/2$ deđerlerine ayarlanmaktadır. C_1 ve C_2 parametreleri ise K_1 ve K_2 parametrelerine bađlı olarak belirlenmektedir ve önerilen deđerleri $K_1 = 0.01$ ve $K_2 = 0.03$ olarak verilmektedir. Böylece SSIM indeksi eřitlik (47)'deki gibi yeniden yazılabilir.

$$SSIM(\mathbf{X}, \hat{\mathbf{X}}) = \frac{(2\bar{X}\bar{\hat{X}} + C_1)(2\sigma_{X\hat{X}} + C_2)}{(\bar{X}^2 + \bar{\hat{X}}^2 + C_1)(\sigma_X^2 + \sigma_{\hat{X}}^2 + C_2)} \quad (47)$$

SSIM indeksi 0 ile 1 arasında ondalıklı bir sayıdır ve yüksek SSIM değeri süper çözünürlük performansının daha iyi olduğunu göstermektedir.

1.6.2. Uydu Görüntülerinde Performans Ölçümü

Farklı uzamsal çözünürlüğe sahip uydu görüntülerinin birleştirilmesinde sonuç görüntülerinin kalitesinin değerlendirilmesi için araştırma topluluklarında genellikle kabul edilen genel bir yaklaşım Wald vd. tarafından önerilmiştir [147]. Bu yaklaşım birleştirilen görüntünün sahip olması gereken iki özellik tabanlıdır: tutarlılık ve birleşim özellikleri. Tutarlılık özelliği pan keskinleştirme sürecinin tersinirliğini gerektirmektedir. Yani orijinal MS görüntü pan keskinleştirilmiş görüntünün bozulmasıyla elde edilebilmelidir. İkinci özellik ise pan keskinleştirilmiş görüntü yüksek çözünürlükte aynı sensör tarafından elde edilen aynı sahnenin görüntüsüne olabildiğince benzemelidir.

Pan keskinleştirme yöntemlerinin kalitesini değerlendirmek için Wald vd.'nin protokolü, referans MS görüntüsünden sentetik gözlemlenen görüntü oluşturmaktadır ve ardından pan keskinleştirme yönteminin sonucunu referans görüntüsüne karşı değerlendirmektedir [72, 73]. Mevcut referans görüntüsüyle ilgili olarak pan keskinleştirilmiş görüntünün uzamsal ve spektral bozulmalarını değerlendirmek için birçok metrik önerilmiştir. Yine Wald vd.'nin protokolüne göre hem skaler - tek bir spektral bantta yapılan ölçümler - hem de vektör – tüm spektral bantları birleştirip yapılan ölçümler – benzerlik ya da benzeşmezlik metriği gereklidir. Sayısal değerlendirme yapmak için sıklıkla kullanılan metrikler aşağıda detaylı verilmektedir. Metriklerin hesaplanmasında kullanılan X ve \hat{X} sırasıyla $m \times n$ boyutlu orijinal MS ve pan keskinleştirilmiş görüntüyü temsil etmektedir. \bar{X} ve $\bar{\hat{X}}$ ise sırasıyla orijinal MS ve pan keskinleştirilmiş görüntünün ortalamasını göstermektedir.

- Korelasyon Katsayısı (CC): Orijinal MS ve pan keskinleştirilmiş görüntünün korelasyon derecesini yani spektral benzerliğini ölçmektedir. CC metriği (48) eşitliği ile hesaplanmaktadır. Eğer CC'nin mutlak değeri 1'e yaklaşırsa X ve \hat{X} arasındaki korelasyon da yüksek olmaktadır.

$$CC(\mathbf{X}, \hat{\mathbf{X}}) = \frac{\sum_{i=1}^m \sum_{j=1}^n (\mathbf{X}_{i,j} - \bar{\mathbf{X}}) (\hat{\mathbf{X}}_{i,j} - \bar{\hat{\mathbf{X}}})}{\sqrt{\sum_{i=1}^m \sum_{j=1}^n (\mathbf{X}_{i,j} - \bar{\mathbf{X}})^2 \sum_{i=1}^m \sum_{j=1}^n (\hat{\mathbf{X}}_{i,j} - \bar{\hat{\mathbf{X}}})^2}} \quad (48)$$

- Ortalama Kareysel Hatanın Karekökü (RMSE): Orijinal MS görüntü ile pan keskinleştirilmiş görüntü arasındaki piksel değerlerinin farkını (49) eşitliği ile hesaplamaktadır. Eşitlik (41)'de verilen MSE metriğinin karekökünün alınmasıyla elde edilir. \mathbf{X} , $\hat{\mathbf{X}}$ 'ne eşit olduğunda RMSE değeri 0 olmaktadır.

$$RMSE(\mathbf{X}, \hat{\mathbf{X}}) = \sqrt{\frac{1}{m*n} \sum_{i=1}^m \sum_{j=1}^n (\hat{\mathbf{X}}(i,j) - \mathbf{X}(i,j))^2} \quad (49)$$

- Spektral Açık Haritalama (SAM): Orijinal MS görüntü ile pan keskinleştirilmiş görüntüden elde edilen iki spektrumun spektral benzerliğini ölçmektedir. Her iki görüntünün piksellerinden oluşan iki farklı vektör oluşturulur. Bu vektörler arasındaki açının mutlak değeri spektral bozulmayı belirtmektedir. SAM metriği [148], (50) eşitliği ile hesaplanmaktadır.

$$SAM(\mathbf{X}, \hat{\mathbf{X}}) = \arccos \left(\frac{\langle \mathbf{x}_j, \hat{\mathbf{x}}_j \rangle}{\|\mathbf{x}_j\| \|\hat{\mathbf{x}}_j\|} \right) \quad (50)$$

Burada \mathbf{x}_j ve $\hat{\mathbf{x}}_j$ sırasıyla orijinal ve pan keskinleştirilmiş görüntülerin j . kolonunu göstermektedir. $\langle \cdot, \cdot \rangle$, skaler çarpımı (ya da iç çarpım) ve $\|\cdot\|$, ℓ^2 normunu göstermektedir. SAM indeksinin tüm görüntü için genel değeri tüm pikseller için hesaplanan değerlerin ortalamasının alınmasıyla elde edilmektedir. SAM indeksinin en uygun değeri 0'dır.

- Erreur relative adimensionnelle de synthèse (ERGAS): ERGAS metriği [149] MS görüntü ile pan keskinleştirilmiş görüntünün spektral farkını ölçerek pan keskinleştirilmiş görüntünün tüm spektral kalite ölçüsünü vermektedir. ERGAS ölçütü (51) ile hesaplanmaktadır.

$$ERGAS(\mathbf{X}, \hat{\mathbf{X}}) = 100 \frac{h}{l} \sqrt{\frac{1}{B} \sum_{i=1}^B \left(\frac{RMSE(\mathbf{X}, \hat{\mathbf{X}})_i}{\mu(\mathbf{X})_i} \right)^2} \quad (51)$$

Burada h/l , PAN görüntü ile orijinal MS görüntünün piksel boyutlarının oranını, B pan keskinleştirilmiş görüntünün bant sayısını, $RMSE(\mathbf{X}, \hat{\mathbf{X}})_i$, i . bandın (49) ile hesaplanan değerini ve $\mu(\mathbf{X})_i$ ise i . bandın ortalamasını göstermektedir. Spektral bilgiyi korumak için ERGAS değerinin olabildiğince küçük olması beklenmektedir.

- Q4: Q4 metriği [150], dört bantlı MS görüntüler için hesaplanmaktadır ve [0,1] aralığında skor üretmektedir. En iyi değer olan 1, MS görüntü ile pan keskinleştirilmiş görüntünün aynı olduğu anlamına gelmektedir. Q4 metriği; korelasyon, ortalama sapma, zıtlık değişimi ve her bir bandın spektral açısını göz önünde bulundurmaktadır. Q4 metriği, (52) eşitliği ile tanımlanmaktadır.

$$Q4(\mathbf{X}, \hat{\mathbf{X}}) \triangleq \frac{4|\sigma_{z_1 z_2}| \cdot |\bar{z}_1| \cdot |\bar{z}_2|}{(\sigma_{z_1}^2 + \sigma_{z_2}^2)(|\bar{z}_1|^2 + |\bar{z}_2|^2)} \quad (52)$$

Burada \mathbf{z}_1 ve \mathbf{z}_2 sırasıyla dört bantlı referans MS görüntüsünü ve pan keskinleştirilmiş görüntüyü ifade etmektedir ve kuaterniyon olarak (53) eşitliği ile tanımlanmaktadır.

$$\mathbf{z}_1 = a_1 + \mathbf{i}b_1 + \mathbf{j}c_1 + \mathbf{k}d_1 \quad \mathbf{z}_2 = a_2 + \mathbf{i}b_2 + \mathbf{j}c_2 + \mathbf{k}d_2 \quad (53)$$

(53)'te verilen a , b , c ve d her bir görüntü pikselinin sırasıyla dört bantta (B, G, R ve NIR) radyans değerlerini ifade etmektedir. Q4 indeksi, [0,1] aralığında gerçek değerler almaktadır ve 1 değeri pan keskinleştirilmiş görüntünün referans görüntüsüyle aynı olduğunu göstermektedir.

2. YAPILAN ÇALIŞMALAR

Bu çalışmada, öğrenme tabanlı tek görüntü süper çözünürlüğü yaklaşımları irdelenmiştir. Sentetik görüntüler üzerinde seyrek gösterim ve konvolüsyonel sinir ağlarına dayalı tek görüntü süper çözünürlüğü yaklaşımları incelenirken süper çözünürlüğün gerçek görüntüler üzerinde de başarısını analiz etmek için uygulama alanı olarak uzaktan algılama ve mikroskobik görüntüler üzerinde de çalışmalar yapılmıştır. Literatürdeki sentetik ve gerçek görüntüler üzerinde yapılan çalışmalar, etkin bir süper çözünürlük performansı için temel olarak sırasıyla aşağıda verilen üç unsurun iyileştirilmesini hedeflemiştir:

- Sentetik görüntülerde tek görüntü süper çözünürlüğü için önerilecek yaklaşımlar, süper çözünürlük yaklaşımlarında kullanılan ortak veri tabanlarında test edileceğinden dolayı görüntü iyileştirme performansının yüksek olması önemli bir unsurdur.
- Pan keskinleştirmenin sınıflandırma, hedef tanıma ve sahne yorumlanması gibi pratik uzaktan algılama uygulamalarında genellikle ön işlem olarak kullanılmasından dolayı uzaktan algılama görüntüleri üzerinde tek görüntü süper çözünürlüğü için önerilecek yaklaşımların yüksek spektral ve uzamsal çözünürlüklü daha iyi görüntü üretmesi istenmektedir. Ayrıca, önerilen yöntemin hesaplama karmaşıklığının azaltılarak işlem zamanının düşürülmesi hedefler arasında yer almaktadır.
- Bilgisayar destekli mikroskobik görüntü analizi, herhangi bir hastalık etkeninin varlığını belirlemede klinik çalışanlarına yardımcı olduğundan ve süper çözünürlük bölütleme ve sınıflandırma aşamalarından önce ön işlem olarak kullanıldığından dolayı iyileştirilen görüntünün süper çözünürlük performansının yüksek olması hastalığın tanı performansını artıracaktır.

Tek görüntü süper çözünürlüğünde literatürdeki araştırmacılar tarafından üzerinde durulan unsurların iyileştirilmesi ve mevcut sorunların giderilmesi tez kapsamında yapılan çalışmaların hedeflerini belirlemektedir. Bu bölümde genel bilgiler kısmında verilen sentetik ve gerçek görüntüler üzerinde öğrenme tabanlı süper çözünürlük yaklaşımlarına yönelik önerilen çalışmalar irdelenerek verilen hedefler doğrultusunda iyileşme sağlayacak yeni süper çözünürlük yaklaşımları önerilmektedir.

Sentetik görüntüler üzerinde gerçekleştirilen seyrek gösterime dayalı süper çözünürlük yaklaşımlarının özellik çıkartımı aşamasında Dalgacık dönüşümü kullanılarak çoklu sözlük

öğrenmesi ve farklı bir özellik çıkarım yöntemi olarak Gabor dalgacıklarının kullanılması bu tez çalışmasında önerilmiştir. DÇ görüntü özelliklerinin PCA yöntemi ile boyut azaltımı gerçekleştirilerek yaklaşımların verimli ve daha hızlı olması sağlanmıştır. Çalışma kapsamında sözlük öğrenmesi ve seyrek kodlama K-SVD ve OMP algoritmaları kullanılarak iteratif bir biçimde gerçekleştirilmiştir. Önerilen süper çözünürlük yaklaşımları bu alanda yaygın kullanıma sahip olan yaklaşımlarla kıyaslanmıştır.

Uzaktan algılama görüntülerinde çoklu çözünürlük analizi ve bileşen yerine koyma yaklaşımları son yıllarda literatürde yaygın olarak pan keskinleştirme amacıyla kullanılmaktadır. Bu çalışmada mevcut yaklaşımlardan farklı olarak süper çözünürlük teorisinden yola çıkılarak seyrek gösterime dayalı sözlüklerin doğrudan kullanılması yerine öğrenildiği yeni bir pan keskinleştirme yaklaşımı önerilmiştir. Sözlük öğrenmesinde algoritmanın hızını önemli bir biçimde geliştirmede gerekli olan zaman karmaşıklığını azaltmak için rastgele örneklenmiş ham görüntü parçalarının doku bilgisi öğrenilmiştir. Ayrıca sadece ayırt edici özelliklerin öğrenilmesini sağlayan varyans hesabına dayalı bir yaklaşım sunulmuştur. YÇ görüntü oluşturma sürecinde örtüşen bölgelerde ortalamanın alınmasıyla meydana gelen bulanıklığın etkisini azaltmak için literatürde ilk kez iteratif geri izdüşürme algoritmasının pan keskinleştirme problemi için kullanımı önerilmiştir. Sunulan her bir katkının sözlük öğrenmesi ve YÇ görüntü oluşturma sürecine uygulanmasıyla süper çözünürlük performansına etkisi incelenmiştir. Önerilen pan keskinleştirme yaklaşımı bu alanda yaygın kullanıma sahip olan birçok çoklu çözünürlük ve bileşen yerine koyma yaklaşımlarıyla kıyaslandığından literatürde en çok karşılaştırmanın yapıldığı ve başarılı performans gösteren ilk çalışma olma özelliğini taşımaktadır.

Bu bölümde incelenen diğer bir öğrenme tabanlı süper çözünürlük yaklaşımı olan konvolüsyonel sinir ağlarının, son birkaç yılda süper çözünürlük performansını büyük ölçüde etkileyerek seyrek gösterime dayalı süper çözünürlük yaklaşımlarından daha başarılı performans gösterdiği görülmektedir. Bu sebeple bu çalışmada literatürde araştırmacılar tarafından süper çözünürlük probleminin çözümü için önerilen konvolüsyonel sinir ağları yapılarının analizi gerçekleştirilmiştir. Süper çözünürlük performansının daha da geliştirilmesi için yoğun atlamalı bağlantılar içeren yeni bir ağ yapısı önerilerek atlamalı bağlantıların, ağ yapısı içerisinde kullanılan blok ve her bir blok içerisindeki katmanların etkisi incelenmiştir. Elde edilen sonuçlar bu alanda yaygın kullanıma sahip olan yaklaşımlarla kıyaslanmıştır.

Mikroskopik görüntüler üzerinde süper çözünürlük probleminin uygulanmasıyla YÇ görüntü elde etme literatürde oldukça yeni bir konu olmakla birlikte sadece tek bir çalışmada incelenmiştir [142]. Bu çalışmadan yola çıkarak tez kapsamında artık öğrenme kavramına dayalı derin bir ağ yapısı problemin çözümü için önerilmiştir. Yeni bir yaklaşım olan bu ağ yapısı aynı zamanda her bir büyütme faktörü için ağın yeniden eğitilmesiyle ortaya çıkan parametre sayısının artarak ağın saklanması ve getirilmesi maliyetini de düşüren çoklu ölçekler için tek model olma özelliği taşımaktadır. Bu özelliğinden farklı olarak [142] çalışmasında vurgulanan farklı doku ve boya türlerinde tek bir ağ modelinin kullanılmasının getirdiği renk bozulması problemi de yine önerilen ağ ile ortadan kaldırılmıştır. Bir diğer katkı olarak [142] çalışmasından farklı olarak ağ yapısının performansı birden fazla büyütme faktörlerinde incelenmiştir.

Bu tez çalışmasında yapılan deneylerde konvolüsyonel sinir ağları toolbox'ı kullanılmış olup diğer uygulamalar Matlab simülasyon ortamında kodlanarak geliştirilmiştir. Tez kapsamında önerilen çalışmaların detayları sırasıyla ilerleyen bölümlerde verilmektedir.

2.1. Ayrık Dalgacık Dönüşümüne Dayalı Tek Görüntü Süper Çözünürlüğü

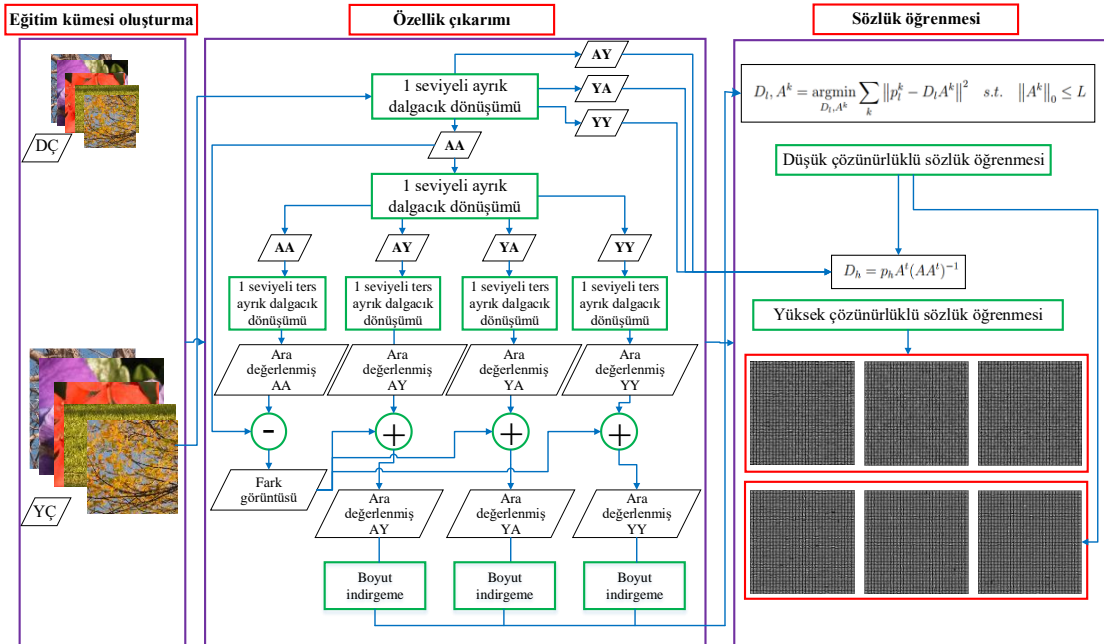
Tek görüntü süper çözünürlüğünde ara değerlendirme tabanlı teknikler, hedef komşu pikseller yardımıyla kayıp piksellerin değerlerini tahmin ederek DÇ görüntüyü YÇ görüntüye dönüştüren en temel tekniklerdir. Bu teknikler arasında 2D en yakın komşu, çift doğrusal ve çift kübik gibi sıklıkla kullanılan teknikler bulunmaktadır. Görüntü süper çözünürlüğünün amacı, DÇ görüntü veya bazı önsel varsayımlara bağlı olarak bir YÇ görüntünün yüksek frekans bileşenlerini kurtarmaktır. Fakat mevcut ara değerlendirme tabanlı teknikler giriş görüntüsünün içerdiği bu bilgiyi yeterince kullanamamaktadır. Dalgacık dönüşümü de görüntü çözünürlüğünü iyileştirmede oldukça yeni bir yaklaşımdır ve bunların içerisinde en çok tercih edileni dalgacık sıfır doldurma (wavelet zero padding) olarak da bilinen dalgacık ara değerlendirme yöntemidir. Bu çalışmada dalgacık dönüşümü ile seyrek temsiliyeti birleştiren ara değerlendirme tekniklerine alternatif olabilecek yeni bir yaklaşım önerilmektedir.

Bu sebeple önerilen çalışmada, [151] görüntü iyileştirme çalışmasından esinlenilerek ayrık dalgacık dönüşümüne (DWT) dayalı seyrek gösterim tabanlı tek görüntü süper

çözünürlüğü yaklaşımı önerilmektedir. Bu amaçla 1 seviyeli DWT kullanılarak verilen görüntü yaklaşık, yatay, dikey ve köşegen detay alt bantları olmak üzere 4 alt banda ayrılmaktadır. Bu ayrıştırmanın yapılmasının sebepleri ise DWT'nin görüntülerin yerel uzamsal ve frekans bilgisini oldukça iyi çıkarması ve çıkarılan bu alt bantlardan sentetik görüntüler arasındaki ilişkinin verimli bir şekilde öğrenilip YÇ görüntü oluşturma aşamasında kullanılmasıdır. Önerilen yaklaşımın sözlüklerin öğrenilmesi ve YÇ görüntü oluşturma süreçleri alt başlıklarda detaylandırılacaktır.

2.1.1. Sözlüklerin Öğrenilmesi

Önerilen yaklaşımın sözlük öğrenmesi süreci Şekil 11'de gösterilmektedir. Eğitim süreci, YÇ görüntülerden oluşan bir eğitim kümesinin oluşturulmasıyla başlamaktadır. Tüm YÇ görüntüler YCbCr renk uzayına dönüştürülür ve önerilen sözlük öğrenmesi algoritması sadece parlaklık kanalına uygulanmaktadır. Eğitim kümesindeki her bir görüntü s büyütme faktörü ile alt örneklerek DÇ görüntüler oluşturulmaktadır. Bu çalışmada s büyütme faktörü ile alt örnekleme süreci, görüntünün boyutunu her boyutta yarıya düşüren DWT'nin karakteristiği kullanılarak gerçekleştirilmiştir. Bu yüzden s büyütme faktörü 2 seçilmiştir.



Şekil 11. Ayrık dalgacık dönüşümüne dayalı önerilen yaklaşımın sözlük öğrenmesi süreci

Bu bölümde öncelikle özellik çıkarımı aşamasında kullanılan DWT ve PCA alt uzay yöntemlerine değinilecek, ardından sözlük öğrenmesi süreci anlatılacaktır.

2.1.1.1. Dalgacık Dönüşümü

Dalgacık dönüşümü, bir işaretin frekans bilgisini farklı zamanlarda ölçerek zaman-frekans analizini sağlayan bir araçtır. Ayrık dalgacık dönüşümü, bir $f(t)$ fonksiyonunun ψ dalgacık ana fonksiyonu ile iç çarpımı olarak (54) ve (55) eşitliği ile hesaplanmaktadır.

$$W_{\psi}f(t) = \langle f, \psi_{j,k} \rangle = \sum_t f(t)\psi_{j,k}(t) \quad (54)$$

$$\psi_{j,k}(t) = 2^{j/2}\psi(2^j t - k) \quad (55)$$

(54) ve (55) eşitliklerindeki j ve k reel sayılardır. Frekans bilgisi j ölçek faktörü ile kontrol edilirken k , t eksenindeki öteleme konumunu belirtmektedir. Bu yüzden (54) ifadesi daha genel biçimde (56) eşitliği ile yeniden yazılabilir.

$$c(\text{ölçek}, \text{konum}) = \sum_t f(t)\psi(\text{ölçek}, \text{konum}) \quad (56)$$

Burada c dalgacık katsayısını ifade etmektedir.

Dalgacık dönüşümünde sıklıkla alt bant kodlama ve piramitsel ayrıştırımadan yararlanılan çoklu çözünürlük analizi teorisi kullanılmaktadır. Piramit ayrıştırmasında giriş işareti alt bant kodlama adı altında bir filtre bankasından geçirilmekte ve böylece her bir ölçekte alçak ve yüksek geçiren filtrelerle iki kısma ayrılarak alt bantlardan oluşan bir kümeye ayrıştırılmaktadır.

Alt bant kodlamada gerekli olan filtre bankaları birkaç yolla oluşturulmaktadır. Sabit bir filtre bankası kullanan alt bant kodlama ile aynı şey olan dalgacık dönüşümünde de işaret alçak ve yüksek geçiren filtreler ile iki parçaya ayrılmaktadır. Ölçekleme ve dalgacık filtre katsayılarından oluşan filtre bankaları (57) ve (58) eşitlikleri ile işarete uygulanarak alçak ve yüksek frekans bilgileri elde edilmektedir.

$$\phi(t) = \sum_k h(k)\sqrt{2}\phi(2t - k) \quad (57)$$

$$\psi(t) = \sum_k g(k)\sqrt{2} \phi(2t - k) \quad (58)$$

Ölçekleme (h) ve dalgacık filtre katsayılarını (g) ifade eden alçak ve yüksek geçiren filtreler tamamen birbirinden bağımsız değildir ve birbirlerine (59) eşitliği ile bağlıdır.

$$g(k) = (-1)^k h(L - 1 - k), \quad k \in \{0, \dots, L - 1\} \quad (59)$$

Burada $g(k)$ yüksek geçiren filtreyi, $h(k)$ alçak geçiren filtreyi ve L filtrenin uzunluğunu göstermektedir. Alçak geçiren filtreden yüksek geçiren filtreye dönüşüm $(-1)^n$ terimi ile sağlanmaktadır.

Görüntü gibi iki boyutlu işaretlere uygulanan dalgacık dönüşümünde öncelikle tek seviyeli bir boyutlu dalgacık dönüşümü görüntünün satırları boyunca uygulanır. Ardından; ilk adımda elde edilen dönüştürülmüş görüntünün kolonları boyunca dalgacık dönüşümü tekrar uygulanır. İki boyutlu ayrık dalgacık dönüşümü (60) ile ifade edilmektedir.

$$W_{\psi} f(x, y) = \langle f(x, y), \psi_{j,kx,ky} \rangle = \sum_x \sum_y f(x, y) \psi_{j,kx,ky}(x, y) \quad (60)$$

Burada kx ve ky sırasıyla x ve y eksenlerindeki ötelemeleri göstermektedir. Bu iki işlemin sonucu 4 ayrı banttı oluşturur: LL (alçak-alçak), LH (alçak-yüksek), HL (yüksek-alçak), HH (yüksek-yüksek). Burada L alçak geçiren filtrelemeyi ifade ederken, H yüksek geçiren filtrelemeyi ifade etmektedir. 2B dalgacık dönüşümünde ölçekleme ve dalgacık filtre katsayılarından oluşan filtre bankaları (61) eşitlik takımı ile verilmektedir.

$$\begin{aligned} \phi(x, y) &= \phi(x)\phi(y) \\ \psi^Y(x, y) &= \psi(x)\phi(y) \\ \psi^D(x, y) &= \phi(x)\psi(y) \\ \psi^K(x, y) &= \psi(x)\psi(y) \end{aligned} \quad (61)$$

(61) eşitlik takımında verilen ilk ifade orijinal görüntünün yaklaşık olarak 2 faktörüyle alt örneklenmiş görüntüsüne karşılık gelirken LL bandını göstermektedir. LH bandını ifade eden ikinci eşitlik yatay özellikleri korurken, üçüncü eşitlik ile ifade edilen HL bandında

orijinal görüntünün dikey özellikleri korunmaktadır. Son olarak, HH bandı ise görüntünün yüksek frekans anahtar noktalarını korumaktadır.

2.1.1.2. Temel Bileşen Analizi

PCA, örüntü tanımada en sık kullanılan öznitelik çıkarma ve veri temsili tekniğidir. Amacı büyük bir küme içerisindeki bilginin çoğunu saklayarak değişkenlerin geniş kümesini küçük bir kümeye indirecek dönüşümün bulunmasıdır [152].

PCA algoritmasının işlem adımları şu şekildedir:

1. Öznitelik uzayını belirleyecek olan eğitim kümesi oluşturulur.
2. Eğitim kümesindeki bütün örneklerden ortalaması 0 olacak şekilde yeni bir veri kümesi oluşturulur. Bunun için her bir boyutta ortalama değer örneklerin ilgili boyutundan çıkartılır.

$$\bar{x}_i = x_i - m, \quad i = 1, 2, \dots, n \quad (62)$$

3. Veri kümesindeki veriler arasındaki dağılımın ölçüsü olan kovaryans matrisi hesaplanır.

$$S_t = \sum_{i=1}^n \bar{x}_i \bar{x}_i^T \quad (63)$$

4. Varyansı en büyük değerine çıkararak izdüşüm yönünü bulmak için kovaryans matrisinin özdeğer ve özvektörleri hesaplanır.

$$S_t e = \lambda e \quad (64)$$

Burada λ özdeğerleri gösterirken e özdeğerlerle ilişkilendirilmiş özvektörlerin kümesini ifade etmektedir. Özdeğer ve özvektörlerin hesaplanması için QR ve QL teknikleri sıklıkla kullanılmaktadır.

5. En yüksek özdeğerlere karşılık gelen özvektörler verinin temel bileşenlerini oluşturmaktadır. Bu nedenle özdeğerler büyükten küçüğe doğru sıralanarak

bileşenlerin önem sırası belirlenmiş olur. Genlikleri toplamı bütün özdeğerlerin genlikleri toplamının belirli bir yüzdesini bulan en az sayıda özdeğere karşılık gelen özvektörler seçilir. Böylece boyut azaltımı gerçekleştirilmiş olur. Her ne kadar bazı bilgiler kaybolursa da özdeğerler küçük olduğundan kaybolan bilgiler anlamsız olmaktadır. Daha açık ifade edilecek olursa orijinal veri n boyutlu olduğunda bu verilerin özdeğer ve özvektörleri hesaplandıktan sonra içerisinde sadece ilk p özvektör seçilir.

$$\text{Özellik vektörü} = e = (e_1, e_2, \dots, e_p)$$

6. PCA'nın son adımında özellik vektörü oluşturulduktan sonra vektörün transpozu alınarak orijinal veriyle çarpılır ve boyut indirgenmiş veri oluşturulur.

Bu tez çalışmasında özellik vektörlerine ayrı ayrı PCA yöntemi uygulanarak parçaların ortalama enerjilerinin %99.9'unu koruyarak izdüşürülecekleri bir alt uzay aranmıştır.

2.1.1.3. Sözlük Öğrenmesi

Eğitim veri kümesindeki YÇ görüntülere öncelikle tek seviyeli DWT uygulanmaktadır; böylece 4 farklı alt bant görüntüsü, LL, LH, HL, HH oluşmaktadır. YÇ görüntününün alçak geçiren filtre ile filtrelenmesiyle elde edilen DÇ görüntü ikinci tek seviyeli DWT'nin girişi olarak kullanılmaktadır. İkinci kez uygulanan DWT ile elde edilen görüntüler her bir boyutta giriş görüntüsünün çeyrek boyutundadır. Bu sebeple, yüksek frekans alt görüntülere diğer 3 alt bant 0'a eşitlenerek ayrı ayrı ters DWT uygulanmaktadır. Sonraki adımda ilk seviyede elde edilen LL alt bandından ara değerlendirilmiş LL alt bandının çıkarılmasıyla elde edilen fark görüntüsünden düşük frekansları bilgisini kaldırmak için yararlanılmıştır. Bu fark görüntüsü ardından yüksek frekans alt bant görüntülerine eklenmektedir. Elde edilen alt bant görüntüleri DÇ sözlükleri oluşturmak için kullanılmıştır.

DÇ sözlükleri öğrenmek için yerel örtüşen parçalar ara değerlendirilmiş alt görüntülerden ayrı ayrı çıkarılmaktadır. Ardından, bu parçalar her bir bant için tek bir vektöre, $x_j^i, i = AY, YA, YY$, birleştirilmektedir. Sözlük öğrenmesi sürecinde hesaplamaları azaltmak için PCA yöntemi boyut indirgeme yöntemi olarak her bir bant için çıkarılan parçalara

uygulanmaktadır. K-SVD sözlük öğrenmesi algoritması (65) eşitliğine göre bu parçalara uygulanarak DÇ sözlükler, D_l^i , oluşturulmuştur.

$$D_l^i, \alpha^i = \underset{D_l^i, \alpha^i}{\operatorname{argmin}} \|x_l^i - D_l^i \alpha^i\|^2 \text{ öyle ki } \|\alpha^i\|_0 \leq T_0 \quad (65)$$

Verilen ifade ayrıca DÇ eğitim parçalarına, x_l^i , ait olan seyrek temsiliyet katsayı vektörünü de üretmektedir. DÇ sözlüklere karşılık gelen YÇ sözlükler ise YÇ görüntü parçaları ve seyrek temsiliyet katsayı vektörü kullanılarak (66) eşitliği ile çözülmektedir.

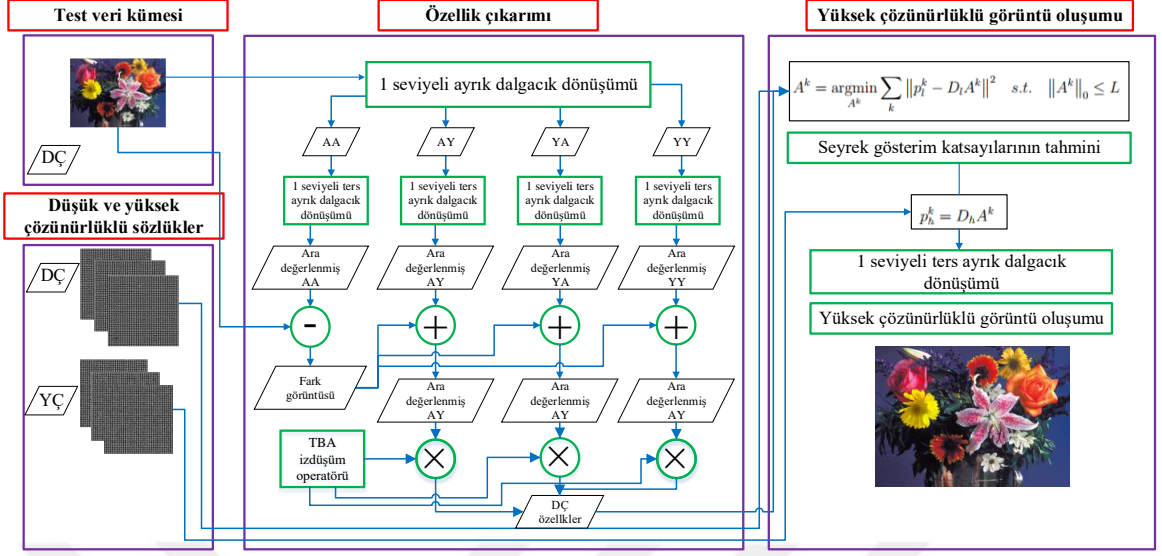
$$D_h^i = X_h A^T (A A^T)^{-1} \quad (66)$$

Burada t ve -1 sırasıyla transpoz operatörünü ve yalancı-ters ifadesini göstermektedir.

2.1.2. Yüksek Çözünürlüklü Görüntü Oluşturma

Önerilen yaklaşımın yüksek çözünürlüklü görüntü oluşturma süreci Şekil 12’de verilmektedir. DWT’ne dayalı önerilen tek görüntü süper çözünürlüğünün girişi olarak kullanılacak DÇ test görüntüsü, YÇ görüntünün dalgacık uzayında alçak geçiren filtre ile filtrelenmesi sonucu elde edilmektedir. DÇ test görüntüsü YCbCr uzayına dönüştürülerek yüksek çözünürlüklü görüntü oluşturma algoritması sözlük öğrenmesi sürecinde olduğu gibi sadece parlaklık kanalına uygulanmaktadır. Öncelikle görüntü dalgacık alt bant görüntülerine ayrıştırılır; ardından her banda 1 seviyeli ters DWT uygulanarak ara değerlendirilmiş alt bant görüntüleri elde edilmektedir.

Süper çözünürlük probleminin asıl amacı kenar yapılarını ve doku bölgelerini koruyarak DÇ görüntülerden YÇ görüntüler elde etmektir. Gerçekleştirilen deneylerde ince detaylara sahip keskin kenarlı görüntüler elde edip yapay bozuklukları bastırmak önemlidir. Bundan dolayı, bu çalışmada ara bir adım yüksek frekans ara değerlendirilmiş alt bant görüntülerini doğrulamak için kullanılmıştır.



Şekil 12. Ayrık dalgacık dönüşümüne dayalı önerilen yaklaşımın yüksek çözünürlüklü görüntü oluşturma süreci

DÇ giriş görüntüsünden ara değerlendirilmiş alçak frekans alt bant görüntüsünün çıkarılmasıyla elde edilen bir fark görüntüsü yüksek frekans alt bant görüntülerine eklenmiştir. Sonraki adım ara değerlendirilmiş alt bant görüntülerinden yerel örtüşen parçaların çıkarılması olan parça çıkarımı adımıdır. Bu parçalar boyut indirgemesi için PCA izdüşüm operatörüyle çarpıldıktan sonra DÇ sözlükler yardımıyla OMP algoritması bu parçalara uygulanıp seyrek temsiliyet vektörü elde edilmektedir.

$$\alpha^i = \underset{\alpha^i}{\operatorname{argmin}} \|x_h^i - D_h^i \alpha^i\|^2 \text{ öyle ki } \|\alpha^i\|_0 \leq T_0 \quad (67)$$

Seyrek temsiliyet vektörünün, α^i , D_h^i YÇ çözünürlüklü sözlükle (68) eşitliğindeki çarpımı yaklaşık YÇ parçaları x_h^i vermektedir.

$$x_h^i = D_h^i \alpha^i \quad (68)$$

Ardından, YÇ alt bant görüntü parçaları örtüşen bölgelerde ortalamalarının alınmasıyla alt bant görüntüleri oluşmaktadır. YÇ çıkış görüntüsü ise yaklaşık alt bant olarak DÇ giriş görüntüsü ile alt bant görüntülerine ters DWT uygulanmasıyla oluşturulmaktadır.

2.2. Çok Ölçekli ve Çok Yönlü Gabor Özellik Temsilietine Dayalı Tek Görüntü Süper Çözünürlüğü

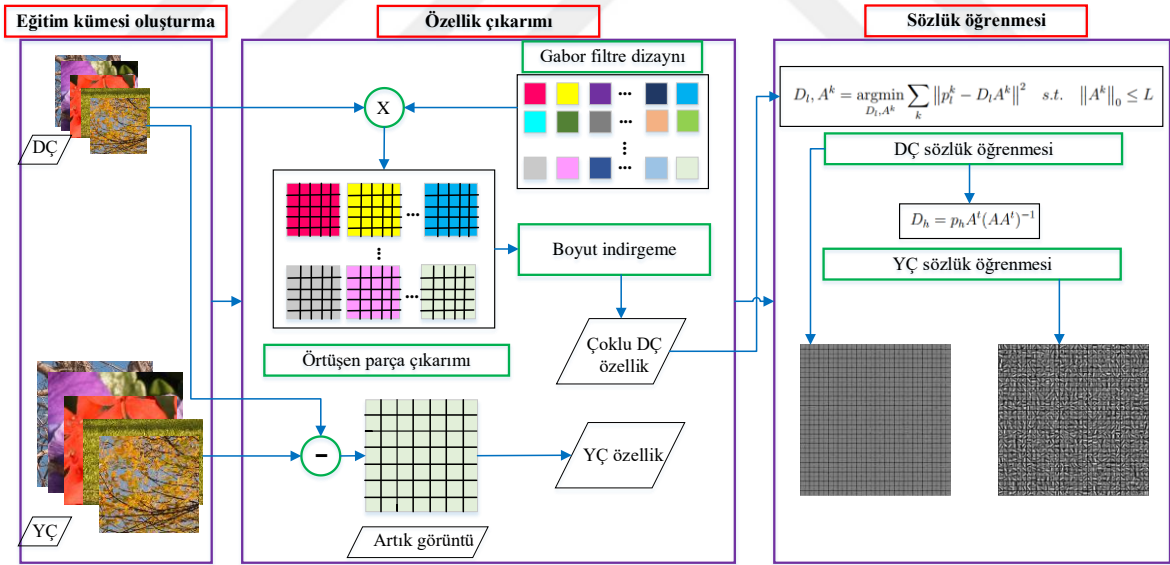
Tek görüntü süper çözünürlüğünde önerilen öğrenme tabanlı çalışmalar, DÇ görüntü parçalarından özellik çıkarılması için çeşitli filtrelerin kullanımını önermiştir. Bu filtreler görüntüdeki, bölgeler arasındaki parlaklık değişimi olarak tanımlanan kenar bilgisi, farklı yönlerdeki kenar bölgelerinin birleşimi olarak tanımlanan köşe bilgisi ve sınır bilgisi gibi tüm görüntü yapılarını çıkarmada başarısız olmaktadır. Öğrenme tabanlı süper çözünürlük için yapılan ilk çalışmada Freeman vd. DÇ parçalardan özellik olarak kenar bilgisini çıkarmak için yüksek geçiren bir filtre kullanmışlardır [60]. Sun vd. ise sınır bilgisini çıkarmak için Gauss türev alıcı filtreleri kullanmışlardır [61]. Chang vd. temsiliyet için parçaların birinci ve ikinci dereceden türev bilgilerini kullanmışlardır [31]. Seyrek temsiliyet teorisi ile süper çözünürlük probleminin çözümünü hedefleyen seyrek temsiliyet tabanlı süper çözünürlük çalışmasının ilki olan Yang vd. [56] tarafından önerilen çalışmada Chang vd. [31]'nin yöntemindeki aynı varsayım kullanılarak birinci ve ikinci dereceden türev bilgisi kullanılmıştır. Bu çalışma seyrek temsiliyet tabanlı süper çözünürlük yaklaşımlarının öncü çalışması konumunda olup literatürde kendinden sonraki seyrek temsiliyet tabanlı çalışmalara [58, 59, 153, 154] referans olmuştur ve bu çalışmalarda da birinci ve ikinci dereceden türev bilgisi DÇ parçalardan kenar ve sınır bölgelerini çıkarmak için özellik tanımlayıcısı olarak kullanılmıştır. Literatürde kullanılan özellik tanımlayıcıları sentetik görüntülerdeki karmaşık yerel yapıları gözardı etmekte ve bulanıklık, basamak ve salınım etkileri daha çabuk görülmektedir. Böylece oluşturulan YÇ görüntünün kalitesi düşmektedir. Bu çalışmada, seyrek temsiliyete dayalı tek görüntü süper çözünürlüğünde farklı görüntü özellikleri kullanılarak daha dayanıklı ve ayırt edici sözlükler oluşturmayı sağlayan yeni bir yöntem önerilmektedir. Bu amaçla literatürde ilk kez DÇ ve YÇ görüntüler arasındaki eşleşmeyi öğrenmek için çok ölçekli ve çok yönlü Gabor özellik tanımlayıcısından yararlanılmıştır. Önerilen yaklaşımın sözlük öğrenmesi ve YÇ görüntü oluşturma süreçleri alt başlıklarda detaylandırılacaktır.

2.2.1. Sözlük Çiftinin Öğrenilmesi

Önerilen yaklaşımın sözlük öğrenmesi süreci Şekil 13'te gösterilmektedir. Seyrek temsiliyete sahip overcomplete bir sözlük genellikle dönüşüm domeni yöntemleri ya da

sözlük öğrenmesi yöntemlerinden yararlanılarak elde edilmektedir. Seyrek temsiliyetten yararlanan sözlük öğrenmesi yöntemleri dönüşüm tabanlı önceden tanımlı sözlüklerden daha iyi performans göstermektedir [50]. Sözlük öğrenmesi yöntemlerinde sözlük eğitim görüntü parçalarından oluşan bir kümeden öğrenilmektedir. Bu yüzden, sözlük öğrenmesi süreci $y_h^j = \{y_h^1, \dots, y_h^i, \dots, y_h^N\}$ YÇ görüntülerden oluşan bir eğitim kümesinin oluşturulmasıyla başlamaktadır. Burada y_h^i i . YÇ görüntüyü ve N YÇ görüntü sayısını göstermektedir. Tahmin edilen \hat{y}_h^j görüntüsünün karşılık gelen y_h^j görüntüsüyle aynı boyutta olduğu ve y_h^j görüntüsüne oldukça benzer olduğu farzedilmektedir. Bu yüzden, YÇ görüntüler s büyütme faktöründe çift kübik ara değerlendirme yöntemi ile alt örneklenecek DC eşi elde edilmekte ve ardından gerçek boyutuna üst örneklenecek y_l^j DC görüntüler, DC sözlük üretmek için kullanılmak üzere oluşturulmaktadır. Diğer taraftan y_h^j ve y_l^j arasındaki fark yani e_h^j artık görüntüsü YÇ sözlük üretmek için kullanılmaktadır.

Bu bölümde öncelikle özellik çıkarımı aşamasında kullanılan Gabor dalgacıkları yöntemine değinilecek, ardından sözlük öğrenmesi süreci anlatılacaktır.



Şekil 13. Gabor özellik temsiliyetine dayalı önerilen yaklaşımın sözlük öğrenmesi süreci

2.2.1.1. Gabor Dalgacıkları

Gabor filtresi tabanlı özellikler son yıllarda özellik çıkarımı, kenar algılama, doku analizi, bölütleme ve sınıflandırma gibi birçok görüntü işleme ve bilgisayarla görü uygulamasında kullanılmaktadır. Bu alanlarda dikkat çekmesinin asıl sebebi Gabor filtreleri ile görme merkezindeki basit hücrelerin alıcı alanlarının benzer olmasıdır [155].

Gabor filtresi 2 boyutlu bir Gaussian zarfı ile modüle edilmiş belirli frekans ve yönde sinüzoidal bir düzlem olarak görülmekte ve (69) eşitliği ile tanımlanmaktadır.

$$h(x, y) = s(x, y)g(x, y) \quad (69)$$

Burada $s(x, y)$ taşıyıcı olarak bilinen 2 boyutlu karmaşık sinüzoid ve $g(x, y)$ zarf olarak bilinen 2 boyutlu Gaussian biçimli bir fonksiyondur. Karmaşık sinüzoidin ilk boyutu olan reel eksen kosinüs dalgası içerirken ilk boyuta dik olan ikinci boyutu imajiner kısımdır ve sinüs dalgası içerir. Karmaşık sinüzoid, (70) ile ifade edilmektedir.

$$s(x, y) = \exp(j(2\pi(u_0x + v_0y) + P)) \quad (70)$$

(70) eşitliğinde u_0 ve v_0 kartezyen koordinatlardaki uzamsal frekansları, P ise fazı ifade etmektedir. 2 boyutlu Gaussian fonksiyonu (71) eşitliği ile verilmektedir.

$$g(x, y) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right) \quad (71)$$

Parametreler için genel notasyon kullanılarak Gabor filtre tabanlı özellik çıkarmanın temelini oluşturan 2 boyutlu Gabor fonksiyonu uzaysal domende (72), frekans domeninde (73) eşitlikleri ile ifade edilir.

$$\psi(x, y) = \frac{f^2}{\pi\gamma\eta} \exp\left(-\left(\frac{f^2}{\gamma^2}x'^2 + \frac{f^2}{\eta^2}y'^2\right)\right) \exp(j2\pi f x') \quad (72)$$

$$x' = x\cos\theta + y\sin\theta$$


$$y' = -x\sin\theta + y\cos\theta$$

$$\psi(u, v) = \exp\left(\frac{\pi^2}{f^2}(\gamma^2(u' - f)^2 + \eta^2 v'^2)\right)$$

$$u' = u \cos \theta + v \sin \theta$$

$$v' = -u \sin \theta + v \cos \theta$$
(73)

Burada f filtrenin merkezi frekansını, θ Gaussian büyük eksen ve düzlem dalgasının döndürme açısını, γ büyük eksen boyunca keskinliği ve η küçük eksen boyunca keskinliği ifade etmektedir. Gabor filtre bankasının tasarlanması f , θ , γ ve η filtre parametrelerinin değerlerinin uygun kümesinin seçiminden oluşmaktadır. Çeşitli parametrelerin olası kombinasyonları filtre bankasının uzamsal ve frekans domenini nasıl analiz edeceğini belirlemektedir. Fourier benzerlik teoremiyle yorumlanabilen parametrelerin etkisi Şekil 14'te gösterilmektedir. Şekil 14'te verilen alt şekillerde sırasıyla parametre değerleri şu şekildedir: ($f = 0.5, \theta = 0^\circ, \gamma = 1.0, \eta = 1.0$); ($f = 1.0, \theta = 0^\circ, \gamma = 1.0, \eta = 1.0$); ($f = 1.0, \theta = 0^\circ, \gamma = 2.0, \eta = 0.5$); ($f = 1.0, \theta = 45^\circ, \gamma = 2.0, \eta = 0.5$).



Şekil 14. Uzamsal domende (üst satır, sadece reel kısımlar) ve frekans domeninde (alt satır) 2 boyutlu Gabor filtre fonksiyonları [155].

Çoğu uygulamalarda, (74) eşitliği ile ifade edilen $U \times V$ Gabor dalgacık ailesi, genellikle çoklu çözünürlük ve çoklu yön analizi gerçekleştirmek için gerekli olmaktadır.

$$\{\varphi_{ayrık}(f_u, \theta_v, \gamma, \eta)(x, y)\}$$

$$f_u = \frac{f_{max}}{\sqrt{2}^u}, \quad \theta_v = \frac{v}{V}\pi, \quad u = 0, \dots, U-1, \quad v = 0, \dots, V-1$$
(74)

Burada f_u ve θ_v Gabor dalgacıklarının sırasıyla yön ve ölçeğini, f_{max} maksimum merkezi frekansı ve $\sqrt{2}$ farklı merkezi frekanslar arasındaki aralık faktörünü ifade etmektedir.

Bu çalışmada $f_{max} = 0.75$, $\eta = \gamma = 0.7$ olarak seçilmiş, 5 ölçek ($u = \{0,1, \dots, 4\}$) ve 8 oryantasyondaki ($v = \{0,1, \dots, 7\}$) Gabor dalgacıklarının sadece reel kısımları kullanılmıştır. Bu parametreler, süper çözünürlük performansını etkileyen özellik tanımlayıcısının temsiliyet başarısı göz önüne alınarak deneysel olarak belirlenmiştir.

2.2.1.2. Sözlük Öğrenmesi

DÇ görüntülerin $U \times V$ Gabor filtresi kullanılarak filtrelenmesiyle DÇ özellikler elde edilmektedir. Bu yüzden, her bir y_l^j DÇ görüntüsü için $U \times V$ filtrelenmiş görüntüden oluşan bir kümeyi, $\{f_r \otimes y_l^j\}$, $r = 1, 2, \dots, U \times V$ meydana getirmektedir. Burada $f_r \otimes y_l^j$ sonucu filtrelenmiş görüntüyü, f_r Gabor filtre bankasındaki her bir filtreyi ve \otimes konvolüsyon işlecini ifade etmektedir. DÇ özellikleri oluşturmak için x_l^k yerel örtüşen parçalar filtrelenmiş görüntülerden çıkarılarak $X = \{x_h^k, x_l^k\}_k$ parça veri kümesi oluşturulmaktadır. Burada k konum bilgisini göstermektedir. DÇ parçaya karşılık gelen x_h^k YÇ parçası ise e_h^j artık görüntüsündeki aynı konum bilgisinden çıkarılmaktadır. Her bir parça için $U \times V$ özellik vektörü birleştirilerek tek bir vektör oluşturulmuştur. Özellik vektörünün boyutunun büyük olmasından ve bu da yüksek zaman karmaşıklığına sebep olduğundan dolayı özellik vektörüne boyut indirgeme uygulanarak sözlük öğrenmesi ve süper çözünürlük algoritmalarında hesaplama süresi azaltılmıştır. Bu yüzden sözlük öğrenmesi sürecinden önceki son adım giriş DÇ parçaların boyutunu azaltmaktır. Boyut indirgeme yöntemi olarak PCA yöntemi bu vektörlere uygulanmış ve parçaların ortalama enerjilerinin %99.9'unu koruyarak izdüşürülecekleri bir alt uzay aranmıştır.

DÇ ve YÇ eğitim parça çifti, $X = \{x_h^k, x_l^k\}_k$, verildiğinde sözlük öğrenmesi sürecinin amacı DÇ ve YÇ görüntü parçaları için sözlükler eğitmektir. Bölüm 1.4.1.'de anlatıldığı üzere DÇ özellikler üzerinden seyrek temsiliyet modeli (75) eşitliği ile verilebilir.

$$x_l^k = D_l \alpha^k \quad (75)$$

Burada x_l DÇ görüntü parçasını, D_l DÇ sözlüğü ve A seyrek temsiliyet katsayılarını ifade etmektedir. K-SVD sözlük öğrenmesi algoritması (76) eşitliğine göre bu parçalara uygulanarak DÇ sözlük oluşturulmuştur.

$$D_l, \alpha^k = \underset{D_l, \alpha^k}{\operatorname{argmin}} \sum_k \|x_l^k - D_l \alpha^k\|^2 \text{ öyle ki } \|\alpha^k\|_0 \leq T_0 \quad (76)$$

Seyreklik ölçüsü olarak adlandırılan T_0 parametresi 3 olarak seçilmiştir. Bu eğitim sürecinin yan ürünü x_l^k eğitim parçalarına karşılık düşen seyrek temsiliyet vektörüdür.

Bir sonraki adım YÇ sözlük oluşturmadır. Sözlük, (77) eşitliğinde verilen yakınsama hatası minimum yapılarak elde edilmektedir.

$$D_h = \underset{D_h}{\operatorname{argmin}} \sum_k \|x_h^k - D_h \alpha^k\|^2 = \underset{D_h}{\operatorname{argmin}} \|X_h - D_h A\|^2 \quad (77)$$

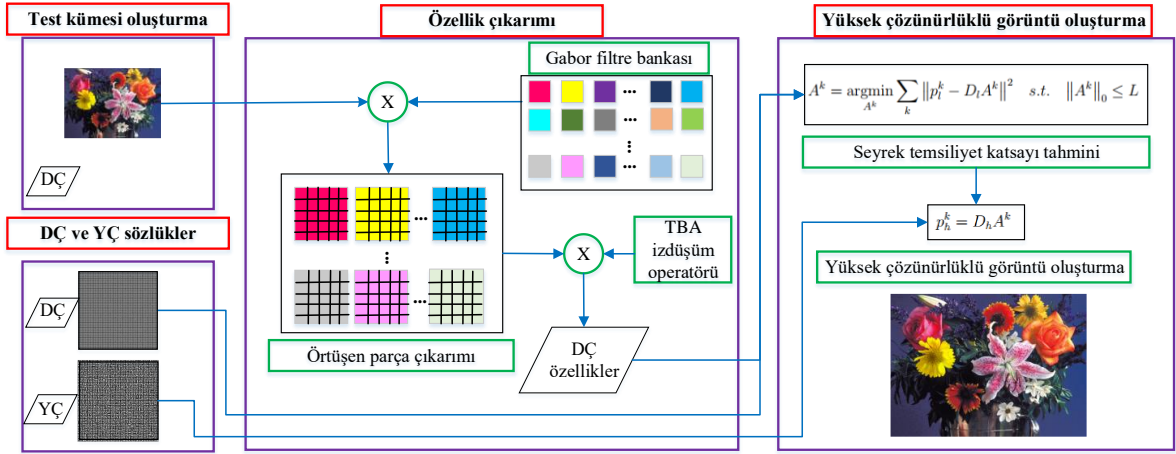
Problemin çözümü (78) eşitliği ile verilen Yalancı-Ters ifadesi ile çözülmektedir.

$$D_h = X_h A^+ = X_h A^T (A A^T)^{-1} \quad (78)$$

Burada t ve -1 sırasıyla transpoz operatörünü ve yalancı-ters ifadesini göstermektedir. $\{D_l, D_h\}$ sözlüklerinin oluşturulması, $\{y_h^j\}_j$ YÇ eğitim veri kümesinin oluşturulmasıyla başlanan süper çözünürlük algoritmasının eğitim sürecini sonlandırmaktadır.

2.2.2. Yüksek Çözünürlüklü Görüntü Oluşturma

Önerilen yaklaşımın yüksek çözünürlüklü görüntü oluşturma süreci Şekil 15'te verilmektedir. Yüksek çözünürlüklü görüntü oluşturma, düşük çözünürlüklü bir z_l görüntüsünü büyütme çalışmaktadır. Bu görüntüsünde sözlük öğrenmesi sürecinde olduğu gibi y_h YÇ görüntüsünden aynı bulanıklık ve alt örnekleme operatörleriyle elde edilmiş olduğu farzedilmektedir.



Şekil 15. Gabor özellik temsiliyetine dayalı önerilen yaklaşımın yüksek çözünürlüklü görüntü oluşturma süreci

z_l görüntüsü s büyütme faktöründe çift kübik ara değerlendirme yöntemi ile üst örneklenerek y_l görüntüsü oluşturulmaktadır. y_l görüntüsünün aynı $U \times V$ Gabor filtreleri kullanılarak filtrelenmesiyle $f_r \otimes y_l$ görüntüleri elde edilmektedir. $U \times V$ adet filtrelenmiş görüntüden $k \in \Omega$ bölgesindeki $\sqrt{n} \times \sqrt{n}$ boyutlu parçalar çıkarılarak her bir görüntüdeki aynı bölgeye karşılık gelen parçalar birleştirilerek x_l^k parça vektörü oluşturulmaktadır. Parçaların birleşimi $\{x_l^k\}_k$ kümesini oluşturmaktadır. Bu küme boyut indirgemenin gerçekleştirilmesi için PCA izdüşüm operatörüyle çarpılmaktadır. OMP algoritması (79) eşitliği kullanılarak bu parçalara uygulandığında $\{\alpha^k\}_k$ seyrek temsiliyet vektörü elde edilmektedir.

$$\alpha^k = \underset{\alpha^k}{\operatorname{argmin}} \sum_k \|x_l^k - D_l \alpha^k\|^2 \text{ öyle ki } \|\alpha^k\|_0 \leq T_0 \quad (79)$$

Seyrek temsiliyet vektörünün, $\{\alpha^k\}_k$, D_h YÇ çözünürlüklü sözlükle (80) eşitliğindeki çarpımı yaklaşık YÇ parçaları $\{\hat{x}_h^k\}_k$ vermektedir.

$$\{\hat{x}_h^k\}_k = \{D_h \alpha^k\}_k \quad (80)$$

Sonuç süper çözünürlüklü \hat{y}_h görüntüsü, \hat{x}_h^k parçalarından (81)'de verilen minimizasyon probleminin \hat{y}_h 'ne bağlı çözümüyle oluşturulmaktadır.

$$\hat{y}_h = \underset{\hat{y}_h}{\operatorname{argmin}} \sum_k \|R_k(\hat{y}_h - y_l) - \hat{x}_h^k\|_2^2 \quad (81)$$

(81)'de verilen problem $\hat{y}_h - y_l$ sonuç fark görüntüsünden çıkarılan parçaların tahmin edilen \hat{x}_h^k parçalarına olabildiğince yakın olmasını göstermektedir. Bu problem, (82)'de verilen kapalı form en küçük kareler çözümüne sahiptir.

$$\hat{y}_h = y_l + [\sum_k R_k^T R_k]^{-1} \sum_k R_k^T \hat{x}_h^k \quad (82)$$

Karmaşık gözükken bu terim aslında \hat{x}_h^k parçasını uygun konumlarına koyup, örtüşen bölgelerde ortalamanın alınıp y_l görüntüsüne eklenmesiyle \hat{y}_h sonuç görüntüsünün oluşturulmasına denktir.

2.3. Yoğun Atlamalı Bağlantılı Konvolüsyonel Sinir Ağlarına Dayalı Tek Görüntü Süper Çözünürlüğü

Konvolüsyonel sinir ağları, öğrenme tabanlı tek görüntü süper çözünürlüğü problemlerinde üstün performans göstermektedir. Fakat ağ derinleştikçe ilk katmanlardaki özellikler son katmanlarda hiç kullanılmamakta ya da daha az kullanılmaktadır. Tek görüntü süper çözünürlüğünde ilk katmanlar daha çok süper çözünürlük problemi için gerekli olan yerel özelliklerden oluşmaktadır. Bu özelliklerin kullanıldığı atlamalı bağlantılı ağ yapılarının önerildiği SRResNet [107], EDSR [108] ve MDSR [108] çalışmalarında uzun tek bir atlamalı bağlantı kullanılarak ilk katmandaki düşük seviyeli özellikler üst örnekleme bloğundan önceki katmanın çıkışına eklenmiştir. Başka bir deyişle, diğer düşük-seviyeli özellikler yerine sadece ilk katmanın özellikleri tekrardan kullanılmıştır. MCSR [109] ve DRNet [110] ağlarında ise blokların içerisinde ve bloklar arasında da atlamalı bağlantılar kullanılarak YÇ görüntü oluşturma probleminde yüksek seviyeli özelliklerden daha önemli olan düşük seviyeli özelliklerin son katmanların özellikleriyle birleştirilmesi sağlanmıştır. Böylece süper çözünürlük kalitesi daha da artırılmıştır. Bu analizlerden yola çıkılarak bu tez çalışmasında blok içi ve bloklar arası yoğun atlamalı bağlantılar içeren bir ağ yapısı önerilerek süper çözünürlük performansının geliştirilmesi hedeflenmiştir.

Literatürdeki konvolüsyonel sinir ağlarına dayalı mevcut yaklaşımların analizleri ile birlikte önerilen yoğun atlamalı konvolüsyonel sinir ağının mimarisi ve ağın eğitimi alt başlıklarda detaylandırılacaktır.

2.3.1. Konvolüsyonel Sinir Ağlarına Dayalı Mevcut Yaklaşımların Analizi

Konvolüsyonel sinir ağlarına dayalı 1.5.3.2 bölümünde verilen çalışmaların analiz sonuçları Tablo 4'te verilmektedir. Bu çalışmalar süper çözünürlük alanında en popüler çalışmalar olup üst düzey dergi ve konferanslarda yayınlanmışlardır. Literatürde bunların dışında başarının bu çalışmaların gerisinde kaldığı farklı birçok çalışma da mevcuttur. Fakat başarının düşük olmasından ve süper çözünürlük alanında daha çok Tablo 4'te verilen çalışmalar referans alındığından dolayı tez kapsamında bunlara yer verilmeyecektir. Tablo 4'te verilen başarı sonuçları $\times 3$ büyütme faktöründe Set14 veri kümesi üzerinde elde edilen sonuç süper çözünürlüklü görüntülerinin PSNR sonuçlarını vermektedir. $\times 3$ büyütme faktörü ve Set14 veri kümesinin seçilmesinin nedeni çalışmaların birçoğunda bu değerlendirmenin popüler olmasıdır. Bazı çalışmalarda başarının sayısal olarak verilmemesinin nedeni de $\times 3$ büyütme faktöründe analiz yapılmaması ya da Set14 veri kümesinin kullanılmamış olmasıdır. Bu çalışmalara ait sonuçlar diğer veri kümeleri ya da büyütme faktörlerine bağlı olarak sayısal olarak açıklanacaktır.

Renk uzayı olarak SRCNN, FSRCNN, VDSR ve DRCN çalışmalarında YCbCr renk uzayının Y kanalı kullanılırken gelişen Grafik İşleme Ünitesi (GPU) teknolojisi ile birlikte SRResNet, EDSR, MDSR ve MCSR çalışmalarında RGB renk uzayı kullanılmaktadır. RGB renk uzayı kullanımı giriş görüntüsünün kanal sayısını artırdığından ağ yapısındaki optimize edilecek olan parametre sayısını artırarak ağın eğitim süresini de artırmaktadır. LapSRN ve DRNet çalışmalarında ise hangi renk uzayının kullanıldığı bilgisi verilmemektedir.

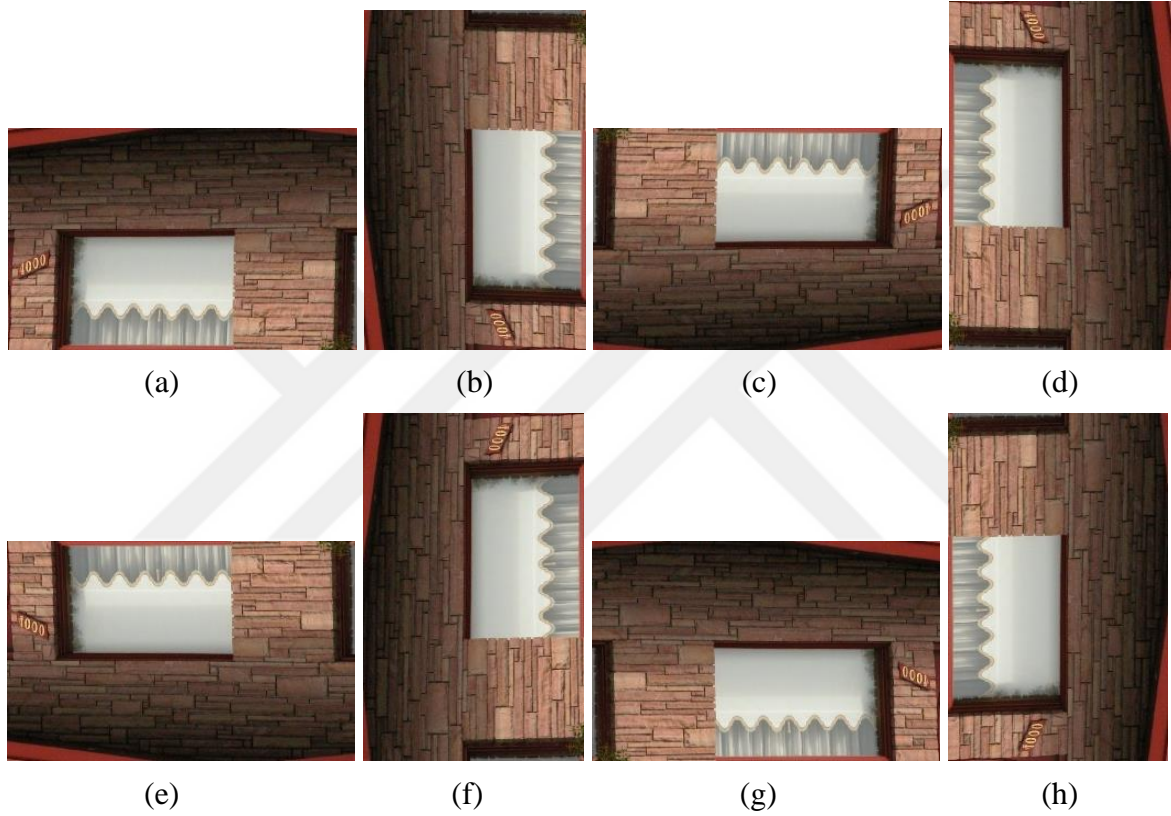
Derin sinir ağları gibi klasik makine öğrenmesi uygulamaları milyarlarca parametre gerektirmekte ve buna bağlı olarak eğitim için büyük verilere ihtiyaç duyulmaktadır. Birçok durumda da kullanılacak olan modelin eğitim veri kümesine aşırı uyumunu önlemek için veri yeterli miktarda bulunmamaktadır. Sınıf etiket verisini koruyarak veri dönüşümünü sağlayan yapay olarak eğitim veri kümesini genişletme tekniği veri artırımı olarak bilinmekte ve veri yetersizliği problemiyle mücadele etmek için önemli ve etkin bir araç olarak kullanılmaktadır [156].

Tablo 4. Konvolüsyonel sinir ağlarına dayalı mevcut yaklaşımların analizi

Ağ yapısı	Eğitim Veri Kümesi	Veri Artırma	Optimizasyon Algoritması	Eğitim Süresi	CPU veya GPU türü	Test Veri Kümesi	Büyütme Faktörleri	PSNR (dB)
SRCNN [30] (2015)	ImageNet > 5 milyon alt görüntü	-	SGD	-	Intel CPU 3.10 GHz	Set5 Set14 BSD200	×2 ×3 ×4	29.30
FSRCNN [101] (2016)	General-100+Timofte veri kümesi (91 görüntü)	Ölçekleme (0.9, 0.8, 0.7, 0.6) ve Döndürme (90, 180, 270)	SGD	-	Intel i7 CPU 4 GHz	Set5 Set14 BSD200	×2 ×3 ×4	29.43
VDSR [105] (2016)	Berkeley veri kümesi (200 görüntü)+ Timofte veri kümesi (91 görüntü)	Ölçekleme ya da çevirme	SGDM	4 saat	Titan Z	Set5 Set14 B100 Urban100	×2 ×3 ×4	29.77
DRCN [100] (2016)	Timofte veri kümesi (91 görüntü)	-	SGDM	6 gün	Titan X	Set5 Set14 B100 Urban100	×2 ×3 ×4	29.76
LapSRN [17] (2017)	Berkeley veri kümesi (200 görüntü)+ Timofte veri kümesi (91 görüntü)	Rastgele sayılarla ölçekleme, rastgele sayılarla döndürme, rastgele çevirme	SGDM	-	Titan X	Set5 Set14 B100 Urban100 Manga109	×2 ×4 ×8	-
SRResNet [107] (2017)	ImageNet veri kümesinden rastgele 350000 görüntü	-	Adam	-	Tesla M40 GPU	Set5 Set14 B100	×4	-
EDSR [108] (2017)	DIV2K veri kümesi	Rastgele yatay çevirme 90° döndürme	Adam	8 gün	Birden fazla Titan X	Set5 Set14 B100 Urban100 DIV2K validasyon	×2 ×3 ×4	30.52
MDSR [108] (2017)	DIV2K veri kümesi	Rastgele yatay çevirme 90° döndürme	Adam	4 gün	Birden fazla Titan X	Set5 Set14 B100 Urban100 DIV2K validasyon	×2 ×3 ×4	30.44
MCSR [109] (2018)	DIV2K veri kümesi	Rastgele yatay çevirme 90° döndürme	Adam	2,5 gün	1080 Ti	DIV2K validasyon	×2 ×3 ×4	-
DRNet [110] (2018)	DIV2K veri kümesi	Rastgele döndürme ve rastgele çevirme	Adam	-	Birden fazla Tesla P100 GPU	Set5 Set14 B100 Urban100	×2 ×3 ×4	30.68

En yaygın olarak kullanılan veri artırımı teknikleri yatay çevirme, döndürme, ölçekleme, kırpma, öteleme ve gauss gürültüsü eklemedir. Bunların yanında ileri veri artırımı teknikleri olarak da bilinen çekişmeli üretici ağlar (generative adversarial network)

ve nöral stil transferi gibi teknikler de kullanılmaktadır. Literatürdeki çalışmalarda ve bu tez kapsamında önerilen çalışmada basit veri artırma teknikleri kullanıldığından gelişmiş veri artırımı tekniklerine tez kapsamında detaylı yer verilmeyecektir. Konvolüsyonel sinir ağlarına dayalı mevcut yaklaşımlar döndürme ve çevirme tekniklerini kullanmaktadır (Şekil 16). Ölçekleme tekniğinde ise elde edilen her bir görüntü farklı ölçek faktörlerinde ölçeklenmektedir.



Şekil 16. Basit veri artırımı tekniklerinin 291 veri kümesindeki ‘tt19’ görüntüsüne uygulanması; (a) 0° döndürme, (b) 90° döndürme, (c) 180° döndürme, (d) 270° döndürme, (e, f, g, h) sırasıyla (a, b, c, d) görüntülerinin dikey çevirmeleri

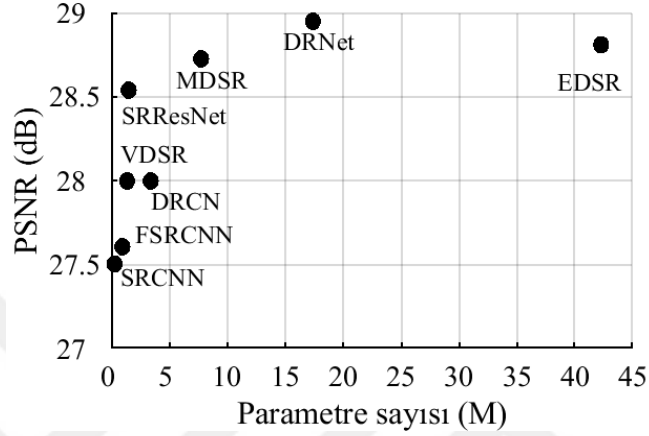
Konvolüsyonel sinir ağlarına dayalı süper çözünürlük çalışmalarında kullanılan eğitim veri kümeleri incelendiğinde FSRCNN, VDSR, DRCN ve LapSRN çalışmalarında seyrek temsiliyete dayalı çalışmalarda kullanılan Timofte veri kümesinin yanında farklı birer veri kümesi eklenerek veri sayısının artırıldığı görülmektedir. Ayrıca, veri artırımı olarak ise döndürme, ölçekleme ve çevirme yapılarak veri sayısı en fazla 40 kata kadar artırılmıştır. Böylece en fazla 11.640 (291×40) görüntü elde edilebilmektedir. SRCNN çalışmasında ise

önerilen ağ yapısı öncelikle Timofte veri kümesi ve ImageNet veri kümesi ile ayrı ayrı eğitilmiştir. Fakat ImageNet veri kümesi daha başarılı sonuçlar ürettiğinden dolayı sonraki deneylerde ImageNet veri kümesi kullanılmış ve Tablo 4'te elde edilen başarı değeri ImageNet veri kümesi ile elde edilmiştir. İlk atlamalı yapının kullanıldığı SRResNet ağında ise ImageNet veri kümesinden rastgele seçilmiş 350000 görüntü kullanılmıştır. CVPR 2017 ve CVPR 2018 konferanslarında gerçekleştirilen NTIRE ve ECCV 2018 konferansında gerçekleştirilen Algısal Görüntü Restorasyonu ve İşleme Yarışması (PIRM) için 2017'de DIV2K veri kümesi oluşturulmuştur. Bu yüzden EDSR, MDSR, MCSR ve DRNet çalışmaları bu veri kümesi üzerinde gerçekleştirilmiştir. Veri kümesi 1000 tane 2K çözünürlüğünde görüntüden oluşmaktadır ve yine bu çalışmalarda da öncekilerde olduğu gibi görüntülere veri artırımı teknikleri uygulanmıştır. Bunun yanında konvolüsyonel sinir ağlarına dayalı süper çözünürlük çalışmalarında veri kümesini oluşturan görüntülerden parçalar çıkarılarak da veri artırımı yapılmaktadır. DIV2K veri kümesindeki görüntülerin çözünürlüğü diğer veri kümelerindeki görüntülerin çözünürlüğünden oldukça büyük olduğundan dolayı parça çıkarımı ile veri artırımı yapıldığında DIV2K veri kümesinden daha çok parça elde edilmektedir. Bu da DIV2K veri kümesinin kullanıldığı çalışmaların daha küçük veri kümesinin kullanıldığı çalışmalardan daha üstün başarı göstermesinin asıl sebebini ortaya koymaktadır.

Ağın eğitiminde kullanılan optimizasyon yöntemleri incelendiğinde derin ağlarda SGDM yöntemi kullanılırken atlamalı bağlantılı CNN yapılarının önerildiği çalışmalarda Adam optimizasyon yönteminin kullanıldığı görülmektedir. Fakat derin modellerin optimize edilmesi problemini çözen algoritmalarından hangisinin seçilmesi gerektiği hakkında herhangi bir çalışma bulunmadığından ve ilgili çalışmalarda da optimizasyon yönteminin seçimi için herhangi bir gerekçe sunulmadığından dolayı optimizasyon yönteminin süper çözünürlük problemine ve süper çözünürlük performansına etkisi bilinmemektedir. Sadece Schaul vd. [128]'nin çalışmasında adaptif öğrenme katsayılarının kullanıldığı algoritmaların performansının oldukça iyi olduğu görülmektedir. Adam yöntemi de adaptif öğrenme katsayılarının kullanıldığı optimizasyon yöntemlerinden biridir.

Atlamalı bağlantılı CNN yapılarının önerildiği süper çözünürlük çalışmalarında ağın karmaşıklığının artmasının yanında veri kümelerinin de boyutunun artmasıyla birlikte gelişmiş GPU donanımı kullanılmasına rağmen ağın eğitilmesi için geçen sürenin 8 güne kadar çıktığı görülmektedir. Bu da önerilen modellerin daha yüksek başarı elde edebilmek için gün geçtikçe artan yüksek donanıma ve yüksek veri kümesine ihtiyaç duyduğunu

göstermektedir. Tablo 4’te verilen yaklaşımların model parametre sayısı ve Set14 veri kümesinde $\times 4$ büyütme faktöründe elde edilen PSNR değerine bağlı karşılaştırmaları Şekil 17’de gösterilmektedir. Şekil 17 analiz edildiğinde veri kümesi büyüklüğünün öğrenmenin iyi olması için modelin karmaşıklığını arttırdığı görülmektedir.



Şekil 17. Konvolüsyonel sinir ağlarına dayalı mevcut yaklaşımlarda ağın karmaşıklık ve başarı analizi

Basit bir CNN yapısının kurulduğu SRCNN ağının $\times 3$ büyütme faktöründe Set14 veri kümesinde test edilmesiyle 29.30 dB PSNR değeri elde edilmiştir. Bu süper çözünürlük başarısının, seyrek temsiliyete dayalı süper çözünürlük yaklaşımlarının performansından oldukça üstün olduğu görülmektedir. FSRCNN, VDSR ve DRCN ağlarının önerilmesiyle birlikte PSNR başarısı sırasıyla 29.43 dB, 29.77 dB ve 29.76 dB değerine kadar artırılmıştır. LapSRN çalışmasının $\times 4$ büyütme faktöründe elde edilen PSNR değeri 28.19 dB iken bu değer VDSR çalışmasında 28.01 dB olarak ölçülmüştür. İlk atlamalı bağlantı yapısının önerildiği SRResNet çalışmasında sadece $\times 4$ büyütme faktöründe elde edilen sonuçlar verilmiş olup Set14 veri kümesinde elde edilen PSNR değeri 28.56 dB’dir. Benzer biçimde bu yöntemin LapSRN çalışmasından daha başarılı olduğu görülmektedir. Aynı makalede farklı ağ yapıları olarak önerilen EDSR ve MDSR çalışmalarında DIV2K veri kümesinin ilk kez kullanılmasıyla birlikte PSNR başarısının sırasıyla 30.66 dB ve 30.53 dB değerine kadar çıktığı görülmektedir. $\times 4$ büyütme faktöründe elde edilen sonuçlar ise sırasıyla 28.94 dB ve 28.82 dB dir. Bu yüzden, EDSR ve MDSR ağlarının da ayrı ayrı SRResNet’ten daha başarılı olduğu görülmektedir. MCSR ağının önerildiği makalede sadece DIV2K validasyon veri kümesi üzerinde gerçekleştirilen test sonuçları verilmektedir ve $\times 3$

büyütme faktöründe elde edilen PSNR başarısı 31.51 dB olarak hesaplanırken EDSR ağının aynı veri kümesi üzerinde elde ettiği PSNR başarısı 31.26 dB dir. Böylece MCSR ağının EDSR ve MDSR ağlarından daha başarılı sonuç ürettiği görülmektedir. Bir diğer atlamalı bağlantılı ağ yapısı içeren DRNet ağı ile birlikte PSNR başarısı 30.68 dB ye kadar artırılmıştır. Gerçekleştirilen sayısal analizlerden büyük veri kümelerinin ve atlamalı bağlantılı ağ yapılarının kullanıldığı çalışmaların daha başarılı performans gösterdiği görülmektedir.

Süper çözünürlük probleminde konvolüsyonel sinir ağlarının kullanımı diğer öğrenme tabanlı yaklaşımlara kıyasla öğrenme süresini oldukça fazla artırmaktadır. Bunun yanı sıra, öğrenme tabanlı süper çözünürlük yaklaşımlarında sıklıkla karşılaşılan her bir ölçek faktörü için ağı tekrar eğitilmesi problemi de düşünüldüğünde ağı eğitilmesi daha da güç olmaktadır. Konvolüsyonel sinir ağları tabanlı süper çözünürlük probleminin çözümünde giriş görüntüsü ya basit bir ara değerlendirme tekniği ile üst örneklenip ağa giriş olarak verilmekte ya da ağı sonunda büyütme katmanları kullanılarak istenen boyuta getirilmektedir. Büyütme katmanları kullanıldığında ilgili katman öğrenilebilir ağırlıklardan oluştuğundan dolayı büyütme katmanından oluşan mimarilerde eğitilmiş ağ farklı bir ölçek faktörü ile test edilememektedir. Buna karşın giriş görüntüsünün hedef boyuta getirilip ağa verildiği ağ mimarilerinde ise farklı ölçek faktörleri ile test mümkün olmaktadır. Farklı ölçek faktörlerinde konvolüsyonel sinir ağlarının süper çözünürlük performansına etkisini incelemek için derin bir ağ modeli $\times 2$, $\times 3$ ve $\times 4$ ölçek faktörlerinde eğitilip kendinden farklı ölçek faktörlerinde test edilerek Tablo 5’te verilen ‘Set5’ veri kümesi üzerinde farklı ölçek faktörlerinde PSNR ölçümleri yapılmıştır.

Tablo 5. Farklı ölçek faktörlerinin süper çözünürlük performansına etkisi (PSNR (dB))

Büyütme faktörü	Çift Kübik Ara Değerleme	Eğitim			
		$\times 2$	$\times 3$	$\times 4$	
Test	$\times 2$	33.66	37.36	29.34	24.99
	$\times 3$	30.39	30.45	33.33	28.75
	$\times 4$	28.42	28.44	28.71	31.01

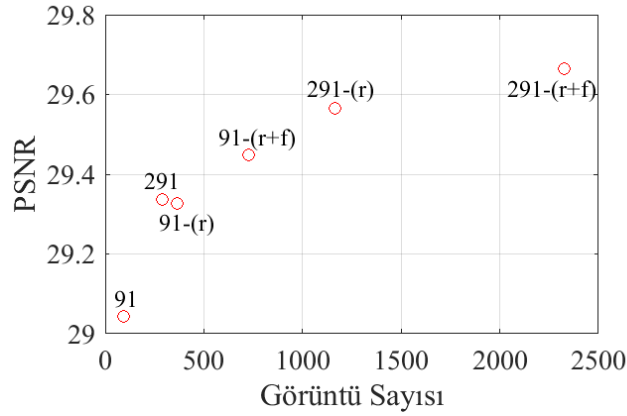
Tablo 5 incelendiğinde ağ modeli eğitimde kullanılan ölçek faktöründen farklı bir ölçek faktörüyle test edildiğinde başarının düştüğü görülmektedir. Bunun yanı sıra küçük ölçek faktörlerinde başarı düşüşü çok fazla iken büyük ölçek faktörlerinde düşüş daha az olmaktadır.

2.3.2. Konvolüsyonel Sinir Ağlarında Eğitim Veri Kümesinin Analizi

Konvolüsyonel sinir ağlarına dayalı mevcut yaklaşımları karşılaştırmak için gerçekleştirilen analizlerde büyük veri kümelerinin kullanıldığı çalışmaların daha küçük veri kümesinin kullanıldığı çalışmalardan daha üstün başarı göstermesinin asıl sebebi veri kümesindeki görüntü sayısının fazla olmasıdır. Konvolüsyonel sinir ağlarında eğitim veri kümesinin süper çözünürlük performansına etkisini analiz etmek için VDSR [105] ağı MATLAB ortamında kodlanmış ve Berkeley (200 görüntü) ile Timofte (91 görüntü) veri kümelerinin farklı kombinasyonları veri artırımı ile birlikte kullanılarak eğitilmiştir. Şekil 18 farklı veri kümeleri kullanılarak eğitilmiş olan ağın $\times 3$ büyütme faktöründe Set14 veri kümesi kullanılarak test edilmesiyle elde edilen PSNR değerlerinin ortalamasını vermektedir. Şekilde her bir veri kümesinin yanında belirtilen ‘r’ sembolü döndürme işlemiyle ve ‘f’ sembolü çevirme işlemiyle veri kümesinin artırıldığını göstermektedir. Döndürme işlemiyle görüntü sayısı 4 katına çıkarken ayrıca çevirme işlemi uygulandığında görüntü sayısı 8 katına çıkmaktadır.

Şekil 18 incelendiğinde veri kümesindeki görüntü sayısı arttıkça başarının gözle görülür biçimde arttığı görülmektedir. Sadece 364 görüntü içeren 91-r veri kümesi ile 291 görüntü içeren veri kümesi kullanıldığında elde edilen sonuçlarda tam tersi bir durum söz konusudur. 91-r veri kümesi 91 görüntü ile bu görüntülerin döndürülmüş görüntülerinden oluştuğundan dolayı 291 görüntü içeren veri kümesi 91-r veri kümesinden görüntü çeşitliliği anlamında daha zengindir. Buradan iyi bir model için sadece veri kümesinin büyüklüğünün yeterli olmadığı veri kümesinin çeşitliliğinin de önemli olduğu sonucu çıkarılmaktadır.

VDSR [105] makalesinde çalışmada kullanılan veri artırımı tekniğinden kesin bahsedilmediğinden ve filtre ağırlıklarının başlangıç değerlerine atanmasında rastgele değerler kullanıldığından dolayı bu çalışmada $\times 3$ büyütme faktöründe Set14 veri kümesi üzerinde elde edilen PSNR değeri (29.66 dB) makalede verilen PSNR değerinden (29.77 dB) farklıdır.



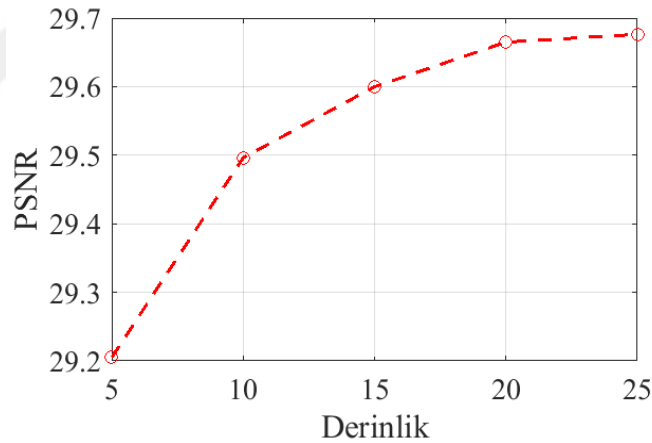
Şekil 18. Eğitim veri kümesindeki görüntü sayısının süper çözünürlük performansına etkisi

Büyük veriyi işlemek için ise yüksek donanıma ihtiyaç duyulmaktadır. Tez kapsamında gerçekleştirilen deneylerde konvolüsyonel sinir ağlarını eğitmek için donanımsal ve mali kısıtlamalardan dolayı başlangıçta NVIDIA GeForce GTX 1050 Ti ve NVIDIA GeForce GTX 1070 Ti GPU'ları kullanılmıştır. Literatürdeki mevcut yaklaşımlarda kullanılan GPU'lar bu tez kapsamında kullanılan GPU'lar ile karşılaştırıldığında, 1050 Ti ve 1070 Ti performans anlamında oldukça geri kalmaktadır. Bu nedenle önerilen ağ yapısının eğitimi için kullanılacak olan veri kümesindeki görüntü sayısı da GPU'nun işleyebileceği veri miktarı ile sınırlı olmaktadır. Bu sebeplerden dolayı ilk gerçekleştirilen deneylerde 291 görüntü içeren veri kümesinden veri artırım teknikleri ile birlikte (döndürme ve çevirme) 2328 görüntü elde edilmiş ve diğer bir veri artırım tekniği olarak parça çıkarımı da uygulanarak veri sayısı artırılmıştır. TÜBİTAK ULAKBİM'in Yüksek Başarım ve Grid Hesaplama Merkezi (TRUBA)'ne Kasım 2018 tarihinden itibaren yüksek CUDA kartlarına sahip Akya-cuda kümesi sunucuları eklenmiştir. Bu kümedeki 24 sunucudan her biri 4 adet NVIDIA Tesla V100 (16GB bellek) CUDA kartlarına sahiptir. Bu tez çalışmasında gerçekleştirilen kısmi deneylerde TRUBA kaynakları da kullanılmıştır.

2.3.3. Yoğun Atlamalı Konvolüsyonel Sinir Ağ Yapısı

Son yıllarda tek görüntü süper çözünürlük problemi için çok derin konvolüsyonel sinir ağları başarılı bir şekilde kullanılmakta ve daha basit ağ yapılarına kıyasla daha önemli iyileştirmeler gözlemlenmektedir. Bu çalışmaların içerisinde en iyi performans gösteren

VDSR [105] çalışmasında da ağın derinliğini artırmanın performansı geliştirdiği görülmektedir. Fakat VDSR ağ mimarisinin derinliğini önerilen derinlik değerinden biraz daha artırıncsa performansta çok fazla iyileştirme görülmemektedir (Şekil 19). Derin ağların kullanılması YÇ görüntülerdeki bilgiyi tahmin etmek için geniş alıcı alanın (receptive field) DÇ görüntülerden daha fazla bilgi almasını sağlamaktadır. Böylece performans da ağ derinliği arttıkça iyileşmektedir. Diğer taraftan atlamalı bağlantı içeren ağ yapılarının kullanılmasından önce yapılan çalışmalarda giriş olarak çift kübik ara değerlendirme fonksiyonuyla istenen boyuta getirilmiş görüntüler kullanılmaktadır. Giriş görüntüsünün boyutunun büyümesi de hesaplama karmaşıklığının artmasına sebep olmaktadır. Bunun yanında ağın derinleşmesi gradyan patlaması / yok olması problemini ortaya çıkarmaktadır. Böyle bir ağın etkin bir biçimde eğitilmesi ise daha zor olmaktadır. Bu problemlerin çözümü ise üst katmanlardan alt katmanlara doğru bilgi ve gradyan akışını sağlayan atlamalı bağlantılar kullanarak ağın eğitimini kolaylaştırmaktır.

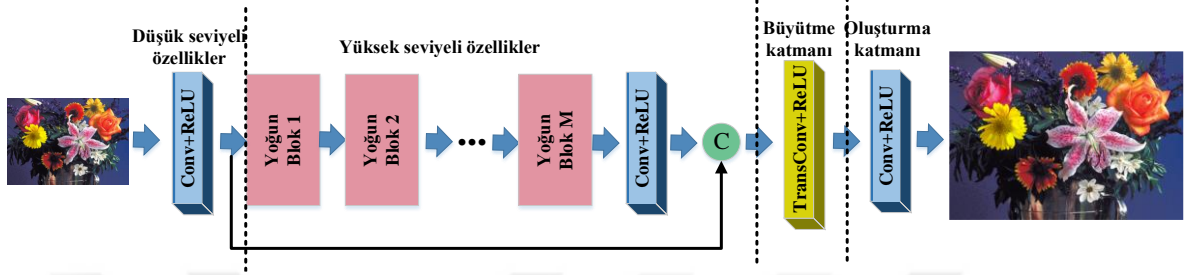


Şekil 19. VDSR ağ mimarisinin derinliğinin süper çözünürlük performansına etkisi

Bu analizlerden yola çıkılarak bu çalışmada blok içi ve bloklar arası yoğun atlamalı bağlantılar içeren bir ağ yapısı önerilerek süper çözünürlük performansının geliştirilmesi hedeflenmiştir. Önerilen yoğun atlamalı bağlantılar içeren konvolüsyonel sinir ağları tabanlı süper çözünürlük yönteminin ağ mimarisi ve ağın eğitimi süreçleri alt başlıklarda detaylandırılacaktır.

2.3.3.1. Ağ Mimarisi

M ardışık yoğun blok, büyütme katmanı ve uzun bir atlamalı bağlantıdan meydana gelen ağ mimarisi Şekil 20’de gösterilmektedir.



Şekil 20. Önerilen yoğun atlamalı konvolüsyonel sinir ağı mimarisi


Çalışmada önceki katmandan çıkarılan özelliklerin tümünü kullanmak için yoğun blok yapısı önerilmiştir. Yoğun bloklar farklı seviye özellikleri birleştirerek özelliklerin tümünü kullanmaktadır. Önerilen ağ yapısında ise yoğun bloklar birbirlerine ardışık bağlanarak ağın öğreneceği özelliklerin çeşitliliği artırılmaktadır. Şekil 20’de görülen ağ yapısı 5 kısma ayrılabilir: düşük seviyeli özellikler, yoğun atlamalı bağlantılı bloklar, atlamalı bağlantı ile özellik birleştirme, büyütme katmanı ve oluşturma katmanı. Ardışık bağlanmış konvolüsyon ve ReLU aktivasyon fonksiyonunun çıkışı olan düşük seviyeli özellikler F_0 , yoğun blokların fonksiyonu H_D ve özellik birleştirme katmanlarının fonksiyonu H_F ile ifade edildiğinde atlamalı bağlantı ile özellik birleştirmenin çıkışı, F_o , eşitlik (83) ile ifade edilmektedir.

$$F_o = F_0 + H_F(H_D(F_0)) \quad (83)$$

Burada + sembolü birleştirme operatörüne karşılık gelmektedir. F_o çıkışı ardışık bağlanan büyütme ve oluşturma katmanına giriş olarak verildiğinde ise çıkışta YÇ görüntü elde edilmektedir. Önerilen modelin her bir katmanının detayları alt başlıklarda verilecektir.

2.3.3.1.1. Düşük Seviyeli Özellikler ve Yoğun Atlamalı Bağlantılı Bloklar

[30, 101, 138] çalışmalarında da belirtildiği üzere düşük seviyeli özellikler daha çok kenar, sınır ve köşe gibi yerel özelliklerden oluştuğundan dolayı görüntü süper çözünürlüğünde yüksek seviyeli özelliklerden daha anlamlı olmaktadır. Çalışmada ilk yoğun bloklara girilmeden önce 3×3 boyutlu 64 filtre giriş görüntüsü üzerinde uygulanarak düşük seviyeli özellikler çıkarılmıştır.



Şekil 21. Şekil 20’de verilen ağ yapısındaki önerilen yoğun alt blok yapısı

Katmanlar arası bilgi akışını geliştirmek için Şekil 21’de verilen her bir yoğun blok içerisinde yoğun atlamalı bağlantılar kullanılarak düşük seviyeli özelliklerin ağ boyunca ilerletilmesi sağlanmıştır. Her bir bloğun içerisindeki katmanların çıkışları kendinden önce gelen tüm katmanların çıkışları ile birleştirilerek bir sonraki katmana giriş olarak verilmiştir. Her bir yoğun blok N adet ardışık bağlanan konvolüsyon ve ReLU katmanından oluştuğunda yoğun blok içerisinde $N - 2$ adet birleştirme operatörü bulunmaktadır. Her bir blok girişinin özellik haritası x_0 ile ifade edildiğinde N . katman kendinden önce gelen tüm katmanların özellik haritalarını (84) eşitliğinde verildiği gibi giriş olarak kabul etmektedir.

$$x_N = [x_0, x_1, \dots, x_{N-1}] \quad (84)$$

Burada $[x_0, x_1, \dots, x_{N-1}]$, $0, \dots, N - 1$ katmanlarında bulunan ardışık bağlanmış 3×3 boyutlu filtreden oluşan konvolüsyon ve ReLU katmanının bileşim fonksiyonuyla üretilen özellik haritalarının birleşimini göstermektedir. Daha çeşitli ve karmaşık özelliklerin çıkartılması için her bir yoğun blok M kere birbiri ardına bağlanmıştır. Kullanılan 3×3

boyutlu tüm konvolüsyon filtreleri için giriş 1 piksel sıfır doldurularak özellik haritasının boyutu sabit tutulmuştur.

Literatürdeki mevcut çalışmalar daha fazla özellik haritası üretmek için konvolüsyon katmanlarında daha çok sayıda filtre kullanmaktadır. Bu çalışmada ise ağın büyüme hızı olarak ifade edilen bir k hiperparametresi filtrelerin sayılarını belirlemek için kullanılmıştır. Önerilen ağ modelindeki her bir katmanın kendinden önceki tüm özellik haritalarına bağlantısı bulunmaktadır ve dolayısıyla her bir katman toplam bilgiye sahiptir. Bu nedenle sabit ve büyük filtre sayısı kullanmak yerine büyüme hızı parametresi ile blok içerisinde bulunan ardışık katmanların filtre sayıları k başlangıç değerinden itibaren k sayısı kadar artırılmıştır.

Önerilen ağ modelinin 3 ana parametresi bulunmaktadır: Blok sayısı M , her bir bloktaki ardışık bağlanan konvolüsyon ve ReLU katmanlarının sayısı N ve filtre sayısının büyüme hızı k . Burada M ve N ağ modelinin derinliğini kontrol etmek için kullanılmaktadır. Çalışmada gerçekleştirilen deneylerde parametreler yapılan analizler sonucunda $M = 6, N = 6, k = 16$ olarak seçilmiştir.

2.3.3.1.2. Atlamalı Bağlantı ile Özellik Birleştirme

Artık öğrenme, herhangi bir katmanın giriş özelliklerinin başka bir katmana atlayarak geçmesini sağlayan atlamalı bağlantı yapısı ile gerçekleştirilmektedir ve ilk kez ResNet [137] çalışmasında önerilmiştir. Süper çözünürlük problemlerinde giriş görüntüsü ile çıkış görüntüsü birbirleriyle oldukça ilişkili olduğundan ağın sadece yüksek seviyeli özellikler ile düşük seviyeli özelliklerin farkı olarak ifade edilen artık özellikleri öğrenilmesi sağlanmıştır. Bu yaklaşım gradyan patlaması/yok olması problemini ortadan kaldırırken süper çözünürlükte görüntü oluşturma performansını da artırmaktadır. Çalışmada düşük seviyeli ve yüksek seviyeli özelliklerin birleşiminden yararlanmak için uzun bir atlamalı bağlantı özellikleri birleştirmek için kullanılmıştır. Birleştirilen özellikler büyütme katmanına giriş olarak verilmektedir.

2.3.3.1.3. Büyütme ve Oluşturma Katmanı

Konvolüsyonel sinir ağları tabanlı süper çözünürlük algoritmalarının birçoğunda seyrek gösterim tabanlı süper çözünürlük algoritmalarında olduğu gibi giriş görüntüsü genellikle çift kübik ara değerlendirme tekniği kullanılmak üzere basit bir ara değerlendirme tekniği ile üst örneklenip ağa giriş olarak verilmektedir [100, 102, 105]. Giriş olarak üst örneklenmiş görüntüyü kullanmak yerine ağın sonunda büyütme katmanlarını kullanmak da son güncel çalışmalarda ayrıca uygulanmaktadır [101, 107-110, 138]. Büyütme katmanlarını kullanmak her bir katmanda elde edilecek özellik boyutunu azaltacağından dolayı ağ modelini değiştirmeden gerçekleştirilecek olan hesaplamaları azaltacaktır. Bu nedenle, bu tez çalışmasında birleştirilen özellikler büyütme katmanına verilerek hedeflenen çıkış boyutuna getirilmektedir. Büyütme katmanı aktivasyon fonksiyonu olarak ReLU tarafından takip edilen bir transpoze konvolüsyon katmanından oluşmaktadır.

Transpoze konvolüsyon katmanı özellik haritasını yüksek boyutlu bir uzaya üst örnekleme için eşlemektedir. Konvolüsyonel sinir ağlarında gerçekleştirilen konvolüsyon işleminde giriş özellik haritası ve filtre ağırlıkları soldan sağa ve yukarıdan aşağıya olacak biçimde sırasıyla bir vektör ve matris olarak ifade edildiğinde konvolüsyon işlemi filtrenin ağırlıklarının sıfırdan farklı olduğu seyrek bir matris olarak düşünülmektedir. Bu doğrusal işlem giriş özellik haritasını da vektör olarak alarak çıkış özellik haritasını seyrek matris ile giriş özellik vektörünün çarpımı olarak elde etmektedir. Transpoze konvolüsyon işleminde ise konvolüsyon matrisinin transpozesi alınarak giriş özellik haritası ile çarpımı gerçekleştirilmektedir. Yine konvolüsyon işleminde olduğu gibi transpoze konvolüsyonda da filtre ağırlıkları öğrenilebilir.

Oluşturma katmanı üst örnekleme gerçekleştirilmiş görüntünün hedeflenen çıkış görüntüsü boyutuna getirilmesini sağlamaktadır. Bu amaçla, çalışmada ReLU aktivasyon fonksiyonunun takip ettiği 3×3 boyutlu tek bir filtre kullanılarak tek kanallı YÇ görüntü elde edilmiştir.

2.3.3.2. Ağ Modelinin Eğitimi

x , θ ve y sırasıyla DÇ giriş görüntüsü, optimize edilecek ağ parametrelerinin kümesi ve YÇ çıkış görüntüsünü gösterebilir. $\{x^{(i)}, y^{(i)}\}_{i=1}^N$ biçiminde eğitim veri kümesi verildiğinde

amaç, $\hat{y} = f(x, \theta)$ YÇ görüntüyü üretecek f en iyi modeli bulmaktır. Burada \hat{y} , kesin referans YÇ görüntüsünün, y , tahminidir. En uygun parametrelerin bulunması için minimum yapılacak kayıp fonksiyonu (85) eşitliği ile verilebilir.

$$\mathbb{E}(L) = \frac{1}{N} \sum_{i=1}^N \frac{1}{2} \|y^{(i)} - f(x^{(i)}, \theta)\|^2 \quad (85)$$

(85) eşitliğinde verilen en uygun model parametrelerini bulmak için $\rho_1 = 0.9$, $\rho_2 = 0.99$ ve $\epsilon = 10^{-8}$ değerine ayarlanarak ADAM optimizasyon yöntemi kullanılmıştır. Başlangıç öğrenme katsayısı 10^{-4} değerine ayarlanmış ve her 30 devirden sonra yarıya düşürülmüştür. Küçük grup (mini batch) boyutu 64 olarak seçilmiştir. Konvolüsyon katmanlarındaki filtrelerin ağırlıklarının tümü He vd. [119] önerdikleri şekilde başlangıç değerlerine atanmış ve sapma değerleri başlangıç olarak 0'a ayarlanmıştır. Ağ modeli MATLAB ortamında TRUBA kaynakları ve NVIDIA GeForce GTX 1070 Ti GPU'su kullanılarak eğitilmiştir.

2.4. Sözlük Öğrenmesi ve Seyrek Temsiliyete Dayalı Pan Keskinleştirme

Seyrek temsiliyete dayalı pan keskinleştirme alanında önerilen çalışmaların sözlük öğrenme aşamasında kullanılan yöntemlerin öğrenme tabanlı olmamasından dolayı büyük sözlük gerektirmesi [70] ve eğitim sürecinde tüm görüntü parçalarının kullanılması [68] gibi sebepler yüksek zaman karmaşıklığına sebep olmaktadır. Benzer şekilde karşılaştırılan yöntemlerin yetersizliği ve pan keskinleştirme performansının düşük olması [96] oluşturulan YÇ görüntünün kalitesini düşürmektedir. Bu çalışmada, öz tek bir sözlük öğrenilerek daha etkin ve dayanıklı pan keskinleştirme sağlayan sözlük öğrenmesi ve seyrek temsiliyete dayalı pan keskinleştirme için yeni bir yaklaşım önerilmektedir. Çalışmanın katkısı 4 kısma ayrılmaktadır:

1. Sözlük öğrenmesinde tüm parçaları eğitmek yerine algoritmanın hızını önemli bir biçimde geliştirmede gerekli olan zaman karmaşıklığını azaltmak için rastgele örneklenmiş ham görüntü parçaları öğrenilmiştir.
2. Rastgelelikten kaynaklı örnek değişmezlik probleminin üstesinden gelmek için örnek azaltımı önerilerek sadece ayırt edici örneklerin öğrenilmesi sağlanmıştır.

3. Her bir bant için parlaklık bilgisi yerine doku bilgisinin kullanımı sözlükteki örneklerin daha iyi temsil edilmesiyle sonuçlanmıştır. Böylece daha iyi pan keskinleştirilmiş görüntü oluşturmak için daha verimli ve dayanıklı sözlük elde edilmiştir.
4. YÇ görüntü oluşturma sürecinde örtüşen bölgelerde ortalamanın alınması bulanıklığa sebep olduğundan iteratif geri izdüşürme algoritması sonuç görüntüsünü keskinleştirmek için kullanılmıştır.

Önerilen yaklaşımın görüntü bozunma modeli, örnek azaltımı ve sözlük öğrenmesi, YÇ görüntü oluşturma ve iteratif geri izdüşürme süreçleri alt başlıklarda detaylandırılacaktır.


2.4.1. Görüntü Bozunma Modeli

Seyrek temsiliyete dayalı pan keskinleştirme probleminin çözümü için YÇ MS ile DÇ MS ve YÇ PAN görüntü arasındaki görüntü bozunma modelinin kurulması gerekmektedir. Şekil 22 mevcut DÇ ve YÇ görüntüler arasındaki ilişkiyi temsil eden görüntü bozunma modelini göstermektedir. Burada pan keskinleştirme problemi R, G, B ve NIR olmak üzere 4 spektral bant ile ele alınmıştır. Yüksek uzamsal çözünürlükten düşük uzamsal çözünürlüğe örnek seyreltme faktörü, MS ile PAN görüntü arasındaki uzamsal ilişkiden dolayı 4 olarak seçilmiştir.

x ve y_{MS} sırasıyla YÇ MS ve ona karşılık gelen DÇ MS görüntüyü temsil ettiğinde aralarındaki görüntü bozunma modeli (86) ile ifade edilmektedir.

$$y_{MS} = M_1 x + v_1 \quad (86)$$

Burada M_1 alt örneklemeyi temsil eden seyreltme matrisini ve v_1 gürültü vektörünü göstermektedir. MS görüntülerin ikisi de B banttan oluşmaktadır. MS görüntünün tüm dalgaboyları PAN görüntü tarafından kapsandığından dolayı B spektral bandın doğrusal kombinasyonu PAN görüntüyü oluşturmaktadır. Bu yüzden YÇ PAN görüntü şu şekilde modellenebilir:



Şekil 22. Pan keskinleştirme görüntü bozunma modeli

$$y_{PAN} = \sum_{b=1}^B w_b x_b + v_2 = M_2 x + v_2 \quad (87)$$

(87) eşitliğindeki w_b ve x_b sırasıyla her bir spektral bandın ağırlığını ve görüntüsünü temsil etmektedir. M_2 doğrusal kombinasyonu temsil eden seyreltme matrisini ve v_2 gürültü vektörünü göstermektedir. (86) ve (87) eşitliğinden yararlanılarak görüntü bozunma modeli (88) ile ifade edilmektedir.

$$y = Mx + v \quad (88)$$

Burada $y = \begin{bmatrix} y_{MS} \\ \beta * y_{PAN} \end{bmatrix}$, $M = \begin{bmatrix} M_1 \\ \beta * M_2 \end{bmatrix}$ ve $v = \begin{bmatrix} v_1 \\ \beta * v_2 \end{bmatrix}$ olarak verilebilir. β parametresi, pan keskinleştirilmiş sonuç görüntüsünü geliştirmek için DÇ MS görüntü ile YÇ PAN görüntüsünün katkısını dengeleyen skaler bir sayıdır. Bu çalışmada β parametresinin değeri, parametrenin pan keskinleştirme performansına etkisi incelenerek deneysel olarak 0.25 seçilmiştir.

YÇ görüntü oluşturma sürecinde tüm görüntüyü kullanmak yerine küçük parçalardan yararlanmak basit ve karmaşık olmayan bir model sunmaktadır. Bu nedenle çalışmada YÇ MS görüntüdeki her bir bant için görüntü parça boyutu 8×8 seçilmiştir, bu da YÇ PAN görüntüde 8×8 boyutlu görüntü parçası ve DÇ MS görüntünün her bir bandında 2×2 boyutlu görüntü parçası üretmektedir. Bu yüzden (86) eşitliğinde verilen M_1 parametresi

$(1/16) \cdot I_{8 \times 8} \otimes (1^T \otimes (I_{2 \times 2} \otimes 1^T))$ ifadesi ile oluşturulmuştur. Burada $I \in R^{N \times N}$, $N \times N$ boyutlu birim matrisi, 1, tüm girişleri 1'e eşit olan 4×1 boyutlu vektörü ve \otimes , Kronecker çarpımı göstermektedir. (87) eşitliğinde verilen M_2 matrisi, $I \in R^{64 \times 64}$ 'nın birim matris olduğu $(w_1 I \ w_2 I \ w_3 I \ w_4 I)$ ifadesi ile oluşturulmaktadır. (87) eşitliğindeki ağırlıklar ilgili sensörün normalize edilmiş spektral cevap eğrisinden hesaplanmış olup sırasıyla B, G, R ve NIR bantlarını gösterecek biçimde şu şekilde seçilmiştir [157]: Quickbird sensörü için $w_1 = 0.1139, w_2 = 0.2315, w_3 = 0.2308, w_4 = 0.4239$ ve IKONOS sensörü için $w_1 = 0.1071, w_2 = 0.2646, w_3 = 0.2696, w_4 = 0.3587$.

2.4.2. Örnek Azaltımı ve Sözlük Öğrenmesi

n boyutlu $Y = (\mathbf{y}_j)_{j=1}^n$ sinyali verildiğinde sözlük öğrenmesi, tüm veriyi seyrek kodlamak için k atomluk en iyi bir $D = (\mathbf{d}_i)_{i=1}^k$ sözlüğü bulmayı amaçlamaktadır. Atom sayısının sinyalin uzunluğunu aştığı overcomplete bir sözlüğün her bir kolonu bir görüntü parçasına karşılık gelmektedir. Bu yüzden, görüntü parçalarının seyrek temsiliyeti pan keskinleştirme probleminin çözümü ile elde edilmektedir.

Bu çalışmada N orijinal YÇ MS görüntü sözlük öğrenmesi için kullanılmıştır. i . eğitim görüntüsü ($i = 1, 2, \dots, N$) için her bir MS bant görüntüsünden M tane örtüşmeyen $p \times p$ boyutlu ham görüntü parçası j . örneği ($j = 1, 2, \dots, MN$) oluşturmak için rastgele örneklenmiştir. Oluşturulan sözlükte parlaklık değerini kullanmak yerine doku bilgisini temsil etmek için her bir parçanın ortalama değeri, parçanın her bir piksel değerinden çıkarılmıştır. Böylece örnekleme, 4 bantlı bir MS görüntü düşünüldüğünde $(4p^2) \times (MN)$ boyutlu bir özellik matrisi oluşturmaktadır.

Rastgeleliğin sonucu olarak meydana gelen örnek değişmezlik probleminin üstesinden gelmek için her bir j . örnek ($j = 1, 2, \dots, MN$) için varyans değeri hesaplanmaktadır. Varyans değerleri belirli bir sayıdan küçük olduğunda, varyans değerine karşılık gelen örnek özellik matrisinden kaldırılarak sadece ayırt edici örneklerin öğrenilmesi sağlanmaktadır. Örnek azaltımı süreci $K < MN$ olduğu $(4p^2) \times (K)$ boyutlu yeni bir özellik matrisi oluşturmaktadır. Eşik değeri deneysel olarak 10 seçilmiştir.

Ayırt edici örnekleri içeren özellik matrisinin elde edilmesinin ardından, sözlük öğrenmesi süreci (89)'da verilen eşitlik kullanılarak gerçekleştirilmektedir.

$$\mathbf{D} = \underset{\mathbf{D}, \alpha}{\operatorname{argmin}} \|\mathbf{Y} - \mathbf{D}\alpha\|_2^2 + \lambda \|\alpha\|_1 \text{ öyle ki } \|\mathbf{D}_i\|_2^2 \leq 1, i = 1, 2, \dots, k \quad (89)$$

Burada \mathbf{D}_i , \mathbf{D} sözlüğündeki her bir kolonu ve k , atom sayısını göstermektedir. λ seyrek düzenleme parametresi çalışmalarımızda 0.15 olarak seçilmiştir. (89) eşitliği \mathbf{D} ve α 'nın ikisinde konveks değildir; fakat herhangi biri sabit tutulduğunda diğeri için konveks olmaktadır. Bu nedenle optimizasyon seyrek kodlama ve sözlük güncellemesi süreçleri arasında değişmeli olarak gerçekleştirilmekte ve Algoritma 4 ile özetlenmektedir.

Algoritma 4. Sözlük öğrenmesi

Giriş: Özellik matrisi \mathbf{Y} , sözlük boyutu $dictSize$, seyrek düzenleme parametresi λ , iterasyon sayısı $iterNum$

Çıkış: \mathbf{D} öğrenilmiş sözlük, α seyrek vektör

\mathbf{D} sözlüğünü, kolonları birim normalize edilmiş biçimde rastgele sayılardan oluşan bir matris ile başlangıç değerine setle

$i=0$

while $i < iterNum$ **do**

\mathbf{D} 'yi sabit tutup (90) eşitliğindeki α 'yı Feature-Sign Search algoritması kullanarak güncelle

$$\underset{\alpha}{\operatorname{argmin}} \|\mathbf{Y} - \mathbf{D}\alpha\|_2^2 + \lambda \|\alpha\|_1 \quad (90)$$

α 'yı sabit tutup (91) eşitliğindeki \mathbf{D} 'yi Lagrange Dual algoritması kullanarak güncelle.

$$\underset{\mathbf{D}}{\operatorname{argmin}} \|\mathbf{Y} - \mathbf{D}\alpha\|_2^2 \text{ öyle ki } \|\mathbf{D}_i\|_2^2 \leq 1, i = 1, 2, \dots, k \quad (91)$$

end

Bu çalışmada her bir eğitim görüntüsünden Quickbird ve IKONOS veri kümeleri için sırasıyla rastgele örneklenmiş 1000 ve 2000 ham görüntü parçası alınmıştır. Parça boyutu 8×8 ve sözlük boyutu 4096 seçilmiştir.

2.4.3. Yüksek Çözünürlüklü Görüntü Oluşturma

DÇ MS görüntünün her bir bandı ve YÇ PAN görüntü için parça boyutları sırasıyla 2×2 ve 8×8 olarak ayarlanmıştır. Bütün parçalar sol üst köşeden sağ alt köşeye, DÇ MS görüntüde 1 piksel ve YÇ PAN görüntüde 4 piksel adımla satır satır taranarak elde edilmiştir. Her bir parça için ortalama değer hesaplanarak karşılık gelen görüntü parçasının piksel değerlerinden çıkarılmaktadır. Ardından parçalar birleştirilerek tek bir y özellik vektörü oluşturulup bir sonraki adımda normalize edilmektedir. (92) eşitliğinde verilen optimizasyon problemi y özellik vektörü, sözlük öğrenmesi sürecinde elde edilen sözlük, (88) eşitliğindeki seyreltme matrisi ve seyrek düzenleştirme parametresi kullanılarak Feature Sign Search algoritması ile çözülmüştür. Optimizasyon probleminin çözümüyle elde edilen α^* seyrek temsiliyet vektörü kullanılarak YÇ görüntü parçası \mathbf{x}^* , $\mathbf{x}^* = \mathbf{D}\alpha^*$ eşitliği ile üretilmektedir. Ardından elde edilen YÇ görüntü parçası normalizasyon değeri kullanılarak ölçeklenir ve ortalama değer görüntü parçasına eklenir. Örtüşen bölgelerde piksel değerleri basitçe ortalama alınarak YÇ X_0 görüntüsü oluşturulmaktadır. Giriş parçaları verildiğinde problemin çözümü Algoritma 5 ile özetlenmektedir.

Algoritma 5. Yüksek çözünürlüklü görüntü oluşturma

Giriş: Öğrenilmiş sözlük \mathbf{D} , seyreltme matrisi \mathbf{M} , seyrek düzenleştirme parametresi λ , DÇ MS görüntü y_{MS} , YÇ PAN görüntü y_{PAN}

Çıkış: \mathbf{X} YÇ MS görüntüsü

for y_{MS} görüntüsündeki her bir 2×2 boyutlu parçalar ve y_{PAN} görüntüsündeki her bir 8×8 boyutlu parçalar

do

parçanın m ortalama piksel değerini hesapla ve piksel değerlerinden çıkar parçaları tek bir y özellik vektörüne birleştir ve normalize et

$\mathbf{x}^* = \mathbf{D}\alpha^*$ YÇ parçayı oluşturmak için \mathbf{D} , \mathbf{M} ve y 'ye bağlı olarak (92) eşitliğindeki optimizasyon problemini çöz

$$\alpha^* = \underset{\alpha}{\operatorname{argmin}} \|\mathbf{M}\mathbf{D}\alpha - y\|_2^2 + \lambda \|\alpha\|_1 \quad (92)$$

YÇ parçayı önceki adımlarda elde edilen normalize değeri ile ölçeklendir ve $\mathbf{x}^* + m$ parçasını X_0 YÇ görüntüsüne koy

end

2.4.4. İteratif Geri İzdüşürme

DÇ MS y görüntüsü ile YÇ MS X görüntüsü arasındaki eşitlik, (10)'da görüldüğü üzere tam olarak sağlanamamaktadır. Bu yüzden, oluşturulan YÇ görüntü (88) eşitliğinde verilen oluşturma sınırlandırmasını karşılayamayabilir. Aradaki eşitsizlik gradyan iniş yöntemi kullanılarak (93) eşitliği ile çözülebilir.

$$X_{t+1} = X_t + ((y_{MS} - M_1 X_t) \uparrow s) * p \quad (93)$$

Burada t iterasyon sayısını, s üst örnekleme faktörünü ve p geri izdüşürme filtresini temsil etmektedir. Bu çalışmada standart sapması ve filtre boyutu sırasıyla 1 ve 3 olan Gaussian filtresi geri izdüşürme filtresi olarak kullanılmıştır. İterasyon sayısı ise 20 seçilmiştir.

2.5. Derin Konvolüsyonel Sinir Ağlarına Dayalı Mikroskopik Görüntü Süper Çözünürlüğü

Mikroskopik görüntü süper çözünürlüğünde derin konvolüsyonel sinir ağlarına dayalı önerilen ilk ve tek çalışmada [142] mikroskobun donanımını değiştirmeden performansını geliştiren bir ağ yapısı önerilmiştir. Sonuçlar önerilen modelin diğer görüntüleme aygıtlarına da uygulanabileceğini göstermesine rağmen çalışmanın bazı kısıtlamaları mevcuttur. Bu kısıtlamalar verimliliğin yüksek derecede büyütme faktörüne ve doku türüne bağlı olmasıdır. Çalışmada istenen YÇ görüntüyü oluşturmak için tek bir büyütme faktörü incelenirken diğer taraftan ağın eğitiminde kullanılan farklı örnek ve boya türlerinin ağın test edilmesinde kullanılması çıkış görüntülerinde renk bozulmalarına sebep olmaktadır. Bu çalışmada [142] çalışmasında olduğu gibi mikroskopik görüntü süper çözünürlüğü için mikroskoptan düşük objektifte alınan görüntüler derin CNN ağına giriş olarak verilerek YÇ görüntüler çıkış olarak elde edilmektedir. Fakat ağ yapısı, yüksek üst örnekleme oranlarında ve farklı doku türlerinde bile yüksek kaliteli görüntü üretmesi için yeniden tasarlanmıştır. Çalışmanın katkısı 2 kısma ayrılmaktadır:

1. Boyama yöntemi mikroskop objektifi altında gözlemlenen yapıların bazı kısımlarının rengini etkilemekte ve mikroskopik görüntüleme farklı türde mikroskopik boyalar

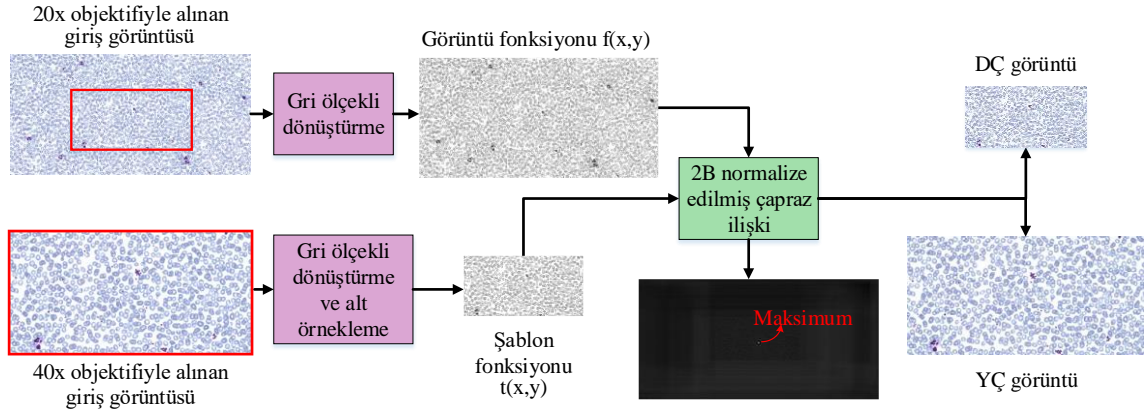
kullanılmaktadır. Önerilen yaklaşım farklı türde örnek ve boyalar için herhangi bir renk bozulmasına yol açmadan verimli bir biçimde çalışmaktadır.

2. Farklı büyütme faktörleri için ağın eğitimi optimize edilecek daha fazla parametreye ve daha fazla zaman ve belleğe ihtiyaç duymaktadır. Önerilen yaklaşım her bir büyütme faktörü için veri kümelerini birleştirerek ve ardından tüm veri setinin kullanılmasıyla ağı eğiterek çoklu ölçek modeller için de kullanılmaktadır.

Önerilen yaklaşımın veri ön işleme, ağ mimarisi ve ağı eğitimi süreçleri alt başlıklarda detaylandırılacaktır.

2.5.1. Veri Ön İşleme

Mikroskobide düşük objektif altında görüş alanı daha geniş iken yüksek objektif altında incelenecek olan numuneye daha da yaklaşılmaktadır. Bu yüzden farklı objektif altında alınan her bir görüntünün görüş alanlarını eşleştirmek için Şekil 23'te akışı verilen görüntü hizalama yöntemi kullanılarak DÇ giriş ve YÇ çıkışlardan oluşan bir veri kümesi oluşturulmuştur.



Şekil 23. Mikroskobik görüntüleme için veri ön işleme akışı

Numuneler gelişmiş teknoloji ile birlikte YÇ mikroskop altında tarandığından dolayı, basit bir hizalama yöntemi karşılık gelen görüntüleri eşleşmek için yeterli olmaktadır. 2B normalize edilmiş çapraz ilişki (NCC) genellikle iki görüntü arasındaki benzerliği ölçmek


için kullanılmaktadır ve basit şablon eşleme uygulamaları için tercih edilmektedir [158, 159]. 2B NCC eşleşen görüntülere şu adımlarla uygulanmaktadır:

1. Farklı objektiflerde alınan giriş görüntüleri gri ölçekli görüntüye dönüştürülür.
2. Yüksek objektifte alınan her bir YÇ görüntü çift kübik ara değerlendirme fonksiyonu kullanılarak s faktörüyle şablon fonksiyonunu oluşturmak için alt örneklenir.
3. Şablon fonksiyonu görüntü fonksiyonu üzerinde piksel piksel kaydırılır ve iki fonksiyon arasında 2B NCC değeri (94) eşitliği kullanılarak hesaplanır.

$$\gamma(u, v) = \frac{\sum_{x,y} [f(x,y) - \bar{f}_{u,v}] [t(x-u, y-v) - \bar{t}]}{\left\{ \sum_{x,y} [f(x,y) - \bar{f}_{u,v}]^2 \sum_{x,y} [t(x-u, y-v) - \bar{t}]^2 \right\}^{0.5}} \quad (94)$$

Burada \bar{t} , şablonun ortalamasını ve $\bar{f}_{u,v}$, şablon altındaki bölgedeki $f(x,y)$ 'nin ortalamasını göstermektedir.

4. Hesaplanan ilişki değerinin maksimum değeri şablon fonksiyonu ile görüntü fonksiyonundaki alt görüntü arasındaki en iyi eşleşmenin merkezini göstermektedir.




Şekil 24. Örnek eşleşen mikroskobik görüntüler üzerinde 2B NCC fonksiyonun sonuç görüntüleri, (a) 10× objektifinde mikroskoptan alınan görüntü (600×300), (b) 40× objektifinde mikroskoptan alınan görüntü (600×300), (c) 2B NCC yönteminin çıkışında elde edilen DÇ görüntü (150×75), (d) 2B NCC yönteminin çıkışında elde edilen YÇ görüntü (600×300)

Şekil 24, $10\times$ ve $40\times$ objektiflerinde mikroskoptan alınan görüntülere 2B NCC algoritmasının uygulanması sonucunda elde edilen DÇ ve YÇ görüntüleri göstermektedir.

2.5.2. Ağ Mimarisi

Mikroskopi görüntülerinde görüntü süper çözünürlüğü problemini çözmek için 20 katmandan oluşan Şekil 25'te gösterilen derin bir CNN yapısı kurulmuştur. Süper çözünürlük yaklaşımlarına benzer olarak ağ giriş olarak istenilen boyuta ara değerlendirilmiş DÇ görüntüyü almakta ve çıkış olarak YÇ görüntü vermektedir.



Şekil 25. Mikroskobik görüntüleme için derin CNN mimarisi

Ağın girişi 48×48 sabit boyutlu Y kanalı görüntüsü almaktadır. Giriş konvolüsyon katmanı giriş görüntüsünü 64 kanala eşlemektedir. Giriş konvolüsyon katmanını sırasıyla konvolüsyon katmanı ve ReLU aktivasyon fonksiyonundan oluşan 18 blok takip etmektedir. Bu blokların her birinde 64 filtre 64 özellik haritasına karşı 3×3 boyutlu bölgede çalışmaktadır. Son katman için 64 kanallı 3×3 boyutlu tek bir filtre giriş görüntüsüne geri eklenecek olan artık görüntüyü üretmek için kullanılmıştır.

Ağın derinliğini artırmak her bir konvolüsyon katmanından sonra özellik haritası boyutunda azalmaya sebep olmaktadır. Bu sebeple, oluşturulan artık görüntünün boyutu giriş ara değerlendirilmiş DÇ görüntü ile karşılaştırıldığında küçük olmaktadır. Bu problemi ortadan kaldırmak için her bir konvolüsyon işlemini uygulamadan önce özellik haritasının sınırları etrafında sıfır doldurma uygulanarak özellik haritasının boyutunun sabit kalması sağlanmıştır.

2.5.3. Ağ Modelinin Eğitimi

x , θ ve y sırasıyla ara değerlendirilmiş DÇ giriş görüntüsü, optimize edilecek ağ parametrelerinin kümesi ve YÇ çıkış görüntüsünü gösterebilir. $\{x^{(i)}, y^{(i)}\}_{i=1}^N$ biçiminde eğitim veri kümesi verildiğinde en uygun parametrelerin bulunması için (85) eşitliğinde verilen kayıp fonksiyonu kullanılmıştır.

(85) eşitliğine göre CNN yapısı kullanan birçok süper çözünürlük çalışmasında olduğu gibi ara değerlendirilmiş DÇ görüntü eğitilmiş ağ üzerinden ileri yayılmaktadır. Fakat ağın her bir katmanında ara değerlendirilmiş DÇ görüntüdeki sadece kayıp detaylar tahmin edilmektedir. Bu uçtan uca eşleme daha fazla bellek gerektirmektedir. Bu yüzden piksellerinin çoğunun 0'a yakın olduğu bir r artık görüntüsü, giriş görüntüsü ile kesin referans görüntüsü arasındaki fark yani $r = y - x$ olarak tanımlanmaktadır. Böylece, doğrudan uçtan uca eşleme problemi artık eşleme problemine dönüştürülmektedir. Sadece artık görüntü tahmin edilerek öğrenme süreci daha kolay optimizasyon probleminin çözümüne karşılık gelmekte ve daha iyi performans sağlamaktadır. (85) ile tanımlanan kayıp fonksiyonu artık öğrenmeden faydalanılarak (95) olarak yeniden düzenlenmektedir.

$$\mathbb{E}(L) = \frac{1}{N} \sum_{i=1}^N \frac{1}{2} \|r^{(i)} - f(x^{(i)}, \theta)\|^2 \quad (95)$$

Bu çalışmada kayıp fonksiyonu SGDM yöntemi ile çözülmüştür. SGDM yönteminin parametrelerinden biri olan öğrenme katsayısının (α) küçük seçilmesi yakınsamayı garanti etmektedir, fakat ağın eğitimi daha uzun süre almaktadır. Diğer taraftan yüksek seçilmesi ise gradyan patlaması/yok olması problemine yol açmaktadır. Bu problem genellikle doğrusal olmayan fonksiyonların kullanıldığı çok fazla katmandan oluşan sinir ağları mimarilerinde ortaya çıkmaktadır.

Çok katmandan oluşan sinir ağları genellikle uçurumlara benzeyen oldukça dik bölgelere sahip olmaktadır. Bu problem geri yayılım sürecinde zincir kuralından dolayı türevlerin birbirleriyle çarpımından kaynaklanmaktadır. Oldukça dik uçurum yapılarıyla karşılaşıldığında, gradyan iniş parametre güncellemesi adımı parametreleri oldukça uzağa taşımaktadır. Bu da o anki çözüme ulaşmak için gerçekleştirilmiş olan optimizasyon sürecinin kaybolmasına neden olmaktadır. Gradyan o anki parametreler ile çevrili olan

sonsuz küçük bölge içerisinde en dik inişe karşılık gelen yönü göstermektedir. Sonsuz küçük bölge dışında, kayıp fonksiyonu yukarı doğru geri dönmeye başlayabilir. Bu yüzden eğriliğin çok fazla yukarı doğru gezinmesini önlemek için güncelleme yeterince küçük seçilmek zorundadır ve genellikle ardışık adımların yaklaşık olarak aynı öğrenme katsayısına sahip olduğu yeterince yavaş azalan öğrenme katsayıları kullanılır. Geleneksel gradyan iniş algoritmaları çok geniş adımlarla ilerlemeyi önerdiklerinde gradyan kesme yöntemleri adım boyutunu azaltarak bölgenin dışına çıkma olasılığını azaltmaktadır [114].

Gradyan patlaması/yok olması problemini çözmek için ilk kez Mikolov vd. [160] basit sezgisel bir çözüm olarak parametre güncellemeden hemen önce küçük gruptaki parametre gradyanlarını eleman eleman kesmeyi önermişlerdir. Diğer bir çalışmada ise Pascanu vd. [161] parametre güncellemeden hemen önce gradyanların normunu kesmeyi (96)'da verildiği gibi önermişlerdir.

$$\text{if } \|g\| > v \quad g \leftarrow \frac{gv}{\|g\|} \quad (96)$$

Burada v norm eşik değeridir ve g parametreleri güncellemek için kullanılmaktadır.

Bu çalışmada momentum parametresi α ve ağırlık azalması parametresi sırasıyla 0.9 ve 0.0001 seçilmiştir. Öğrenme katsayısı başlangıçta 0.1 değerine ayarlanmış ve her 10 eğitim devri için 10 faktörü ile azaltılmıştır. Konvolüsyon katmanlarındaki filtrelerin ağırlıklarının tümü He vd. [119] önerdikleri şekilde başlangıç değerlerine atanmış ve sapma değerleri başlangıç olarak 0'a ayarlanmıştır. Öğrenme 100 devirden sonra (grup boyutu 64 olduğunda 25800 iterasyon) durdurulmuştur. Gradyan kesme yöntemi olarak Pascanu vd. [161]'nin önerdikleri yöntem kullanılarak v eşik değeri 0.01 seçilmiştir. Ağ modeli MATLAB ortamında NVIDIA GeForce GTX 1050 Ti GPU'su kullanılarak eğitilmiş ve eğitim yaklaşık 4 saat sürmüştür.

3. BULGULAR VE İRDELEME

Bu bölümde öğrenme tabanlı tek görüntü süper çözünürlüğüne dayalı sentetik, uzaktan algılama ve mikroskobik görüntüler üzerinde gerçekleştirilen deneylerden elde edilen görsel ve sayısal bulgular irdelenerek, literatürde var olan çalışmalara ait sonuçlarla kıyaslanması gerçekleştirilecektir. Önerilen yaklaşımlar tek görüntü süper çözünürlüğünde belirli problemlere çözüm getirmeyi hedeflemektedir. Literatürdeki çeşitli problemlere çözüm getirmek için önerilen tekniklerden elde edilen bulgular ve literatürde var olan çalışmalarla kıyaslanması ilgili ana başlıklar altında incelenmiştir. Öncesinde sentetik görüntülerden oluşan erişime açık süper çözünürlük veritabanlarının ve uzaktan algılama ile mikroskobik görüntüler için oluşturulan veritabanlarının analizi verilecektir.


3.1. Veritabanlarının Analizi

Sentetik görüntüler üzerinde gerçekleştirilen çalışmalarımızda Timofte [55], B100 [130], Urban100 [131] ve DIV2K [133] veritabanları performans analizi için kullanılmıştır. Ayrıca gerçek görüntüler üzerinde analizler gerçekleştirmek için uzaktan algılama ve mikroskopi görüntülerini içeren iki adet veritabanı oluşturulmuştur. Bu kısımda sentetik görüntülerden oluşan erişime açık süper çözünürlük veritabanı ile gerçek görüntülerden elde edilen veritabanları ayrı ayrı incelenecektir.


3.1.1. Sentetik Görüntülerden Oluşan Veritabanları

Öğrenme tabanlı tek görüntü süper çözünürlüğü amacıyla yapılan çalışmalarda kullanılmak üzere ilk oluşturulan veritabanı olma özelliği taşıyan ve en çok tercih edilen Timofte veritabanı [55] sentetik görüntüler üzerinde yapılan süper çözünürlük deneylerinde kullanılmıştır. Bu veritabanı eğitim ve test görüntülerinden oluşan ayrı ayrı üç alt veri kümesi içermektedir. Bunlardan 91 görüntüden oluşan eğitim veri kümesi [56] altı farklı türde renkli görüntü içermektedir: bitki, hayvan, insan, yapı, meyve ve araba (Şekil 26). Eğitim veri kümesinde bulunan görüntülerin çözünürlükleri birbirinden farklı olup .bmp dosya formatında saklanmaktadır. Test görüntülerinden oluşan veri kümeleri olan Set5 [57]

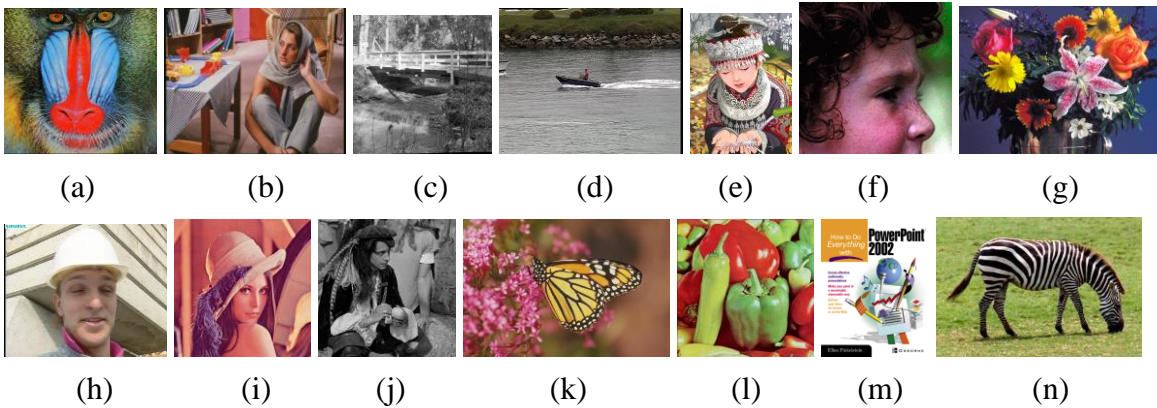
ve Set14 [58] veri kümeleri ise sırasıyla Şekil 27 ve Şekil 28'de verildiği üzere 5 ve 14 görüntüden oluşmaktadır. Set5 veri kümesinde renkli görüntüler bulunurken Set14 veri kümesindeki görüntüler gri seviye ve renkli görüntülerdir. Eğitim test veri kümesinde olduğu gibi test veri kümesinde de görüntüler yine farklı çözünürlükte olup .bmp dosya formatında saklanmaktadır.



Şekil 26. 91 görüntüden oluşan veri kümesindeki farklı sınıflara ait örnek eğitim görüntüleri: (a) t4, (b) t36, (c) t53, (d) tt2, (e) tt26, (f) tt18




Şekil 27. Set5 veri kümesindeki test görüntüleri: (a) baby, (b) bird, (c) butterfly, (d) head, (e) woman




Şekil 28. Set14 veri kümesindeki test görüntüleri: (a) baboon, (b) barbara, (c) bridge, (d) coastguard, (e) comic, (f) face, (g) flowers, (h) foreman, (i) lenna, (j) man, (k) monarch, (l) pepper, (m) ppt3, (n) zebra


Konvolüsyonel sinir ağlarının süper çözünürlük problemlerine uygulanmasıyla birlikte sentetik görüntüler üzerinde yapılan süper çözünürlük deneylerinde DIV2K [133] veritabanı ağı eğitiminde ve B100 [130] ve Urban100 [131] veritabanları ise ağı test edilmesinde kullanılmıştır. DIV2K eğitim veri kümesinde bulunan renkli görüntüler 2K yüksek çözünürlüğe sahip olup .png dosya formatında saklanmaktadır (Şekil 29). Test veri kümelerinden B100 veri kümesinde bulunan renkli görüntüler (Şekil 30) çözünürlükleri 481×321 boyutunda .png formatında kaydedilmiş görüntülerden oluşurken Urban100 veri kümesinde bulunan renkli görüntülerin (Şekil 31) çözünürlükleri birbirinden farklı olup görüntüler .png formatında saklanmaktadır.



Şekil 29. DIV2K veri kümesindeki örnek görüntüler: (a) 0007, (b) 0058, (c) 0089, (d) 0158, (e) 0690



Şekil 30. B100 veri kümesindeki örnek görüntüler: (a) 3096, (b) 69015, (c) 102061, (d) 145086, (e) 351093



Şekil 31. Urban100 veri kümesindeki örnek görüntüler: (a) img_011, (b) img_049, (c) img_085, (d) img_089, (e) img_091

3.1.2. Uzaktan Algılama Görüntülerinden Oluşturulan Veritabanları


Uzaktan algılama görüntülerinde gerçekleştirilen pan keskinleştirme çalışması için erişime açık uzaktan algılama görüntüleri sağlayan DigitalGlobe'un IKONOS ve Quickbird uydularından elde edilen iki farklı veritabanı üzerinde temsili deneyler yapılmıştır. Wald vd. [162]'nin önerdikleri protokole göre sentetik oluşturulan herhangi bir görüntü, ilgili sensörün en yüksek çözünürlükte elde edebildiği görüntüye olabildiğince yakın olmalıdır. Bu nedenle deneyler bozunmuş veri kümeleri üzerinde gerçekleştirilmiş ve orijinal MS görüntüler sonuç görüntüsünün kalitesini sayısal olarak değerlendirmek için referans görüntü olarak kullanılmıştır.

Quickbird uydusu 2.8 m. uzamsal çözünürlükte 4 bantlı MS görüntü ile 0.7 m. çözünürlüğünde PAN görüntüsü sağlamaktadır. Quickbird görüntüleri Hindistan'ın Sundurbans bölgesinden Kasım 2002 tarihinde çekilmiştir [163]. Quickbird deneylerinde kullanılan eğitim veri kümesi, 2.8 m. çözünürlüğündeki MS görüntülerin 4 faktörüyle bozularak 11.2 m. çözünürlüğünde MS görüntü ile 2.8 m. çözünürlüğünde PAN görüntü elde edilmesiyle oluşturulan 500×500 piksel boyutunda .tif dosya formatında 20 orijinal görüntü içermektedir. Görüntüler yerleşim yeri bölgesinden alınmış olup Şekil 32'de görüldüğü gibi daha çok bina, yol, araç ve nehir gibi yapılardan oluşmaktadır.



Şekil 32. Quickbird veritabanında bulunan eğitim MS ve PAN görüntülerinden bir örnek

IKONOS uydusu 4 m. uzamsal çözünürlükte 4 bantlı MS görüntü ile 1 m. çözünürlüğünde PAN görüntüsü sağlamaktadır. IKONOS görüntüleri Çin'in Sichuan bölgesinden Mayıs 2008 tarihinde çekilmiştir [164]. IKONOS deneylerinde kullanılan eğitim veri kümesi, 4 m. çözünürlüğündeki MS görüntülerin 4 faktörüyle bozularak 16 m. çözünürlüğünde MS görüntü ile 1 m. çözünürlüğünde PAN görüntü elde edilmesiyle oluşturulan 500×500 piksel boyutunda .tif dosya formatında 10 orijinal görüntü içermektedir. Görüntüler kırsal bölgeden alınmış olup Şekil 33'te görüldüğü gibi daha çok küçük yerleşim bölgelerine sahip dağlık alandan oluşmaktadır.



Şekil 33. İKONOS veritabanında bulunan eğitim MS ve PAN görüntülerinden bir örnek


Uydulardan elde edilen erişime açık görüntüler sınırlı olduğundan test veri kümesi her bir uydu için ikişer temsili görüntüden oluşmaktadır.

3.1.3. Mikroskobik Görüntülerden Oluşturulan Veritabanları

Mikroskobik görüntülerde gerçekleştirilen süper çözünürlük çalışması için ince kan yayma örneklerinin parazitoloji slaytlarını sanal mikroskopi platformu ile tarama olanağı sağlayan erişime açık MaMic görüntü veritabanı kullanılmıştır. Parazitoloji slaytları sıtma hastalığına neden olan *Plasmodium Falciparum* türünün teşhisi için hastalardan kan örneği alınarak hazırlanmış olan ince kan yayma örneklerini içermektedir.

MaMic görüntü veritabanındaki örnekler farklı boyama prosedüründen kaynaklı mavi ve pembe renge boyalı yaymaları içermekte ve yaymaların 2×, 5×, 10×, 20×, 40× ve 100× objektifleri altında taranarak görüntü alınmasına izin verilmektedir. Yayma örnekleri olarak mavi boyalı örneği içeren *mamic_57551* ve pembe boyalı örneği içeren *mamic_57552* yaymaları kullanılmıştır. 2× ve 5× objektifleri ile alınan görüntülerde büyütme oranı küçük olduğundan tüm yayma alanı görüş alanı içerisine girmektedir. Bu da birden fazla farklı görüntü olarak veritabanı oluşumunu sınırlandırmaktadır. Diğer taraftan 100× objektifi altında alınan görüntülerin yaptığımız çalışmalar doğrultusunda gerçek 100× görüntüsü olmayıp 80× objektifinde alınan görüntülere karşılık geldiği görülmüştür. Bu nedenle bu tez çalışmasında veritabanını oluşturmak için kullanılan görüntüler sadece 10×, 20× ve 40× objektifinde alınmıştır. Alınan görüntüler MaMic sanal mikroskopi platformunun sınırlandırdığı ölçüde 600×300 piksel boyutunda .jpeg dosya formatında saklanmaktadır.

DÇ görüntüler 10× ve 20× objektifinde alınırken YÇ görüntüler 40× objektifinde alınmıştır. Her bir yayma örneği için her bir objektifte yaymanın farklı bölgelerine karşılık gelen 26 görüntüden oluşan bir veritabanı hazırlanmıştır. Bu görüntülerden 16 DÇ görüntü ile onlara karşılık gelen YÇ görüntü eğitim veri kümesini oluştururken diğer 10 görüntü test veri kümesini oluşturmaktadır. *mamic_57551* ve *mamic_57552* yaymalarından elde edilen görüntülerle oluşturulan veritabanından 40× objektifinde alınan örnek birer görüntü sırasıyla Şekil 34(a) ve Şekil 34(b)'de verilmiştir.



Şekil 34. Mikroskobik veritabanındaki (a) *mamic_57551* ve (b) *mamic_57552* yaymalarına ait örnek görüntüler

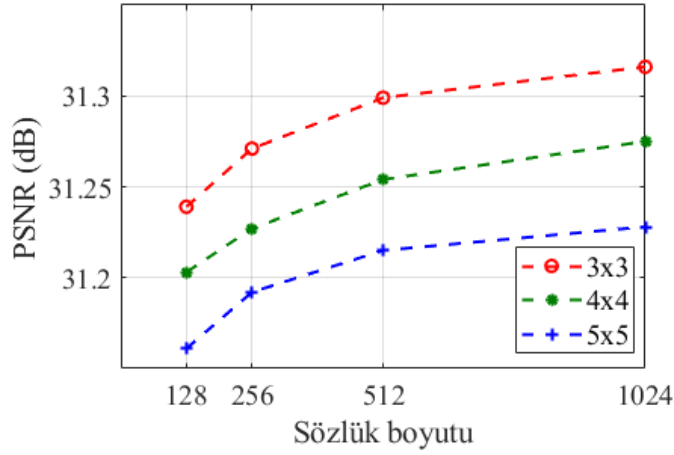
3.2. Ayrık Dalgacık Dönüşümüne Dayalı Tek Görüntü Süper Çözünürlüğü Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar

Deneysel ve algoritma performanslarının karşılaştırmaları Set5 ve Set14 veri kümeleri üzerinde $\times 2$ büyütme faktöründe gerçekleştirilmiştir. Önerilen modelin performansını analiz etmek için sonuçlar her bir veri kümesi ve her bir büyütme faktörü için çift kübik ara değerlendirme ve dalgacık ara değerlendirme yaklaşımlarıyla karşılaştırılmıştır. Orijinal görüntü ile süper çözünürlüklü görüntü arasındaki farkı ölçmek için kalite metriği olarak PSNR ve SSIM metrikleri kullanılmıştır. İnsan gözü sistemi parlaklık kanalına daha hassas olduğundan görüntüler YCbCr renk uzayına dönüştürülüp süper çözünürlük sadece parlaklık kanalında (Y) gerçekleştirilmiştir. Eğitim ve test aşamalarında kullanılacak olan tüm DÇ görüntüler olarak orijinal görüntüye dalgacık dönüşümü uygulandıktan sonra elde edilen LL bandı kullanılmıştır.

Uygun parametre seçimi yapmak için ayrık dalgacık dönüşümüne dayalı tek görüntü süper çözünürlük yaklaşımının analizi ve elde edilen deneysel sonuçlar alt başlıklarda detaylandırılacaktır. Bunun için ilk olarak parametrelerin süper çözünürlük performansına etkisi seyrek temsiliyet parametreleri açısından incelenip ardından sayısal ve görsel sonuçlar sunulacaktır.

3.2.1. Seyrek Temsiliyet Parametrelerinin Etkisi

Seyrek temsiliyete dayalı süper çözünürlük yöntemlerinin performansı her zaman parça ve sözlük boyutuna bağlı olmaktadır. Genellikle yüksek hesaplama gerektiren büyük sözlükler ve küçük parça boyutları ile daha iyi performans elde edilmektedir. Parça ve sözlük boyutunun süper çözünürlüklü görüntünün kalitesindeki etkisini analiz etmek için farklı parça ve sözlük boyutlarıyla elde edilen ortalama PSNR sonuçları Şekil 35'te verilmiştir. Burada önerilen model Set14 veri kümesi üzerinde $\times 2$ büyütme faktöründe test edilmiştir.

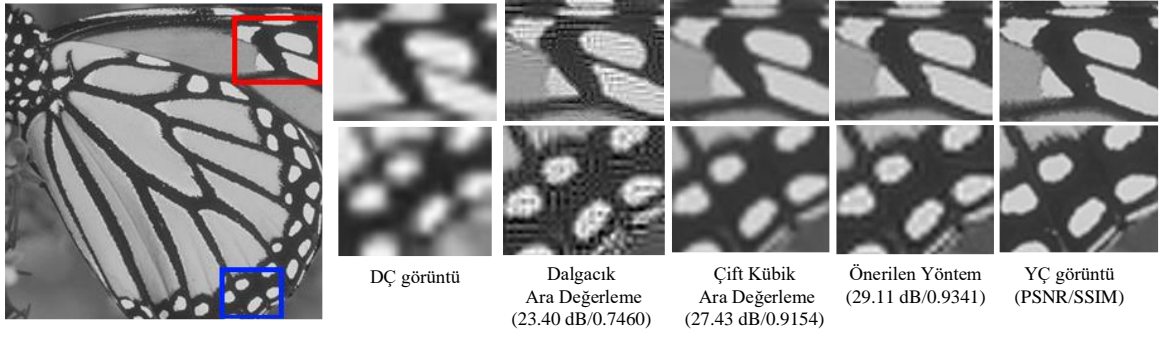


Şekil 35. Set14 veri kümesi üzerinde $\times 2$ büyütme faktöründe sözlük boyutunun süper çözünürlük performansına etkisi


Parça boyutu 3×3 , 4×4 ve 5×5 seçilirken sözlük boyutu 128 ile 1024 arasında 2'nin katı olacak biçimde çeşitlenmektedir. Parça boyutu azalıp sözlük boyutu arttıkça PSNR değerinin arttığı grafikten görülmektedir. Fakat sözlük boyutunun daha da artması daha yüksek zaman karmaşıklığına sebep olacaktır. Bu nedenle gerçekleştirilen deneylerde parça boyutu ve sözlük boyutu sırasıyla 3×3 ve 1024 olarak seçilmiştir.

3.2.2. Deneysel Sonuçlar ve Analizler

Önerilen yöntemin verimliliğini göstermek için Set5 ve Set14 test veri kümeleri üzerinde $\times 2$ büyütme faktöründe gerçekleştirilen deneylerde yapılan karşılaştırmalara ait birer görsel sonuç sırasıyla Şekil 36 ve 37'de görülmektedir. YÇ görüntü üzerinde bulunan kırmızı ve mavi dikdörtgen kutular yapılan karşılaştırmalara ait sonuçlardaki farkı daha iyi görebilmek için DÇ görüntü, YÇ görüntü ve her bir sonuç görüntüsünde büyütülerek görüntünün yanında gösterilmektedir. Şekil 36 ve 37'den şu çıkarımlar yapılabilir: dalgacık ara değerlendirme yönteminin süper çözünürlük sonuç görüntüsünde görüntü keskinleşirken görüntü üzerinde çizgi etkileri meydana gelmektedir. Çift kübik ara değerlendirme yöntemi görüntüdeki keskinliği artırırken diğer taraftan bulanıklığa neden olmaktadır. Önerilen yöntem diğer yaklaşımlarla kıyaslandığında çizgi etkisinin ve bulanıklığın azaldığı keskinliğin ise arttığı görülmektedir. Şekil 36'da görüldüğü gibi kelebeğin kanadındaki desenler karşılaştırılan yöntemlere nazaran daha keskindir. Benzer şekilde Şekil 37'de verilen görüntülerde yazı karakterleri ve kenar bölgelerde keskinlik sağlanmaktadır.



Şekil 36. Set5 veri kümesinden ‘Butterfly’ görüntüsünün $\times 2$ büyütme faktöründe süper çözünürlük sonuçları



Şekil 37. Set14 veri kümesinden ‘PPT3’ görüntüsünün $\times 2$ büyütme faktöründe süper çözünürlük sonuçları

Tablo 6. Set5 veri kümesi üzerinde $\times 2$ büyütme faktöründe önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları

Yöntem Görüntü	Dalgacık Ara Değerleme	Çift Kübik Ara Değerleme	Önerilen Yöntem
Baby	31.96 0.8932	37.07 0.9520	38.15 0.9635
Bird	30.76 0.8837	36.81 0.9721	38.96 0.9816
Butterfly	23.40 0.7460	27.43 0.9154	29.11 0.9341
Head	30.46 0.7990	34.86 0.8623	35.52 0.8837
Woman	27.59 0.8490	32.09 0.9469	33.62 0.9608
Ortalama	28.83 0.8342	33.65 0.9297	35.07 0.9447

Tablo 7. Set14 veri kümesi üzerinde $\times 2$ büyütme faktöründe önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları

Yöntem Görüntü	Dalgacık Ara Değerleme	Çift Kübik Ara Değerleme	Önerilen Yöntem
Baboon	22.92 0.6522	24.86 0.6978	25.48 0.7598
Barbara	25.60 0.7768	28.00 0.8413	28.60 0.8740
Bridge	23.85 0.7139	26.58 0.7929	27.37 0.8403
Coastguard	25.33 0.7097	29.12 0.7893	30.10 0.8444
Comic	22.76 0.7315	26.01 0.8491	27.27 0.8916
Face	30.25 0.7992	34.81 0.8636	35.46 0.8850
Flowers	26.74 0.7929	30.32 0.8981	31.62 0.9225
Foreman	27.39 0.8559	34.14 0.9518	35.48 0.9630
Lenna	30.70 0.8474	34.70 0.9112	35.96 0.9264
Man	26.58 0.7598	29.25 0.8458	30.11 0.8756
Monarch	28.93 0.8981	32.94 0.9601	34.55 0.9686
Pepper	30.87 0.8427	34.95 0.9073	35.89 0.9172
PPT3	24.36 0.8277	26.87 0.9450	28.35 0.9556
Zebra	26.35 0.8111	30.61 0.9098	32.17 0.9357
Ortalama	26.62 0.7871	30.23 0.8688	31.31 0.8971

Tablo 6 ve 7 sırasıyla önerilen yöntemin Set5 ve Set14 veri kümeleri üzerinde $\times 2$ büyütme faktöründe PSNR ve SSIM metrikleri kullanılarak güncel yaklaşımlarla sayısal karşılaştırmalarını göstermektedir. Tablolardaki sonuçlarda üst satır PSNR sonuçlarını gösterirken alt satır SSIM sonuçlarını vermektedir ve her bir kalite metriği için en iyi sonuçlar koyu yazılmıştır. Tablo 6 ve 7 incelendiğinde önerilen yöntemin dalgacık ve çift kübik ara değerlendirme yöntemlerinden daha yüksek PSNR ve SSIM değerlerine sahip olduğu

görülmektedir. Ortalama PSNR ve SSIM değeri olarak kendine en yakın başarılı sonuç veren yaklaşımdan Tablo 6'da sırasıyla 1.42 dB ve 0.015 ve Tablo 7'de sırasıyla 1.08 dB ve 0.0283 kazançlarıyla daha iyi performans göstermektedir.

3.3. Çok Ölçekli ve Çok Yönlü Gabor Özellik Temsiliyetine Dayalı Tek Görüntü Süper Çözünürlüğü Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar

Deneysel ve algoritma performanslarının karşılaştırmaları Set5 ve Set14 veri kümeleri üzerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde gerçekleştirilmiştir. Adil bir karşılaştırma yapmak için diğer öğrenme tabanlı süper çözünürlük yaklaşımlarındaki deneylerde de kullanılan 91 görüntüden oluşan eğitim veri kümesi önerilen yöntemi eğitmek için kullanılmıştır. Önerilen modelin performansını analiz etmek için sonuçlar her bir veri kümesi ve her bir büyütme faktörü için çift kübik ara değerlendirme, NE [31], ScSR [59], ANR [136] ve Zeyde vd. [58] yaklaşımlarını içeren çeşitli güncel süper çözünürlük yaklaşımlarıyla karşılaştırılmıştır. Orijinal görüntü ile süper çözünürlüklü görüntü arasındaki farkı ölçmek için kalite metriği olarak PSNR ve SSIM metrikleri kullanılmıştır. İnsan gözü sistemi parlaklık kanalına daha hassas olduğundan görüntüler YCbCr renk uzayına dönüştürülüp süper çözünürlük sadece parlaklık kanalında (Y) gerçekleştirilmiştir. Bu sebeple deneysel sonuçlarda elde edilen sonuç görüntülerinde Cb ve Cr kanalları çift kübik ara değerlendirme yöntemiyle doğrudan istenen boyuta büyütülmüş ve görsel sonuçlar için YCbCr kanalından RGB kanalına dönüşüm yapılmıştır. Eğitim ve test aşamalarında kullanılacak olan tüm DÇ görüntüler orijinal görüntüden $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde çift kübik ara değerlendirme yöntemiyle alt örneklendirilerek elde edilmiştir.


Uygun parametre seçimi yapmak için çok ölçekli ve çok yönlü süper çözünürlük yaklaşımının analizi ve elde edilen deneysel sonuçlar alt başlıklarda detaylandırılacaktır. Bunun için ilk olarak parametrelerin süper çözünürlük performansına etkisi 2 açıdan incelenecektir: özellik tanımlayıcısı ve seyrek temsiliyet parametreleri. Ardından önerilen yaklaşım güncel yaklaşımlarla karşılaştırılıp sayısal ve görsel sonuçlar sunulacaktır.

3.3.1. Özellik Tanımlayıcısı Parametrelerinin Etkisi

Gabor filtre bankası, özellik temsiliyeti analizinde ayırt edici özellikleri çıkarmak için sıklıkla kullanılmaktadır. Gabor filtre fonksiyonları çeşitli parametrelere bağlı olduğundan

ve bu parametrelerin seçimi süper çözünürlük performansını etkileyeceğinden Gabor filtre bankasının tasarlanması karmaşık bir süreç olmaktadır. Bunun yanında uygun seçilen parametreler ile filtre fonksiyonları kullanılarak çıkarılan özellikler daha doğru ve temsil edici olmaktadır. Bu sebeple, Gabor filtre fonksiyonlarının parametrelerinin etkisini incelemek için deneyler yapılmıştır. Yapılan deneylerde seyrek temsiliyet parametreleri olan parça boyutu ve sözlük boyutu sırasıyla 3×3 ve 4096 seçilmiştir.


İlk gerçekleştirilen deneyde η ve γ parametreleri sabit tutularak filtrelerin maksimum merkez frekansının, f_{max} , etkisi değerlendirilmiştir. Bunun için f_{max} değeri 0.5 ile 1.2 arasında 0.05 değeri ile artırılmıştır. Deneyler sonucunda f_{max} değerinin süper çözünürlük performansına etkisinin çok zayıf olduğu belirlenmiştir ve en iyi değer $f_{max} = 0.75$ olarak seçilmiştir. η ve γ parametrelerinin etkisini incelemek için değeri 0.50 ve 1 arasında değişen çeşitli η ve γ parametreleri kullanılarak Gabor filtre bankası tasarlanmıştır. Önerilen modelin farklı parametreler kullanılarak Set14 veri kümesi üzerinde $\times 3$ büyütme faktöründe test edilmesiyle elde edilen ortalama PSNR değerleri Şekil 38’de verilmektedir. Elde edilen sonuçlar yumuşatma parametrelerinin Gabor filtre bankası tasarlanmasında önemli bir role sahip olduğunu göstermektedir. Ayrıca, en iyi süper çözünürlüklü görüntünün η ve γ ’nın 0.70 olarak seçildiği durumda elde edildiği de görülmektedir.



Şekil 38. Set14 veri kümesi üzerinde $\times 3$ büyütme faktöründe η ve γ parametrelerinin süper çözünürlük performansına etkisi

3.3.2. Seyrek Temsiliyet Parametrelerinin Etkisi

Seyrek temsiliyete dayalı süper çözünürlük yöntemlerinin performansı her zaman parça ve sözlük boyutuna bağlı olmaktadır. Genellikle yüksek hesaplama gerektiren büyük sözlükler ile daha iyi performans elde edilmektedir. Benzer şekilde küçük parça boyutları da daha iyi performans sağlarken yüksek hesaplama maliyetine sebep olmaktadır. Parça ve sözlük boyutunun süper çözünürlüklü görüntünün kalitesindeki etkisini analiz etmek için farklı parça ve sözlük boyutlarıyla elde edilen ortalama PSNR sonuçları Şekil 39'da verilmiştir. Burada önerilen model Set14 veri kümesi üzerinde $\times 3$ büyütme faktöründe test edilmiş ve özellik tanımlayıcı parametreleri önerilen değerler olarak seçilmiştir.



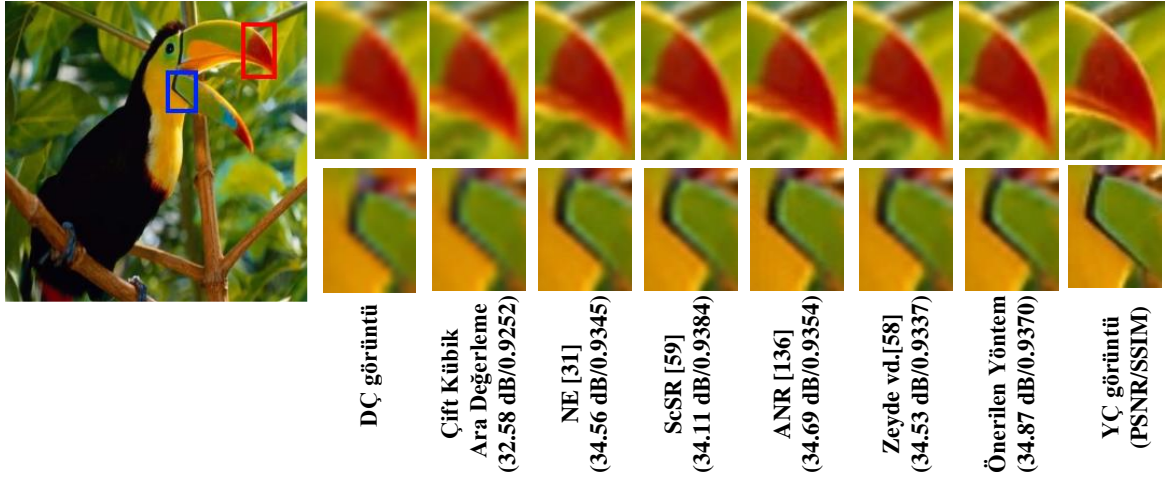
Şekil 39. Set14 veri kümesi üzerinde $\times 3$ büyütme faktöründe sözlük boyutunun süper çözünürlük performansına etkisi

Şekil 39'dan görüldüğü üzere parça boyutu 3×3 , 4×4 ve 5×5 seçilirken sözlük boyutu 1024 ile 8192 arasında 2'nin katı olacak biçimde çeşitlenmektedir. Parça boyutu azalıp sözlük boyutu arttıkça PSNR değerinin arttığı grafikten görülmektedir. Fakat sözlük boyutunun daha da artması daha yüksek zaman karmaşıklığına sebep olacaktır. Ayrıca hesaplama maliyeti dikkate alındığında sözlük boyutunun 4096 değerinden daha yüksek olması PSNR değerinde çok büyük artış sağlamamaktadır. Bu nedenle gerçekleştirilen deneylerde parça boyutu ve sözlük boyutu sırasıyla 3×3 ve 4096 olarak seçilmiştir.


3.3.3. Deneysel Sonular ve Analizler

Önerilen yöntemin verimliliğini göstermek için Set5 ve Set14 test veri kümeleri üzerinde $\times 3$ büyütme faktöründe gerçekleştirilen deneylerde yapılan karşılaştırmalara ait birer görsel sonuç sırasıyla Şekil 40 ve 41’de görülmektedir. Görüntüler üzerinde bulunan kırmızı ve mavi dikdörtgen kutular, yapılan karşılaştırmalara ait sonuçlardaki farkı daha iyi görebilmek için büyütülmüş ilgi bölgelerini göstermektedir. Şekil 40 ve 41’den şu çıkarımlar yapılabilir: çift kübik ara değerlendirme yönteminin süper çözünürlük performansı oldukça zayıf kalmaktadır. Örnekleme teorisinin basitliğinden ve DÇ görüntüdeki sınırlı bilgiden dolayı görüntünün içerdiği kenarlar boyunca salınım ile tırtıklı yapılar ve bulanık doku bilgisi sağlamaktadır. ScSR [59] yaklaşımı da sonuç görüntülerinde bulanık doku detaylarına ve zigzag etkisine neden olmaktadır. NE [31], ANR [136] ve Zeyde vd. [58] yaklaşımları bozucu yapay etkileri azaltarak ve keskin kenarlar sağlayarak görsel sonuçlarda birbirine benzer sonuçlar üretmektedir. Diğer yandan, önerilen yöntemin diğer yöntemlerle karşılaştırıldığında yapay etki olmadan daha fazla detaya sahip olarak bulanıklığı azalttığı ve keskin kenarlar ürettiği açıkça görülmektedir. Şekil 40’da görüldüğü gibi ağız bölgesindeki siyah kenar (mavi dikdörtgen) ile kırmızı gaga bölgesi (kırmızı dikdörtgen) karşılaştırılan yöntemlere nazaran daha keskindir. Benzer şekilde Şekil 41’de verilen görüntülerde güncel yaklaşımlarla elde edilen sonuçlarda şapkanın kenar ve püskül detayları daha bulanıkken önerilen yaklaşımla bölgeler keskinleşmektedir.

Tablo 8 ve 9 önerilen yöntemin sırasıyla Set5 ve Set14 veri kümeleri üzerinde $\times 3$ büyütme faktöründe PSNR ve SSIM metrikleri kullanılarak güncel yaklaşımlarla sayısal karşılaştırmalarını göstermektedir. Tablolardaki sonuçlarda üst satır PSNR sonuçlarını gösterirken alt satır SSIM sonuçlarını vermektedir ve her bir kalite metriği için en iyi sonuçlar koyu yazılmıştır. Tablo 8 ve 9 incelendiğinde önerilen yöntemin çift kübik ara değerlendirme yöntemi ve NE [31] yaklaşımından daha yüksek değerlere sahip olduğu görülmektedir. ScSR [59], ANR [136] ve Zeyde vd. [58] yaklaşımlarıyla karşılaştırıldığında ise önerilen yaklaşım veri kümelerindeki görüntülerin çoğunluğunda yine en yüksek PSNR ve SSIM değerini üretmektedir. Daha açık ifade etmek gerekirse önerilen yaklaşım ortalama PSNR ve SSIM değeri olarak kendine en yakın başarılı sonuç veren yaklaşımdan Tablo 8’de sırasıyla 0.12 dB ve 0.0025 ve Tablo 9’da 0.12 dB ve 0.0024 kazançlarıyla daha iyi performans göstermektedir.



Şekil 40. Set5 veri kümesinden 'Bird' görüntüsünün $\times 3$ büyütme faktöründe süper çözünürlük sonuçları



Şekil 41. Set14 veri kümesinden 'Lenna' görüntüsünün $\times 3$ büyütme faktöründe süper çözünürlük sonuçları

Tablo 8. Set5 veri kümesi üzerinde $\times 3$ büyütme faktöründe önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları

Yöntem Görüntü	Çift Kübik Ara Değerleme	NE [31]	ScSR [59]	ANR [136]	Zeyde vd. [58]	Önerilen Yöntem
Baby	33.91 0.9047	35.06 0.9100	34.29 0.9049	35.13 0.9115	35.09 0.9097	35.06 0.9097
Bird	32.58 0.9252	34.56 0.9345	34.11 0.9384	34.60 0.9354	34.53 0.9337	34.87 0.9370
Butterfly	24.04 0.8200	25.75 0.8577	25.58 0.8586	25.90 0.8589	25.97 0.8638	26.02 0.8659
Head	32.88 0.8009	33.60 0.8128	33.17 0.8026	33.63 0.8141	33.58 0.8109	33.66 0.8156
Woman	28.56 0.8895	30.22 0.9079	29.94 0.9034	30.33 0.9088	30.35 0.9091	30.60 0.9128
Ortalama	30.39 0.8681	31.84 0.8846	31.42 0.8816	31.92 0.8857	31.90 0.8854	32.04 0.8882

Önerilen yöntemin performansını farklı büyütme faktörlerinde sayısal olarak analiz etmek için gerçekleştirilen deneyin tüm veri kümelerinde ve tüm büyütme faktörlerinde elde edilen ortalama PSNR ve SSIM değerleri Tablo 10'da listelenmektedir. Burada ScSR [59] yaklaşımının $\times 2$ ve $\times 4$ büyütme faktörlerinde elde edilen sonuçları [59] referans numaralı makalede verilmediğinden ve önerilen yaklaşımın paylaşımına açık kodu kullanılarak $\times 2$ ve $\times 4$ büyütme faktörlerinde eğitim yapılırken karşılaşılan koşma hatasından dolayı Tablo 10'da sadece bu yaklaşım için $\times 3$ büyütme faktöründeki ortalama değerlere yer verilmiştir. Sonuçlar önerilen yaklaşımın farklı büyütme faktörlerinde veri kümelerinin birçoğunda karşılaştırma yapılan yöntemlerden daha üstün performans elde ettiğini göstermektedir. Ayrıca dikkat edilmelidir ki Tablo 8, 9 ve 10'da elde edilen sonuçlar ilgili makalelerin deneysel sonuçlarında sunulan sonuçlara eşdeğerdir.

Tablo 9. Set14 veri kümesi üzerinde $\times 3$ büyütme faktöründe önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları

Yöntem Görüntü	Çift Kübik Ara Değerleme	NE [31]	ScSR [59]	ANR [136]	Zeyde vd. [58]	Önerilen Yöntem
Baboon	23.21 0.5433	23.55 0.5925	23.47 0.5868	23.56 0.5946	23.52 0.5862	23.59 0.6038
Barbara	26.25 0.7546	26.74 0.7805	26.39 0.7648	26.69 0.7803	26.79 0.7812	26.70 0.7840
Bridge	24.40 0.6469	24.98 0.6942	24.82 0.6908	25.01 0.6963	25.01 0.6922	25.05 0.6971
Coastguard	26.55 0.6174	27.07 0.6513	27.02 0.6423	27.08 0.6531	27.12 0.6509	27.15 0.6570
Comic	23.12 0.7023	23.98 0.7499	23.90 0.7583	24.04 0.7535	23.97 0.7486	24.01 0.7501
Face	32.82 0.7992	33.56 0.8116	33.11 0.8013	33.62 0.8133	33.54 0.8097	33.62 0.8144
Flowers	27.23 0.8030	28.38 0.8307	28.25 0.8308	28.49 0.8332	28.43 0.8302	28.63 0.8355
Foreman	31.16 0.9026	33.21 0.9149	32.04 0.9095	33.23 0.9157	33.18 0.9145	33.58 0.9182
Lenna	31.68 0.8592	33.01 0.8694	32.64 0.8653	33.08 0.8709	33.02 0.8684	33.26 0.8727
Man	27.01 0.7500	27.87 0.7822	27.76 0.7751	27.92 0.7839	27.91 0.7810	28.05 0.7873
Monarch	29.43 0.9206	30.95 0.9283	30.71 0.9295	31.09 0.9298	31.12 0.9295	31.58 0.9327
Pepper	32.38 0.8687	33.80 0.8748	33.32 0.8660	33.82 0.8754	34.05 0.8759	34.18 0.8775
PPT3	23.71 0.8770	24.94 0.8893	24.98 0.8938	25.03 0.8898	25.21 0.8992	25.03 0.8955
Zebra	26.63 0.7937	28.31 0.8294	27.95 0.8250	28.43 0.8313	28.51 0.8303	28.58 0.8292
Ortalama	27.54 0.7742	28.60 0.8000	28.31 0.7957	28.65 0.8015	28.67 0.7998	28.79 0.8039

Tablo 10. Set5 ve Set14 veri kümesi üzerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları

Yöntem Veri Kümesi	Büyütme Faktörü	Çift Kübik Ara Değerleme	NE [31]	ScSR [59]	ANR [136]	Zeyde vd. [58]	Önerilen Yöntem
Set5	$\times 2$	33.66 0.9300	35.77 0.9449	- -	35.83 0.9458	35.72 0.9442	35.81 0.9453
	$\times 3$	30.39 0.8681	31.84 0.8846	31.42 0.8816	31.92 0.8857	31.90 0.8854	32.04 0.8882
	$\times 4$	28.42 0.8102	29.61 0.8210	- -	29.69 0.8228	29.71 0.8235	29.75 0.8262
Set14	$\times 2$	30.23 0.8689	31.76 0.8959	- -	31.80 0.8971	31.76 0.8944	31.84 0.8967
	$\times 3$	27.54 0.7742	28.60 0.8000	28.31 0.7957	28.65 0.8015	28.67 0.7998	28.79 0.8039
	$\times 4$	26.00 0.7027	26.81 0.7202	- -	26.85 0.7223	26.90 0.7218	26.99 0.7251

3.4. Yoğun Atlamalı Bağlantılı Konvolüsyonel Sinir Ağlarına Dayalı Tek Görüntü Süper Çözünürlüğü Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar

Deneyler ve algoritma performanslarının karşılaştırmaları Set5, Set14, Urban100, B100 ve DIV2K validasyon veri kümeleri üzerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde gerçekleştirilmiştir. Önerilen yoğun atlamalı bağlantılı konvolüsyonel sinir ağını eğitmek için DIV2K veri kümesi kullanılmıştır. Görüntüler üzerinde rastgele döndürme ve çevirme ile birlikte veri artırımı uygulanmıştır. Önerilen modelin performansını analiz etmek için sonuçlar her bir veri kümesi ve her bir büyütme faktörü için çift kübik ara değerlendirme, Ayas vd. [165], A+ [55], SRCNN [30], VDSR [105] ve DRCN [100] yaklaşımlarını içeren çeşitli güncel süper çözünürlük yaklaşımlarıyla karşılaştırılmıştır. Orijinal görüntü ile süper çözünürlüklü görüntü arasındaki farkı ölçmek için kalite metriği olarak PSNR ve SSIM metrikleri kullanılmıştır. İnsan görü sistemi parlaklık kanalına daha hassas olduğundan görüntüler YCbCr renk uzayına dönüştürülüp süper çözünürlük sadece parlaklık kanalında (Y) gerçekleştirilmiştir. Bu sebeple deneysel sonuçlarda elde edilen sonuç görüntülerinde Cb ve Cr kanalları çift kübik ara değerlendirme yöntemiyle doğrudan istenen boyuta büyütülmüş ve görsel sonuçlar için YCbCr kanalından RGB kanalına dönüşüm yapılmıştır. Eğitim aşamasında kullanılacak olan DÇ görüntülerin $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörleri için çift

kübik ara değerlendirme yöntemiyle alt örneklenmiş görüntüleri DIV2K veri kümesi içerisinde hazır olarak bulunmaktadır. Test sürecinde kullanılacak olan tüm DÇ görüntüler orijinal görüntülerden $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde çift kübik ara değerlendirme yöntemiyle alt örneklenerek elde edilmiştir.

Yoğun atlamalı bağlantılı konvolüsyonel sinir ağlarına dayalı tek görüntü süper çözünürlük yaklaşımının çeşitli parametrelere bağlı analizi ve elde edilen deneysel sonuçlar alt başlıklarda detaylandırılacaktır. Bunun için öncelikle önerilen ağ yapısı içerisindeki blok sayısının, her bir bloktaki ardışık bağlanmış konvolüsyon ve ReLU katman sayısının, transpoz konvolüsyon filtre sayısının, küçük grup boyutunun, başlangıç öğrenme katsayısının ve atlamalı bağlantı ile özellik birleştirmenin süper çözünürlük performansına etkisi incelenecektir. Yapılan analizlerde ağın varsayılan parametreleri olarak blok sayısı 6, blok içi katman sayısı 6, devir sayısı 100, başlangıç öğrenme katsayısı 10^{-4} , küçük grup boyutu 64, transpoze konvolüsyon filtre sayısı 256 seçilmiş olup analizler Set14 veri kümesi üzerinde $\times 3$ büyütme faktöründe gerçekleştirilmiştir. Analizlerin ardından önerilen yaklaşım güncel yaklaşımlarla karşılaştırılıp sayısal ve görsel sonuçlar sunulacaktır.

3.4.1. Yoğun Blok Sayısı ve Blok İçerisindeki Katman Sayısının Etkisi

Önerilen ağ modeli 2 temel parametreye sahiptir: Blok sayısı M ve her bir blokta bulunan konvolüsyon katman sayısı N dir. M ve N sayısı ağın derinliğini kontrol etmek için kullanılmaktadır. Blok ve konvolüsyon katman sayısının süper çözünürlük performansına etkisini incelemek için blok sayısı ve konvolüsyon katman sayısı 5, 6 ve 7 seçilerek Tablo 11 oluşturulmuştur.


Tablo 11. Blok sayısı (M) ve konvolüsyon katman sayısının (N) ağın performansına etkisi (PSNR (dB) ve zaman (saat))

$M \backslash N$	5	6	7
5	29.8990 s:17.46	29.8964 s: 20.08	29.9187 s: 22.36
6	29.8718 s: 22.19	29.9506 s: 26.57	X
7	X	X	X

Tablo 11 incelendiğinde blok sayısının ve konvolüsyon katman sayısının süper çözünürlük performansına etkisinin hangi yönde artıp azalacağı hakkında kesin bir yargıya varılamamaktadır. Konvolüsyonel sinir ağlarının süper çözünürlük problemine uygulandığı literatürdeki blok tabanlı çalışmalar da incelendiğinde blok ve konvolüsyon katmanı sayısına bağlı analiz yapılmayıp sadece ağ yapısında kullanılacak olan önerilen sayıların verildiği görülmektedir [108-110]. Tablo 11’den çıkarılacak bir başka sonuç ise blok ve konvolüsyon sayısının belli bir sayıdan sonra artması ağın karmaşıklığını artırmaktadır. Bu da aşırı uyma problemini ortaya çıkarmaktadır. Aşırı uyma problemini ortadan kaldırmak için veri kümesini artırmak ya da ağın karmaşıklığını azaltmak gerekmektedir. Bu sonuçlardan yola çıkarak bu çalışmada $M = 6$ ve $N = 6$ olarak seçilmiştir.

3.4.2. Transpoze Konvolüsyon Filtre Sayısının Etkisi

Çalışmada DC görüntüyü hedeflenen YÇ görüntü çıkış boyutuna getirmek için kullanılan transpoze konvolüsyon filtre sayısının süper çözünürlük performansına etkisini incelemek için filtre sayısı 32 ile 256 arasında 2’nin katı olacak biçimde artırılmıştır. Farklı transpoze konvolüsyon filtre sayısına bağlı olarak elde edilen ortalama PSNR değerleri Şekil 42’de verilmektedir.



Şekil 42. Transpoze konvolüsyon filtre sayısının ağın performansına etkisi (PSNR (dB) ve zaman (saat))


Şekil 42 incelendiğinde transpoze konvolüsyon filtre sayısının artmasının performansı geliştirdiği görülmektedir. Fakat filtre sayısının artışına bağlı olarak ağın eğitimi için geçen süre de artmaktadır. Başarı ve zaman arasındaki ödünleşme göz önüne alındığında çalışmada transpoze konvolüsyon sayısı 256 seçilmiştir. Önerilen modelde farklı büyütme faktörleri için kullanılan transpoze konvolüsyon katmanının filtre boyutları da birbirinden farklıdır. $\times 2$, $\times 3$ ve $\times 4$ modellerinde kullanılan filtrelerin boyutları sırasıyla 2 piksel atlamalı 2×2 , 3 piksel atlamalı 3×3 ve 4 piksel atlamalı 4×4 olarak seçilmektedir.

3.4.3. Küçük Grup Boyutunun Etkisi

Eğitim veri kümesinin milyonlarca örnekten oluştuğu düşünüldüğünde tek bir parametre güncellemesi yapmak için tüm eğitim veri kümesi üzerinden kayıp fonksiyonunun hesaplanması çok zaman almaktadır. Bu problemin çözümü, eğitim veri kümesindeki küçük gruplar üzerinden kayıp fonksiyonunun hesaplanmasıdır. Küçük grupların boyutu genellikle hesaplamaların yapılacağı mimarinin bellek gereksinimlerine göre ayarlanmaktadır. 2'nin katı gibi bir değere ayarlamak GPU'nun bellek gereksinimine uyarak vektörize işlemlerin daha hızlı çalışmasını sağlamaktadır.

Çalışmada küçük grup boyutunun süper çözünürlükte görüntünün kalitesine etkisini incelemek için küçük grup sayısı 16 ile 128 arasında 2'nin katı olacak şekilde artırılmıştır. Farklı küçük grup sayısına bağlı olarak elde edilen ortalama PSNR değerleri Şekil 43'te verilmektedir.

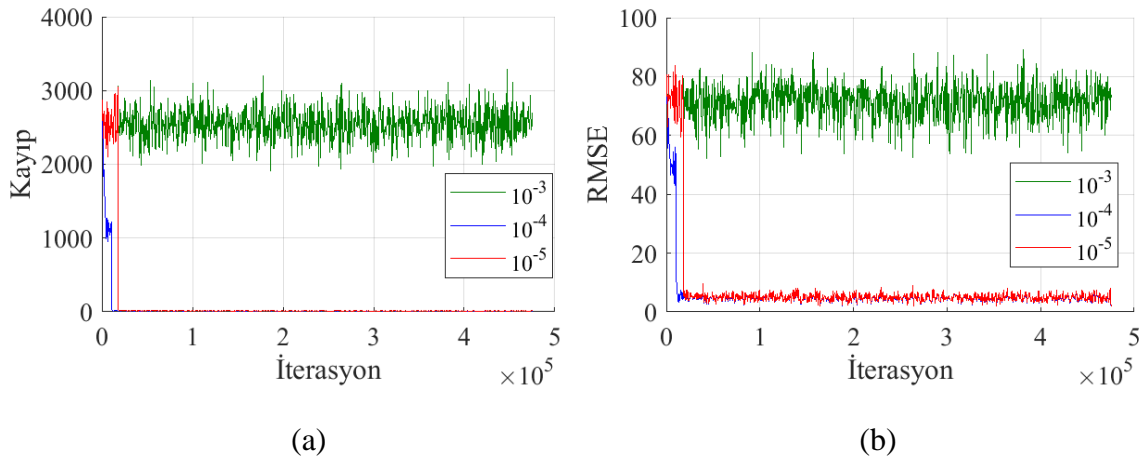
Şekil 43'te görüldüğü üzere önerilen ağ modeli için küçük grup boyutunun 64 değerine kadar artması performansta artış sağlarken eğitimi de hızlandırmaktadır. Küçük grup boyutu 128 seçildiğinde ise başarıda da bir düşüş yaşanmaktadır. Bu sebeple çalışmada küçük grup boyutu 64 seçilmiştir.



Şekil 43. Küçük grup boyutunun ağırlık performansına etkisi (PSNR (dB) ve zaman (saat))

3.4.4. Başlangıç Öğrenme Katsayısının Etkisi

Çalışmada başlangıç öğrenme katsayısının süper çözünürlük performansına etkisini incelemek için öğrenme katsayısı 10^{-3} , 10^{-4} ve 10^{-5} olarak değiştirilmiştir. Farklı başlangıç öğrenme katsayısına bağlı olarak kayıp fonksiyonu ve RMSE değerinin değişim grafiği Şekil 44'te gösterilmektedir.



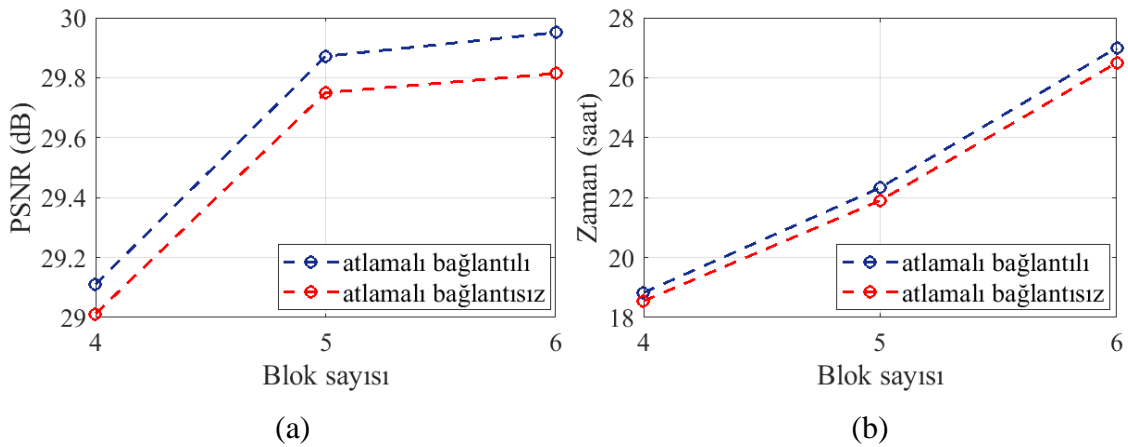
Şekil 44. Başlangıç öğrenme katsayısının ağırlık performansına etkisi a) Kayıp fonksiyonu ve b) RMSE

Şekil 44 incelendiğinde başlangıç öğrenme katsayısının 10^{-3} başka bir deyişle büyük seçilmesinin, ağırlıkların değişim miktarında sert güncellemeler yapıldığından dolayı

salınımlara sebep olduğu görülmektedir. 10^{-5} gibi küçük bir değer seçilmesi en uygun noktaya ulaşmaya kadar küçük adımlarla ilerlendiğinden çok güncelleme gerektirmektedir ve bu da ağın yakınsama süresini artırmaktadır. 10^{-4} değeri ise önerilen ağ modeli için en uygun değer olup kayıp ve RMSE hatasının kısa sürede azalmasına neden olmaktadır. Bu sebeple çalışmada başlangıç öğrenme katsayısı 10^{-4} seçilmiş ve her 30 devirden sonra yarıya düşürülmüştür.

3.4.5. Atlamalı Bağlantı ile Özellik Birleştirmenin Etkisi

Şekil 20’de verilen önerilen yoğun atlamalı konvolüsyonel sinir ağı mimarisinde ilk özellik haritasının büyütme katmanından önce son özellik haritası ile birleştirilmesinin, başka bir deyişle atlamalı bağlantı kullanımının, süper çözünürlük performansına etkisini incelemek için her bir blokta bulunan konvolüsyon katman sayısı sabit tutularak blok sayısı değiştirilmiştir ve ölçümler yapılmıştır.



Şekil 45. Atlamalı bağlantı kullanımının ağına etkisi a) PSNR (dB) ve b) zaman (saat)


Atlamalı bağlantılı ve atlamalı bağlantısız ağ modelinin PSNR ve zaman açısından analizi sırasıyla Şekil 45(a) ve (b)’de verilmektedir. Burada mavi doğru atlamalı bağlantılı ağ kullanımını ve kırmızı doğru atlamalı bağlantısız ağ kullanımını göstermektedir. Beklenildiği üzere ağına eğitimi blok sayısı ile doğru orantılı bir şekilde artmaktadır. Atlamalı bağlantının kullanılıp kullanılmamasının zaman üzerinde önemli bir etkisi bulunmamaktadır. Buna karşın, atlamalı bağlantılı ağ modeliyle performansta önemli artış

elde edilmektedir. Bu sebeple, başarı ve zaman arasındaki ödünleşme ele alındığında atlamalı bağlantı içeren ağ modeli seçilerek üzerinde deneyler gerçekleştirilmiştir.

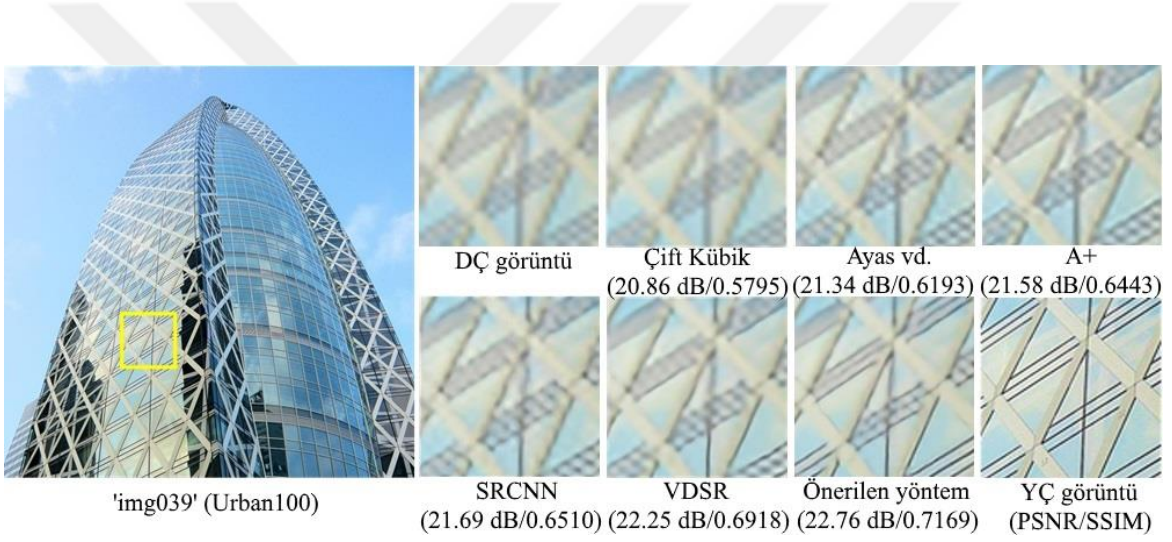
3.4.6. Deneysel Sonuçlar ve Analizler

Önerilen yöntemin verimliliğini göstermek için çift kübik ara değerlendirme fonksiyonuyla bozunmuş DIV2K validasyon ve Urban100 test veri kümelerindeki görüntülerin $\times 4$ büyütme faktöründe gerçekleştirilen deneylerinde yapılan karşılaştırmalara ait görsel sonuçlar Şekil 46-48'de verilmektedir. Görüntüler üzerinde bulunan sarı dikdörtgen kutular büyütülmüş ilgi bölgelerini göstermektedir. Şekil 46 incelendiğinde çift kübik ara değerlendirme yönteminin DÇ görüntüde bulunan çizgilere keskinlik kazandıramadığı görülmektedir. Ayas vd. [165]'nin önerdikleri seyrek temsiliyet tabanlı yaklaşımda keskinlik biraz daha artarken tırtıklı yapılar göze çarpmaktadır. Bir diğer öğrenme tabanlı yaklaşım olan A+ [55] yöntemiyle özellikle sol alt ve sağ üst köşede bulunan çizgilerin biraz daha netlik kazandığı görülmektedir. İlk konvolüsyonel sinir ağları tabanlı yaklaşım olan SRCNN [30] yöntemiyle bulanıklık biraz daha azalırken tırtıklı yapılar varlığını korumaktadır. VDSR [105] yaklaşımı ile birlikte sayısal olarak PSNR ve SSIM değerlerinde fazla miktarda iyileşme sağlanırken kenarlar boyunca keskinliğin artarak tırtıklı bölgelerin kısmen gözden kaybolduğu görülmektedir. Önerilen yöntem VDSR yöntemi ile karşılaştırıldığında ise VDSR yönteminde karşılaşılan bulanık bölgelerde önerilen yaklaşım ile çizgilerin çok daha belirgin olduğu görülmektedir. Sayısal sonuçlarda da VDSR yöntemine kıyasla üstün başarı elde edildiği görülmektedir.


Şekil 47'de verilen Urban100 veri kümesindeki 'img039' görüntüsünün süper çözünürlük sonuçlarında ilgi bölgeleri incelendiğinde benzer sonuçlarla karşılaşılmaktadır. Önerilen yöntemle bina üzerindeki detayların daha çok keskinleştiği göze çarpmaktadır. İlgi bölgesinin sağ alt köşesinde görüldüğü üzere bazı bölgelerde detaylarda tamamen keskinlik sağlanırken diğer bölgelerde bulanıklık ve tırtıklı yapıların azaldığı görülmektedir. Şekil 48'de verilen '0853' görüntüsünün süper çözünürlük sonuçlarında da önerilen yaklaşım ile çizgi desenlerinde keskinliğin arttığı görülmektedir.



Şekil 46. DIV2K veri kümesinden '0828' görüntüsünün $\times 4$ büyütme faktöründe süper çözünürlük sonuçları



Şekil 47. Urban100 veri kümesinden 'img039' görüntüsünün $\times 4$ büyütme faktöründe süper çözünürlük sonuçları



Şekil 48. DIV2K veri kümesinden '0853' görüntüsünün $\times 4$ büyütme faktöründe süper çözünürlük sonuçları


Tablo 12 önerilen yöntemin Set5, Set14, B100, Urban100 ve DIV2K validasyon veri kümeleri üzerinde tüm büyütme faktörlerinde PSNR ve SSIM metrikleri kullanılarak güncel yaklaşımlarla sayısal karşılaştırmalarını göstermektedir. Tablo 12 incelendiğinde önerilen yöntemin tüm veri kümeleri ve büyütme faktörlerinde karşılaştırılan yöntemlere kıyasla daha başarılı sonuç ürettiği sayısal değerlerden de görülmektedir.

Tablo 12. Set5, Set14, B100, Urban100 ve DIV2K validasyon veri kümesi üzerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde önerilen yöntemin literatürdeki yaklaşımlarla karşılaştırılmasının PSNR (dB) ve SSIM sonuçları


Yöntem Veri Kümesi	Büyütme Faktörü	Çift Kübik Ara Değerleme	Ayas vd. [165]	A+ [55]	SRCNN [30]	VDSR [105]	DRCN [100]	Önerilen Yöntem
Set5	$\times 2$	33.66 0.9300	35.81 0.9453	36.54 0.9544	36.66 0.9542	37.53 0.9587	37.63 0.9588	38.01 0.9609
	$\times 3$	30.39 0.8681	32.04 0.8882	32.58 0.9088	32.75 0.9090	33.66 0.9213	33.82 0.9226	34.05 0.9238
	$\times 4$	28.42 0.8102	29.75 0.8262	30.28 0.8603	30.48 0.8628	31.35 0.8838	31.53 0.8854	31.68 0.8874
Set14	$\times 2$	30.23 0.8689	31.84 0.8967	32.28 0.9056	32.42 0.9063	33.03 0.9124	33.04 0.9118	33.35 0.9145
	$\times 3$	27.54 0.7742	28.79 0.8039	29.13 0.8188	29.28 0.8209	29.77 0.8314	29.76 0.8311	29.95 0.8348
	$\times 4$	26.00 0.7027	26.99 0.7251	27.32 0.7491	27.49 0.7503	28.01 0.7674	28.02 0.7670	28.13 0.7711
B100	$\times 2$	29.56 0.8431	30.82 0.8800	31.21 0.8863	31.36 0.8879	31.90 0.8960	31.85 0.8942	32.04 0.8983
	$\times 3$	27.21 0.7385	28.01 0.7777	28.29 0.7835	28.41 0.7863	28.82 0.7976	28.80 0.7963	28.93 0.8004
	$\times 4$	25.96 0.6675	26.57 0.7015	26.82 0.7087	26.90 0.7101	27.29 0.7251	27.23 0.7233	27.37 0.7279
Urban100	$\times 2$	26.88 0.8403	28.42 0.8785	29.20 0.8938	29.50 0.8946	30.76 0.9140	30.75 0.9133	31.13 0.9305
	$\times 3$	24.46 0.7349	25.53 0.7795	26.03 0.7973	26.24 0.7989	27.14 0.8279	27.15 0.8276	27.62 0.8400
	$\times 4$	23.14 0.6577	23.96 0.6998	24.32 0.7183	24.52 0.7221	25.18 0.7524	25.14 0.7510	25.52 0.7653
DIV2K validasyon	$\times 2$	31.01 0.9393	-	32.89 0.9570	33.05 0.9581	33.66 0.9625	-	-
	$\times 3$	28.22 0.8906	-	29.50 0.9116	29.64 0.9138	30.09 0.9208	-	-
	$\times 4$	26.66 0.8521	-	27.70 0.8736	27.78 0.8753	28.17 0.8841	-	-

Önerilen yöntemin performansını farklı bozunma modelinde de test etmek için YÇ görüntüler, standart sapması çekirdek genişliğine eşit olan 15×15 boyutlu bir Gauss filtresiyle bulanıklaştırıldıktan sonra ölçek faktörüyle alt örneklenmiştir ve elde edilen görüntülere gürültü seviyesine bağlı olarak gürültü eklenerek Şekil 49’da verilen DÇ görüntüler oluşturulmuştur.

Gerçekleştirilen deneysel çalışmada, Tablo 12’de verilen karşılaştırılan yaklaşımların bozunma modelleri farklı olduğundan sadece çift kübik ara değerlendirme yaklaşımıyla karşılaştırma yapılmıştır. Set5 test veri kümesindeki görüntülerin farklı bozunma parametreleri kullanıldığında $\times 3$ büyütme faktöründe gerçekleştirilen deneylerinde yapılan karşılaştırmalara ait görsel sonuçlardan bir kısmı Şekil 50’de verilmektedir. Şekil 50 incelendiğinde çift kübik ara değerlendirme yönteminin süper çözünürlük sonucunun DÇ görüntünün bulanık ve gürültülü olması durumunda oldukça zayıf kaldığı ve giriş görüntüsü sadece bulanık olduğunda ise bulanıklık etkisinin azaltılamadığı görülmektedir. Buna karşın önerilen yaklaşım ile bulanıklık etkisinin yok edildiği gürültünün ise kısmen kaldırıldığı yapılan analizlerde belirlenmiştir.



Şekil 49. Set5 veri kümesinden ‘butterfly’ görüntüsünün $\times 3$ büyütme faktöründe farklı bozunma parametrelerine bağlı oluşturulan DÇ Y kanalı görüntüleri: (a) orijinal YÇ görüntü, (b) Çekirdek genişliği (ÇG) = 1.0, Gürültü seviyesi (GS) = 0; (c) ÇG = 1.0, GS = 15; (d) ÇG = 1.0, GS = 50; (e) ÇG = 2.6, GS = 0; (f) ÇG = 2.6, GS = 15; (g) ÇG = 2.6, GS = 50.



Şekil 50. Set5 veri kümesinden ‘butterfly’ görüntüsünün $\times 3$ büyütme faktöründe farklı bozunma parametrelerine bağlı (a,b,c) çift kübik ara değerlendirme yönteminin ve (d,e,f) önerilen yaklaşımın süper çözünürlük sonuçları; (a, d) $\text{ÇG} = 1.0$, $\text{GS} = 15$; (b, e) $\text{ÇG} = 2.6$, $\text{GS} = 0$; (c,f) $\text{ÇG} = 2.6$, $\text{GS} = 50$.

Tablo 13. Set5 veri kümesi üzerinde $\times 2$, $\times 3$ ve $\times 4$ büyütme faktörlerinde önerilen yöntemin farklı bozunma modelleri kullanıldığında elde edilen PSNR (dB) sonuçları

Bozunma Parametreleri			PSNR (dB) ($\times 2/\times 3/\times 4$)	
Çekirdek genişliği	Alt örnekleme işlemi	Gürültü seviyesi	Çift Kübik Ara Değerleme	Önerilen Yöntem
1.0	Çift Kübik	0	31.10/29.38/27.90	34.05/32.10/30.12
1.0	Çift Kübik	15	24.84/24.28/23.72	28.52/27.01/25.85
1.0	Çift Kübik	50	16.23/16.13/16.05	24.21/23.39/22.45
2.6	Çift Kübik	0	26.31/26.09/25.73	37.23/34.11/28.74
2.6	Çift Kübik	15	22.96/22.82/22.67	26.30/25.86/25.04
2.6	Çift Kübik	50	15.81/15.76/15.76	23.42/22.52/21.75

Tablo 13 önerilen yöntemin Set5 veri kümesi üzerinde farklı bozunma parametreleri kullanıldığında tüm büyütme faktörlerinde PSNR metriği kullanarak çift kübik ara değerlendirme yaklaşımıyla sayısal karşılaştırmasını vermektedir. Tablo 13 incelendiğinde önerilen yaklaşımın tüm büyütme faktörlerinde hem bulanıklık hem gürültü etkisine karşı çift kübik ara değerlendirme yaklaşımına nazaran daha başarılı sonuç verdiği anlaşılmaktadır.

Her iki bozunma etkeni ayrı ayrı ele alındığında önerilen yaklaşımın bulanıklığa karşı daha dayanıklı olduğu görülmektedir.

3.5. Sözlük Öğrenmesi ve Seyrek Temsiliyete Dayalı Pan Keskinleştirme Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar

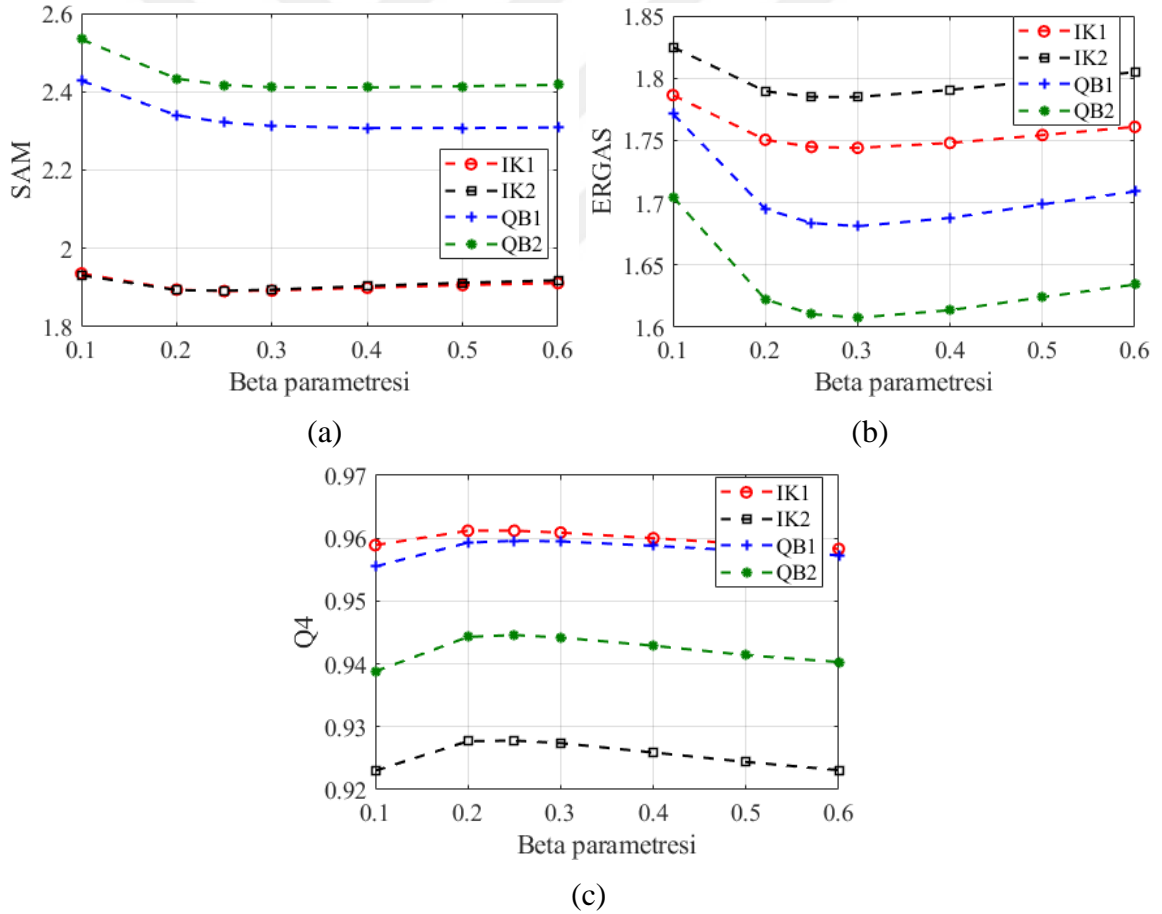
Deneyler ve algoritma performanslarının karşılaştırmaları Quickbird ve IKONOS uydusu için ayrı ayrı iki farklı veri kümesi üzerinde gerçekleştirilmiştir. Uydudan alınan görüntülerde MS görüntünün boyutunun PAN görüntünün boyutuna oranı 1/4 olduğundan deneyler $\times 4$ büyütme faktöründe yapılmıştır. Önerilen modelin performansını analiz etmek için sonuçlar her bir veri kümesi için $\times 4$ büyütme faktöründe PCA [76], GS [77], Brovey dönüşümü [79], HPF [82], AWLP [83], BDSF [81], ATWT [84], MTF-GLP-CBD [85], GSA [80] ve Li vd. [70] yaklaşımlarını içeren çeşitli güncel bileşen yerine koyma, çoklu çözünürlük analizi ve seyrek gösterim tabanlı yaklaşımlarla karşılaştırılmıştır. Orijinal görüntü ile süper çözünürlüklü görüntü arasındaki farkı ölçmek için kalite metriği olarak CC, RMSE, SAM, ERGAS ve Q4 metrikleri kullanılmıştır. Burada CC ve RMSE metrikleri her bir bant için ayrı ayrı hesaplanırken SAM, ERGAS ve Q4 metrikleri görüntünün tümü için hesaplanmaktadır.

Kullanıcı tanımlı parametrelerin etkisini incelemek için sözlük öğrenmesi ve seyrek temsiliyete dayalı pan keskinleştirme yaklaşımının analizi ve elde edilen deneysel sonuçlar alt başlıklarda detaylandırılacaktır. Bunun için ilk olarak parametrelerin pan keskinleştirme performansına etkisi incelenecektir. Ardından önerilen yaklaşım Quickbird ve IKONOS veri kümelerinde ayrı ayrı güncel yaklaşımlarla karşılaştırılıp sayısal ve görsel sonuçlarla birlikte zaman karmaşıklığı karşılaştırmaları sunulacaktır.

3.5.1. Kullanıcı Tanımlı Parametrelerin Etkisi

Bu bölümde, β parametresinin, sözlük boyutunun, iterative geri izdüşürme adımının, doku tabanlı sözlük kullanımının ve örnek azaltımı sürecinin pan keskinleştirme performansına etkisi ERGAS, SAM ve Q4 metriklerine göre değerlendirilmiştir. Temsili deneyler Quickbird ve IKONOS uydularından elde edilen bozunmuş veri kümelerinde gerçekleştirilmiş ve orjinal MS görüntüler kesin referans görüntüsü olarak kullanılmıştır.

İlk olarak DÇ MS görüntü ve YÇ PAN görüntünün etkisini dengeleyerek pan keskinleştirilmiş sonuç görüntüsünün performansına katkı sağlayan β parametresinin etkisi incelenmiştir. Parametrenin değeri 0.1 ile 0.6 arasında değiştirilmiştir. Parametrenin değerlerine göre kalite metriklerinin hesaplanan değerleri Şekil 51'in alt şekillerinde çizdirilmiştir. Burada dikey eksen her bir kalite metriğinin hesaplanan değerini gösterirken yatay eksen parameter değerlerini vermektedir. 'QB' ve 'IK' sembolleri sırasıyla Quickbird ve IKONOS veri kümelerini gösterirken sayılar ise deney numarasını vermektedir. 1.6.2. bölümünde açıklandığı üzere daha büyük Q4 ve daha küçük SAM ve ERGAS metrikleri daha iyi pan keskinleştirme sonucunu göstermektedir. Şekil 51'den görüleceği üzere önerilen yaklaşım tüm deneyler için $\beta = 0.25$ seçildiğinde en iyi performansı üretmektedir. Bu yüzden bu çalışmada β parametresi 0.25 olarak seçilmiştir.

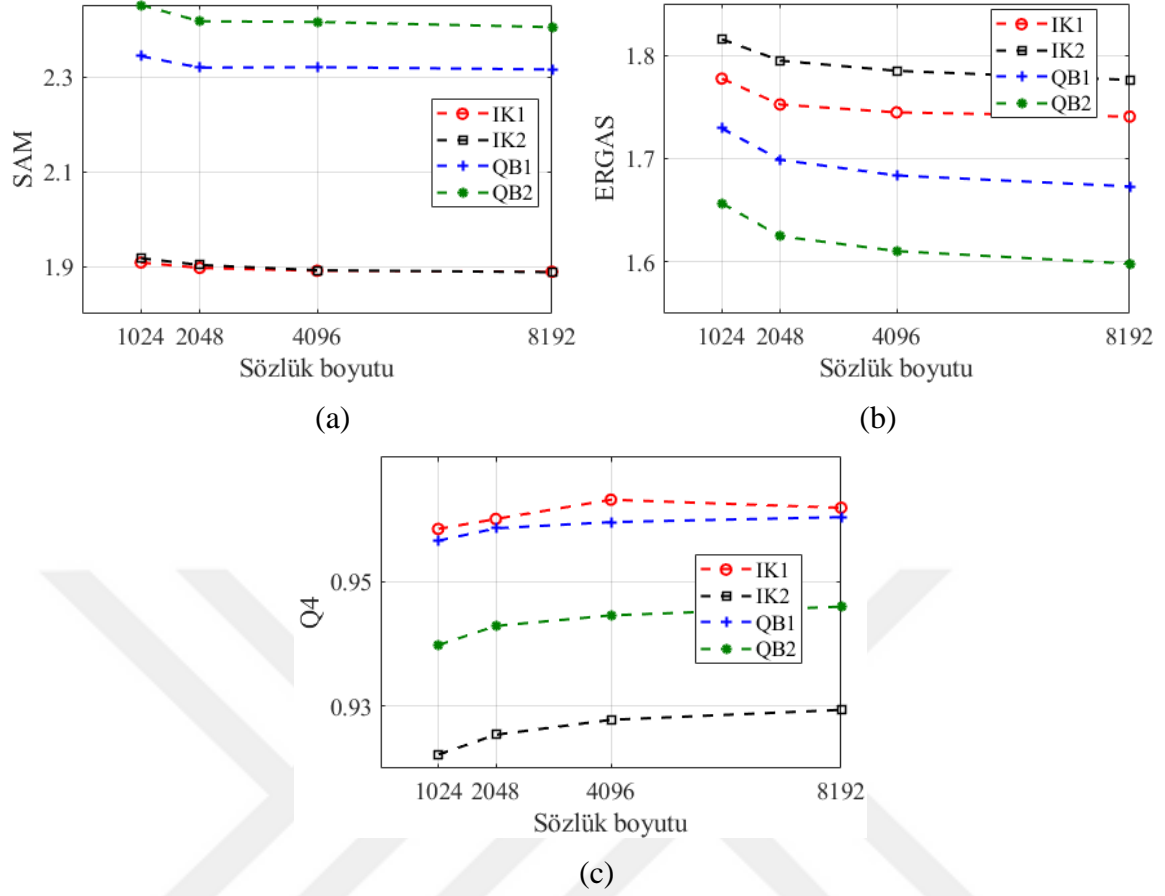


Şekil 51. Farklı β parametreleri ile önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirilmesi


Parça ve sözlük boyutu, oluşturulan YÇ görüntünün kalitesini ve hesaplama karmaşıklığını önemli biçimde etkilediğinden dolayı diğer önemli parametrelerdendir. Gerçekleştirilen deneylerde DÇ MS görüntü ve YÇ PAN görüntü orijinal MS görüntülerden oluşturulduğundan ve MS görüntünün boyutunun PAN görüntünün boyutuna oranı 1/4 olduğundan dolayı en küçük oluşturulabilecek parça MS görüntü için 2×2 ve PAN görüntü için 8×8'e karşılık gelmektedir. Yüksek parça boyutunun seçimi de sözlük öğrenmesi aşamasında kullanılacak olan özellik matrisinin boyutunu artıracığından dolayı parça boyutu doğrudan 8×8 seçilmiştir.

Farklı sözlük boyutlarına göre kalite metriklerinin hesaplanan değerleri Şekil 52'nin alt şekillerinde çizdirilmiştir. Parça boyutu sabit iken sözlük boyutu 1024 ile 8192 arasında 2'nin katı olacak biçimde çeşitlenmektedir. Büyük sözlük boyutları kullanıldığında önerilen yaklaşımın daha iyi performans gösterdiği Şekil 52'den görülmektedir. Fakat büyük sözlükler yüksek zaman karmaşıklığına sebep olmaktadır. Ayrıca gerçekleştirilen her bir deneyde 4096 değerinden sonra performans çok fazla artmadığından dolayı sözlük boyutu tüm deneyler için 4096 seçilmiştir.


Örnek azaltımı sürecinin gerçekleştirilmesi, özellik çıkarımında her bir spektral bant için parlaklık değerlerinin yerine doku bilgisinin kullanılması ve son işlem olarak iteratif geri izdüşürme algoritmasının kullanılması gibi yaklaşımların birbirinden bağımsız olarak pan keskinleştirme performansına etkisini değerlendirmek için her bir deneyde hesaplanan kalite metriklerini temsil eden çubuk grafikleri Şekil 53, 54 ve 55'in alt şekillerinde gösterilmektedir. Şekillerde yatay eksen deney türünü gösterirken dikey eksen her bir kalite metriği için hesaplanan değeri temsil etmektedir. Ayrıca her dikey mavi ve kırmızı çubuk sırasıyla ilgili adımın kullanılmamasını ve kullanılmasını temsil etmektedir. Şekil 53, 54 ve 55'ten görüldüğü üzere bu adımların kullanılması pan keskinleştirmede daha iyi performansa neden olmaktadır. Fakat diğer adımlarla karşılaştırıldığında örnek azaltımı sürecinin pan keskinleştirme performansı üzerindeki etkisi çok küçüktür.



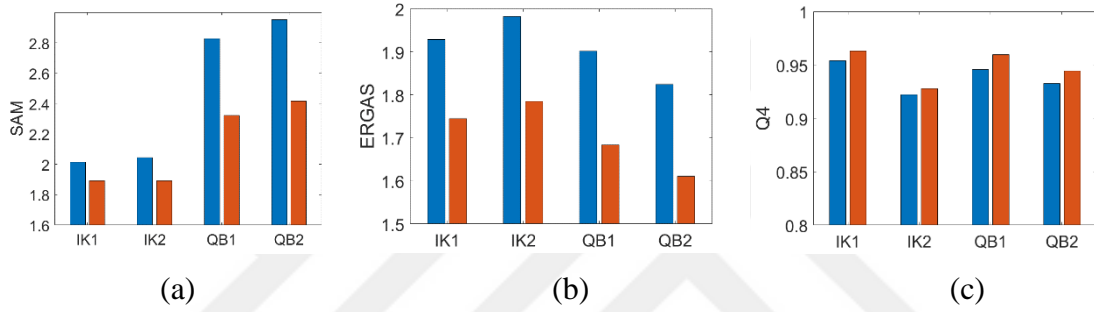
Şekil 52. Farklı sözlük boyutları ile önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi



Şekil 53. İteratif geri izdüşürme adımının kullanılmasına bağlı olarak önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi (mavi: kullanılmamış, kırmızı: kullanılmış)



Şekil 54. Doku tabanlı sözlük kullanılmasına bağlı olarak önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi (mavi: normal, kırmızı: doku tabanlı sözlük)




Şekil 55. Örnek azaltımı uygulanmasına bağlı olarak önerilen yöntemin (a) SAM, (b) ERGAS ve (c) Q4 parametrelerine göre performans değerlendirmesi (mavi: orijinal, kırmızı: örnek azaltılmış)

3.5.2. Quickbird Verisi ile Yapılan Deneyler

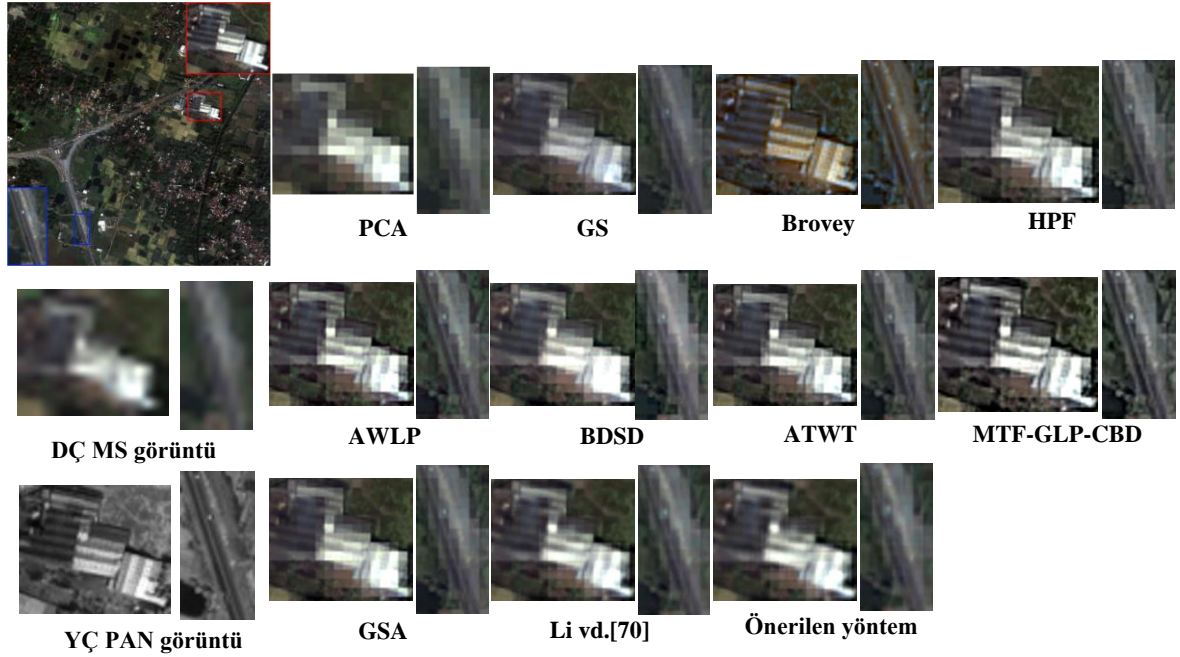
Önerilen yöntemin performansını test etmek için iki farklı temsili Quickbird görüntüsü kullanılmıştır. Şekil 56(a) ve Şekil 57(a) 11.2-m çözünürlükteki DÇ MS görüntüleri ve Şekil 56(b) ve Şekil 57(b) 2.8-m çözünürlükteki PAN görüntüleri göstermektedir. Kesin referans görüntüsü olarak kullanılan orijinal YÇ MS görüntüleri Şekil 56(c) ve Şekil 57(c)'de ve 11 farklı pan keskinleştirme yönteminin deneysel sonuçları ise Şekil 56(d)-56(n) ve Şekil 57(d)-57(n)'de gösterilmektedir. Görüntüler üzerinde bulunan kırmızı ve mavi dikdörtgen kutular, yapılan karşılaştırmalara ait sonuçlardaki farkı daha iyi görebilmek için büyütülmüş ilgi bölgelerini göstermektedir. Elde edilen pan keskinleştirme sonuçları kesin referans görüntüsüyle görsel olarak karşılaştırıldığında Şekil 56 ve Şekil 57'den şu çıkarımlar yapılabilmektedir: PCA ve GS yöntemleri spektral bilgiyi korurken kenar bilgisini bulanıklaştırarak bazı uzamsal detayları kaybetmektedir. Brovey dönüşümünün pan keskinleştirme sonuçlarında kısmen görüntü keskinleşirken bazı renk bozulmaları da

meydana gelmektedir. Çoklu çözünürlük analizi yöntemleri olan HPF, AWLP, ATWT, spektral bilgiyi korumalarına rağmen PCA ve GS yöntemleri kadar olmasa da sonuç görüntülerinde yine bulanıklığa neden olmaktadır. Ayrıca MTF-GLP-CBD yönteminin ürettiği sonuç görüntüsünün aşırı keskinleştirilmiş olduğu görülmektedir. BDS ve GSA yöntemleri önerilen yönteme göre karşılaştırılabilir performans göstermektedir. Fakat özellikle ilk deneyde uzamsal detaylar bulanıklaşmış ve spektral bilgi kaybolmuştur. Li vd. [70] önerdikleri yöntem önerilen yaklaşıma benzer sonuçlar üretse de önerilen yöntemin üstünlüğü sayısal analizlerden çıkarılmaktadır. Önerilen yaklaşım spektral bilgiyi korurken bulanıklık etkisini azaltarak yüksek kalitede uzamsal detaylı görüntü sağlamaktadır. Deneysel olarak görsel karşılaştırma yapmak için sonuç görüntülerinin sadece RGB kanalları kullanılmıştır.

Şekil 56 ve Şekil 57'nin sayısal değerlendirme sonuçları sırasıyla Tablo 14 ve 15'te verilmektedir. CC ve RMSE metriği her bir bant için ayrı ayrı hesaplandığından bu satırlardaki sonuçlar sırasıyla R, G, B ve NIR bant ile ortalama değeri vermektedir ve her bir kalite metriği için en iyi sonuçlar koyu yazılmıştır. Önerilen yaklaşım CC ve RMSE metriğinde NIR bant dışında en iyi sonuçları vermektedir. Tablo 14'de verilen SAM ve ERGAS metrikleri dikkate alındığında en iyi sonuçlar önerilen yaklaşımla elde edilmiştir. Ayrıca önerilen yaklaşım Tablo 15'teki diğer metriklere göre en iyi ikinci ve üçüncü sonucu vermektedir.



Şekil 56. Kaynak Quickbird görüntüleri (kıyı boyu) ve pan keskinleştirme sonuçları



Şekil 57. Kaynak Quickbird görüntüleri (otoyol) ve pan keskinleştirme sonuçları

Tablo 14. Quickbird_1 veri kümesi ile gerçekleştirilen temsili deneylerin sayısal değerlendirme sonuçları

	PCA	GS	Brovey	HPF	AWLP	BDSB	ATWT	MTF-GLP-CBD	GSA	Li vd. [70]	Önerilen Yöntem
CC	0.8016	0.9196	0.9247	0.8922	0.9187	0.9061	0.8884	0.8497	0.9038	0.9310	0.9400
	0.7966	0.9367	0.8621	0.9112	0.9020	0.9197	0.9093	0.8877	0.9093	0.9450	0.9512
	0.8090	0.9219	0.6013	0.8886	0.8966	0.9042	0.8853	0.8615	0.9078	0.9273	0.9461
	0.8905	0.9529	0.9425	0.9634	0.9619	0.9812	0.9650	0.9567	0.9822	0.9578	0.9649
	0.8244	0.9328	0.8327	0.9139	0.9198	0.9278	0.9120	0.8889	0.9258	0.9403	0.9506
RMSE	3.0836	2.1736	2.2050	2.4137	2.0555	2.3094	2.4951	3.2315	2.2006	1.9864	1.7569
	2.9812	1.9316	2.5960	2.1076	2.3493	2.0219	2.1730	2.6892	2.0490	1.7214	1.5188
	1.4181	0.9959	2.0034	1.1530	1.1107	1.0857	1.1905	1.4434	1.0079	0.9143	0.7784
	6.8165	4.6058	5.0267	4.1152	5.0345	3.1920	4.1790	5.6162	3.7298	4.0113	3.9449
	3.5749	2.4267	2.9578	2.4474	2.6375	2.1523	2.5094	3.2451	2.2468	2.1584	1.9998
SAM	4.6815	2.9127	3.3028	2.5546	2.4209	2.3831	2.5981	3.0382	2.4955	2.3812	2.3217
ERGAS	2.9660	2.0282	2.3282	2.0412	2.1459	1.8127	2.0946	2.7316	1.8666	1.9527	1.6837
Q4	0.8961	0.9497	0.9281	0.9513	0.9441	0.9658	0.9510	0.9261	0.9635	0.9542	0.9596

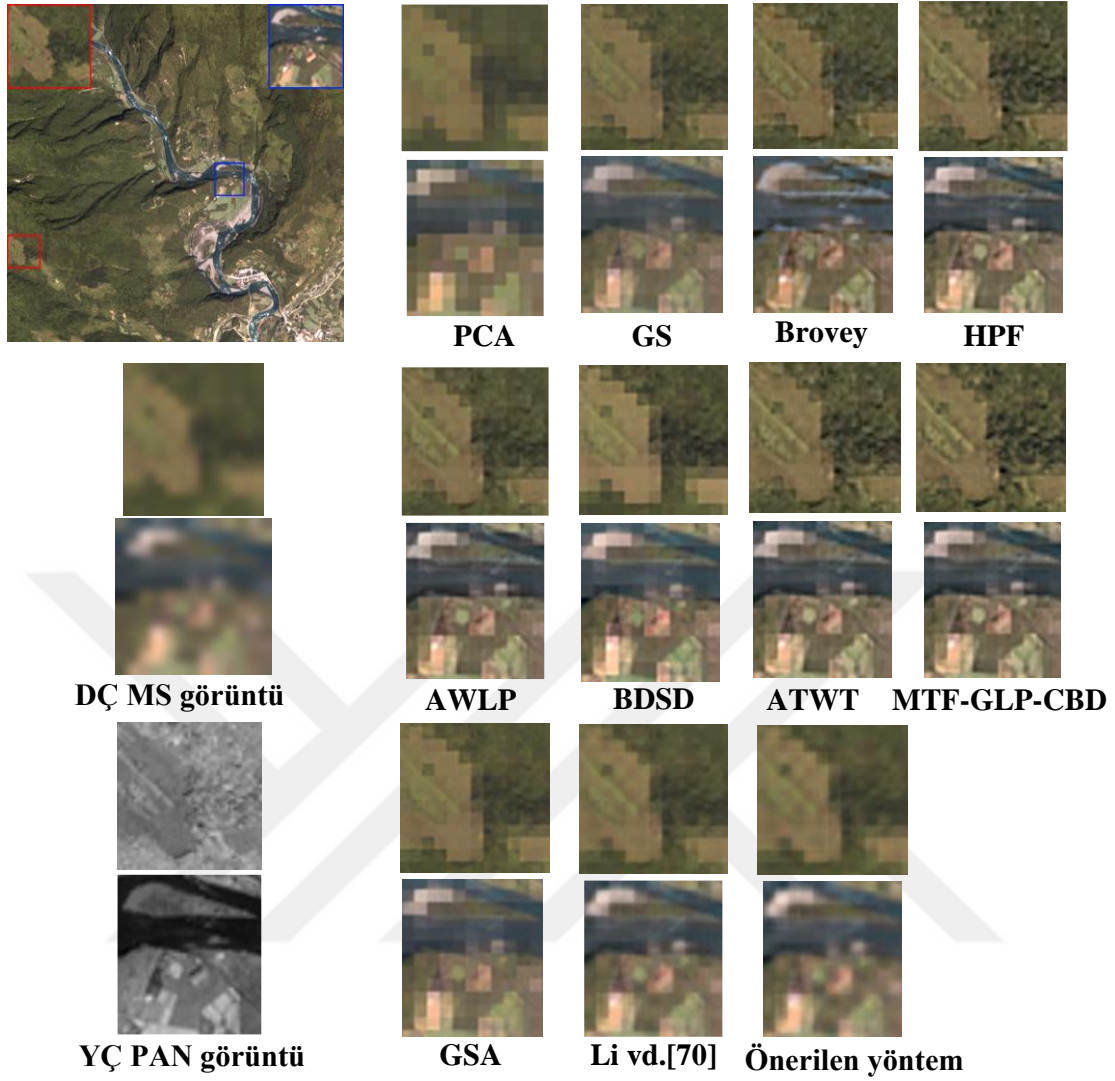
3.5.3. IKONOS Verisi ile Yapılan Deneyler

IKONOS uydusundan alınan görüntülerde önerilen yöntemin performansını test etmek için iki farklı temsili görüntü kullanılmıştır. 16-m çözünürlükteki DÇ MS görüntüler ve 4-m çözünürlükteki PAN görüntüler Şekil 58 ve Şekil 59'un ilk iki alt şeklinde gösterilmektedir. Kesin referans görüntüsü olarak kullanılan orjinal YÇ MS görüntüler Şekil 58(c) ve Şekil 59(c)'de ve 11 farklı pan keskinleştirme yönteminin deneysel sonuçları ise Şekil 58(d)- 58(n) ve Şekil 59(d)-59(n)'de verilmektedir. Pan keskinleştirilmiş görüntüler kesin referans görüntüsüyle görsel olarak karşılaştırıldığında deneysel yöntemlerin başarılı bir şekilde MS görüntüyü keskinleştirdiği gözlemlenmektedir. Quickbird deneyinde olduğu gibi Brovey dönüşümünün sonuçlarında küçük renk bozulmaları meydana gelmektedir. Renk bozulmalarının derecesinin çok güçlü olmamasının sebebi ise kaynak MS görüntüdeki karmaşık olmayan renk bilgisidir. Yani renk geçişleri diğer deneylere nazaran daha yumuşaktır. Ayrıca sonuç görüntülerinde özellikle ikinci deneyde bazı bölgelerde aşırı

Tablo 15. Quickbird_2 veri kümesi ile gerçekleştirilen temsili deneylerin sayısal değerlendirme sonuçları

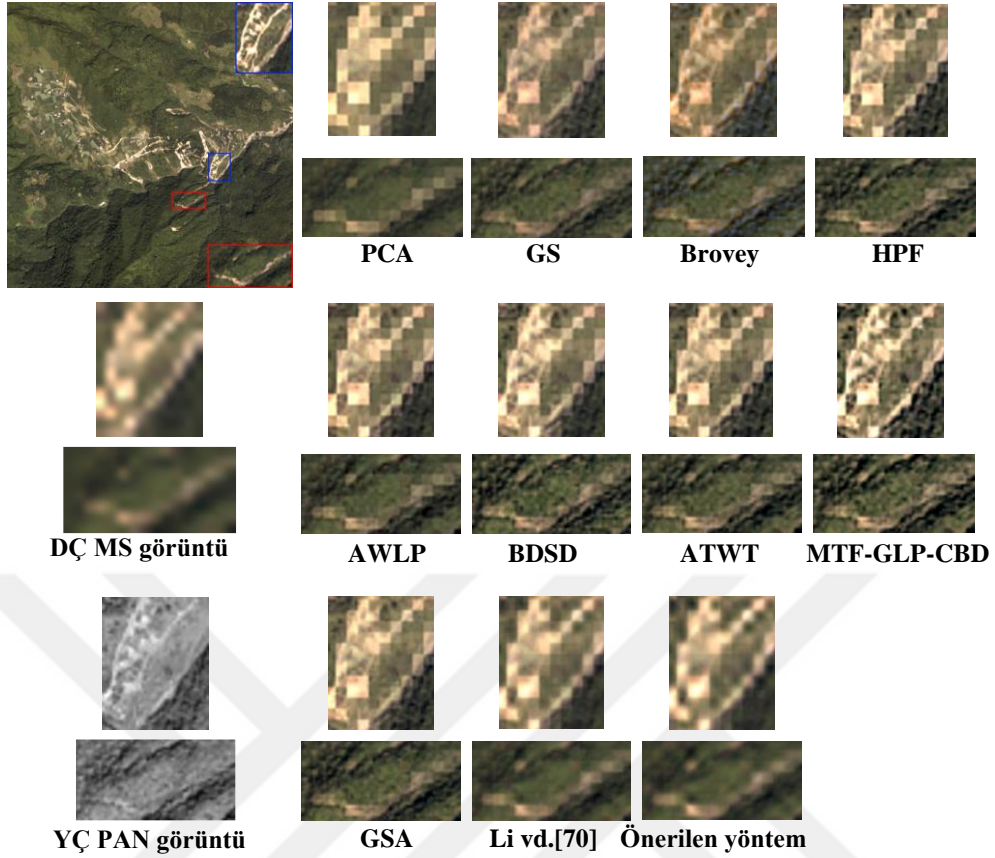
	PCA	GS	Brovey	HPF	AWLP	BDS	ATWT	MTF-GLP-CBD	GSA	Li vd. [70]	Önerilen Yöntem
CC	0.8846	0.8924	0.9028	0.8766	0.8998	0.8896	0.8719	0.8272	0.8992	0.9067	0.9206
	0.8977	0.9097	0.7985	0.8983	0.8899	0.9034	0.8960	0.8684	0.9152	0.9208	0.9311
	0.8734	0.8879	0.4650	0.8674	0.8708	0.8811	0.8623	0.8248	0.8936	0.8910	0.9140
	0.9618	0.9557	0.9245	0.9413	0.9531	0.9771	0.9459	0.9491	0.9881	0.9501	0.9519
	0.9044	0.9114	0.7727	0.8959	0.9034	0.9128	0.8940	0.8674	0.9240	0.9172	0.9294
RMSE	1.8980	1.8979	1.8509	2.0259	1.7910	2.1054	2.0999	2.7251	1.7978	1.7115	1.5944
	1.6081	1.6021	2.1994	1.6482	1.8186	1.6898	1.7014	2.1214	1.5051	1.4554	1.3334
	0.7906	0.7687	1.8501	0.8352	0.8269	0.8322	0.8648	1.0617	0.7310	0.7210	0.6608
	3.9664	3.7825	4.9162	4.2437	4.3317	2.9343	4.1826	5.5401	2.8694	3.9512	3.8423
	2.0658	2.0128	2.7042	2.1883	2.1921	1.8904	2.2122	2.8621	1.7258	1.9598	1.8577
SAM	2.5231	2.6480	3.5760	2.7194	2.4415	2.2870	2.7435	3.2256	2.1293	2.5223	2.4172
ERGAS	1.7902	1.7505	2.1782	1.9060	1.8549	1.7047	1.9313	2.5160	1.5253	1.6872	1.6105
Q4	0.9346	0.9410	0.8964	0.9329	0.9391	0.9596	0.9365	0.9114	0.9668	0.9427	0.9446

keskinlik üretmektedir. PCA ve GS yöntemleri spektral bilgiye korumasına rağmen sonuç görüntüleri bulanıklıktan kaynaklı keskin gözükmemektedir. HPF, AWLP ve ATWT yöntemleri spektral bilgiyi iyi korumaktadır; fakat kesin referans görüntüsüyle karşılaştırıldığında bazı bölgelerde bulanıklık mevcuttur. MTF-GLP-CBD yöntemi ise aşırı keskinlikten kaynaklı gürültü etkisini artırmaktadır. Şekil 58(n) ve 59(n) önerilen yaklaşımın spektral bilgiyi koruduğunu ve aşırı keskinlik probleminin üstesinden gelerek yüksek kaliteli uzamsal detay sağladığını göstermektedir. Benzer sonuçlar diğer üç deneyde de, BDS, GSA ve Li vd. [70], elde edilmiştir. Fakat önerilen yöntemin verimliliği sayısal sonuçlarla doğrulanmıştır.



Şekil 58. Kaynak IKONOS görüntüleri (nehir) ve pan keskinleştirme sonuçları

Tablo 16 ve 17, sırasıyla Şekil 58 ve 59’da verilen görsel sonuçların sayısal değerlendirmelerini göstermektedir. CC ve RMSE metrikleri önerilen yaklaşımın Tablo 16 ve 17’de NIR bant dışında en yüksek değere sahip olduğunu göstermektedir. Ayrıca, birinci deneyde de SAM ve ERGAS ölçütleri dikkate alındığında tüm deneysel yaklaşımlardan daha iyi sonuç verdiği ve Q4 metriği için üçüncü en iyi sonucu verdiği görülmektedir. İkinci IKONOS deneyinde ise önerilen yaklaşım SAM metriğine göre en iyi ikinci sonucu vermektedir. Q4 metriğinin değerleri incelendiğinde Tablo 16’da BDSD yöntemi ve Tablo 17’de GSA yöntemi en iyi sonuçları üretmektedir. Bunun sebebi ise daha çok görüntünün tamamının kalitesini kötü etkilerken aşırı keskin sonuçlara sebep olan aşırı keskinlik problemidir. Bu sonuç diğer metriklerden de görülebilir.



Şekil 59. Kaynak IKONOS görüntüleri (dağ) ve pan keskinleştirme sonuçları

Q4 metriği için tatmin edici olmayan sonuçların ikinci sebebi ise orijinal kesin referans görüntüsünün zayıf doku bilgisine sahip olmasıdır. Sonuç olarak, diğer yaklaşımlar en iyi Q4 metriği değerini üretmelerine rağmen her iki deneyde en iyi CC, RMSE, ERGAS değerleri ve bunun yanında ilk deneyde en iyi SAM değeri görsel sonuçlarla birlikte önerilen yaklaşımın üstünlüğünü ortaya koymaktadır.

3.5.4. Zaman Karmaşıklığı

Seyrek temsiliyete dayalı pan keskinleştirmede önerilen yaklaşımın zaman karmaşıklığını değerlendirmek için yaklaşımların kaynak kodları mevcut olmadığından sayısal karşılaştırma deneyleri yapılamamıştır. Fakat [68], [70] ve [99] çalışmalarından sunulan algoritma akışlarından şu çıkarımlar yapılabilir: Seyrek temsiliyet tabanlı pan keskinleştirmede başlıca üç alt adım bulunmaktadır. Bunlar görüntü bozunum modelinin kurulması, sözlük öğrenmesi ve YÇ görüntü oluşturmaktır. Görüntü bozunum modelinin

Tablo 16. IKONOS_1 veri kümesi ile gerçekleştirilen temsili deneylerin sayısal değerlendirme sonuçları

	PCA	GS	Brovey	HPF	AWLP	BDS	ATWT	MTF-GLP-CBD	GSA	Li vd. [70]	Önerilen Yöntem
CC	0.8740	0.9141	0.9195	0.8929	0.9120	0.9148	0.8928	0.8821	0.9109	0.9167	0.9198
	0.8715	0.9246	0.9075	0.9069	0.9182	0.9231	0.9072	0.8974	0.9171	0.9224	0.9247
	0.8542	0.9222	0.8137	0.8973	0.9153	0.9226	0.8950	0.8924	0.9080	0.9285	0.9321
	0.9164	0.9704	0.9677	0.9664	0.9357	0.9829	0.9670	0.9633	0.9839	0.9722	0.9685
	0.8790	0.9328	0.9021	0.9159	0.9203	0.9359	0.9155	0.9088	0.9300	0.9350	0.9363
RMSE	2.7682	2.3924	2.3834	2.6142	2.3416	2.4373	2.6439	2.8738	2.3496	2.3021	2.2347
	2.7403	2.2354	2.4507	2.3925	2.2398	2.2764	2.4158	2.6525	2.2279	2.2156	2.1271
	2.0451	1.5268	2.2773	1.7729	1.5952	1.5913	1.8108	1.8805	1.6369	1.4958	1.4161
	9.0227	5.4431	5.7708	5.8928	10.728	4.2901	5.9998	6.7519	4.5931	5.4573	5.6233
	4.1441	2.8994	3.2206	3.1681	4.2262	2.6488	3.2176	3.5397	2.7019	2.8677	2.8503
SAM	2.9276	2.0555	2.4597	2.1845	2.8992	2.0473	2.2280	2.2653	2.0313	1.9513	1.8910
ERGAS	2.3735	1.8240	2.0020	1.9973	2.2633	1.7927	2.0247	2.2076	1.7731	1.7850	1.7448
Q4	0.9177	0.9612	0.9556	0.9577	0.9125	0.9736	0.9576	0.9502	0.9730	0.9524	0.9632

oluşturulmasında DÇ MS görüntü ile PAN görüntü, YÇ MS görüntünün sırasıyla alt örneklenmesi ve spektral bantların doğrusal kombinasyonları olarak modellendiğinden bu alt adım önerilen çalışmada dahil olmak üzere tüm çalışmalarda birbirine benzerdir. Dolayısıyla, seyrek temsiliyete dayalı yaklaşımların en çok zaman alan adımı sözlük öğrenmesi ve YÇ görüntü oluşturma sürecidir.

[70] çalışmasında sunulan yaklaşım öğrenme tabanlı olmadığından sözlük öğrenmesi adımı oluşturulacak olan sözlük için çok fazla sayıda rastgele örneklenmiş parça gerekmektedir. Sözlük 10000 ham görüntü parçası kullanılarak oluşturulmuştur; bu da büyük bir sözlüğe ve yüksek hesaplama sebeptir. [68] çalışmasında DÇ ve YÇ görüntü görüntü çiftlerinin her birinin tüm ham görüntü parçaları sözlük öğrenmesi adımı kullanılmaktadır. Ayrıca, tüm eğitim görüntü çiftleri ayrı ayrı eğitilip ardından birleştirilmektedir. Çalışmada 20 eğitim görüntü çiftinin kullanıldığı ve sözlük boyutunun 1000 olarak seçildiği belirtilmektedir. Bu yüzden, sözlük öğrenmesi sürecinde boyutları

Tablo 17. IKONOS_2 veri kümesi ile gerçekleştirilen temsili deneylerin sayısal değerlendirme sonuçları

	PCA	GS	Brovey	HPF	AWLP	BDS	ATWT	MTF-GLP-CBD	GSA	Li vd. [70]	Önerilen Yöntem
CC	0.9092	0.8915	0.9178	0.8774	0.9133	0.9051	0.8778	0.8447	0.8962	0.9024	0.9256
	0.9220	0.9103	0.9091	0.9012	0.9201	0.9203	0.9022	0.8747	0.9147	0.9246	0.9346
	0.9106	0.8891	0.7210	0.8652	0.8940	0.9019	0.8651	0.8284	0.8946	0.9101	0.9287
	0.9441	0.9523	0.9531	0.9455	0.9468	0.9750	0.9466	0.9542	0.9781	0.9480	0.9345
	0.9215	0.9108	0.8753	0.8973	0.9186	0.9256	0.8979	0.8755	0.9209	0.9213	0.9309
RMSE	2.3610	2.5757	2.3370	2.8308	2.2977	2.5645	2.8564	3.4745	2.5924	2.2514	2.1298
	2.1508	2.3137	2.3426	2.4927	2.1967	2.3159	2.5123	3.0868	2.3429	2.1067	1.9537
	1.2893	1.4305	2.2480	1.6445	1.4219	1.4447	1.6615	2.0255	1.4257	1.3743	1.1516
	6.6440	5.7953	5.8608	5.7841	8.1618	4.1377	5.7334	6.0175	3.7655	6.0446	6.3784
	3.1113	3.0288	3.1971	3.1880	3.5195	2.6157	3.1909	3.6511	2.5316	2.9443	2.9034
SAM	1.8774	2.3855	2.5777	2.4422	2.2564	1.9296	2.4451	2.2538	1.9977	2.0110	1.8921
ERGAS	1.9463	2.0237	2.0718	2.1921	2.0653	1.9346	2.2061	2.6407	1.9326	1.9054	1.7850
Q4	0.9173	0.9335	0.9283	0.9352	0.9187	0.9619	0.9375	0.9320	0.9657	0.9304	0.9278

64×1000 olan 20 farklı sözlük oluşturulmaktadır. Tüm görüntü parçaları sözlük öğrenmesi sürecinde kullanıldığından ve birçok sözlük oluşturulduğundan dolayı çalışmada önerilen yaklaşım zaman karmaşıklığı bakımından dezavantaja sahiptir. [99] çalışmasında DÇ MS, PAN ve YÇ MS görüntülerden oluşan üç farklı sözlük oluşturulmaktadır. Ayrıca çalışmada 64×64 boyutlu bir MS görüntü için bileşen yerine koyma ve çoklu çözünürlük analizi yaklaşımlarının koşum zamanları yaklaşık 1 sn. iken önerilen yaklaşımla pan keskinleştirme sürecinin yaklaşık 15 dakika sürdüğü belirtilmektedir. [68], [70] ve [99] çalışmalarıyla karşılaştırıldığında bu tez çalışmasında boyutu 256×4096 olan tek bir MS sözlük oluşturularak sözlük sayısı azaltılmış ve sözlük öğrenmesi ile YÇ görüntü oluşturma süreçleri hızlandırılmıştır. Ayrıca, 128×128 boyutlu bir MS görüntü için bir parçanın YÇ parçasının oluşturulması 4 GB belleğe sahip Intel Core i7-4500 CPU olan bir bilgisayarda önerilen yöntem ile yaklaşık 0.008 sn. sürerken [70] çalışmasında yaklaşık 100 sn. sürmekte olduğu tespit edilmiştir.

3.6. Derin Konvolüsyonel Sinir Ağlarına Dayalı Mikroskobik Görüntü Süper Çözünürlüğü Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar

Deneysel ve algoritma performanslarının karşılaştırmaları *mamic_57551* ve *mamic_57552* veri kümeleri üzerinde $\times 2$ ve $\times 4$ büyütme faktörlerinde gerçekleştirilmiştir. Önerilen modelin performansını analiz etmek için sonuçlar her bir veri kümesi ve her bir büyütme faktörü için çift kübik ara değerlendirme yöntemiyle karşılaştırılmıştır. Orijinal görüntü ile süper çözünürlüklü görüntü arasındaki farkı ölçmek için kalite metriği olarak PSNR ve SSIM metrikleri kullanılmıştır. İnsan görü sistemi parlaklık kanalına daha hassas olduğundan görüntüler YCbCr renk uzayına dönüştürülüp süper çözünürlük sadece parlaklık kanalında (Y) gerçekleştirilmiştir. Bu sebeple deneysel sonuçlarda elde edilen sonuç görüntülerinde Cb ve Cr kanalları çift kübik ara değerlendirme yöntemiyle doğrudan istenen boyuta büyütülmüş ve görsel sonuçlar için YCbCr kanalından RGB kanalına dönüşüm yapılmıştır. Eğitim veri kümesi 12 piksel atlamalı 48×48 alt görüntülerin çıkarılmasıyla artırılmıştır. Böylece her bir büyütme faktörü için 16000'den fazla görüntü çifti elde edilmiştir.

Bu tez çalışmasının ana katkıları olan çoklu ölçekler için tek model kullanma özelliği ile renk değişimine karşı dayanıklı olma özelliği ve elde edilen deneysel sonuçlar alt başlıklarda detaylandırılacaktır. Bu amaçla her bir katkı için önerilen yaklaşımın sayısal ve görsel sonuçları sunulduktan sonra zaman karmaşıklığı da verilecektir.

3.6.1. Çoklu Ölçekler İçin Tek Model

Derin CNN çalışmalarının birçoğu belirli bir büyütme faktöründe YÇ görüntü oluşturmak için aynı büyütme faktöründe eğitilmiş ağ kullanmaktadır. Benzer şekilde, derin öğrenmeye dayalı mikroskobik görüntü süper çözünürlüğü için önerilen ilk ve tek çalışmada da [142], tek bir büyütme faktöründe; $\times 2.5$, eğitilmiş bir model aynı büyütme faktöründe YÇ mikroskobik görüntü oluşturmak için kullanılmıştır. Bu tez çalışmasında ise farklı ağ modelleri oluşturmak için farklı büyütme faktörleri kullanılmış ve tek modelin çoklu ölçek özelliğini göstermek için deneyler gerçekleştirilmiştir. Özetle, tek ölçekli ve çoklu ölçekli modeller şu şekilde açıklanabilir:

- Tek ölçekli model: Her bir büyütme faktörü için farklı bir ağ eğitilmektedir. Bu da ağın tanımlanması ve optimize edilmesi için daha çok parametre gereksinimiyle sonuçlanmaktadır. Bu yüzden, daha çok bellek harcamakta ve zaman almaktadır.
- Çoklu ölçekli model: Her bir büyütme faktörü için oluşturulmuş eğitim veri kümeleri birleştirilerek büyük bir veri kümesi oluşturulmakta ve ağ bu veri kümesiyle eğitilmektedir. Bu yüzden, tüm büyütme faktöründe parametreler paylaşılmaktadır. Ağın eğitimi, saklanması ve getirilmesi için ekonomik bir yoldur.

Mikroskobik görüntü süper çözünürlüğü için gerçekleştirilen deneylerde iki büyütme faktörü ($\times 2, \times 4$) incelenmiştir. Tek ölçekli model için ilk olarak ağ tek bir büyütme faktörü ile eğitilmiş ve aynı büyütme faktörü ile test edilmiştir. Ayrıca aynı eğitilmiş ağın farklı bir büyütme faktörüyle test edilmesi de gerçekleştirilmiştir. Çoklu ölçekli model için ise ağ $\times 2$ ve $\times 4$ büyütme faktöründen oluşan eğitim veri kümesi ile birlikte eğitilerek her bir büyütme faktöründe ayrı ayrı test edilmiştir.

Deneysel sonuçlar Tablo 18’de özetlenmiştir. Tablolarda verilen koyu metinler test ölçeğinin eğitim boyunca kullanıldığını göstermektedir ve her bir hücredeki üst satır PSNR sonuçlarını gösterirken alt satır SSIM sonuçlarını vermektedir.

Tablo 18. MaMic veri kümeleri için çift kübik interpolasyon ile tek ölçekli ve çoklu ölçekli modellerde derin CNN sonuçlarının ortalama PSNR (dB) ve SSIM değerleri


Veritabanı	Büyütme faktörü		Çift Kübik Ara Değerleme	Eğitim		
				Tek Ölçekli		Çoklu Ölçekli
				$\times 2$	$\times 4$	$\times 2,4$
Veri Kümesi 1 (<i>mamic_57551</i>)	$\times 2$	$\times 4$	26.2849 0.8024	27.4025 0.8376	24.9003 0.6918	27.2336 0.8294
			21.9487 0.5602	22.5964 0.5910	22.8977 0.5622	22.9829 0.5707
Veri Kümesi 2 (<i>mamic_57552</i>)	$\times 2$	$\times 4$	29.0063 0.8250	29.7153 0.8529	29.2688 0.8230	29.6277 0.8491
			25.8648 0.7024	26.5085 0.7380	27.0794 0.7496	27.1281 0.7526

Tek ölçekli modeller YÇ görüntü eğitimde kullanılan büyütme faktöründe oluşturulduğunda başarılı performans göstermektedirler. Bir başka deyişle aynı büyütme faktörüyle eğitilip aynı büyütme faktöründe test edildiğinde başarılı sonuç vermektedir.


Diğer taraftan eğitimde kullanılan büyütme faktöründen farklı bir büyütme faktöründe test yapıldığında başarı düşmektedir. Farklı büyütme faktörlerinde tek ölçekli modelin başarısının düşmesine rağmen yine de çift kübik ara değerlendirme yönteminden daha başarılı sonuçlar verdiği görülmektedir. Tablo 18 incelendiğinde Veri Kümesi 1 için $\times 2$ test büyütme faktöründe, $\times 2$ büyütme faktörü ile eğitilmiş model tarafından elde edilen PSNR değeri 27.4025 dB iken $\times 4$ büyütme faktörü ile eğitilmiş model 24.9003 dB değerini vermektedir. Benzer şekilde ağ $\times 4$ test büyütme faktöründe, $\times 4$ büyütme faktörü ile eğitilmiş ağda 22.8977 dB ve $\times 2$ büyütme faktörü ile eğitilmiş ağda 22.5964 dB PSNR değeri üretmektedir. Aynı ağ Veri Kümesi 2 içinde Veri Kümesi 1 kullanılarak elde edilen sonuçlara benzer sonuçlar vermektedir.

Diğer bir deneyde aynı ağ çoklu büyütme faktörlerinde ($\times 2, \times 4$) eğitilmiştir. Çoklu ölçekli modelde her bir büyütme faktörü için elde edilen PSNR sonuçları tek ölçekli model ile karşılaştırıldığında Veri Kümesi 1 için $\times 2$ büyütme faktöründe 27.2336 dB ye karşın 27.4025 dB değeri, $\times 4$ büyütme faktöründe 22.9829 dB ye karşın 22.8977 dB ve Veri Kümesi 2 için $\times 2$ büyütme faktöründe 29.6277 dB ye karşın 29.7153 dB değeri, $\times 4$ büyütme faktöründe 27.1281 dB ye karşın 27.0794 dB değeri elde edilmektedir. Bu sonuçlardan da anlaşıldığı üzere önerilen yaklaşım YÇ görüntü oluşturma sürecinin eğitim süresince kullanılan herhangi bir büyütme faktöründe gerçekleştirildiği çoklu ölçekli modellerde de başarılı sonuçlar üretmektedir. Bunun yanında, önerilen çoklu ölçekli modelin büyük büyütme faktörlerinde tekli ölçekli modelin performansını geçtiğide görülmektedir. Bir başka deyişle Veri Kümesi 1 ve Veri Kümesi 2 için ($\times 2, \times 4$) büyütme faktörlerinde eğitilmiş model sırasıyla 22.9829 dB ve 27.1281 dB PSNR değeri üretirken $\times 4$ büyütme faktöründe eğitilmiş ağ sırasıyla 22.8977 dB ve 27.0794 dB PSNR değeri üretmektedir. SSIM değerleri de PSNR değerleri ile ilişkili sonuçlar üretmektedir.


DÇ görüntüler ve oluşturulan YÇ görüntüler Şekil 60-63'te verilmektedir. DÇ giriş görüntüleri oldukça bozuk olmasına rağmen önerilen yaklaşım ile görüntülerdeki yapıların kenarlarının keskinleştiği görülmektedir. Sonuç görüntüleri incelendiğinde önerilen yaklaşımın kenar bölgelerine biraz bulanıklık kattığı da görülmektedir. Bunun sebebi olarak ise erişime açık olan veritabanındaki görüntülerin .jpg dosya formatında sıkıştırılmış olarak kaydedilmesi ve görüntülerin kalitesinin sınırlı olması düşünülmektedir. Ayrıca, yüksek kaliteli görüntüler kullanıldığında süper çözünürlük sonucunun daha da iyileşeceği düşünülmektedir.




Şekil 60. Tek ölçekli model kullanılarak Veri Kümesi 1 test kümesinden bir görüntünün $\times 2$ büyütme faktörü ile eğitilip $\times 2$ büyütme faktörü ile test edilmesinin süper çözünürlük sonuçları; (a) $20\times$ giriş görüntüsüne karşılık gelen derin CNN çıkış görüntüsü, (b,e) DÇ giriş görüntüsünün büyütülmüş ilgi bölgeleri ($20\times$), (c,f) çift kübik ara değerlendirme sonucunun büyütülmüş ilgi bölgeleri (PSNR: 24.9961 dB, SSIM: 0.7844), (d,g) derin CNN sonucunun büyütülmüş ilgi bölgeleri (PSNR: 26.7010 dB, SSIM: 0.8380)



Şekil 61. Tek ölçekli model kullanılarak Veri Kümesi 2 test kümesinden bir görüntünün $\times 4$ büyütme faktörü ile eğitilip $\times 4$ büyütme faktörü ile test edilmesinin süper çözünürlük sonuçları; (a) $10\times$ giriş görüntüsüne karşılık gelen derin CNN çıkış görüntüsü, (b,e) DÇ giriş görüntüsünün büyütülmüş ilgi bölgeleri ($10\times$), (c,f) çift kübik ara değerlendirme sonucunun büyütülmüş ilgi bölgeleri (PSNR: 28.4036 dB, SSIM: 0.7967), (d,g) derin CNN sonucunun büyütülmüş ilgi bölgeleri PSNR: 29.7667 dB, SSIM: 0.8406)



Şekil 62. Çoklu ölçekli model kullanılarak Veri Kümesi 1 test kümesinden bir görüntünün $\times 2,4$ büyütme faktörü ile eğitilip $\times 2$ büyütme faktörü ile test edilmesinin süper çözünürlük sonuçları; (a) $20\times$ giriş görüntüsüne karşılık gelen derin CNN çıkış görüntüsü, (b,e) DÇ giriş görüntüsünün büyütülmüş ilgi bölgeleri ($20\times$), (c,f) çift kübik ara değerlendirme sonucunun büyütülmüş ilgi bölgeleri (PSNR: 28.2829 dB, SSIM: 0.8494), (d,g) derin CNN sonucunun büyütülmüş ilgi bölgeleri (PSNR: 29.7518 dB, SSIM: 0.8856)



Şekil 63. Çoklu ölçekli model kullanılarak Veri Kümesi 2 test kümesinden bir görüntünün $\times 2,4$ büyütme faktörü ile eğitilip $\times 4$ büyütme faktörü ile test edilmesinin süper çözünürlük sonuçları; (a) $10\times$ giriş görüntüsüne karşılık gelen derin CNN çıkış görüntüsü, (b,e) DÇ giriş görüntüsünün büyütülmüş ilgi bölgeleri ($10\times$), (c,f) çift kübik ara değerlendirme sonucunun büyütülmüş ilgi bölgeleri (PSNR: 23.5932 dB, SSIM: 0.6053), (d,g) derin CNN sonucunun büyütülmüş ilgi bölgeleri (PSNR: 25.3092 dB, SSIM: 0.6846)


3.6.2. Renk Değişimine Karşı Dayanıklılık

Mikroskobik görüntülemelerde boyama prosedürü, mikroskop altında gözlemlenen yapının bazı parçalarının rengini değiştirirken ilgili yapıların daha iyi görüntülenmesini

sağlamaktadır. Birçok çeşit mikroskobik boya bulunmakta ve mikroskobik görüntüleme de kullanılmaktadır.

Çoklu ölçekler için tek model deneyinde, kendi veri kümesi içerisinde aynı boya ile boyanan örnekleri içeren iki farklı veri kümesi üzerinde deneyler gerçekleştirilmiş ve DÇ görüntülerden önerilen yaklaşım ile birlikte yüksek kalitede mikroskobik görüntüler elde edilmiştir. Bu bölümde ise [142] çalışmasında farklı boya ya da dokulardan kaynaklı meydana gelen renk değişiminin ([142] numaralı çalışmada Şekil 4) üstesinden gelmek ve önerilen yaklaşımın renk değişimine karşı dayanıklılığını göstermek için deneyler gerçekleştirilmiştir. Bunun için gerçekleştirilen deneylerde önerilen derin CNN modeli ilk olarak *mamic_57552* pembe boyalı yayma örneğinden alınan görüntülerle oluşturulan Veri Kümesi 2 ile eğitilmiş ve *mamic_57551* mavi boyalı yayma örneğinden alınan görüntülerle oluşturulan Veri Kümesi 1 ile test edilmiştir. Ardından eğitim ve test veri kümeleri tam tersi olacak biçimde değiştirilmiştir. Çoklu ölçekler için tek model deneyinde olduğu gibi farklı ağ modellerini oluşturmak için farklı büyütme faktörleri incelenmiş ve ortalama PSNR ve SSIM değerleri Tablo 19’da verilmiştir. Tablo 18 ile karşılaştırıldığında iki senaryo üzerinde gerçekleştirilen deneylerin benzer sonuçlar ürettiği görülmektedir. Ayrıca beklenilmediği üzere $\times 2$ büyütme faktöründe Veri Kümesi 2 için aynı veri kümesinin eğitim ve test için kullanıldığında elde edilen sonuçlardan daha iyi sonuçlar elde edilmiştir. Başka bir deyişle, $\times 2$ test büyütme faktöründe $\times 2$, $\times 4$ ve $\times 2,4$ büyütme faktörüyle eğitim yapılmış ağlar kullanıldığında farklı boyalı veri kümesinin kullanıldığı Tablo 19’da sırasıyla 29.7987 dB, 29.3364 dB ve 29.7259 dB PSNR değeri elde edilirken aynı boyalı veri kümesinin kullanıldığı Tablo 18’de 29.7153 dB, 29.2688 dB ve 29.6277 dB PSNR değeri elde edilmiştir. SSIM değerleri de PSNR değerleri ile ilişkili sonuçlar üretmektedir.

Şekil 64 ve Şekil 65’te renk değişimine karşı dayanıklılığın görsel sonuçları verilmiştir. Şekil 64(a) ve Şekil 65(a) aynı veri kümesi ile eğitim ve test yapılmış derin CNN ağın super çözünürlük sonucunu verirken Şekil 64(b) ve Şekil 65(b) eğitim ve test için farklı veri kümelerinin kullanıldığı derin CNN modelinin sonuçlarını göstermektedir. DÇ görüntünün, (a) alt şeklinin, (b) alt şeklinin ve original YÇ görüntünün büyütülmüş ilgi bölgeleri ise (c)-(f) alt şekillerinde verilmektedir. Görsel sonuçlara bakıldığında farklı doku ya da boya örneklerinde bile önerilen yaklaşımın daha kaliteli görüntüler elde etmek için herhangi bir renk bozulması olmadan mikroskobik görüntülere uygulanabilirliği görülmektedir.



Şekil 65. Renk değişimine karşı dayanıklılık modelinin süper çözünürlük sonuçları; (a) Veri Kümesi 2 görüntüleri ile eğitilmiş ağın $\times 2$ büyütme faktöründe Veri Kümesi 2 görüntüsüyle test edilmesinin süper çözünürlük sonucu, (b) Veri Kümesi 1 görüntüleri ile eğitilmiş ağın $\times 2$ büyütme faktöründe Veri Kümesi 2 görüntüsüyle test edilmesinin süper çözünürlük sonucu, (c) DÇ giriş görüntüsünün büyütülmüş ilgi bölgesi ($20\times$), (d) (a)'da verilen süper çözünürlük sonucunun büyütülmüş ilgi bölgesi (PSNR: 29.7103 dB, SSIM: 0.8516), (e) (b)'de verilen süper çözünürlük sonucunun büyütülmüş ilgi bölgesi (PSNR: 30.9416 dB, SSIM: 0.8795), (f) orijinal YÇ görüntünün büyütülmüş ilgi bölgesi

3.6.3. Zaman Karmaşıklığı

Gerçek zamanlı uygulamalar için düşük karmaşıklık ve yüksek doğruluk her zaman istenmektedir. Ayrıca, bu tür uygulamalar için eğitim bir kez gerçekleştirileceğinden test süresi daha önemli olmaktadır. Bu yüzden önerilen yaklaşımın zaman karmaşıklığı yönünden verimliliğini göstermek için bir deney gerçekleştirilmiştir. Önerilen yaklaşım ile karşılaştırılan yöntemin ortalama koşum zamanları Tablo 20'de verilmektedir. Algoritmalar MATLAB 2018b ortamında 8 GB RAM ile 3.6 GHz işlemciye sahip 64-bitlik Linux bilgisayarda koşturulmuştur. Tablo 20 incelendiğinde önerilen yaklaşımın makul hesaplama karmaşıklığına sahip olduğu ve gerçek zamanlı uygulamalarda kullanılabileceği görülmektedir.

Tablo 20. Farklı veri kümelerinde süper çözünürlük yöntemlerinin test edilmesi için sn cinsinden geçen süre

Veritabanı	Büyütme Faktörü	Çift Kübik Ara Değerleme	Önerilen Yöntem
Veri Kümesi 1 (<i>mamic_57551</i>)	×2	0.05	0.24
	×4	0.05	0.23
Veri Kümesi 2 (<i>mamic_57552</i>)	×2	0.04	0.24
	×4	0.05	0.25

4. SONUÇLAR

Tez çalışmaları kapsamında, öğrenme tabanlı süper çözünürlükte görüntü oluşturma amacıyla yeni yaklaşımlar geliştirilmiş, literatürdeki ortak veri kümeleri üzerinde eğitimler yapılmış ve önerilen yaklaşımların ortak test veri kümelerine uygulanması ile çeşitli sayısal ve görsel sonuçlar elde edilmiştir. Ayrıca, süper çözünürlüğün gerçek görüntüler üzerinde başarısını incelemek için uydudan alınan MS görüntüler ile mikroskobtan alınan mikroskobik görüntülerin de çözünürlüğü artırılarak sayısal ve görsel sonuçlarla performansları ölçülmüştür. Bu bölümde, çalışma kapsamında elde edilen sonuçlar özet biçimde sıralanacaktır.

- Sentetik görüntüler üzerinde süper çözünürlükte görüntü oluşturma için DÇ görüntülerden özellik çıkarımında Dalgacık dönüşümünü kullanan çalışma literatürdeki ara değerlendirme tabanlı teknikler içerisinde en çok tercih edilen çift kübik ara değerlendirme ve dalgacık ara değerlendirme yöntemine göre daha yüksek PSNR ve SSIM değeri vermektedir. Ayrıca sözlüklerin öğrenilmesinden önce boyut azaltımı gerçekleştirilmesi sonucu işlem zamanında da iyileştirmeye gidilmiştir.

- DÇ görüntülerden özellik çıkarılması amacıyla Gabor dalgacıkları yöntemi önerilmiştir. Bu yöntemin kullanılmasıyla görüntülerdeki yüksek frekans bilgisi içeren kenar, köşe ve sınır bölgeleri daha iyi korunmuştur. Ayrıca sözlüklerin öğrenilmesinden önce boyut azaltımı gerçekleştirilmesi sonucu işlem zamanında da iyileştirmeye gidilmiştir. Gabor özellik tanımlayıcısı ve seyrek temsiliyet parametrelerinin etkisi incelenerek en uygun parametreler belirlenmiştir. Önerilen seyrek gösterim tabanlı yaklaşımın ortak test veri kümelerinde literatürdeki öğrenme ve seyrek gösterim tabanlı çalışmalarla [31, 58, 59, 136] karşılaştırılması yöntemin başarısını ortaya koymuştur.

-Konvolüsyonel sinir ağlarına dayalı süper çözünürlük yaklaşımlarının detaylı bir analizi yapılarak elde edilen bilgilerden yararlanılarak yoğun atlamalı bağlantılar içeren yeni bir ağ yapısı süper çözünürlük probleminin çözümü için önerilmiştir. Önerilen ağ yapısındaki blok sayısının, her bir blok sayısı içerisindeki katman sayısının, transpoze konvolüsyon filtre sayısının, küçük grup boyutunun, başlangıç öğrenme katsayısının ve atlamalı bağlantı ile özellik birleştirmenin süper çözünürlük performansına ayrı ayrı etkileri sayısal olarak incelenmiştir. Yapılan analizlerden yararlanılarak önerilen modelin ortak test veri kümelerinde literatürdeki seyrek gösterim ve konvolüsyonel sinir ağlarına dayalı

çalışmalarla [Ayas vd. [165], 30, 55, 100, 105] karşılaştırılmasında da üstün sonuçlar elde edilmiştir.

- Süper çözünürlük uygulanacak görüntünün uzaktan algılama görüntüsü olması durumu da çalışma kapsamında değerlendirilmiştir. Literatürdeki yaklaşımlardan farklı olarak görüntü parçalarını doğrudan kullanarak sözlük oluşturmak yerine sözlüğün öğrenildiği bir yaklaşım önerilmiştir. Sözlük öğrenmesinde algoritmanın hızını geliştirmek için gerekli olan işlem zamanını azaltmak için rastgele örnekleme yapılmasının yanında görüntü parçalarından doku bilgisinin çıkarılarak kullanılmasının başarıyı arttırdığı yapılan analizler sonucunda görülmüştür. Bunun yanında varyans hesabına dayalı bir yaklaşım önerilerek sadece ayırt edici özelliklerin kullanılması ve YÇ görüntü oluşturma sürecinde karşılaşılan bulanıklığın etkisini azaltmak için iteratif geri izdüşürme algoritmasının kullanılmasının başarıyı artırdığı yapılan testlerle belirlenmiştir. Literatürdeki seyrek temsiliyete dayalı pan keskinleştirme yaklaşımlarının [68, 70, 99] algoritma akışlarından faydalanılarak önerilen yaklaşımın zaman karmaşıklığının da diğer yöntemlere kıyasla daha düşük olduğu sonucuna varılmıştır. Önerilen yaklaşım literatürde sıklıkla kullanılan birçok çoklu çözünürlük analizi ve bileşen yerine koyma yöntemleriyle kıyaslandığından literatürde en çok karşılaştırmanın yapıldığı ve başarılı performans gösteren ilk çalışma olma özelliğini taşımaktadır.

-Süper çözünürlük uygulanacak görüntünün mikroskobik görüntüler olması durumu da bir diğer uygulama alanı olarak çalışma kapsamında değerlendirilmiştir. Çalışmada artık öğrenme kavramına dayalı derin bir ağ yapısı önerilmiştir. Literatürdeki mevcut tek çalışmadan [142] farklı olarak deneysel sonuçlar birden fazla büyütme faktöründe alınarak başarılı sonuçlar elde edilmiştir. Önerilen ağ yapısının çoklu ölçekler için tek model oluşturma özelliği ile parametre sayısının artmasıyla birlikte ağın saklanması ve getirilmesi maliyeti düşürülmüştür. Bunun yanında her bir büyütme faktörü için ağın yeniden eğitilmesi gereksinimi de ortadan kaldırılmıştır. Deneysel sonuçlardan çoklu ölçekli modelin tek ölçekli modele yakın sonuçlar ürettiği görülmüştür. Farklı doku ve boya türlerinde tek bir ağ modelinin kullanılmasıyla süper çözünürlükte oluşturulan görüntüde renk bozulmasının meydana gelmediği görülmüştür.

5. ÖNERİLER VE TARTIŞMA

Süper çözünürlükte görüntü oluşturma üzerine yapılan çalışmalarda sentetik görüntüler üzerinde yüksek başarı oranları elde edildiğinden dolayı literatürde son yıllarda öğrenme tabanlı süper çözünürlük üzerine yapılan çalışmalar artmıştır. Öğrenme tabanlı tek görüntü süper çözünürlüğü alanında seyrek temsiliyet ve konvolüsyonel sinir ağları tabanlı yaklaşımlar üzerinde ise özellikle sırasıyla 2010 ve 2015 yıllarından itibaren birçok araştırma yapılmıştır. Konvolüsyonel sinir ağlarının süper çözünürlük probleminin çözümü için önerilmesi başarı oranını artırdığından dolayı süper çözünürlük üzerine çalışacak araştırmacıların bu alana yönelmesi çalışmaların niteliğini artıracaktır.

Seyrek temsiliyet tabanlı süper çözünürlük yaklaşımlarının performansı konvolüsyonel sinir ağları tabanlı yaklaşımların performansından oldukça geri kaldığından dolayı son yıllarda seyrek temsiliyet tabanlı çalışmalara çok fazla ilgi duyulmamaktadır. Seyrek temsiliyet tabanlı çalışmaların performansının artırılması için farklı özellik çıkarma algoritmaları kullanılabilir. Bunun yanı sıra eğitim veri kümesindeki tüm görüntülerden ortak bir sözlük oluşturmak yerine farklı doku türlerine göre birden fazla sözlük oluşturup ya da eğitim görüntü parçalarını kümeleme algoritmalarıyla birden fazla kümeye ayırıp yine birden fazla sözlük oluşturularak başarının artırılabilceği düşünülmektedir.

Konvolüsyonel sinir ağları tabanlı yaklaşımlar baştan uca öğrenme gerçekleştirdiğinden dolayı süper çözünürlükte görüntü oluşturmada herhangi bir özellik çıkarma aşamasına ihtiyaç duyulmamaktadır. Bu nedenle süper çözünürlükte oluşturulan görüntünün kalitesi tamamen oluşturulan ağ mimarisine bağlı olarak değişmektedir. Bunun için farklı ağ mimarileri oluşturularak süper çözünürlük kalitesinin iyileştirilebileceğini düşünmekteyiz. Bunun yanı sıra, oluşturulan ağ modelinin performansı çoğunlukla seçilecek olan parametrelere bağlı olduğundan ve konvolüsyonel sinir ağlarında hiperparametre sayısı oldukça fazla olduğundan konvolüsyonel sinir ağlarının süper çözünürlük problemlerine uygulanmasında detaylı bir parametre analizi yapılabilir.

Literatürdeki mevcut çalışmalarda genellikle DC görüntü $\times 2$, $\times 3$ ve $\times 4$ ölçek faktörlerinde büyütülmektedir ve büyük ölçek faktörlerinde süper çözünürlük kalitesi düşmektedir. Gerçek dünyada her zaman daha yüksek çözünürlüğe sahip görüntü istendiğinden dolayı araştırmacıların yüksek ölçek faktörlerinde performans düşüşüne sebep olmayan çalışmalara yönelmesi yapılacak çalışmaların yararlılığını artıracaktır.

Konvolüsyonel sinir ağlarının eğitilmesi için büyük veri kümelerine ihtiyaç duyulmakta ve büyük veri kümelerinin kullanılması da ağı eğitimi için geçen süreyi artırmaktadır. Mevcut çalışmalarda belirli bir ölçek faktörüyle süper çözünürlükte görüntü oluşturulurken ilgili ölçek faktöründe eğitilmiş ağ parametreleri kullanılmaktadır ve ağı eğitimi için kullanılan ölçek faktöründen farklı bir ölçek faktörü kullanıldığında süper çözünürlük performansı düşmektedir. Araştırmacıların farklı ölçek faktörlerinde eğitim ve test yapıldığında performansta çok fazla düşüşe sebep olmayan ağ mimarileri oluşturmaya yönelmesi çalışmaların niteliğini artıracaktır.

Mikroskobik görüntü süper çözünürlüğü süper çözünürlük uygulamaları içerisinde oldukça yeni bir alandır. Bunun yanı sıra DÇ görüntülerin YÇ görüntülerden bozunma modellerine bağlı kalınıp üretilmemesi bir diğer deyişle görüntülerin doğrudan mikroskobun farklı objektifleri altında alınması bu alanın önemini ve gerçek dünyaya uygulanabilirliğini ortaya koymaktadır. Bu alanın literatürde çok yeni olmasından dolayı yeni oluşturulacak ağ mimarileri ile süper çözünürlükte görüntü kalitesi artırılabilir.

Pan keskinleştirme alanında konvolüsyonel sinir ağları tabanlı yaklaşımların uygulanması literatürde oldukça yeni olduğundan dolayı yeni ağ mimarileri ile pan keskinleştirilmiş görüntü kalitesi artırılabilir.

6. KAYNAKLAR

1. Hayat, K., Multimedia Super-Resolution via Deep Learning: A Survey, Digital Signal Processing, 81 (2018) 198-217.
2. Park, S. C., Park, M. K. ve Kang, M. G., Super-Resolution Image Reconstruction: A Technical Overview, IEEE Signal Processing Magazine, 20, 3 (2003) 21-36.
3. Nasrollahi, K. ve Moeslund, T. B., Super-Resolution: A Comprehensive Survey, Machine Vision and Applications, 25, 6 (2014) 1423-1468.
4. Huang, T. ve Yang, J., Image Super-Resolution: Historical Overview and Future Challenges, Super Resolution Imaging, 19-52, CRC Press, 2010.
5. Özdemir, H. ve Sankur, B., Subjective Evaluation of Single-Frame Superresolution Algorithms, 17th European Signal Processing Conference, Ağustos 2009, Glasgow, UK.
6. Amanatiadis, A. ve Andreadis, A., A Survey on Evaluation Methods for Image Interpolation, Measurement Science and Technology, 20, 10 (2009) 104015.
7. Tsai, R. Y. ve Huang, T. S., Multipleframe Image Restoration and Registration, Advances in Computer Vision and Image Processing, 317-339, CT: JAI Press Inc., Greenwich, 1984.
8. Rhee, S. ve Kang, M. G., DCT-based Regularized Algorithm for High-Resolution Image Reconstruction, IEEE International Conference on Image Processing, Ekim 1999, Los Alamitos, 184-187.
9. Chappali, M. B. ve Bose, N. K., Simultaneous Noise Filtering and Super-Resolution with Second-Generation Wavelets, IEEE Signal Processing Letters, 12, 11 (2005) 772-775.
10. Fermüller, H. J. C., Robust Wavelet-based Super-Resolution Reconstruction: Theory and Algorithm, IEEE Transactions on Pattern Analysis and Machine Intelligence, 31, 4 (2009), 649-660.
11. Pandey, G. ve Ghanekar, U., A Compendious Study of Super-Resolution Techniques by Single Image, Optik, 166 (2018), 147-160.
12. Yang, W., Yuan, T., Wang, W., Zhou, F. ve Liao, Q., Single-image Super Resolution by Subdictionary Coding and Kernel Regression, IEEE Transactions on Systems, Man, and Cybernetics: Systems, 47, 9 (2017) 2478-2488.

13. Cheon, J. Y. ve Park, I. K., Deep CNN-Based Super-Resolution Using External and Internal Examples, IEEE Signal Processing Letters, 24, 8 (2017) 1252-1256.
14. Wang, Z., Yang, Y., Wang, Z., Chang, S., Yang, J. ve Huang, T. S., Learning Super-Resolution Jointly From External and Internal Examples, IEEE Transactions on Image Processing, 24, 11 (2015) 4359-4371.
15. Baker, S. ve Kanade, T., Hallucinating Faces, IEEE International Conference on Automatic Face and Gesture Recognition, Mart 2000, Fransa, 83-88.
16. Su, C., Zhuang, Y., Huang, L. ve Wu, F., Steerable Pyramid Based Face Hallucination, Pattern Recognition, 38, 6 (2005) 813-824.
17. Lai, W. S., Huang, J. B., Ahuja, N. ve Yang, M. H., Deep Laplacian Pyramid Networks for Fast and Accurate Super Resolution, IEEE Conference on Computer Vision and Pattern Recognition, Temmuz 2017, Hawaii, 624-632.
18. Elad, M. ve Datsenko, D., Example-Based Regularization Deployed to Super-Resolution Reconstruction of a Single Image, The Computer Journal, 52, 1 (2009) 15-30.
19. Stephenson, T. A. ve Chen, T., Adaptive Markov Random Fields for Example-Based Super-Resolution of Faces, Eurasip Journal on Advances in Signal Processing, (2006) 1-11.
20. Ma, Y. J., Zhang, H. ve Xue, Y., Super-Resolution Image Reconstruction Based on K-Means-Markov Network, IEEE International Conference on Natural Computation, Ağustos 2009, Çin, 316-318.
21. Sumali, B., Sarkan, H. ve Hamada, N., Single Image Super-Resolution by No-Reference Image Quality Index Optimization in PCA Subspace, IEEE International Colloquium on Signal Processing and Its Applications, Mart 2016, Malezya, 183-187.
22. Zhu, Z., Guo, F., Yu, H. ve Chen, C., Fast Single Image Super Resolution via Self-Example Learning and Sparse Representation, IEEE Transactions on Multimedia, 16, 8 (2014) 2178-2190.
23. Huang, H. ve Wu, N., Fast Facial Image Super Resolution via Local Linear Transformations for Resource-Limited Applications, IEEE Transactions on Circuits and Systems for Video Technology, 21, 10 (2011) 1363-1377.
24. Liang, Y., Lai, J. H., Xie, X. ve Liu, W., Face Hallucination Under an Image Decomposition Perspective, International Conference on Pattern Recognition, Ağustos 2010, İstanbul, 2158-2161.

25. Chakrabarti, A., Rajagopalan, A. ve Chellappa, R., Super Resolution of Face Images using Kernel-Based Prior, IEEE Transactions on Multimedia, 9, 4 (2007) 888-892.
26. Liang, Y., Lai, J. H. Zou, Y. X., Zheng, W. S. ve Yuen, P. C., Face Hallucination through KPCA, IEEE International Congress on Image and Signal Processing, Ekim 2009, Çin, 316-318.
27. Nguyen, K., Srdiharan, S., Denman, S. ve Fookes, C., Feature Domain Super Resolution Framework for Gabor-Based Face and Iris Recognition, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2012, Providence, 2642-2649.
28. Huang, J. J. ve Siu, W. C., Learning Hierarchical Decision Trees for Single-Image Super Resolution, IEEE Transactions on Circuits and Systems for Video Technology, 27, 5 (2017) 937-950.
29. Liu, Z. S., Siu, W. C. ve Huang, J. J., Image Super-Resolution via Weighted Random Forest, IEEE International Conference on Industrial Technology, Mart 2017, Kanada, 1019-1023.
30. Dong, C, Loy, C. C., He, K. ve Tang, X., Image Super-Resolution using Deep Convolutional Networks, IEEE Transactions on Pattern Analysis and Machine Intelligence, 38, 2 (2016) 295-307.
31. Chang, H., Yeung, D. Y. ve Xiong, Y., Super-Resolution Through Neighbor Embedding, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2004, Washington, 275-282.
32. Li, B. ve Chang, H., Aligning Coupled Manifolds for Face Hallucination, IEEE Signal Processing Letters, 16, 11 (2009) 957-960.
33. Li, B., Chang, H. ve Shan, S., Low Resolution Face Recognition via Coupled Locality Preserving Mappings, IEEE Signal Processing Letters, 17, 1 (2010) 20-23.
34. Wang, J. ve Zhu, S., Resolution-Invariant Coding for Continuous Image Super-Resolution, Neurocomputing, 82 (2012) 21-28.
35. Kumar, B. G. V. ve Aravid, R., Face Hallucination using OLPP and Kernel Ridge Regression, IEEE International Conference on Image Processing, Ekim 2008, San Diego, 353-356.
36. Kang, Q., Patch-Based Face Hallucination with Locality Preserving Projection, International Conference on Genetic and Evolutionary Computing, Aralık 2010, Çin, 394-397.
37. Jia, K. ve Gong, S., Generalized Face Super-Resolution, IEEE Transactions on Image Processing, 17, 6 (2008) 873-886.

38. Liu, W., Lin, D. ve Tang, X., Hallucinating Faces: TensorPatch Super-Resolution and Coupled Residue Compensation, *IEEE Conference on Computer Vision and Pattern Recognition*, Haziran 2005, San Diego, 478-484.
39. Ferreira, J. C., Le Meur, O., Guillemot, C., da Silva, E. A. B. ve Carrijo, G. A., Single Image Super-Resolution using Sparse Representations with Structure Constraints, *IEEE International Conference on Image Processing*, Ekim 2014, Paris, 3862-3866.
40. Wright, J., Ma, Y., Mairal, J., Sapiro, G., Huang, T. S. ve Yan, S., Sparse Representation for Computer Vision and Pattern Recognition, *Proceedings of the IEEE*, 98, 6 (2010) 1031-1044.
41. Zhang, Z., Xu, Y., Yang, J., Li, X. ve Zhang, D., A Survey of Sparse Representation: Algorithms and Applications, *IEEE Access*, 3 (2015) 490-530.
42. Amaldi, E. ve Kann, V., On The Approximability of Minimizing Nonzero Variables or Unsatisfied Relations in Linear Systems, *Theoretical Computer Science*, 209, 1 (1998) 237-260.
43. Chen, S. ve Donoho, D. L., Basis Pursuit, *Asilomar Conference on Signals, Systems and Computers*, Ekim 1994, USA, 41-44.
44. Chen, S., Donoho, D. L. ve Saunders, M. A., Atomic Decomposition by Basis Pursuit, *SIAM Review*, 43, 1 (2001) 129-159.
45. Tibshirani, R., Regression Shrinkage and Selection via The Lasso, *Journal of the Royal Statistical Society Series B*, 58, 1 (1996) 267-288.
46. Efron, B., Hastie, T., Johnstone, I. ve Tibshirani, R., Least Angle Regression, *The Annals of Statistics*, 32, 2 (2004) 407-499.
47. Mallat, S. ve Zhang, Z., Matching Pursuits with Time-Frequency Dictionaries, *IEEE Transactions on Signal Processing*, 41, 12 (1993) 3397-3415.
48. Rath, G. ve Guillemot, C., A Complementary Matching Pursuit Algorithm for Sparse Approximation, *European Signal Processing Conference*, Ağustos 2008, İsviçre, 1-5.
49. Pati, Y. C., Rezaifar, R. ve Krishnaprasad, P. S., Orthogonal Matching Pursuit: Recursive Function Approximation with Applications to Wavelet Decomposition, *Asilomar Conference on Signals, Systems and Computers*, Kasım 1993, USA, 40-44.
50. Aharon, M., Elad, M. ve Bruckstein, A., K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation, *IEEE Transactions on Signal Processing*, 54, 11 (2006) 4311-4322.

51. Rubinstein, R., Bruckstein, A. ve Elad, M., Dictionaries for Sparse Representation Modeling, Proceedings of The IEEE, 98, 6 (2010) 1045-1057.
52. Zontak, M. ve Irani, M., Internal Statistics of a Single Natural Image, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2011, Colorado, 977-984.
53. Weiss, Y. ve Freeman, W. T., What Makes A Good Model of Natural Images?, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2007, USA, 1-8.
54. Mousavi, H. S., Guo, T. ve Monga, V., Deep Image Super Resolution via Natural Image Priors, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2018, Salt Lake City.
55. Timofte, R., De Smet, V. ve Van Gool, L., A+: Adjusted Anchored Neighborhood Regression for Fast Super-Resolution, Asian Conference on Computer Vision, Kasım 2014, Singapore.
56. Yang, J., Wright, J., Huang, T. ve Ma, Y., Image Super Resolution via Sparse Representation, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2008, Alaska, 1-8.
57. Bevilacqua, M., Roumy, A., Guillemot, C. ve Alberi Morel, M. -L., Low-Complexity Single Image Super Resolution Based on Nonnegative Neighbor Embedding, British Machine Vision Conference, Eylül 2012, Surrey, 1-10.
58. Zeyde, R., Elad, M. ve Protter, M., On Single Image Scale-Up Using Sparse Representations, Curves and Surfaces, (2010) 711-730.
59. Yang, J., Wright, J., Ma, Y. ve Huang, T., Image Super Resolution as Sparse Representation of Raw Image Patches, IEEE Transactions on Image Processing, 19, 11 (2010) 2861-2873.
60. Freeman, W. T., Pasztor, E. C. ve Carmichael, O. T., Learning Low-Level Vision, International Journal of Computer Vision, 40, 1 (2000) 25-47.
61. Sun, J., Zheng, N. N., Tao, H. ve Shum, H., Image Hallucination with Primal Sketch Priors, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2003, Wisconsin, 729-736.
62. Lee, H., Battle, A., Raina, R. ve Ng, A. Y., Efficient Sparse Coding Algorithms, International Conference on Neural Information Processing Systems, Aralık 2006, Kanada, 801-808.
63. Wang, S., Zhang, L., Liang, Y. ve Pan, Q., Semi-Coupled Dictionary Learning with Applications to Image Super-Resolution and Photo-Sketch Synthesis, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2012, Rhode Island, 2216-2223.

64. Yang, M., Zhang, L., Yang, J. ve Zhang, D., Metaface Learning for Sparse Representation based Face Recognition, *IEEE International Conference on Image Processing*, Eylül 2010, Hong Kong, 1601-1604.
65. He, L., Qi, H. ve Zaretzki, R., Beta Process Joint Dictionary Learning for Coupled Feature Spaces with Application to Single Image Super Resolution, *IEEE Conference on Computer Vision and Pattern Recognition*, Haziran 2013, Portland, 345-352.
66. Yang, J., Wang, Z., Lin, Z., Shu, X. ve Huang, T., Bilevel Sparse Coding for Coupled Feature Spaces, *IEEE Conference on Computer Vision and Pattern Recognition*, Haziran 2012, Rhode Island, 2360-2367.
67. Dong, W., Zhang, L., Shi, G. ve Wu, X., Image Deblurring and Super-Resolution by Adaptive Sparse Domain Selection and Adaptive Regularization, *IEEE Transactions on Image Processing*, 20, 7 (2011) 1838-1857.
68. Jiang, C., Zhang, H., Shen, H. ve Zhang, L., A Practical Compressed Sensing-Based Pan Sharpening Method, *IEEE Geoscience and Remote Sensing Letters*, 9, 4 (2012) 629-633.
69. Garzelli, A., A Review of Image Fusion Algorithms Based on The Super Resolution Paradigm, *Remote Sensing*, 8, 10 (2016) 797.
70. Li, S. ve Yang, B., A New Pansharpening Method Using A Compressed Sensing Technique, *IEEE Transactions on Geoscience and Remote Sensing*, 49, 2 (2011) 738-746.
71. Zhong, S., Zhang, Y., Chen, Y. ve Wu, D., Combining Component Substitution and Multiresolution Analysis: A Novel Generalized BDSD Pansharpening Algorithm, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10, 6 (2017) 2867-2875.
72. Vivone, G., Alparone, L., Chanussot, J., Mura, M. D., Garzelli, A., Licciardi, G. A., Restaino, R. ve Wald, L., A Critical Comparison Among Pansharpening Algorithms, *IEEE Transactions on Geoscience and Remote Sensing*, 53, 5 (2015) 2565-2586.
73. Loncan, L., Almeida, L. B., Bioucas-Dias, J. M., Briottet, X., Chanussot, J., Dobigeon, N., Fabre, S., Liao, W., Licciardi, G. A., Simoes, M., Tournet, J. Y., Veganzones, M. A., Vivone, G., Wei, Q. ve Yokoya, N., Hyperspectral Pansharpening: A Review, *IEEE Geoscience and Remote Sensing Magazine*, 3, 3 (2015) 27-46.
74. Thomas, C., Ranchin, T., Wald, L. ve Chanussot, J., Synthesis of Multispectral Images to High Spatial Resolution, *IEEE Transactions on Geoscience and Remote Sensing*, 46, 5 (2008) 1301-1312.

75. Tu, T. M., Huang, P. S., Hung, C. L. ve Chang, C. P., A Fast Intensity-Hue-Saturation Fusion Technique with Spectral Adjustment for IKONOS Imagery, IEEE Geoscience and Remote Sensing Letters, 1, 4 (2004) 309-312.
76. Chavez Jr, P. S. ve Kwarteng, A. Y., Extracting Spectral Contrast in Landsat Thematic Mapper Image Data Using Selective Principal Component Analysis, Photogrammetric Engineering and Remote Sensing, 55, 3 (1989) 339-348.
77. Laben, C. A. ve Brower, B. V., Process for Enhancing The Spatial Resolution of Multispectral Imagery Using Pansharpening, US Patent 6 011 875, 2000.
78. Carper, W., Lillesand, T. ve Kiefer, R., The Use of Intensity-Hue-Saturation Transformations for Merging SPOT Panchromatic and Multispectral Image Data, Photogrammetric Engineering and Remote Sensing, 56, 4 (1990) 459-467.
79. Gillespie, A. R., Kahle, A. B. ve Walker, R. E., Color Enhancement of Highly Correlated Images. II. Channel Ratio and "Chromaticity" Transformation Techniques, Remote Sensing of Environment, 22, 3 (1987) 343-365.
80. Aiazzi, B., Baronti, S. ve Selva, M., Improving Component Substitution Pansharpening Through Multivariate Regression of MS+Pan Data, IEEE Transactions on Geoscience and Remote Sensing, 45, 10 (2007) 3230-3239.
81. Garzelli, A., Nencini, F. ve Capobianco, L., Optimal MMSE Pan Sharpening of Very High Resolution Multispectral Images, IEEE Transactions on Geoscience and Remote Sensing, 46, 1 (2008) 228-236.
82. Chavez Jr., P. S., Sides, S. C. ve Anderson, J. A., Comparison of Three Different Methods to Merge Multiresolution and Multispectral Data: Landsat TM and SPOT Panchromatic, Photogrammetric Engineering and Remote Sensing, 57, 3 (1991) 295-303.
83. Otazu, X., Gonzales-Audicana, M., Fors, O. ve Nunez, J., Introduction of Sensor Spectral Response into Image Fusion Methods. Application to Wavelet-Based Methods, IEEE Transactions on Geoscience and Remote Sensing, 43, 10 (2005) 2376-2385.
84. Shensa, M. J., The Discrete Wavelet Transform: Wedding The A Trous and Mallat Algorithms, IEEE Transactions on Signal Processing, 40, 10 (1992) 2464-2482.
85. Aiazzi, B., Alparone, L., Baronti, S., Garzelli, A. ve Selva, M., MTF-Tailored Multiscale Fusion of High Resolution MS and Pan Imagery, Photogrammetric Engineering and Remote Sensing, 72, 5 (2006) 591-596.
86. Donoho, D. L., Compressed Sensing, IEEE Transactions on Information Theory, 52, 4 (2006) 1289-1306.

87. Candes, E., Romberg, J. ve Tao, T., Stable Signal Recovery From Incomplete and Inaccurate Information, Communications on Pure and Applied Mathematics, 59, 8 (2005) 1207-1233.
88. Candes, E. J. ve Wakin, M. B., An Introduction to Compressive Sampling, IEEE Signal Processing Magazine, 25, 2 (2008) 21-30.
89. Elad, B., Figueiredo, M. A. T. ve Ma, Y., On The Role of Sparse and Redundant Representations in Image Processing, Proceedings of the IEEE, 98, 6 (2010) 972-982.
90. Mairal, J., Elad, M. ve Sapiro, G., Sparse Representation for Color Image Restoration, IEEE Transactions on Image Processing, 17, 1 (2008) 53-69.
91. Elad, M. ve Aharon, M., Image Denoising via Sparse and Redundant Representations over Learned Dictionaries, IEEE Transactions on Image Processing, 15, 12 (2006) 3736-3745.
92. Wright, Y., Yang, A. Y., Ganesh, A., Sastry, S. S. ve Ma, Y., Robust Face Recognition via Sparse Representation, IEEE Transactions on Pattern Analysis and Machine Intelligence, 31, 2 (2009) 210-227.
93. Zheng, S., Shi, W. Z., Liu, J. ve Tian, J. W., Remote Sensing Image Fusion Using Multiscale Mapped LS-SVM, IEEE Transactions on Geoscience and Remote Sensing, 46, 5 (2008) 1313-1322.
94. Garzelli, A. ve Nencini, F., Interband Structure Modeling for Pansharpening of Very High Resolution Multispectral Images, Information Fusion, 6, 3 (2005) 213-224.
95. Garzelli, A. ve Nencini, F., PAN-Sharpener of Very High Resolution Multispectral Images Using Genetic Algorithms, International Journal of Remote Sensing, 27, 15 (2006) 3273-3292.
96. Zhu, X. X. ve Bamler, R., A Sparse Image Fusion Algorithm with Application to Pan Sharpening, IEEE Transactions on Geoscience and Remote Sensing, 51, 5 (2013) 2827-2836.
97. Zhu, X. X. ve Bamler, R., Tomographic Sar Inversion by L_1 Norm Regularization The Compressive Sensing Approach, IEEE Transactions on Geoscience and Remote Sensing, 48, 10 (2010) 3839-3846.
98. Zhu, X. X. ve Bamler, R., Super Resolution Power and Robustness of Compressive Sensing for Spectral Estimation with Application to Spaceborne Tomographic SAR, IEEE Transactions on Geoscience and Remote Sensing, 50, 1 (2012) 247-258.

99. Li, S., Yin, H. ve Fang, L., Remote Sensing Image Fusion via Sparse Representations over Learned Dictionaries, IEEE Transactions on Geoscience and Remote Sensing, 51, 9 (2013) 4779-4789.
100. Kim, J., Lee, J. K. ve Lee, K. M., Deeply-Recursive Convolutional Network for Image Super Resolution, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2016, Las Vegas, 1637-1645.
101. Dong, C., Loy, C. C. ve Tang, X., Accelerating The Super-Resolution Convolutional Neural Network, European Conference on Computer Vision, Ekim 2016, Amsterdam, 391-407.
102. Dong, C., Loy, C. C., He, K. ve Tang, X., Learning a Deep Convolutional Network for Image Super Resolution, European Conference on Computer Vision, Eylül 2014, Zürich, 184-199.
103. Wang, Z., Yang, Y., Wang, Z., Chang, S., Han, W., Yang, J. ve Huang, T., Self-Tuned Deep Super Resolution, IEEE Conference on Computer Vision and Pattern Recognition Workshops, Haziran 2015, Boston, 1-8.
104. Masci, J., Meier, U., Ciresan, D. Ve Schmidhuber, J., Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction, International Conference on Artificial Neural Networks, Haziran 2011, Finlandiya, 52-59.
105. Kim, J., Lee, J. K. ve Lee, K. M., Accurate Image Super Resolution Using Very Deep Convolutional Networks, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2016, Las Vegas, 1646-1654.
106. Wang, Z., Liu, D., Yang, J., Han, W. ve Huang, T., Deep Networks for Image Super Resolution with Sparse Prior, IEEE International Conference on Computer Vision, Aralık 2015, Chile, 370-378.
107. Ledig, C., Theis, L., Huszar, F., Caballero, J., Aitken, A. P., Tejani, A., Totz, J., Wang, Z. ve Shi, W., Photo-Realistic Single Image Super Resolution using A Generative Adversarial Network, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2017, Hawaii, 4681-4690.
108. Lim, B., Son, S., Kim, H., Nah, S. ve Lee, K. M., Enhanced Deep Residual Networks for Single Image Super Resolution, IEEE Conference on Computer Vision and Pattern Recognition Workshops, Haziran 2017, Hawaii, 1132-1140.
109. Chu, J., Zhang, J., Lu, W. ve Huang, X., A Novel Multiconnected Convolutional Network for Super Resolution, IEEE Signal Processing Letters, 25, 7 (2018) 946-950.
110. Wen, R., Fu, K., Sun, H., Sun, X. ve Wang, L., Image Superresolution Using Densely Connected Residual Networks, IEEE Signal Processing Letters, 25, 10 (2018) 1565-1569.

111. Xie, J., Xu, L ve Chen, E., Image Denoising and Inpainting with Deep Neural Networks, Neural Information Processing Systems Conference, Aralık 2012, Lake Tahoe, 341-349.
112. Zhang, K., Zuo, W., Chen, Y., Meng, D. ve Zhang, L., Beyond A Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising, IEEE Transactions on Image Processing, 26, 7 (2017) 3142-3155.
113. Jain, V. ve Seung, S., Natural Image Denoising with Convolutional Networks, Neural Information Processing Systems Conference, Aralık 2009, Kanada, 769-776.
114. Goodfellow, I., Bengio, Y. ve Courville, A., Deep Learning, MIT Press, 2016.
115. Convolutional Neural Networks for Visual Recognition, Stanford University, Course Notes (2018).
116. Xu, B., Wang, N., Chen, T. ve Li, M., Empirical Evaluation of Rectified Activations in Convolutional Network, International Conference on Machine Learning, Temmuz 2015, Fransa.
117. Nair, V. ve Hinton, G. E., Rectified Linear Units Improve Restricted Boltzmann Machines, International Conference on Machine Learning, Haziran 2010, İsrail, 807-814.
118. Maas, A. L., Hannun, A. Y. ve Ng, A. Y., Rectifier Nonlinearities Improve Neural Network Acoustic Models, International Conference on Machine Learning, Haziran 2013, Atlanta.
119. He, K., Zhang, X., Ren, S. ve Sun, J., Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, IEEE International Conference on Computer Vision, Aralık 2015, Şili, 1026-1034.
120. Clevert, D., Unterthiner, T. ve Hochreiter, S., Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs), arXiv preprint arXiv:1511.07289, 2015.
121. Zhou, Y. ve Chellappa, R., Computation of Optical Flow Using A Neural Network, IEEE International Conference on Neural Networks, Temmuz 1988, San Diego, 71-78.
122. Weston, J. ve Watkins, C., Support Vector Machines for Multi-Class Pattern Recognition, European Symposium on Artificial Neural Networks, Nisan 1999, Belçika, 219-224.
123. Bottou, L., Online Algorithms and Stochastic Approximations, Online Learning in Neural Networks, Cambridge University Press, 1998, 9-42.

124. Polyak, B. T., Some Methods of Speeding Up The Convergence of Iteration Methods, USSR Computational Mathematics and Mathematical Physics, 4, 5 (1964) 1-17.
125. 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.
126. Hinton, G., Neural Networks for Machine Learning, Coursera, video lectures 2012.
127. Kingma, D. ve Ba, J., Adam: A Method for Stochastic Optimization, International Conference on Learning Representations, Mayıs 2015, San Diego, 1637-1645.
128. Schaul, T., Antonoglou, I. ve Silver, D., Unit Tests for Stochastic Optimization, International Conference on Learning Representations, Nisan 2014, Kanada, 1-13.
129. Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C. ve Fei-Fei, L., Imagenet Large Scale Visual Recognition Challenge, International Journal of Computer Vision, 115, 3 (2015) 211-252.
130. Martin, D., Fowlkes, C., Tal, D. ve Malik, J., A Database of Human Segmented Natural Images and Its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics, IEEE International Conference on Computer Vision, Temmuz 2001, Kanada, 416-423.
131. Huang, J. B., Singh, A. ve Ahuja, N., Single Image Super Resolution from Transformed Self-Exemplars, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2015, Boston, 5197-5206.
132. Schuler, S., Leistner, C. ve Bischof, H., Fast and Accurate Image Upscaling with Super Resolution Forests, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2015, Boston, 3791-3799.
133. Timofte, R., Agustsson, R., Gool, L. V., Yang, M. H., Zhang, L., Lim, B., Son, S., Kim, H., Nah, S., Lee, K. M., Wang, X., Tian, Y., Yu, K., Zhang, Y., Wu, S., Dong, C., Lin, L., Qiao, Y., Loy, C. C., Bae, W., Yoo, J., Han, Y., Ye, J. C., Choi, J. S., Kim, M., Fan, Y., Yu, J. Han, W., Liu, D., Yu, H., Wang, Z., Shi, H., Wang, X., Huang, T. S., Chen, Y., Zhang, K., Zuo, W., Tang, Z., Luo, L., Li, S., Fu, M., Cao, L., Heng, W., Bui, G., Le, T., Duan, Y., Tao, D., Wang, R., Lin, X., Pang, J., Xu, J., Zhao, Y., Xu, X., Pan, J., Sun, D., Zhang, Y., Song, X., Dai, Y., Qin, X., Huynh, X. P., Guo, T., Mousavi, H. S., Vu, T. H., Monga, V., Cruz, C., Egiazarian, K., Katkovnik, V., Mehta, R., Jain, A. K., Agarwalla, A., Praveen, C. V. S., Zhou, R., Wen, H., Zhu, C., Xia, Z., Wang, Z. ve Guo, Q., NTIRE 2017 Challenge on Single Image Super Resolution: Methods and

- Results, IEEE Conference on Computer Vision and Pattern Recognition Workshops, Haziran 2017, Honolulu, 1110-1121.
134. Fujimoto, A., Ogawa, T., Yamamoto, K., Matsui, Y., Yamasaki, T. ve Aizawa, K., Manga109 Dataset and Creation of Metadata, International Workshop on Comics Analysis, Processing and Understanding, Aralık 2016, Meksika, 2:1-2:5.
 135. Kim, K. I. ve Kwon, Y., Single-Image Super-Resolution Using Sparse Regression and Natural Image Prior, IEEE Transactions on Pattern Analysis and Machine Intelligence, 32, 6 (2010) 1127-1133.
 136. Timofte, R., De Smet, V. ve Van Gool, L., Anchored Neighborhood Regression for Fast Example-Based Super Resolution, IEEE International Conference on Computer Vision, Aralık 2013, Sydney, 1920-1927.
 137. He, K., Zhang, X., Ren, S. ve Sun, J., Deep Residual Learning for Image Recognition, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2016, Las Vegas, 770-778.
 138. Shi, W, Caballero, J., Huszar, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D. ve Wang, Z., Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2016, Las Vegas, 1874-1883.
 139. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghahfarokian, M., Van Der Laak, J. A. W. M., Van Ginneken, B. ve Sanchez, C. I., A Survey on Deep Learning in Medical Image Analysis, Medical Image Analysis, 42, (2017) 60-88.
 140. Eaton-Rosen, Z., Bragman, F., Ourselin, S. ve Cardoso, M. J., Improving Data Augmentation for Medical Image Segmentation, 1st Conference on Medical Imaging with Deep Learning, Temmuz 2018, Amsterdam, 1-3.
 141. Hussain, Z., Gimenez, F., Yi, D. ve Rubin, D., Differential Data Augmentation Techniques for Medical Imaging Classification Tasks, American Medical Informatics Association Annual Symposium, Nisan 2018, San Francisco, 979.
 142. Rivenson, Y., Göröcs, Z., Günaydın, H., Zhang, Y., Wang, H. ve Özcan, A., Deep Learning Microscopy, Optica, 4, 11 (2017) 1437-1443.
 143. Tian, L., Suzuki, A. ve Koike, H., Task-Oriented Evaluation of Super-Resolution Techniques, International Conference on Pattern Recognition, Ağustos 2010, İstanbul, 493-498.
 144. Begin, I. ve Ferrie, F. P., Comparison of Super-Resolution Algorithms Using Image Quality Measures, The 3rd Canadian Conference on Computer and Robot Vision, Haziran 2006, Kanada, 72.

145. 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.
146. Reibman, A. R., Bell, R. M. ve Gray, S., Quality Assesment for Super Resolution Image Enhancement, IEEE International Conference on Image Processing, Ekim 2006, Atlanta, 2017-2020.
147. Wald, L., Ranchin, T. ve Mangolini, M., Fusion of Satellite Images of Different Spatial Resolutions: Assessing The Quality of Resulting Image, IEEE Transactions on Geoscience and Remote Sensing, 43 (2005) 1391-1402.
148. Yuhas, R. H., Goetz, A. F. H. ve Boardman, J. W., Discrimination Among Semi-Arid Landscape Endmembers Using The Spectral Angle Mapper (SAM) Algorithm, Third Annual JPL Airborne Geoscience Workshop, Haziran 1992, USA, 147-149.
149. Wald, L., Data Fusion: Definitions and Architectures-Fusion of Images of Different Spatial Resolutions, ss. 200, Presses de l'Ecole, Ecole des Mines de Paris, 2002.
150. Alparone, L., Baronti, S., Garzelli, A. ve Nencini, F., A Global Quality Measurement of Pan-Sharpned Multispectral Imagery, IEEE Geoscience and Remote Sensing Letters, 1, 4 (2004) 313-317.
151. Demirel, H. ve Anbarjafari, G., Discrete Wavelet Transform Based Satellite Image Resolution Enhancement, IEEE Transactions on Geoscience and Remote Sensing, 49, 6 (2011) 1997-2004.
152. Shih, F. Y., Image Processing and Pattern Recognition, IEEE Press, 2010.
153. Zhang, C., Liu, W., Liu, J., Liu, C. ve Shi, C., Sparse Representation and Adaptive Mixed Samples Regression for Single Image Super Resolution, Signal Processing: Image Communication, 67 (2018) 79-89.
154. Liu, N., Xu, X., Li, Y. ve Zhu, A., Sparse Representation Based Image Super-Resolution on The KNN Based Dictionaries, Optics and Laser Technology, 110 (2019) 135-144.
155. Kamarainen, J. K., Gabor Features in Image Analysis, 3rd International Conference on Image Processing Theory, Tools and Applications, Ekim 2012, İstanbul, 147-149.
156. Ratner, A.J., Ehrenberg, H.R, Hussain, Z., Dunnmon, J. ve Re, C., Learning to Compose Domain-Specific Transformations for Data Augmentation, Neural Information Processing Systems Conference, Aralık 2017, Long Beach, 3236-3246.

157. Li, Z. ve Leung, H., Fusion of Multispectral and Panchromatic Images Using A Restoration-Based Methods, IEEE Transactions on Geoscience and Remote Sensing, 47, 5 (2009) 1482-1491.
158. Lewis, J. P., Fast Template Matching, Vision Interface, (1995) 120-123.
159. Tsai, D. M., Lin, C. T., Fast Normalized Cross Correlation for Defect Detection, Pattern Recognition Letters, 24, 15 (2003) 2625-2631.
160. Mikolov, T., Statistical Language Models Based on Neural Networks, Doktora Tezi, Brno University of Technology, 2012.
161. Pascanu, R., Mikolov, T. ve Bengio, Y., On The Difficulty of Training Recurrent Neural Networks, International Conference on Machine Learning, Haziran 2013, Atlanta.
162. Wald, L., Ranchin, T. ve Mangolini, M., Fusion of Satellite Images of Different Spatial Resolution: Assessing The Quality of Resulting Images, Photogrammetric Engineering and Remote Sensing, 63, 6 (1997) 691-699.
163. DigitalGlobe, Quickbird scene 000000185940_01_P001, Level Standard 2A, digital globe, Longmont, Colorado, 2002.
164. Space Imaging, IKONOS scene po-58205, Level Standard Geometrically Corrected, GeoEye, Dulles, Virginia, 2000.
165. Ayas, S. ve Ekinci, M., Çok Ölçekli Ve Çok Yönlü Özellik Tanımlayıcısı Kullanarak Yeni Bir Seyrek Gösterim Tabanlı Süper Çözünürlük Yaklaşımı, 26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Mayıs 2018, İzmir, 1-4.

7. EKLER

Ek 1. Matris Formunda Gerçekleştirilen Temel Matematiksel İşlemler

A. Sözlüksel Temsiliyet

Sözlüksel temsiliyet bir görüntünün satırlarını bir değerine ekleyerek uzun bir kolon vektörü oluşturmaktır. 3×3 boyutlu örnek bir matrisin 9×1 boyutlu bir vektör olarak sözlüksel biçimde yeniden yazılması aşağıda verilmektedir.

$$I = \begin{bmatrix} 1 & 4 & 8 \\ 5 & 2 & 3 \\ 7 & 8 & 3 \end{bmatrix} \rightarrow \begin{bmatrix} 1 \\ 4 \\ 8 \\ 5 \\ 2 \\ 3 \\ 7 \\ 8 \\ 3 \end{bmatrix} \quad (\text{E.1})$$

B. Görüntü Oluşum Operatörleri

i. Alt Örnekleme Operatörü

(E.2) eşitliğinde verilen D alt örnekleme matrisi 4×4 boyutlu bir görüntüden her iki pikselde bir piksel örnekleyerek 2×2 boyutlu bir görüntü oluşturmaktadır.

$$D = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (\text{E.2})$$

ii. Eğrilik Operatörü

(E.3) eşitliğinde verilen F eğrilik matrisi görüntünün her bir pikselini bir piksel sola kaydırmaktadır.

$$F = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \quad (E.3)$$

iii. Bulanıklık Operatörü

$$3 \times 3 \text{ boyutunda } b = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \text{ Gaussian bulanıklık operatörü için bulanıklık matrisi}$$

(E.4) eşitliği ile ifade edilmektedir.

$$B = \begin{bmatrix} 4 & 2 & 0 & 0 & 2 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 2 & 4 & 2 & 0 & 1 & 2 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 2 & 4 & 2 & 0 & 1 & 2 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 2 & 4 & 0 & 0 & 1 & 2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 2 & 1 & 0 & 0 & 4 & 2 & 0 & 0 & 2 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 2 & 1 & 0 & 2 & 4 & 2 & 0 & 1 & 2 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 2 & 1 & 0 & 2 & 4 & 2 & 0 & 1 & 2 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 2 & 0 & 0 & 2 & 4 & 0 & 0 & 1 & 2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 2 & 1 & 0 & 0 & 4 & 2 & 0 & 0 & 2 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 2 & 1 & 0 & 2 & 4 & 2 & 0 & 1 & 2 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 & 2 & 1 & 0 & 2 & 4 & 2 & 0 & 1 & 2 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 2 & 0 & 0 & 2 & 4 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2 & 1 & 0 & 0 & 4 & 2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 2 & 1 & 0 & 2 & 4 & 2 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 2 & 1 & 0 & 2 & 4 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 2 & 0 & 0 & 2 & 4 \end{bmatrix} \times \frac{1}{16} \quad (E.4)$$

C. Çift Kübik Ara Değerleme

Çift kübik ara değerlendirme yöntemi, YÇ bir ızgara üzerinde kayıp bir pikseli tahmin etmek için 4×4 piksel komşuluk kullanmaktadır. Pikselin değerine karar vermek için 4 piksel

üzerinde polinomial geçiş kullandığından oluşturulan YÇ görüntüler daha yüksek kalitede ve pürüzsüzdür. (E.5) eşitliği kübik ara değerlendirme sürekli zaman konvolüsyon çekirdeğini vermektedir. Ara değerlendirme bir görüntünün satır ve sütunlarına ayrı ayrı uygulandığında çift kübik ara değerlendirme elde edilmektedir.

$$u(s) = \begin{cases} \frac{3}{2}|s|^3 - \frac{5}{2}|s|^2 + 1 & 0 < |s| < 1 \\ -\frac{1}{2}|s|^3 + \frac{5}{2}|s|^2 - 4|s| + 2 & 1 < |s| < 2 \\ 0 & 2 < |s| \end{cases} \quad (\text{E.5})$$

D. Kronecker Çarpım

$m \times n$ boyutlu bir A matrisi ve $p \times q$ boyutlu bir B matrisi (E.6) eşitliğindeki gibi verilsin.

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix}, B = \begin{bmatrix} b_{11} & b_{12} & \dots & b_{1q} \\ b_{21} & b_{22} & \dots & b_{2q} \\ \vdots & \vdots & \ddots & \vdots \\ b_{p1} & b_{p2} & \dots & b_{pq} \end{bmatrix} \quad (\text{E.6})$$

\otimes sembolü ile ifade edilen A ve B matrislerinin Kronecker tensör çarpımı, B matrisinin A matrisinin her bir elemanı ile çarpımı ile elde edilen büyük bir matristir.

$$A \otimes B = \begin{bmatrix} a_{11}b_{11} & a_{11}b_{12} & \dots & a_{11}b_{1q} & \dots & \dots & a_{1n}b_{11} & a_{1n}b_{12} & \dots & a_{1n}b_{1q} \\ a_{11}b_{21} & a_{11}b_{22} & \dots & a_{11}b_{2q} & \dots & \dots & a_{1n}b_{21} & a_{1n}b_{22} & \dots & a_{1n}b_{2q} \\ \vdots & \vdots & & \vdots & & & \vdots & \vdots & & \vdots \\ a_{11}b_{p1} & a_{11}b_{p2} & \dots & a_{11}b_{pq} & \dots & \dots & a_{1n}b_{p1} & a_{1n}b_{p2} & \dots & a_{1n}b_{pq} \\ \vdots & \vdots & & \vdots & & & \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots & & & \vdots & \vdots & & \vdots \\ a_{m1}b_{11} & a_{m1}b_{12} & \dots & a_{m1}b_{1q} & \dots & \dots & a_{mn}b_{11} & a_{mn}b_{12} & \dots & a_{mn}b_{1q} \\ a_{m1}b_{21} & a_{m1}b_{22} & \dots & a_{m1}b_{2q} & \dots & \dots & a_{mn}b_{21} & a_{mn}b_{22} & \dots & a_{mn}b_{2q} \\ \vdots & \vdots & & \vdots & & & \vdots & \vdots & & \vdots \\ a_{m1}b_{p1} & a_{m1}b_{p2} & \dots & a_{m1}b_{pq} & \dots & \dots & a_{mn}b_{p1} & a_{mn}b_{p2} & \dots & a_{mn}b_{pq} \end{bmatrix} \quad (\text{E.7})$$

E. Pan Keskinleştirme Görüntü Oluşum Modelinde Kullanılan Matrisler İfadeler

$$M_1 = (1/16) \cdot I_{8 \times 8} \otimes (1^T \otimes (I_{2 \times 2} \otimes 1^T)) \quad (\text{E.8})$$

$$I_{2 \times 2} \otimes 1^T = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} [1 \ 1 \ 1 \ 1] = \begin{bmatrix} 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (\text{E.9})$$

$$\begin{aligned} 1^T \otimes (I_{2 \times 2} \otimes 1^T) &= [1 \ 1 \ 1 \ 1] \begin{bmatrix} 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{bmatrix} \\ &= \begin{bmatrix} 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & \dots & \dots & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & \dots & \dots & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{bmatrix} \end{aligned} \quad (\text{E.10})$$

$$\begin{aligned} &\frac{1}{16} \cdot I_{8 \times 8} \otimes 1^T \otimes (I_{2 \times 2} \otimes 1^T) \\ &= \frac{1}{16} \cdot \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 1 & 1 & 1 & \dots & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \dots & 1 & 1 & 1 & 1 \end{bmatrix} \\ &= \begin{bmatrix} 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & \dots & \dots & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & \dots & \dots & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \ddots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \dots & \dots & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \dots & \dots & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{bmatrix} \end{aligned} \quad (\text{E.11})$$

$$\begin{aligned} M_2 &= (w_1 I \ w_2 I \ w_3 I \ w_4 I) = \\ &\begin{bmatrix} w_1 & 0 & 0 & 0 & \dots & 0 & 0 & w_2 & 0 & 0 & 0 & \dots & 0 & 0 & \dots & \dots & 0 & 0 & 0 \\ 0 & w_1 & 0 & 0 & \dots & 0 & 0 & 0 & w_2 & 0 & 0 & \dots & 0 & 0 & \dots & \dots & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \ddots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 & 0 & 0 & 0 & 0 & \dots & 0 & 0 & \dots & \dots & 0 & 0 & w_4 \end{bmatrix} \end{aligned} \quad (\text{E.12})$$

F. Feature-Sign Search Algoritması

$$\min_x f(x) \equiv \|Y - D\alpha\|^2 + \gamma \|\alpha\|_1 \quad (\text{E.13})$$

γ 'nın sabit olduğu (E.13)'te verilen optimizasyon probleminin çözümü için kullanılan Feature-Sign Search algoritmasının akışı Algoritma Ek 1 ile özetlenmektedir.

Algoritma sıfırdan farklı katsayıların ve karşılık gelen işaretlerin aktif kümesini tutmakta ve en uygun aktif küme ve katsayı işaretlerini aramaktadır. Algoritma feature-sign adımlarının serisinde ilerlemektedir; yani her bir adımda aktif küme ve işaretler için güncel bir tahmin verilir ve $\hat{\alpha}_{yeni}$ analitik çözümü hesaplanarak güncel çözüm ile $\hat{\alpha}_{yeni}$ arasında etkin ayrık doğru arama kullanılarak işaretler, aktif küme ve çözüm güncellenir. Her bir adım $f(x)$ kayıp fonksiyonunu azaltmakta ve tüm algoritma her zaman en uygun çözüme yakınsamaktadır.

Algoritma Ek 1. Feature-Sign Search Algoritması
Giriş: Özellik matrisi \mathbf{Y} , \mathbf{D} sözlüğü, seyrek düzenleme parametresi λ
<p>1. Başlangıç değerlerine atama: $\alpha = \vec{0}$, $\theta = \vec{0}$ ve <i>aktif küme</i> = { }</p> <p style="text-align: center;">$(\theta_i \in \{-1, 0, 1\}, \text{sign}(\alpha_i)$ eşitliğini ifade etmektedir)</p> <p>2. α'nın sıfır katsayılarından $i = \underset{i}{\operatorname{argmax}} \left \frac{\partial \ \mathbf{Y} - \mathbf{D}\alpha\ ^2}{\partial \alpha_i} \right$ indisi seç</p> <p>Yerel olarak amaç fonksiyonunu geliştiriyorsa α_i'yi, i'yi aktif kümeye ekleyerek etkinleştir:</p> $\left \frac{\partial \ \mathbf{Y} - \mathbf{D}\alpha\ ^2}{\partial \alpha_i} \right > \gamma \text{ ise } \theta_i := -1, \text{aktif küme} := \{i\} \cup \text{aktifk\u00fcm\u00e9} \quad (\text{E.14})$ $\left \frac{\partial \ \mathbf{Y} - \mathbf{D}\alpha\ ^2}{\partial \alpha_i} \right < -\gamma \text{ ise } \theta_i := 1, \text{aktif küme} := \{i\} \cup \text{aktifk\u00fcm\u00e9} \quad (\text{E.15})$ <p>3. Feature-sign adımı:</p> <p>$\hat{\mathbf{D}}$, sadece aktif kümeye karşılık gelen kolonları içeren \mathbf{D} matrisinin alt matrisi olsun</p> <p>$\hat{\alpha}$ ve $\hat{\theta}$, aktif kümeye karşılık gelen α ve θ'nin alt vektörleri olsun</p> <p>Sınırlandırılmamış QP sonucunu veren analitik çözümü hesapla ($\min_{\hat{\alpha}} \ \mathbf{Y} - \hat{\mathbf{D}}\hat{\alpha}\ ^2 + \gamma \hat{\theta}^T \hat{\alpha}$)</p> $\hat{\alpha}_{yeni} := (\hat{\mathbf{D}}^T \hat{\mathbf{D}})^{-1} (\hat{\mathbf{D}}^T \mathbf{Y} - \gamma \hat{\theta} / 2) \quad (\text{E.16})$ <p>$\hat{\alpha}$'den $\hat{\alpha}_{yeni}$'ye kapalı doğru bölümü üzerinde ayrık doğru aramayı gerçekleştir:</p> <p>$\hat{\alpha}_{yeni}$ değerindeki ve herhangi bir katsayının işareti değiştirdiği tüm noktalarda amaç fonksiyon değerini kontrol et</p> <p>$\hat{\alpha}$ değerini ve α'daki karşılık gelen girişleri en küçük amaç fonksiyon değerini veren noktaya güncelle</p> <p>$\hat{\alpha}$'nın sıfır katsayılarını aktif kümeden kaldır ve $\theta := \text{sign}(x)$ güncelle</p> <p>4. En uygunluk koşulunu kontrol et:</p>

(a) Sıfırdan farklı katsayılar için en uygunluk koşulu:

$$\left| \frac{\partial \|Y - D\alpha\|^2}{\partial \alpha_j} \right| + \gamma \text{sign}(\alpha_j) = 0, \forall \alpha_j \neq 0 \quad (\text{E.17})$$

Eğer (a) şartı sağlanmazsa Adım 3'e git; diğer durumda (b) koşulunu kontrol et.

(b) Sıfır katsayıları için en uygunluk koşulu:

$$\left| \frac{\partial \|Y - D\alpha\|^2}{\partial \alpha_j} \right| \leq \gamma, \forall \alpha_j = 0 \quad (\text{E.18})$$

Eğer (b) şartı sağlanmazsa, Adım 2'ye git; diğer durumda α 'yı çözüm olarak geri döndür.

G. Lagrange Dual Algoritması

$$\min \|Y - D\alpha\|_F^2 \quad \text{öyle ki} \quad \sum_{i=1}^k D_{i,j}^2 \leq c, \quad \forall j = 1, \dots, n. \quad (\text{E.19})$$

Lagrange Dual algoritması verilen sabit α katsayıları üzerinden D sözlüğünü oluşturmak için (E.19) eşitliğinde verilen optimizasyon problemini çözmektedir. Burada verilen problem ikinci dereceden sınırlandırmaya sahip bir en küçük kareler problemidir. Genellikle optimizasyon problemi iteratif izdüşüm ile gradyan iniş algoritması kullanılarak çözülebilmektedir. Fakat problem Lagrange Dual kullanılarak daha etkin çözülebilmektedir. İlk olarak, Lagrangian eşitliği dikkate alınırsa (E.20) elde edilmektedir.

$$\mathcal{L}(D, \vec{\lambda}) = \text{trace}((Y - D\alpha)^T(Y - D\alpha)) + \sum_{j=1}^n \lambda_j (\sum_{i=1}^k D_{i,j}^2 - c) \quad (\text{E.20})$$

Burada $\lambda_j \geq 0$ çift değişkendir. Analitik olarak D üzerinden minimizasyon yapılarak Lagrange Dual elde edilmektedir:

$$\mathcal{D}(\vec{\lambda}) = \min_D \mathcal{L}(D, \vec{\lambda}) = \text{trace}(Y^T Y - Y\alpha^T (\alpha\alpha^T + \Lambda)^{-1} (Y\alpha^T)^T - c\Lambda) \quad (\text{E.21})$$

Burada $\Lambda = \text{diag}(\vec{\lambda})$ 'dır. $\mathcal{D}(\vec{\lambda})$ 'nın gradyan ve Hessian'ı ise (E.22) ve (E.23) ile hesaplanmaktadır.

$$\frac{\partial \mathcal{D}(\vec{\lambda})}{\partial \lambda_i} = \|Y\alpha^T(\alpha\alpha^T + \Lambda)^{-1}e_i\|^2 - c \quad (\text{E.22})$$

$$\frac{\partial^2 \mathcal{D}(\vec{\lambda})}{\partial \lambda_i \partial \lambda_j} = -2((\alpha\alpha^T + \Lambda)^{-1}(Y\alpha^T)^T Y\alpha^T(\alpha\alpha^T + \Lambda)^{-1})_{i,j}((\alpha\alpha^T + \Lambda)^{-1})_{i,j} \quad (\text{E.23})$$

Burada $e_i \in \mathbb{R}^n$ i . birim vektördür. (E.21)'de verilen Lagrange Dual Newton yöntemi ya da eşlenik gradyan ile optimize edilebilir. $\mathcal{D}(\vec{\lambda})$ 'yi maksimize ederek en uygun \mathbf{D} sözlüğü (E.24) ile elde edilebilir:

$$\mathbf{D}^T = (\alpha\alpha^T + \Lambda)^{-1}(Y\alpha^T)^T \quad (\text{E.24})$$

ÖZGEÇMİŞ

06.10.1988 Tarihinde İstanbul'da doğdu. İlkokul, ortaokul ve lise öğrenimini İstanbul'da tamamladı. 2006 yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nde lisans programına başladı ve 2010-2011 eğitim-öğretim döneminde Erasmus öğrenci değişimi programı kapsamında İsveç Halmstad Üniversitesine gitti. 2011 yılında Bilgisayar Mühendisliği Bölümü'nden Bilgisayar Mühendisi unvanı ile bölüm ikincisi olarak mezun oldu. 2011 yılı güz döneminde Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. 2012 yılında, Bilgisayar Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. 2014 yılında yüksek lisans eğitimini tamamlayarak, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. TÜBİTAK BİDEB 2214-A Yurt Dışı Araştırma Burs Programı kapsamında Ekim 2015- Ağustos 2016 tarihleri arasında doktora çalışması yapmak için ABD Tennessee Üniversitesine gitti. Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümünde halen çalışmaya devam etmektedir. 5'i SCI/expanded indeksli dergilerde, 2' si diğer dergilerde, 8'i uluslararası konferanslarda, 3'ü ulusal konferanslarda olmak üzere toplam 18 yayını mevcuttur. Yabancı dil olarak İngilizce bilmektedir. Yayınları aşağıda verilmiştir.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

1. Ayas, S. ve Ekinci M., Microscopic Image Super Resolution Using Deep Convolutional Neural Networks, Multimedia Tools and Applications, (2019)
2. Ayas, S., Dogan, H., Gedikli, E. ve Ekinci, M., A Novel Approach for Bi-Level Segmentation of Tuberculosis Bacilli Based on Meta-Heuristic Algorithms, Advances in Electrical and Computer Engineering, 18, 1 (2018) 113-120.
3. Ayas, S., Gormus, E. T. ve Ekinci, M., An Efficient Pan Sharpening via Texture Based Dictionary Learning and Sparse Representation, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 11, 7 (2018) 2448 – 2460.
4. Ayas, S. ve Ekinci, M., Single Image Super Resolution Based on Sparse Representation using Discrete Wavelet Transform, Multimedia Tools and Applications, 77, 13 (2018) 16685–16698.

5. Ayas S. ve Ekinci M., Random Forest-Based Tuberculosis Bacteria Classification in Images of Zn-Stained Sputum Smear Samples, Signal Image and Video Processing, 8, 1(2014) 49-61.

Diğer dergilerde yayınlanan makaleler

1. Ayas, S., Dogan, H., Gedikli, E. ve Ekinci, M., Sürü Zekası Optimizasyon Algoritmaları Tabanlı Mikroskobik Görüntü Segmentasyonu, Akıllı Sistemler ve Uygulamaları Dergisi, 1 (2018) 291-297.
2. Doğan H., Ayas S., Gedikli E. ve Ekinci M., Parçacık Sürü Zekası Optimizasyonu İle Mikroskobik Görüntülerin Segmentasyonunda Farklı Entropi Ölçülerinin Etkisi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 22, 2 (2018) 703-710.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan yayınlar

1. Ayas, S., Görmüş, E. T. ve Ekinci, M., Öğrenilmiş Sözlük Üzerinden Seyrek Gösterim Aracılığıyla Yeni Bir Pan Keskinleştirme Yöntemi, 26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2018), Mayıs 2018, İzmir.
2. Ayas S. ve Ekinci M., Çok Ölçekli Ve Çok Yönlü Özellik Tanımlayıcısı Kullanarak Yeni Bir Seyrek Gösterim Tabanlı Süper Çözünürlük Yaklaşımı, 26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2018), Mayıs 2018, İzmir.
3. Ayas, S., Görmüş, E. T. ve Ekinci, M., Seyrek Gösterim Tabanlı Pan Keskinleştirme, 25. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2017), Mayıs 2017, Antalya.
4. Ayas S. ve Ekinci M., Learning Based Single Image Super Resolution using Discrete Wavelet Transform, 17th international Conference on Computer Analysis of Images and Patterns, Ağustos 2017, Ystad, İSVEÇ.
5. Doğan H., Ayas S., Gedikli E. ve Ekinci M., Parçacık Sürü Zekası Optimizasyonu ile Mikroskobik Görüntülerin Segmentasyonunda Farklı Entropi Ölçülerinin Etkisi, 20. Biyomedikal Mühendisliği Ulusal Toplantısı, Kasım 2016, İzmir.
6. Ayas S., Doğan H., Gedikli E. ve Ekinci M., Mikroskobik Görüntülerin İki Seviyeli Bölütlenmesi İçin Sürü Zekası Optimizasyonu Algoritmaları Tabanlı Yeni Bir Yaklaşım, 20. Biyomedikal Mühendisliği Ulusal Toplantısı, Kasım 2016, İzmir.
7. Üstübioğlu B., Ayas S., Doğan H. ve Ulutaş G., Renkli Sift Tabanlı Görüntü Sahtecilik Tespit Yöntemi, 23. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2015), Mayıs 2015, Malatya.
8. Ayas S., Doğan H., Gedikli E. ve Ekinci M., Tüberküloz Bakterilerinin Tespiti Amacıyla Ateşböceği Algoritmasına Dayalı Mikroskobik İmgelerin Bölütlenmesi,

23. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2015), Mayıs 2015, Malatya.
9. Doğan H., Ayas S. ve Ekinci M., Auto-focusing with Multi Focus Color Image Fusion Based on Curvelet Transform on Microscopic Imaging, 9th International Conference on Electrical and Electronics Engineering, Kasım 2015, Bursa.
10. Ayas S. ve Ekinci M., Automatic Segmentation Of Mycobacterium Tuberculosis In Ziehl-Neelsen Sputum Slide Images Using Support Vector Machines, 11th IASTED International Conference on Biomedical Engineering, Haziran 2014, Zürih, İSVİÇRE.
11. Ayas S. ve Ekinci M., Tüberküloz Bakterisinin Mikroskopik Görüntü Analiziyle Algılanması, 21. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2013), Nisan 2013, Girne, KUZEY KIBRIS TÜRK CUM.

Burslar

- TÜBİTAK BİDEB 2214-A Yurt Dışı Doktora Araştırma Bursu, 2015-2016.
- TÜBİTAK BİDEB 2228-B Yurt İçi Doktora Bursu, 2014-2017.