T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

KENAR DUYARLI ODAK PİKSELLER İLE YENİ BİR SÜPER ÇÖZÜNÜRLÜK YÖNTEMİNİN GELİŞTİRİLMESİ

Hürkal HÜSEM

DANIŞMAN
Doç. Dr. Gülsüm Zeynep GÜRKAŞ AYDIN

II. DANIŞMAN
Doç. Dr. Önder DEMİR

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Doktora Programı

Haziran, 2025

TEZ KABUL VE ONAYI

Hürkal HÜSEM tarafından, **Doç. Dr. Gülsüm Zeynep GÜRKAŞ AYDIN** danışmanlığında hazırlanan **"KENAR DUYARLI ODAK PİKSELLER İLE YENİ BİR SÜPER ÇÖZÜNÜRLÜK YÖNTEMİNİN GELİŞTİRİLMESİ"** başlıklı bu çalışma, jürimiz tarafından **25/06/2025** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Doktora Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Doç. Dr. Gülsüm Zeynep GÜRKAŞ AYDIN İstanbul Üniversitesi-Cerrahpaşa Siber Güvenlik Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Prof. Dr. Rüya ŞAMLI İstanbul Üniversitesi-Cerrahpaşa Yazılım Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Anıl BAŞ Marmara Üniversitesi Bilgisayar Bilimleri Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Prof. Dr. Ahmet SERTBAŞ İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Donanımı ve Gömülü Sistemler Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Eyüp Emre ÜLKÜ Marmara Üniversitesi Siber Güvenlik Anabilim Dalı		☒ Kabul ☐ Ret

Ada'ya…

BÜTÇE DESTEKLERİ

KENAR DUYARLI ODAK PİKSELLER İLE YENİ BİR SÜPER ÇÖZÜNÜRLÜK YÖNTEMİNİN GELİŞTİRİLMESİ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

En güzel anılarımın ortağı değerli kızım Ada'ya, doktora öğrenim hayatım boyunca desteğini hep hissettiğim eşim Seçil'e, görüşleri ve tecrübeleriyle yol gösteren danışmanlarım Doç. Dr. Gülsüm Zeynep GÜRKAŞ AYDIN ve Doç. Dr. Önder DEMİR'e, çok değerli yönlendirmeleri ile tez izleme komite üyeleri Prof. Dr. Rüya ŞAMLI ve Dr. Öğr. Üyesi Anıl BAŞ'a teşekkürlerimi iletiyorum.

Haziran 2025 Hürkal HÜSEM

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BÜTÇE DESTEKLERİ ..... **iv**
TEŞEKKÜR ..... **v**
İÇİNDEKİLER ..... **vi**
ŞEKİL LİSTESİ ..... **viii**
TABLO LİSTESİ ..... **x**
SİMGE VE KISALTMA LİSTESİ ..... **xi**
ÖZET ..... **xiii**
ABSTRACT ..... **xv**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **6**
2.1. ÇÖZÜNÜRLÜK İYİLEŞTİRME YÖNTEMLERİ 6
2.1.1. Bilinmeyen Bozulmalı (Blind) Süper Çözünürlük Yöntemleri 7
2.1.2. Bilinen Bozulmalı (Non-Blind) Süper Çözünürlük Yöntemleri 9
2.2. RENK UZAYLARI 22
2.2.1. RGB 23
2.2.2. YCbCr 24
2.2.3. CIELab 24
2.3. VERİ SETLERİ 27
2.3.1. Set5 28
2.3.2. Set14 29
2.3.3. BSD100 30
2.3.4. Urban100 31
2.3.5. DIV2K 32
2.4. ÇÖZÜNÜRLÜK İYİLEŞTİRMEDE KULLANILAN KALİTE ÖLÇÜMLERİ 33
2.4.1. Peak Signal-to-Noise Ratio (PSNR) 34
2.4.2. Structural Similarity Index (SSIM) 35
2.4.3. Mean Opinion Score (MOS) 36

2.4.4. Adaptive - Deep Image Structure and Texture Similarity (A-DISTS) 37
2.4.5. Learned Perceptual Image Patch Similarity (LPIPS) 37
3. YÖNTEM 39
3.1. KENAR-DUYARLI ODAK PİKSELLERE UYGULANAN DIAMOND-EYE MATRİSİ İLE SÜPER ÇÖZÜNÜRLÜK 39
3.1.1. Fark Görsellerinin Oluşturulması 40
3.1.2. Odak Piksellerin Elde Edilmesi 40
3.1.3. Önerilen Çözünürlük İyileştirme Matrisi: Diamond-Eye 43
3.1.4. Odak Pikseller Üzerinde Diamond-Eye Matrisinin Uygulanması 45
3.2. RENK UZAYI DÖNÜŞÜMÜNÜN SÜPER ÇÖZÜNÜRLÜK ÜZERİNDEKİ ETKİSİNİN İNCELENMESİ 46
3.2.1. Karşılaştırmada Kullanılan Yöntemlerin Gerçekleştirme Detayları 48
4. BULGULAR 52
4.1. DIAMOND-EYE MATRİSİNİN SÜPER ÇÖZÜNÜRLÜK ÜZERİNDEKİ BULGULARI 52
4.2. AKROMATİK EKSENE SAHİP YCbCr VE CIELab RENK UZAYLARININ SÜPER ÇÖZÜNÜRLÜK ÜZERİNDEKİ BULGULARI 55
5. TARTIŞMA 59
5.1. DIAMOND-EYE MATRİSİ KULLANIMININ ETKİLERİ 59
5.2. RENK UZAYI DÖNÜŞÜMÜNÜN ETKİLERİ 61
6. SONUÇ VE ÖNERİLER 65
6.1. DIAMOND-EYE MATRİSİNİN ETKİLİLİĞİ 65
6.2. RENK UZAYI DÖNÜŞÜMÜ 66
KAYNAKLAR 68
EKLER 76
İNTİHAL RAPORU İLK SAYFASI 82

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Bilinmeyen bozulmalı (blind) ve bilinen bozulmalı (non-blind) yöntemlerinin kapsam bakımından şematik gösterimi [24] 7

Şekil 2.2: Bilineer interpolasyon yönteminin matris üzerinde uygulanışı [40] 11

Şekil 2.3: Bikübik interpolasyon algoritmasının diyagramı [40] 13

Şekil 2.4: Lineer olmayan bikübik interpolasyon algoritmasının gösterimi [40] 13

Şekil 2.5: Lanczos pencere fonksiyonları (a, b) ile bunlara karşılık gelen interpolasyon kernelleri (Orijinal sinc fonksiyonu kesikli gösterilmiştir.) [42] 15

Şekil 2.6: GAN tabanlı sinir ağlarının temel çalışma prensibi [50] 18

Şekil 2.7: CIELab renk uzayında farklı ΔE değerleri ile algısal ayırt edilebilirlik 27

Şekil 2.8: Set5 veri seti içerisindeki görsellerin çözünürlük-frekans dağılımı 29

Şekil 2.9: Set14 veri seti içerisindeki görsellerin çözünürlük-frekans dağılımı 30

Şekil 2.10: BSD100 veri seti içerisindeki görsellerin çözünürlük-frekans dağılımı 31

Şekil 2.11: Urban100 veri seti içerisindeki görsellerin çözünürlük-frekans dağılımı 32

Şekil 2.12: DIV2K veriseti içerisindeki görsellerin çözünürlük-frekans dağılımı 33

Şekil 3.1: Çözünürlük iyileştirme süreçleri sonunda iyileştirilen görsel çıktısı ile orijinal görsel arasındaki farkların görsel üzerinde gösterimi 40

Şekil 3.2: Önerilen yöntemin temel uygulama adımları 41

Şekil 3.3: Odak piksellerin çıkartılması 43

Şekil 3.4: Diamond-Eye (d-Eye) matrisi 44

Şekil 3.5: Renk uzayı dönüşümünün süper çözünürlük üzerinde etkisinin incelendiği şematik gösterim 48

Şekil 4.1: Örnek görseller üzerinde önerilen yöntem ile Lanczos interpolasyon çıktılarının karşılaştırması 53

Şekil 4.2: Set14 veri kümesindeki baboon.png ve comic.png görüntüleri üzerinde gerçekleştirilen interpolasyon, SRGAN, Real-ESRGAN ve Swin2SR sonuçları 56

Şekil 4.3: Set5 veri kümesi üzerindeki interpolasyon, SRGAN, Real-ESRGAN ve Swin2SR sonuçları 57

Şekil 4.4: DIV2K veri kümesi üzerindeki interpolasyon, SRGAN, Real-ESRGAN ve Swin2SR sonuçları 57

TABLO LİSTESİ

Sayfa No

Tablo 2.1: Kullanılan veri setleri ve istatistiki veriler 27

Tablo 4.1: PSNR sonuçlarına göre en başarılı 5 görsel 53

Tablo 4.2: SSIM sonuçlarına göre en başarılı 5 görsel 54

Tablo 4.3: A-DISTS sonuçlarına göre en başarılı 5 görsel 54

Tablo 4.4: LPIPS sonuçlarına göre en başarılı 5 görsel 54

Tablo 4.5: Çözünürlük iyileştirme işleminin öncesi ve sonrasındaki PSNR, SSIM, A-DISTS ve LPIPS değerleri ile başarı değişim oranları 55

Tablo 4.6: Görsellerin YCbCr ve CIELab renk uzaylarına dönüştürülmeden önce ve sonra elde edilen kalite değerlendirme puanları [102] 58

Tablo 5.1: Kenar-duyarlı uygulanan merkez ağırlıklı keskinleştirme filtresi ile elde edilen sonuçların Lanczos interpolasyonu ile karşılaştırmalı sonuçlar 61

Tablo 5.2. Xu ve diğ. [109] tarafından önerilen yöntem ile bikübik interpolasyonun YCbCr renk uzayında x2 büyütme faktörüyle elde edilen sonuçları 63

Tablo 5.3. RGB, YCbCr ve CIELab renk uzaylarına ait eksenlerin değer aralıkları [110] 64

Tablo Ek-1: Set5 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri 76

Tablo Ek-2: Set14 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri 76

Tablo Ek-3: BSD100 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri 76

Tablo Ek-4: Urban100 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri 78

Tablo Ek-5: DIV2K veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri 80

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
$\hat{x}$	MAP algoritmasında yüksek çözünürlüklü görsel
G_x	Görüntünün yatay yönde türevi
G_y	Görüntünün dikey yönde türevi
G	Toplam gradyan değeri
μ	Ortalama (Mean)
σ	Standart sapma (Standard deviation)
D	Ağırlık matrisi veya mesafe matrisi
D_w	Normalize edilmiş ağırlık matrisi
$L(x)$	Lanczos interpolasyonu çıktısı
a	Lanczos kerneli genişlik parametresi
Y	YCbCr renk uzayında aydınlık bileşeni
Cb	YCbCr renk uzayında maviye olan uzaklık
Cr	YCbCr renk uzayında kırmızı olan uzaklık
L*	CIELab renk uzayında aydınlık bileşeni
a*	CIELab renk uzayında yeşil-kırmızı ekseni
b*	CIELab renk uzayında mavi-sarı ekseni
H(x)	Entropi
$l(x, y)$	SSIM'de kullanılan parlaklık fonksiyonu
$c(x, y)$	SSIM'de kullanılan kontrast fonksiyonu
$s(x, y)$	SSIM'de kullanılan yapı fonksiyonu
S(x)	B-spline fonksiyonu
∇	Gradyan operatörü (kenar tespiti)
f(x,y)	Giriş görüntüsünün konum bazlı yoğunluk fonksiyonu

Kısaltmalar	Açıklama
AI	: Artificial Intelligence – Yapay Zeka
ANN	: Artificial Neural Network – Yapay Sinir Ağı
CNN	: Convolutional Neural Network – Evrişimli Sinir Ağı
DNN	: Deep Neural Network – Derin Sinir Ağı
ESRGAN	: Enhanced Super-Resolution GAN – Gelişmiş Süper Çözünürlük GAN
GAN	: Generative Adversarial Network – Üretken Çekişmeli Ağ
HR	: High Resolution – Yüksek Çözünürlük
LPIPS	: Learned Perceptual Image Patch Similarity – Algısal Benzerlik Ölçütü
LSR	: Learned Super-Resolution – Öğrenilmiş Süper Çözünürlük
MFSR	: Multiple-frame super-resolution – Çok-görsel süper-çözünürlüğü
SISR	: Single-Image Super-Resolution – Tek-görsel süper-çözünürlüğü
PSNR	: Peak Signal-to-Noise Ratio – Tepe Sinyal-Gürültü Oranı
RGB	: Red-Green-Blue – Renk Modeli
SAM	: Segment Anything Model - Her Şeyi Segmentleme Modeli
SR	: Super Resolution – Süper Çözünürlük
SRGAN	: Super-Resolution GAN – Süper Çözünürlük Üretken Çekişmeli Ağı
SSIM	: Structural Similarity Index – Yapısal Benzerlik İndeksi
SwinIR	: Swin Transformer for Image Restoration
Swin2SR	: Swin Transformer for Super-Resolution
YCbCr	: Luminance and Chrominance Color Space – Parlaklık-Renk Bileşen Uzayı
CIELab	: International Commission on Illumination Color Space – CIE Renk Uzayı
HR	: High Resolution – Yüksek Çözünürlük
LR	: Low Resolution – Düşük Çözünürlük
DIV2K	: DIVerse 2K Resolution Dataset – 2K Çözünürlük Veri Seti
BSD100	: Berkeley Segmentation Dataset 100 – Berkeley Bölütleme Veri Seti
VGG	: Visual Geometry Group – VGGnet ağ mimarisi ile öne çıkan Oxford Üniversitesi merkezli Görsel Geometri Grubu, ağ mimarisinin adı
ViT	: Vision Transformer

ÖZET

DOKTORA TEZİ

KENAR DUYARLI ODAK PİKSELLER İLE YENİ BİR SÜPER ÇÖZÜNÜRLÜK YÖNTEMİNİN GELİŞTİRİLMESİ

Hürkal HÜSEM

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Doktora Programı

Danışman: Doç. Dr. Gülsüm Zeynep GÜRKAŞ AYDIN
II. Danışman: Doç. Dr. Önder DEMİR

Süper çözünürlük, düşük çözünürlüklü görsellerden yüksek çözünürlüklü görseller üretmeyi amaçlayan ve özellikle görüntü işleme, bilgisayarla görme, tıbbi teşhis ve uzaktan algılama gibi alanlarda kritik rol oynayan bir tekniktir. Süper çözünürlük, görüntülerde kaybolmuş detayların yeniden yapılandırılmasını sağlayarak hem görsel kaliteyi artırır hem de bu görsellerin analitik kullanımına olanak tanır. Günümüzde bu amaçla kullanılan yöntemler, geleneksel interpolasyon tekniklerinden derin öğrenme tabanlı modellere kadar geniş bir yelpazeye yayılmıştır.

Bu doktora tezinde, alanda öne çıkan çalışmalar incelenmiş ve süper-çözünürlüğü etkileyen temel sorunlar tespit edilmeye çalışılmıştır. Süper çözünürlük algoritmalarının, özellikle görsellerin kenar kısımlarında yeterli başarı gösteremediği tespit edilmiş ve bu soruna yönelik kenar odaklı yeni bir algoritma önerilmiştir. Bunun yanında sorunlu olabilecek kenar pikseller üzerinde adaptif bir şekilde çalışan, Diamond-Eye isimli bir matris önerilmiştir. Çeşitli standart veri setleri (Set5, Set14, BSD100, Urban100, DIV2K) kullanılarak yapılan deneylerde, önerilen yöntem PSNR, SSIM, A-DISTS ve LPIPS gibi hem piksel-temelli hem de algısal kalite

metriklerinde başarı göstermiştir. Bu çalışma, yalnızca görsel iyileştirme değil, aynı zamanda algı kalitesine odaklanan bütünsel bir süper çözünürlük yaklaşımı sunmakta ve gelecekteki araştırmalar için bir temel oluşturmaktadır.

Bu çalışmanın bir diğer konusu da RGB renk uzayına alternatif olarak YCbCr ve CIELab gibi akromatik eksenli renk uzaylarının süper çözünürlük üzerindeki etkisi sistematik biçimde incelemektir. Süper çözünürlük işleminden sonra sonuç görüntülerin, akromatik eksene sahip farklı renk uzayları olan YCbCr ve CIELab renk uzaylarına dönüştürülmesi hâlinde PSNR ve SSIM gibi standart metriklerde daha yüksek skorlar elde edilebildiğini ancak bu skor artışlarının görsel olarak gerçek kalite artışı anlamına gelmediği gösterilmiştir. A-DISTS ve LPIPS gibi insan algısına dayalı metriklerle yapılan değerlendirmeye göre, bu artışların yanıltıcı olabileceği, gerçek kalite iyileşmesiyle ilişkilendirilmemesi gerektiği vurgulanmıştır.

Haziran 2025 , 102 sayfa.

Anahtar kelimeler: Süper çözünürlük, Kenar-duyarlı süper çözünürlük, Diamond-Eye matrisi, Akromatik eksenli renk uzayları

ABSTRACT

Ph.D. THESIS

DEVELOPMENT OF A NOVEL SUPER-RESOLUTION METHOD USING EDGE-AWARE FOCAL PIXELS

Hürkal HÜSEM

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Computer Engineering

Computer Engineering, Doctorate Programme

Supervisor: Assoc. Prof. Dr. Gülsüm Zeynep GÜRKAŞ AYDIN

Co-Supervisor: Assoc. Prof. Dr. Önder DEMİR

Super-resolution is a technique that aims to generate high-resolution images from low-resolution inputs and plays a critical role in domains such as image processing, computer vision, medical diagnostics, and remote sensing. By reconstructing lost details in images, super-resolution enhances visual quality and enables their effective analytical use. Today, methods used for this purpose range from traditional interpolation techniques to deep learning-based models.

In this doctoral dissertation, prominent studies in the field are reviewed and common issues affecting super-resolution performance are identified. It is observed that many super-resolution algorithms fail to preserve sufficient detail around object edges. To address this limitation, a novel edge-focused algorithm is proposed along with an adaptive matrix named Diamond-Eye, which operates specifically on problematic edge pixels. Experimental evaluations conducted on standard benchmark datasets (Set5, Set14, BSD100, Urban100, DIV2K) demonstrate that the proposed method yields promising results across both pixel-based

and perceptual quality metrics, including PSNR, SSIM, A-DISTS, and LPIPS. The study presents a holistic approach that targets not only visual enhancement but also perceptual quality, offering a solid foundation for future research.

Another major focus of this study is to systematically examine the impact of achromatic-axis color spaces such as YCbCr and CIELab as alternatives to the RGB color space in super-resolution tasks. The findings indicate that converting super-resolved images into these alternative color spaces may result in higher scores in traditional metrics like PSNR and SSIM. However, assessments using perceptual metrics such as A-DISTS and LPIPS reveal that these score increases can be misleading and do not necessarily reflect real improvements in visual quality.

June 2025, 102 pages.

Keywords: Super-resolution, Edge-aware super-resolution, Diamond-Eye matrix, Achromatic-axis color spaces

1. GİRİŞ

Çözünürlük, bir görüntüleme sisteminin görüntüdeki ince detayları veya birbirine yakın nesneleri ayırt etme kapasitesini ifade eder. Bu özellik, görüntüyü temsil eden piksel sayısıyla doğrudan ilişkilidir ve bir görüntüde yakalanabilecek detay seviyesini belirler. Yue ve diğ. [1], çözünürlüğün sadece görsel netliği artırmakla kalmadığı, aynı zamanda analiz edilebilirlik açısından da kritik bir rol oynadığını çalışmalarında vurgulamışlardır. Dijital kameralar gibi görüntüleme sistemleri tarafından elde edilen görsel veriler, çeşitli yöntemlerle iyileştirilebilmektedir. Süper çözünürlük teknikleri, bu sistemler tarafından yakalanan verilerin kalitesini artırmayı hedeflemektedir [2]. Bu tür çözünürlük artırma yöntemleri sayesinde, daha kısa pozlama süresi gerektiren ya da yüksek kaliteli görüntüler sağlayan pahalı optik sistemlerin yerine daha ekonomik çözümler tercih edilebilmektedir.

Süper çözünürlük, kaybolmuş detayların geri kazanılmasını mümkün kılar ve görüntülerin algısal kalitesini önemli ölçüde iyileştirir. Çözünürlük kavramı, hem donanım (sensör yetenekleri) hem de yazılım (süper çözünürlük algoritmaları) aracılığıyla optimize edilebilir ve farklı uygulama alanlarına yönelik özel tekniklerle geliştirilir [1]. Düşük çözünürlüklü görüntüler piksel yoğunluğunun azalmasıyla karakterize edilir; bu durum, ince detayların kaybolmasına veya bulanıklaşmasına neden olur. Bu tür görüntüler, yüksek doğruluk veya ayrıntılı analiz gerektiren görevler için uygunsuz hale gelmiş olabilir. Bashir ve diğ. [3] çalışmalarında vurguladıkları gibi, düşük çözünürlük sadece görsel estetiği olumsuz etkilemekle kalmayarak aynı zamanda bilgisayarla görme, tıbbi teşhis ve uzaktan algılama gibi alanlardaki görevlerin başarısını da sınırlar. Bu sınırlamaları gidermek için tek görüntü süper çözünürlük (SISR) yöntemleri, düşük çözünürlüklü görüntülerden kaybolmuş yüksek frekanslı detayları yeniden oluşturmayı hedefler. Böylece, bu teknikler sadece görsel kalitenin artırılmasını sağlamakla kalmaz, aynı zamanda düşük kaliteli görüntülerin analitik kullanımlarını da mümkün kılar. Yüksek çözünürlüklü görüntüler, artırılmış piksel yoğunluğuna sahip olup karmaşık detayların ve dokuların net bir şekilde temsil edilmesini sağlar. Bu özellik, görüntülerin daha keskin, görsel olarak daha doğru ve gerçeğe daha yakın şekilde sunulmasına olanak tanır. Zhang ve diğ. [4] de değindiği şekilde yüksek çözünürlük, yalnızca estetik bir iyileştirme sağlamaz, aynı zamanda bilgisayarla görme, uzaktan algılama

ve tıbbi görüntüleme gibi uygulamalarda kritik öneme sahip detayların doğru bir şekilde algılanmasını ve analiz edilmesini mümkün kılar. Özellikle tek görüntü süper çözünürlük teknikleri, bu görsel doğruluğu artırmak için eksik yüksek frekanslı bileşenleri geri kazandırarak düşük çözünürlüklü görüntülerden yüksek çözünürlüklü çıktılarının yeniden oluşturulmasını sağlar. Bu da daha yüksek piksel yoğunluğunun hem görsel kalite hem de işlevsellik açısından nasıl bir fark oluşturduğunu açıkça ortaya koyar. Süper-çözünürlük çalışmaları, düşük çözünürlüklü görsellerden daha yüksek çözünürlük ve kalitede görsel üretmeyi amaçlar. Medikal görüntüleme, güvenlik, robotik gibi alanlarda yüksek görüntü kalitesine ihtiyaç duyulan çalışmalarda bir ön işlem olarak kullanılabileceği gibi görüntünün daha iyi anlamlandırılmasına da olanak tanımaktadır.

Tek görsel süper-çözünürlüğü (SISR), bilgisayarla görme alanında önemli bir araştırma konusudur ve düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntüler elde etmeyi amaçlar. SISR'nin temel zorluğu, tek bir düşük çözünürlüklü girdi için birden fazla yüksek çözünürlüklü çıktının olabilmesidir. Bu karmaşıklık, mevcut düşük çözünürlüklü verilerden kaybolan yüksek frekanslı detayları çıkarabilen algoritmaların geliştirilmesini gerektirmektedir [5–7].

Özellikle görüntüdeki detaylara ve süper çözünürlük alanında görsellerdeki nesnelerin kenarlarına odaklanan çalışmalar, bu tez çalışmasının ilgi alanına doğrudan girmektedir. Alanda yapılan çalışmalar arasında ilk örnekler arasında geleneksel metotlar diyebileceğimiz tahmine dayalı, kenar tabanlı, istatistiksel, yama tabanlı, seyrek-temsil gibi yöntemler ile çalışılmıştır. Keys [8] kübik konvolüsyonel interpolasyon yöntemi ile örneklendirilmiş veriler arasından ara değerleri tahmin eden bir algoritma geliştirmiştir. Önerdiği yöntem ile lineer interpolasyon ve kübik interpolasyon arasında bir performans sunar. Sayısal açıdan dijital bilgisayarlarda kullanılabilecek verimli bir algoritma olmasıyla önemli bir çalışmadır. Kübik konvolüsyonel interpolasyon, bikübik interpolasyonun optimize edilmiş ve görüntü işlemeye uygun halidir.

Duchon [9] Fourier tabanlı bir dijital filtreleme yöntemi olan Lanczos filtresini tanıtarak sinyallerde görülen Gibbs osilasyonunu azaltmaya yardımcı olarak tamamlanacak eksik veriler arasında daha düzgün geçişler yapılmasına olanak tanımıştır. Bikübik interpolasyona göre daha keskin sonuçlar ortaya koyduğundan modern süper çözünürlük algoritmalarında sıklıkla yararlanılır. Gibbs osilasyonu, eksik veriler nedeniyle sinyaldeki süreksizliğin Fourier

yaklaşımıyla temsilinde kenar bölgelerde ortaya çıkan dalgalanmalar olarak ifade edilmektedir [10].

Irani ve Peleg [11] çoklu görüntü süper-çözünürlüğü üzerine çalışmışlar ve alt piksel düzeyindeki hareket farklılıklarından yararlanarak görüntünün yeniden oluşturulmasında doğru hizalama yapmanın başarıyı artıracak en önemli etmen olduğunu göstermişlerdir. Bunun için öncelikle kayma miktarı tespit edilmiştir. Bilinen bozulmalı ve çok görüntülü süper çözünürlük çalışmalarına temel oluşturmuşlardır.

Freedman ve Fattal [12] yama tabanlı çalıştıkları yöntemde görüntüdeki lokal kendine benzerliklerden yararlanarak kenar koruma konusunda önemli bir aşama kaydetmişlerdir. Lokal kendine benzerlik, aynı görüntüde bulunan daha yüksek frekanslı bir karşılık olduğu varsayımıyla geliştirilen yerel öz benzerlik eşleme (local self-example matching) algoritmasını temel alır. Görüntüdeki her bölge için en uygun filtre seçilerek adaptif bir şekilde uygulanır. Özellikle video süper-çözünürlüğü için daha iyi sonuçlar elde edilmesini sağlar çünkü sahne içi tutarlılığın sağlanmasında yerel özellikler daha iyi başvuru kaynaklarıdır.

Sun ve diğ. [13], kenar duyarlı süper çözünürlük çalışmaları için temel kaynaklardan biri haline gelen bir imge önceliklendirme algoritması önermişlerdir. Doğal görüntülerdeki gradyanların istatistiksel modellenmesiyle oluşturulan parametrik bir yapı kullanılmıştır. Nesnelerin kenar bölgelerinde, dik doğrultuda değişimleri içeren gradyan profil ile tahmin aşamasında her pikselin gradyan büyüklüğünü çevresel yapıya göre konumlandırarak kenarların daha doğal hale getirilmesi amaçlanır.

Kim ve Kwon [14] daha az gürültü oluşturan, buna rağmen daha yüksek kaliteli kenar hatları oluşturabilen bir algoritma önermişlerdir. Seyrek regresyon ve doğal görüntü öncülü kullanarak düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntülere eşleme yapan bir model olarak öne çıkar. Kenar yapılarını korumak için yüksek çözünürlüklü gradyanlardaki kesiklikleri hesaba katarak örnek tabanlı algoritmalara göre daha az gürültü üretir. Seyrek temsil kuramına dayalı olarak doğal görüntülerin yapısal özelliklerini istatistiksel olarak modelleyerek modern tek-görüntü süper çözünürlük çalışmalarına katkı sağlamıştır.

Xiong ve diğ. [15] web görüntülerindeki sıkıştırma ve yüksek düşürme faktörünün sebep olduğu bozulmalara karşı bir yöntem önermişlerdir. Görüntülerdeki kenar, köşe ve düz alanlardaki verilerin değişimini inceleyerek bir analiz gerçekleştirilir. Değişim oranları

kullanılarak bir “düzenleme gücü” parametresi ayarlanır. Bu parametrenin kullanıldığı çift eşleme algoritması sıkıştırma bozulmalarını giderilebilmektedir. Düzenleme gücü parametresi adaptif bir şekilde ayarlanarak algoritmanın ne kadar agresif düzeltme yapacağı belirlenir.

Freeman ve diğ. [16] önerdikleri yöntem ile düşük çözünürlüklü görüntüdeki yamalardan daha önce öğrenilmiş yüksek çözünürlüklü yamalarla eşleştirilmesi ve kaybolan detayların tahmin edilmesi temeline dayanır. Kenar yapıları ve detaylar, çok daha gerçekçi bir şekilde modellenebilmektedir. Düşük ve yüksek çözünürlüklü yamalar bir veri tabanında eşleştirilir. Ancak eğitim verisine duyarlı bir yöntem olduğu için eğitim setine benzemeyen görüntülerde performans düşüklüğü söz konusudur. Eğitim verilerindeki çeşitlilik, yöntemin başarısını artırır.

Yang ve diğ. [17], yüksek çözünürlüklü görüntülerden rastgele seçilmiş yamalar ile bir eğitim sözlüğü oluşturarak tek-görüntü süper-çözünürlüğü üzerine bir yöntem önermişlerdir. Seyrek temsile dayalı olarak geliştirdikleri çözüm ile düşük çözünürlüklü bir yama, sadece temel bileşenleri içeren lineer bir model ile temsil edilebilmiştir. Böylece kenar ve doku gibi yüksek frekanslı bileşenlerin korunması sağlanırken hem veri daha az parametre ile ifade edilir hem de tekrar eden yapılar daha net bir şekilde hesaplamaya dahil edilir. Böylece gürültüye sebep olan bileşenler hesaplama dışında bırakılabilir. Bu sayede çok fazla bilgi taşıyan veri, daha az sayıda ve anlamlı yapılar ile ifade edilir.

Yang ve diğ. [18] seyrek temsile dayalı önerdikleri yöntemle ikili sözlük eğitimi gerçekleştirmişlerdir. İki farklı konsepti oldukça etkili bir şekilde kullanmasıyla öne çıkan çalışmada yüksek frekanslı verilerin korunması konusunda interpolasyon temelli yaklaşımlara göre daha avantajlı bir çözüm ortaya koyulmuştur. Yüksek çözünürlüklü görüntü oluşturulurken yamalar birbirinin üzerine bindirilerek birleştirilir. Pencereleme fonksiyonları ile geçişlerin yumuşatılması sağlanır. Burada amaç, görseldeki nesnelerin kenarlarını temsil eden yüksek frekansları, verilerdeki süreksizlikleri azaltması ile doğal bir görünüm elde edilmesini sağlamaktır. Bu yöntem ile istatistiksel benzerlik ön plana çıkarken kenar yapılardaki detaylar önemli ölçüde korunur.

Renk uzayı dönüşümü ve yeni bir kenar-duyarlı süper çözünürlük yöntemi içeren bu tezde her iki konu ayrı ayrı tartışılmıştır. Bölüm 2’de süper çözünürlük yaklaşımları öncelikle bilinmeyen bozulmalı (blind) ve bilinen bozulmalı (non-blind) çalışmalar olmak üzere iki ana kısma ayrılarak incelenmiştir. Özellikle eğitildikleri veya çözüm getirdikleri veri setleri

temelinde ayrışan bu yöntemler, gerçek dünya sorunlarına karşı yöntemlerin ne kadar etkili çözümler üretebileceği üzerine de ipucu vermektedir. Bu bölümde hem klasik hem de derin öğrenme tabanlı yaklaşımlar detaylandırılmıştır. Tez çalışmasının bir diğer konusu olan renk uzaylarının süper-çözünürlüğe etkisi incelenmiş ve çalışma kapsamında yararlanılan renk uzayları yine bu bölümde verilmiştir. Tez çalışmasında kullanılan veri setleri ve yöntemlerini başarısını ölçmek için kullanılan kalite metriklerinden de yine Bölüm 2 içerisinde ayrı bir başlıkta bahsedilmiştir. Bölüm 3'te, renk uzaylarının kalite metrikleri üzerindeki etkisinin nasıl değerlendirildiğine ilişkin detaylar paylaşılmış ve kenar-duyarlı geliştirilen süper çözünürlük algoritması kapsamında önerilen Diamond-Eye matrisinden bahsedilerek bu algoritmanın teknik detayları verilmiştir. Bölüm 4'te renk uzayı değişimi geleneksel ve yenilikçi başarı metrikleriyle test edilerek sonuçları paylaşılmıştır. Ayrıca önerilen yöntemin kavramsal çerçevede sunulan veri setleri ve kalite metrikleriyle test edilmesi sonucu elde edilen sonuçları paylaşılmıştır. Bölüm 5'te elde edilen bulgular, literatürdeki diğer çalışmalar ile birlikte değerlendirilmiştir ve çalışmanın özgün katkısı ortaya konulmuştur. Bölüm 6'da sonuçlar genelleştirilmiş, yapılabilecek diğer çalışmalara nasıl zemin hazırlayabileceği üzerine görüşler dile getirilmiştir.

2. KAVRAMSAL ÇERÇEVE

Süper çözünürlük çalışmaları, düşük çözünürlüklü görsellerden belirlenen yükseltme oranı doğrultusunda daha yüksek çözünürlük ve kalitede görsel üretmeyi amaçlar. Böylece insanlar için görsellerin daha iyi anlaşılabilmesi sağlanırken bilgisayarla görü iş ve işlemlerinde daha kesin sonuçların elde edilmesinin önü açılır. Medikal görüntüleme, güvenlik, robotik gibi yüksek görüntü kalitesine ihtiyaç duyulan alanlarda bir ön işlem olarak kullanılabileceği gibi görüntünün daha iyi anlamlandırılmasına da hizmet etmektedir.

Maiseli ve Abdalla [19], süper çözünürlük teriminin kökenini 1952 yılında Giuliano Toraldo di Francia tarafından yapılan, konusu optik sistemin açısal çözünürlüğünü geliştirmek üzerine olan teorik bir çalışmaya dayandırmaktadır. Kim ve Su [20], bulanık ve düşük çözünürlüklü birden fazla görüntüden yüksek çözünürlüklü bir görüntü elde etme yöntemlerinin tartışıldığı çalışmalarıyla süper çözünürlük tekniklerinin geliştirilmesinde önemli bir katkı sağlamıştır. Bahsedilen erken dönem çözünürlük iyileştirme çalışmaları, süper çözünürlük alanının temelini atmış ve günümüzde kullanılan birçok yönteme ışık tutmuştur.

Her ne kadar tez konusu ile doğrudan alakası olmasa da adaptif süper çözünürlük yaklaşımlarında kullanımı mümkün olan, Krillov ve diğ. [21] tarafından önerilmiş “Segment Anything Model (SAM)” isimli yöntemleriyle görüntü bölütlemesi konusunda önemli bir yenilik getirmişlerdir. Bugüne kadar oluşturulan en geniş bölütleme kümesi ve maskesiyle eğitilen “Vision Transformer (ViT)” [22] tabanlı model, daha önce eğitilmediği nesne türlerini de başarılı bir şekilde ayırabilmektedir. Büyük ölçekli veriyle eğitildiği için “her şeyi bölütleyebilen bir model” fikrine en yakın model olarak öne çıkmaktadır.

2.1. ÇÖZÜNÜRLÜK İYİLEŞTİRME YÖNTEMLERİ

Süper çözünürlük çalışmaları, bilinmeyen bozulmalı (blind) ve bilinen bozulmalı (non-blind) süper çözünürlük yöntemleri olarak iki gruba ayrılarak incelenebilir [23, 24]. Şekil 2.1 incelendiğinde, problemin kapsamı açısından çizilen şemaya göre bilinen bozulmalı (non-blind) süper çözünürlük yöntemlerinin problemi sınırlandırma adına daha dar bir çerçeveyi kapsadığı görülmektedir.

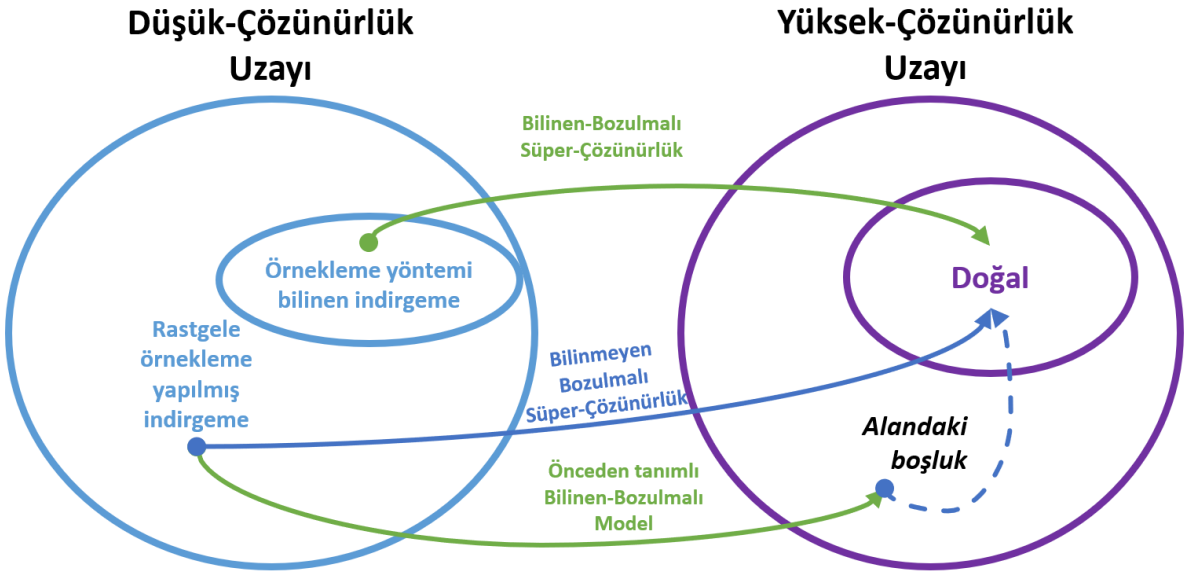

Şekil 2.1: Bilinmeyen bozulmalı (blind) ve bilinen bozulmalı (non-blind) yöntemlerinin kapsam bakımından şematik gösterimi [24]

2.1.1. Bilinmeyen Bozulmalı (Blind) Süper Çözünürlük Yöntemleri

Bilinmeyen bozulmalı süper çözünürlük tanımı, literatürde ilk defa Pan [25] tarafından yapılarak "Poisson Maximum a Posteriori (MAP)" temelli bir yaklaşım olarak tanıtılmıştır. Rajan ve Chaudhuri [26] ise bulanıklık bilgisinden yola çıkılarak bu bilginin önemli bir ipucu olarak kullanılabileceğini, dolaylı olarak bilinen ve bilinmeyen bozulmalı yöntemlerin teorik bir ayrımını vermişlerdir. Bilinen bozulmalı süper çözünürlük terimi ise daha çok "bilinmeyen bozulmalı" terimine zıt bir kavram olarak doğmuştur. Yagle [27] bilinmeyen bozulma durumu için bir algoritma geliştirmiş olmasına karşın bilinen bozulmalı yöntemlerin sınırlarını da çalışmasında tanımlanmıştır ve bilinen bozulmalı yöntemlerin gerçek dünya uygulamaları için yeterli olmayacağını belirtmiştir.

Pan [25] tarafından literatüre kazandırılan bilinmeyen bozulmalı (blind) süper çözünürlük teriminin ortaya konulduğu çalışmada, bozulma durumu bilinmeyen görsellerin yeniden oluşturulması hedeflenmektedir. Poisson MAP algoritması temelinde yapılan geliştirmeler ile Wiener filtresi, lineer minimum ortalama karesel hata tahminine dayandırılarak kullanılmıştır. Böylece sinyal ve gürültü istatistikleri kullanılarak yapılan tahmin iyileştirilmiştir. Kenar haritaları üzerinde gerçekleştirilen işlemler ile gürültü etkilerinin azaltılması hedeflenmiştir. Geleneksel Poisson MAP algoritmasından daha iyi sonuçlar veren bu yöntem ile uzaktan algılama ve tıbbi görüntüleme alanlarına katkı sağlanmıştır.

Poisson MAP algoritması, özellikle görüntü iyileştirme ve süper çözünürlük işlemleri için kullanılmaktadır. Temelde olasılık modeli (likelihood) ve "a priori bilgi" bileşenlerinin denklem (2.1)'de görüldüğü gibi birleştirilmesiyle elde edilen bilgiyi kullanır. MAP tahmini, olasılıkların logaritmik toplamını maksimize etmeye çalışarak gözlenen veri *y*'den yola çıkarak istenilen durum *x*'i tahmin etmeye çalışır. $P(y \mid x)$ ile düşük çözünürlüklü görüntünün yüksek çözünürlüklü bir görüntüye karşılık gelip gelmediğini gösterirken $P(x)$ yüksek çözünürlüklü görüntülere dair sahip olunan bilgilere karşılık gelir. MAP tahmini ile gözlenen veri y'ye karşılık gelen en doğal x'i bulmaya çalışır [28].

$$\hat{x} = argmax_{\mathrm{x}} [\log P(y \mid x) + \log P(x)] \quad (2.1)$$

Wang ve diğ. [29], derin öğrenme ile mikroskopide kullanılan görüntüleme modları arasında, GAN tabanlı çapraz mod süper çözünürlük elde etme yöntemini geliştirmişlertir. Eğitim sürecinde yüksek ve düşük çözünürlüklü görüntüler arasında dönüşüm yapmayı öğrenen ağ sayesinde hızlı ve parametre ayarını en aza indirerek başarıya ulaşmışlardır. Geliştirilen yöntem, bozulma fonksiyonunun bilinmediği durumlara uyum sağlayabilen bir model olduğundan dolayı bilinmeyen bozulmalı yöntem sınıfındadır. Bu yöntem, geleneksel mikroskoplarla elde edilen görüntülerden yüksek çözünürlüklü görüntüler üretmeyi mümkün kılmaktadır.

Qin ve diğ. [30], tuz ve karabiber gürültüsü içeren bir görüntüden yüksek çözünürlüklü görüntü oluşturmayı hedefleyen çalışmada, öncelikle gürültüyü azaltmak için medyan filtre kullanmışlardır. İlk işlemin ardından üretilen yeni görüntü, halen düşük çözünürlüklüdür. Süper çözünürlük için ise "yinelemeli geri yansıtma" algoritması kullanılarak görüntü iyileştirilmiştir. İki aşamalı gerçekleşen bu süreçte amaç gürültünün etkisini azaltmak ve detayları korumaktır. Görsellerdeki gürültü ve bulanıklık bozulmalarının türü ve miktarı bilinmediğinden bilinmeyen bozulmalı bir yaklaşımdır.

Wang ve diğ. [31] tarafından geliştirilen Real-ESRGAN isimli çalışma, gerçek dünya problemlerini çözmek üzere kurgulanan ESRGAN [32] temelli bir yöntemdir. Kayıp fonksiyonları konusunda algısal kayıp fonksiyonunun yanında çekişmeli kayıp fonksiyonunu da kullanmasıyla görüntülerin gerçekçi ve keskin bir şekilde elde edilmesini sağlamaktadır. Eğitildiği veriler, birçok bilinen bozulmalı yöntemin kullandığı veri setlerindeki Gauss

bulanıklığı ve bikübik alt-örneklemenin ötesinde çok aşamalı ve rastgele bozulma fonksiyonları da ekleyerek gerçek dünya problemlerine karşı daha duyarlı bir hale getirilmiştir.

Conde ve diğ. [33], SwinIR [34] üzerinde geliştirilmiş, özellikle JPEG sıkıştırması sonrasındaki hataların giderilmesinde daha da başarılı hale gelen transformer tabanlı bir yöntem olan Swin2SR ile eğitimi daha dengeli hale getirmişler, özellikle transformer tabanlı yöntemlerde parametrenin öğrenilmesi aşamasında ortaya çıkması olası ani dalgalanmalar, öğrenmenin durması (plateau), gradyan patlaması (gradient explosion), gradyan sönmesi (gradient vanishing), aşırı ezberleme (overfitting) gibi durumları en aza indirmişlerdir. Bu modelde, giriş görselinin çözünürlüğü değişse de dikkat pencereleri etkilenmiyor ve farklı yükseltme faktörleri uygulansa da yüksek başarı değerlerine ulaşılabilmektedir. Parametre paylaşımı daha dengeli hale getirildiğinden öğrenme eğrisi daha düzenli ilerlemektedir. Böylece eğitim sırasında kayıp değerlerinde ani dalgalanmalar yerine normalize edilmiş bir azalma söz konusu olmaktadır. Bu yaklaşım ile model daha hızlı öğrenebilirken eğitim süreci de kısalmaktadır.

2.1.2. Bilinen Bozulmalı (Non-Blind) Süper Çözünürlük Yöntemleri

Bilinen bozulmalı süper çözünürlük yöntemleri, düşük çözünürlüklü görüntünün elde edilirken tam olarak hangi bozulma süreçlerinden geçtiği bilinen veri setleri üzerinde eğitilen ve bu veri setleri üzerinde süper çözünürlük gerçekleştirebilen yöntemlerdir. Bu yöntemlerin geliştirme ve değerlendirme süreçleri daha kontrollü ve ölçülebilirdir. Geliştirilen modellerin, diğer modeller ile kıyaslanabilmesi için kullanılan ortak veri setlerinin (tez çalışmasında da yararlanılan Set5, Set14, BSD100 ve Urban100'de olduğu gibi) çoğunda bilinen degradasyon süreçleri kullanıldığından geliştirilen yöntemler doğrudan PSNR ve SSIM gibi klasik yöntemlerle karşılaştırılabilir niteliktedir. Buna karşın gerçek dünya temsillerini yansıtmada bilinen bozulmalı yöntemler, her zaman iyi sonuçlar vermeyebilir [23].

Ur ve Gross [35] çalışmalarında, düşük çözünürlüklü görüntülerin alt piksel kaymaları kullanılarak nasıl daha yüksek çözünürlüklü görüntülere dönüştürülebileceğini incelenmişlerdir. Bu süreçte bozulma fonksiyonunun bilindiği varsayıldığından bilinen bozulmalı bir yöntemdir. Yazarlar, bir sahnenin farklı alt piksel konumlarından alınan birden fazla düşük çözünürlüklü görüntüsünü birleştirerek, orijinal sahnenin yüksek çözünürlüklü bir temsilini elde etmeyi amaçlamışlardır. Bu yöntem, özellikle görüntü işleme ve bilgisayarla görme alanlarında önemli bir adım olarak kabul edilir.

Kim ve Su [20], bulanık ve düşük çözünürlüklü birden fazla görüntüden yüksek çözünürlüklü bir görüntü elde etmeyi hedeflemektedir. Uzaktan algılama, tıbbi görüntüleme, video işleme gibi alanlarda, bir sahnenin ardışık zamanlarda ve farklı açılarda elde edilen görüntüsünden yola çıkılarak yapılan çalışmaları kapsamaktadır. Ayrık Fourier dönüşümü kullanarak yinelemeli en küçük kareler algoritması temelinde işlemler gerçekleştirilir. Kullandıkları yöntemde her bir ayrık Fourier dönüşümü bağımsız bir birim olarak işlenir, paralel hesaplama yapısı sayesinde işlem gereksinimlerinin azaltılması hedeflenmiştir. Özellikle çok görüntülü süper çözünürlük çalışmaları için önemli bir dayanak noktası olmuştur. Bulanıklık fonksiyonunun bilindiğinden dolayı bilinen bozulmalı bir yöntemdir.

Çözünürlük iyileştirme üzerine geliştirilen ilk algoritmada Fourier dönüşümü kullanılmış ve önerilen çözüm birçok araştırmacı tarafından benimsenmiştir. Söz konusu çalışma, sınırlı spektrumun genişletilmesi problemini ele alır ve Fourier dönüşümü ile elde edilen verilerle nesne spektrumunun tamamlanması amaçlanmıştır. Frekans bilgilerinin eksik olduğu kısımlar “hata enerjisi” adıyla “eksikliklerin ölçüsü” olarak ifade edilmiştir. Hata enerjisinin ise eksik frekans değerlerinin tamamlanarak azaltılması amaçlanır. Bu da Fourier dönüşüm uzayındaki eksik frekans bilgilerinin tahmin edilmesi anlamına gelir [36]. İlk çalışma olarak ortaya konulan Fourier dönüşümü sonrasında, bilinen en basit ve temel yöntemler arasında, grafik programlarında da temel olarak benimsenen interpolasyon yöntemleri yer almaktadır.

Çözünürlük iyileştirme yöntemleri, sorunu çözmek için kullanılan yöntemlerin temel aldığı tekniklere göre interpolasyon yöntemleri, sinir ağı temelli derin öğrenme yaklaşımları ve transformer tabanlı derin öğrenme yaklaşımları olarak üç ana başlık altında incelenmiştir.

2.1.2.1. İnterpolasyon Yöntemleri

İnterpolasyon, modele dayalı olmak üzere eksik olan sürekli verinin kesikli verilere bakılarak apsis aralıkları dahilinde elde edilmesidir. İnterpolasyon için aşağıdaki üç hipotez mevcuttur [37]:

1. Gerçek veri sürekli bir veri olarak tanımlıdır.

2. Örnek verilerden yola çıkılarak sürekli fonksiyondaki verinin değeri herhangi bir apsis için hesaplanabilir.

3. Örneklenen noktalarda temel alınan sürekli fonksiyon, verilerin kendileriyle aynı değeri verir.

Süper çözünürlük için interpolasyon yöntemleri, özellikle görüntü çözünürlüğünü artırma konusunda önemli bir araştırma alanıdır. Bu alandaki ilk çalışmalar genellikle en yakın komşu, iki boyutlu ve üç boyutlu interpolasyon gibi klasik interpolasyon yöntemlerine odaklanmıştır. Bu yöntemler uygulanması kolay ve hesaplama açısından verimlidir ancak sonuç olarak elde edilen görüntülerde bulanıklık söz konusudur [38].

2.1.2.1.1. En Yakın Komşu İnterpolasyonu

En yakın komşu interpolasyonunda elde edilmek istenen piksel değeri, bilinen en yakın noktanın değerini alır. Uygulanması ve anlaşılması en kolay interpolasyon yöntemi olmasına karşın oluşturulan görseller düşük kalitelidir. Bunun sebebi ise Fourier dönüşümünde dikdörtgen fonksiyonun sinc fonksiyona eşdeğer olması ve geçiş kazancında hızlı bir kaybın ortaya çıkmasıdır [39]. En yakın komşu interpolasyonunda "piksellenme" veya "bloklanma" denilen görüntü bozulması, özellikle yükseltme faktörü artırıldıkça daha fazla göze çarpan bir sorundur.

2.1.2.1.2. Bilineer İnterpolasyon

Tahmin edilecek veri elde edilirken, Şekil 2.2'de görülen nokta çiftlerinden yola çıkarak tahmin yapılmasını sağlar. A-B çiftlerinden E değeri, C-D çiftlerinden de F değeri elde edilir. Ardından E-F nokta çiftlerinden de P değeri elde edilir. En yakın komşu interpolasyonuna göre daha gerçekçi sonuçlara ulaşılmaktadır [40].

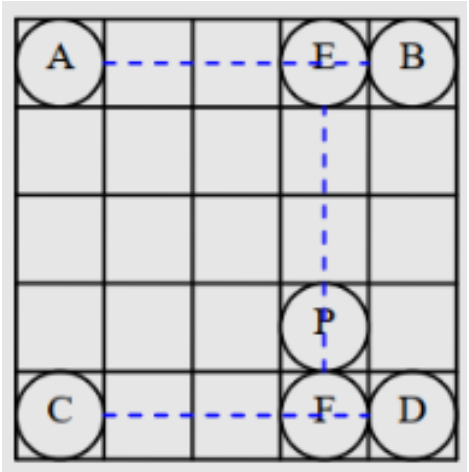

Şekil 2.2: Bilineer interpolasyon yönteminin matris üzerinde uygulanışı [40]

Şekil 2.2‘de gösterilen A, B, C ve D noktalarının verileri bilinmektedir ve P noktasının verisine ulaşılmak istenmektedir. Bu durumda söz edilen verilerin koordinatları şu şekilde tanımlı ise:

- A(i,j)
- B(i, j+1)
- C(i+1, j)
- D(i+1, j+1)
- P(u, v)

Bu durumda öncelikle A ve B noktalarının etki değerleri denklem (2.2)‘ye göre hesaplanmalıdır.

$$f(i, j + v) = [f(i, j + 1) - f(i, j)]v + f(i, j) \tag{2.2}$$

Bir sonraki adımda C ve D noktalarının etki değerlerine ihtiyaç duyulacaktır. Bunun için denklem (2.3)’ten faydalanılır.

$$f(i + 1, j + v) = [f(i + 1, j + 1) - f(i + 1, j)]v + f(i + 1, j) \tag{2.3}$$

Denklem (2.2) ve (2.3)’ten yola çıkılarak E ve F noktalarının da etki değerleri denklem (2.4)’e göre hesaplanarak P noktasına ulaşılır.

$$\begin{aligned} f(i + u, j + v) = {} & (1 - u)(1 - v)f(i, j) - (1 - u)vf(i, j + 1) \\ & + u(1 - v)f(i + 1, j) + uvf(i + 1, j + 1) \end{aligned} \tag{2.4}$$

2.1.2.1.3. Bikübik İnterpolasyon

Bilineer interpolasyon algoritmasına benzer şekilde çalışmaktadır. A-B-C-D noktalarının köşelere yerleştirildiği, 16 elemanlı karesel bir matris olduğu düşünülerek hesaplama yapılır. Noktaların yerleşimi Şekil 2.3’te gösterilmiştir. Bu algoritmada etki, bilineer interpolasyon algoritmasına göre daha fazla genişletilir ve hem yatay hem dikey doğrultuda üçüncü dereceden kübik polinomlarla hesaplanır. Bu sayede detay koruma ve kenar yumuşatma açısından bilineer interpolasyon algoritmasına göre daha iyi sonuçlar verir. Şekil 2.4’te gösterilen A ve B noktaları arasındaki e noktasının hesaplaması yapılırken A-1 ve B+1 noktalarından da yararlanılarak doğrusal ve kırıklı olmayan bir eğriden yararlanılır [40].

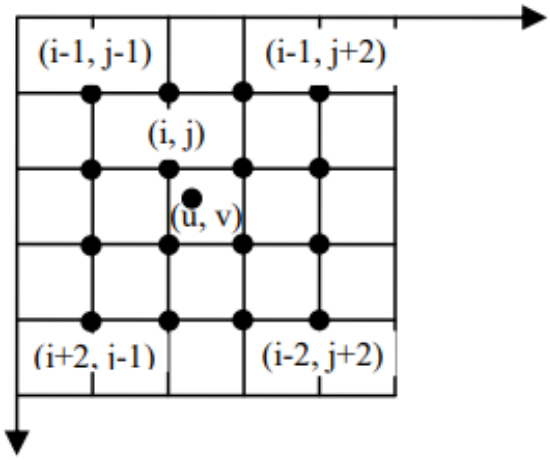

Şekil 2.3: Bikübik interpolasyon algoritmasının diyagramı [40]

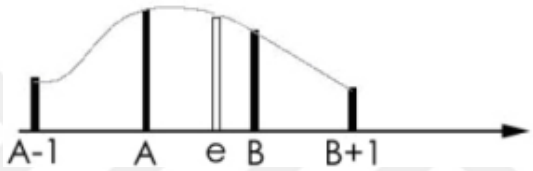

Şekil 2.4: Lineer olmayan bikübik interpolasyon algoritmasının gösterimi [40]

2.1.2.1.4. B-spline İnterpolasyon

B-spline, bikübik interpolasyonuna göre daha iyi sonuçlar vermesine karşın keskin detayları koruma noktasında zayıf düşmektedir. Polinomsal parçaların birleşiminden oluşur.

Denklem (2.5)'te görülen formüle göre *S(x)* b-spline fonksiyonunu ifade eder. $N_{i,k}(x)$ ile i-nci fonksiyon elde edilir, *k* ile polinom derecesi belirtilir. P_i ise kontrol noktalarını içerir. Burada *k* derecesine göre baz fonksiyonları değişiklik gösterir ki iki farklı durum ele alınır.

$$S(x) = \sum_{i=0}^{n} N_{i,k}(x).P_i \tag{2.5}$$

k değerinin sıfıra eşit olması ile sıfırdan büyük olması ayrı ayrı denklem (2.6)'da görüldüğü gibi değerlendirilir [41].

$$\begin{aligned} k = 0: \quad & N_{i,0}(x) = \begin{cases} 1, & t_i \le x \le t_{i+1} \\ 0, & diğer \end{cases} \\ k > 0: \quad & N_{i,k}(x) = \frac{x - t_i}{t_{i+k} - t_i} N_{i,k-1}(x) + \frac{t_{i+k+1} - x}{t_{i+k+1} - t_{i+1}} N_{i+1,k-1}(x) \end{aligned} \tag{2.6}$$

Bu yöntemde keskin geçişlerden ziyade daha yumuşak geçişler elde edilir, ince kenarlar ve keskin detaylar iyi korunmamaktadır. Düğüm noktalarının seçimi kaliteyi önemli ölçüde etkiler, bu yüzden değer seçimi konusunda iyi bir optimizasyon gereklidir.

2.1.2.1.5. Lanczos İnterpolasyonu

Lanczos interpolasyonu, sinyal ve görüntü işleme alanlarında yüksek kaliteli yeniden örnekleme (resampling) ve süper çözünürlük (super-resolution) uygulamaları için yaygın olarak kullanılan bir tekniktir.

İyileştirme sürecinde Fourier dönüşümü ile girdi olarak kabul edilen düşük çözünürlüklü görselin yüksek frekans bileşenleri tahmin edilmeye çalışılır. Görüntüdeki keskin değişimlerin Fourier serisi ile temsil edilmesi pek mümkün değildir. Çözünürlük iyileştirme sonrasında, görseldeki kenarların çevresinde ortaya çıkan parlaklıklar Gibbs osilasyonu olarak adlandırılır. Lanczos interpolasyonu, sinc fonksiyonunun etkisini sınırlayarak Gibbs osilasyonunu en aza indirir ve bu başarısı sayesinde diğer interpolasyon yöntemlerine göre daha avantajlı hale gelmiştir. Bu yöntem, sinc fonksiyonunun pencereleme (windowing) tekniğiyle sınırlandırılmasıyla elde edilen bir çekirdek (kernel) kullanarak, orijinal sinyalin frekans bileşenlerini daha doğru bir şekilde yeniden yapılandırılmasını hedefler. Bu sayede görseldeki kenar kısımlarda daha iyi sonuçlar elde edilir [9].

Lanczos interpolasyonu, ideal sinc fonksiyonuna yakın bir düşük bant filtreleme yöntemidir. Budanmış sinc filtresi kullanılarak gerçekleştirilir. Hesaplama maliyeti, trigonometrik fonksiyonları barındırması nedeniyle diğer yöntemlere göre daha maliyetlidir. Sinc fonksiyonu, Şekil 2.5'te gösterildiği gibi pencereli budanmış bir sinc fonksiyonu kullanır [42]. Görüntüdeki istenmeyen pürüzlerin giderilmesinde, bahsedilen diğer interpolasyon yöntemlerine göre daha başarılıdır.

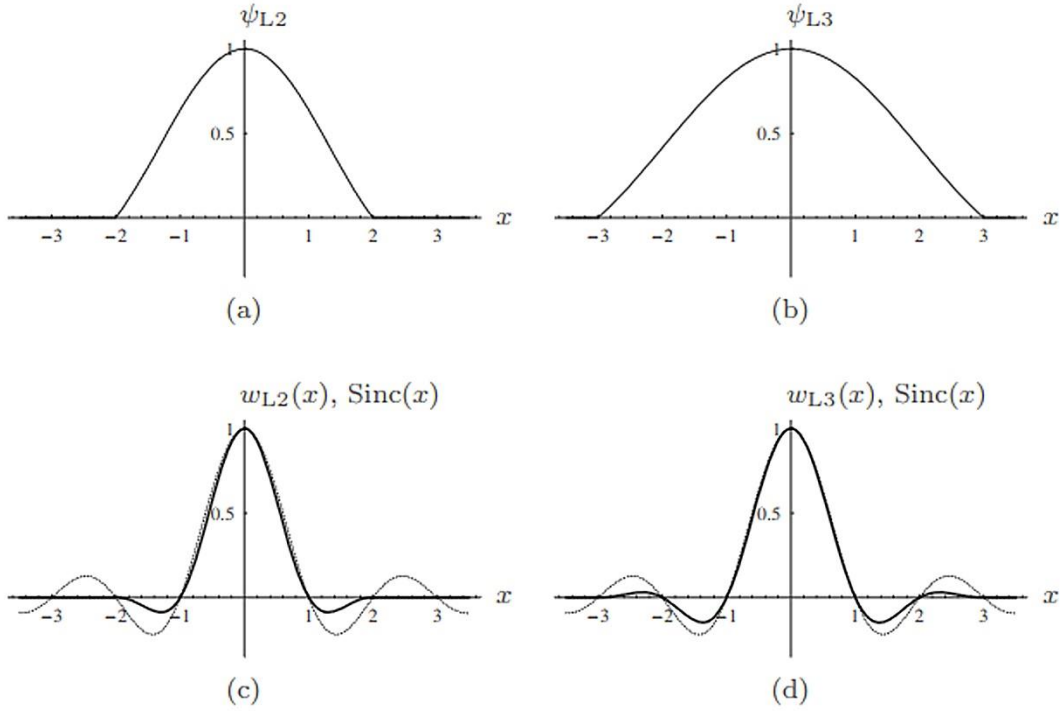

Şekil 2.5: Lanczos pencere fonksiyonları (a, b) ile bunlara karşılık gelen interpolasyon kernelleri (Orijinal sinc fonksiyonu kesikli gösterilmiştir.) [42]

Sonuçlarda keskinliği ve ayrıntıyı artırmak için budanmış sinc fonksiyonu denklem (2.7)'de gösterilen formül yardımıyla kullanılır.

$$L(x) = \begin{cases} sinc(x).sinc\left(\frac{x}{a}\right) & |x| < a \\ 0 & diğer \end{cases} \tag{2.7}$$

Burada *x*, interpolasyon yapılan noktanın merkezi konuma uzaklığıdır, bir diğer ifadeyle normalleştirilmiş mesafesidir. *a* ise Lanczos kernelinin genişlik parametresidir. Bu parametre ile kernel etkisinin etki edeceği uzaklık belirlenir ve genellikle 2 veya 3 gibi tamsayı değerler kabul edilir. *L(x)* formülünde geçen $|x| < a$ koşulu ise teoride sonsuz kabul edilen aralığı sınırlandırmak için kullanılır. Böylece hesaplama işlemlerinin daha pratik olması hedeflenir çünkü *x* değerinin artmasıyla sinc fonksiyonu hızlı bir şekilde sıfıra yakınsar ancak zaten çekirdeğe uzak olan kısımlarda kernelin katkısı çok küçüktür ve bu durum hesaplama maliyetinden kurtulmak için ihmal edilir [39, 43, 44].

Formülde geçen *sinc* fonksiyonu denklem (2.8)'de gösterilmiştir.

$$sinc(x) = \frac{\sin(\pi x)}{\pi x} \tag{2.8}$$

2.1.2.2. Sinir Ağı Temelli Derin Öğrenme Yaklaşımları

İnterpolasyon sonucu oluşan görsellerde sıkça görülen sorunlar arasında yumuşama ve pürüzleşme bulunmaktadır. Sinir ağı yaklaşımları, bu gibi sorunların üstesinden çok daha başarılı bir şekilde gelmektedir.

Süper çözünürlük sorununu uçtan uca tasarlanmış bir yaklaşımla çözüm üreten ilk derin öğrenme tabanlı model Dong ve diğ. [6] tarafından geliştirilen SRCNN (Super-resolution Convolutional Neural Network) adıyla bilinen modeldir. Önerilen yöntem sayesinde tasarlanması gereken özellik çıkarım süreçleri otomatize edilerek öğrenme temelli bir hale getirilmiştir. Düşük çözünürlüklü görseller; SRCNN'de üç aşamalı bir süreçten geçirilerek özellik çıkarımı, yüksek çözünürlüklü öğrenme haritasının oluşturulması ve yüksek çözünürlüklü görüntünün elde edilmesi şeklinde iyileştirilirler. SRCNN, birçok derin öğrenme tabanlı modelin temelini oluşturmaktadır. Ancak uçtan uca öğrenme modelleri, problemin tamamını ele alan bir yaklaşım olduğu için söz konusu problemi modelleyebilecek ağ tasarımları daha karmaşık olmaktadır.

Çoklu Çerçeve Süper Çözünürlük (Multiple Frame Super-Resolution - MFSR) ile birden fazla düşük çözünürlüklü görüntüden yüksek çözünürlüklü bir görüntü oluşturmayı hedeflenir. MFSR, zaman ve mekân bilgilerini bir araya getirerek daha fazla detay elde etmeyi sağlar. Örneğin, Haris ve diğ. [45], video süper çözünürlüğü için tekrarlayan geri projeksiyon ağları (Recurrent Back-Projection Network - RBPN) kullanarak bu yöntemi geliştirmişlerdir. Model içerisinde eğitim verilerinin bozulma fonksiyonu bilindiğinden dolayı bilinen bozulmalı bir modeldir.

Referans Tabanlı Süper Çözünürlük (RefSR) ile düşük çözünürlüklü bir görüntüyü iyileştirmek için ek bir yüksek çözünürlüklü referans görüntü kullanılır. Burada bahsedilen referans görüntü, düşük çözünürlüğe sahip görüntü ile benzer sahnede olan ancak daha yüksek çözünürlüklü bir görüntüyü ifade eder. Referans alınan görüntünün birebir aynı açıdan bir sahne içermesine gerek yoktur, benzer yapıları içermesi yeterli olmaktadır. CrossNet içinde geliştirilen çoklu-ölçek özellik hizalaması (cross-scale wrapping) ile benzer bölgeler tespit edilerek hedef görüntüye uyarlama yapılır. Referans görüntü kullanılarak tek-görüntü süper-çözünürlüğe göre daha iyi sonuçlara ulaşılmıştır [46]. Bozulma fonksiyonu bilindiği için bilinen bozulmalı bir yöntemdir.

Tai ve diğ. [47] çalışmalarında görüntü iyileştirme üzerine odaklanmışlardır. Geliştirdikleri mimari CNN tabanlı olup bellek blokları üzerinde hem kısa hem uzun vadeli bilgi akışı yönetilir. Bu yaklaşım, düşük çözünürlüklü görüntülerdeki gürültü ve bulanıklık ile ilgili sorunları azaltmaya yardımcı olan analitik çözümler ve düzenleme teknikleri ile desteklenmektedir. Ardışık katmanlar arasında bilgi daha uzun süre tutulur, böylece bilgi kaybı ve gradyan sönmesi gibi sorunların azaltılması hedeflenir. Bu süreç, tekrarlı birimler (recursive units) ve kapı birimleri (gate units) ile sağlanmıştır. Tekrarlı birimler ile kısa vadeli temsiller modellenir. Kapı birimleri ile uzun vadeli bellek yönetilir ve bilgi geçişi kontrol edilir.

Pham ve diğ. [48], beyin MR görüntülerinin süper-çözünürlüğü için derin 3 boyutlu evrişimli ağlar ile çalışmışlardır. Çalışmalarında optimizasyon yöntemleri, ağ derinliği, artıklı öğrenme, ağırlık başlatma, filtre sayısı ve boyutu, eğitim yamasının sayısı ve boyutu gibi çok yönlü bir inceleme sunmuşlardır. Birçok ardışık görselden oluşan MR ve tomografi gibi tıbbi görüntüler uzamsal bir bağlam içerisinde olduğundan yüksek doğruluk ve klinik geçerlilik gibi nedenlerle 3 boyutlu CNN'ler tercih edilmektedir.

Hu ve diğ. [49], tek bir model ile farklı büyütme faktörlerinin işlenmesini mümkün hale getiren bir çalışma ortaya koymuşlardır. Geleneksel modellerde her büyütme faktörü için ayrı model tasarımları önerilirken istenilen yükseltme oranına özel olarak filtre ağırlıklarını tahmin eder. Meta-SR adı verilen çalışmaları ile hem tam sayı hem de kesirli büyütme faktörleri uygulanabilmektedir.

Çözünürlük iyileştirme amacıyla sıkça kullanılan derin öğrenme tabanlı yöntemlerden birisi de başarılı sonuçlar üreten Üretken Çekişmeli Ağlar (Generative Adversarial Networks - GAN) ile yapılan çalışmalardır. GAN mimarisinin temel çalışma şekli Şekil 2.6'da göstermiştir. İçeriisnde üretici ve ayrıştırıcı ağ içeren bir sinir ağı olan GAN içerisinde temel kurgu, "sıfır" toplamlı bir oyun şeklinde kurgulanmıştır. Üretici ağ, gerçeğe yakın veriler üretmeyi hedeflerken ayrıştırıcı ağ, kendisine gelen verilerin gerçek olup olmadığını sınıflandırmaya çalışır. Çekişmeli bir şekilde geçen bu süreç sonucunda GAN giderek daha gerçekçi veriler üretmeyi öğrenir [50, 51].

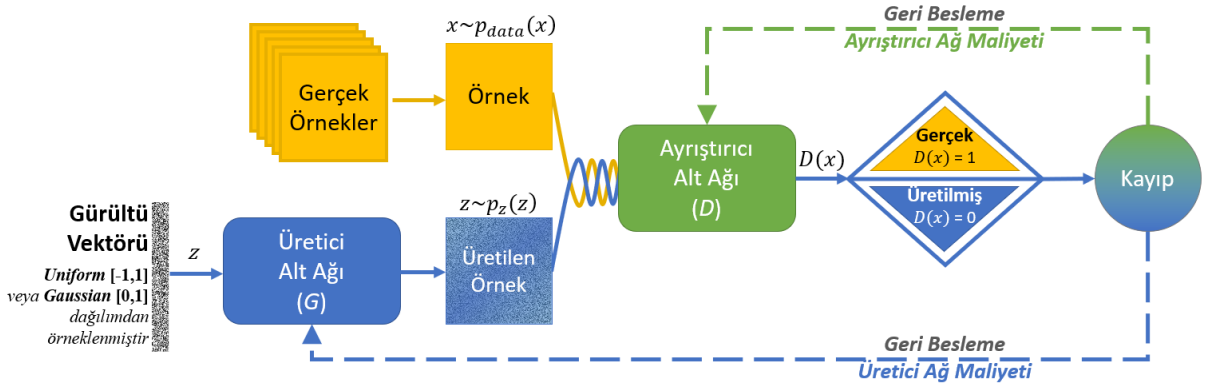

Şekil 2.6: GAN tabanlı sinir ağlarının temel çalışma prensibi [50]

Ledig ve diğ. [52] süper çözünürlük problemine kayıp fonksiyonları açısından yaklaşmışlar ve kayıp fonksiyonu olarak GAN tabanlı bir ağ geliştirmişlerdir. GAN kullanılarak yapılan birçok süper çözünürlük çalışmasına ilham veren SRGAN ile her bir görsele fotoğraf çekimi kalitesinde gerçekçi bir süper çözünürlük işlemi uygulanmıştır. Aynı çalışma kapsamında, derin konvolüsyonel sinir ağının da verimini SRGAN ile karşılaştırmak amacıyla "deep residual network" tabanlı SRResNet isimli bir sinir ağı daha geliştirilmiştir. SRGAN, SRResNet'i temel alır ve onu geliştirerek daha gerçekçi ve keskin görüntüler üretmek için Generative Adversarial Network (GAN) yapısını entegre eder. SRResNet'in aksine, piksel tabanlı benzerlik yerine algısal ve çekişmeli kayıp fonksiyonlarının ağırlıklı toplamıyla elde edilen yeni bir kayıp fonksiyonu kullanılmıştır. SRGAN'ı SRResNet'ten ayıran en önemli yapısal tasarımdan birisi de atlamalı bağlantı kullanılarak geliştirilen "residual block" mimarisidir. Böylece eğitim işlemi kolaylaştırılmasına rağmen daha derin bir ağ tasarımına ulaşılmıştır. Karşılaştırma sonucunda PSNR ve SSIM sonuçlarına bakıldığında, ağın optimize edildiği yitim fonksiyonunun farklılığı sebebiyle daha düşük değerler çıkmasına rağmen GAN tabanlı SRGAN hem SRResNet hem de literatürdeki önceki çalışmalardan daha yüksek ortalama görüş skoru (Mean Opinion Score - MOS) sonuçlarına ulaşmıştır. Buna rağmen kullanım alanlarına bakıldığında, daha kesin sonuçlar gerektiren tıbbi görüntü işleme gibi uygulamalarda doğruluğa odaklanan SRResNet tercih edilirken insan algısına hitap etmesi gereken daha doğal görüntüler gerektiren uygulamalarda SRGAN tercih edilmektedir. Karesel hatayı merkeze alan PSNR gibi metriklerin yetersizliğine dikkat çekerek piksel temelli kayıp fonksiyonları yerine algısal kayıp fonksiyonlarının konması gerektiğini savunarak ve sonuçları insan değerlendiricileriyle de tasdik ederek ortalama görüş skoru (Mean Opinion Score – MOS)'nu da değerlendirmeye alan çalışmayla süper çözünürlük alanında ciddi bir katkı sağlamışlardır.

Wang ve diğ. [32] geliştirdikleri Gelişmiş Süper Çözünürlük Üretici Karşıt Ağlar (Enhanced Super-Resolution GAN - ESRGAN) modeli ile gerçekçi dokuların üretilmesi konusunda önemli bir adım atmışlardır. Çalışmaları ile SRGAN [52]'ın bazı dezavantajlarını gidererek görsel kalitenin artırılmasına yönelik ana bileşenleri kapsamlı bir şekilde incelemektedir. SRGAN ağlarındaki görüntü kalitesini daha da fazla artırmak için hem çekişmeli yitim hem de algısal yitim fonksiyonları ve ağ üzerinde iyileştirmeler yapmışlardır. SRGAN'daki artıklı (residual) bloklar yerine daha yoğun bağlantılı artıklı bloklar (Residual-in-Residual Dense Block - RRDB) kullanmışlardır. Toplu normalizasyon (batch normalisation) adımının kaldırılmasıyla ağın daha kararlı hale geldiğini gözlemlemişlerdir. Çekişmeli kayıp fonksiyonu olarak Relativistic GAN (RaGAN) ismini verdikleri, hangi görüntünün daha gerçekçi olduğunu tespit etme konusunda daha isabetli sonuçlar veren bir ağ modeli kullanmışlardır. Ön aktivasyon temelli ReLU öncesi özellikleri kullanan algısal kayıp fonksiyonunun da ağın başarısına önemli bir katkısı olduğu belirtilmiştir.

Zhang ve diğ. [53] tarafından önerilen Derin Kalıntı Kanal Dikkat Ağları, düşük çözünürlüklü bir görüntüden yüksek çözünürlüklü bir görüntü elde etme sorununu ele almıştır. Bu yöntem, çeşitli bilgisayarla görme uygulamalarında, özellikle güvenlik ve tıbbi görüntüleme alanlarında etkili sonuçlar vermektedir. Eğitim sırasında bozulma fonksiyonu bilindiğinden bilinen bozulmalı yöntemler sınıfındadır.

Liu ve Chen [54], SRGAN [52] temel alınarak ve "Residual Channel Attention Block" yaklaşımıyla geliştirilen ilgi mekanizması ile ağ derinliğini artırarak yüksek frekanslı özelliklerin daha iyi bir şekilde yakalanmasını sağlamışlardır. SRGAN üzerindeki yığın normalleştirme katmanları, ESRGAN [32] yaklaşımında da olduğu gibi performansı iyileştirmek amacıyla kaldırılmıştır. Yitim fonksiyonunda yapılan düzenleme ile de görsel üzerindeki gürültülerin etkisi azaltılmıştır. Çalışmanın en önemli noktası Residual-in-Residual Dense Block (RRDB) adını verdikleri yöntem sayesinde SRGAN'dan çok daha iyi bir şekilde doğal görsellerdeki desenler üzerinde çalışarak anlamlı sonuçlara ulaşılmıştır.

Lim ve diğ. [55] geliştirdikleri Enhanced Deep Super-Resolution Network (EDSR) ve Multi-Scale Deep Super-Resolution Network (MDSR) ile ağın verimliliğini artırma konusuna odaklanmışlar, toplu normalizasyon katmanını kaldırmışlar ve daha derin kalıntılı bloklar kullanarak ağın yapısını genişletmişlerdir. Böylece hem daha iyi öğrenme sağlanmış hem de düşük çözünürlükteki görsellerin detayları daha iyi elde edilmiştir. Bu yaklaşım ile ciddi bir

performans artışı sağlanmış, önceki yaklaşımlara göre PSNR ve SSIM başarı değerleri açısından öne geçmiştir. EDSR ile tek bir yükseltme faktörüne odaklanılmış, MDSR ile birden çok yükseltme faktörü ile çalışabilen bir model ortaya çıkarılmıştır. Başarı bakımından, MDSR daha geride kalsa da parametre sayısı, genelleme yeteneği ve hesaplama verimliliği açısından daha kullanışlıdır.

Kim ve diğ. [56] tarafından SRCNN'den sonra geliştirilen ve Very Deep Super-Resolution Network (VDSR) olarak adlandırılan çalışma, daha fazla katman (20 katman) içerdiği için daha derin olarak da ifade edilen bir ağ yapısı kullanarak daha yüksek doğruluk değerlerine ulaşmayı başarmıştır. Ağırlık başlangıç değerleri ve öğrenme oranlarının hassas bir şekilde ayarlanmasıyla gradyan sönmesi sorunu önemli ölçüde aşılmıştır. VDSR'ın bir diğer yeniliği ise farklı büyütme faktörleriyle yüksek bir uyum içerisinde çalışabilmesidir, her bir büyütme faktörü için ayrı bir modellemeye gerek duyulmamaktadır. Katman bakımından derinliği yüksek bir ağ mimarisi olmasına rağmen artıklı öğrenme sayesinde hızlı bir yakınsama sağlar.

Li ve diğ. [57] tarafından tasarlanan, küçük boyutlu nesne tanıma problemine çözüm getiren Perceptual GAN yapısı ile sınırı veya silueti belli ancak mevcut boyutu sebebiyle yorumlandığında hatalı sonuçların ortaya çıkması muhtemel durumlarda söz konusu küçük boyutlu nesnelere, daha iyi nesne tanıma uygulaması geliştirilebilmesi amacıyla önce çözünürlük yükseltme işlemi uygulanmış, ardından trafik işaret levhaları üzerinde çalışılmıştır.

Wu ve diğ. [58] tarafından geliştirilen SRPGAN ile piksel temelli yitim metotlarındaki kısıtlamaların üstesinden gelmek için hem üretici hem ayırt edici ağ için yitim fonksiyonları tasarlanmıştır. 4x ve 8x gibi yükseltme işlemlerinde daha keskin ve doğal görüntü kalitesine erişilmiş ve yüksek SSIM (Structural Similarity Index) sonuçlarına ulaşılmıştır. Yapılan bu çalışma süper çözünürlük alanında sadece sayısal sonuçlara odaklanmak yerine insan algısını da hesaba katan yitim fonksiyonlarını kullanması sebebiyle oldukça önemlidir.

Motamed ve Khalvati [59] Multi-class GAN (MCGAN) adı verilen çalışmada tek bir model kullanılarak birden fazla sınıflandırma yapılması tasarlanmıştır. Böylece metin, yüz, mimari görselleri için farklı modeller veya ağ yapıları kullanmak yerine ortak bir ağ tasarımı kullanarak çözüm bulmak amaçlanmıştır. Sınıflara ait öğrenilmesi gereken özelliklerle hem paylaşımlı hem de sınıfların kendilerine ait özellikleri öğrenilir. Paylaşılan özelliklerin ortak bir şekilde öğrenilmesi sayesinde parametrelerin sayısı önemli ölçüde azaltılabilmiştir, böylece

yöntem hesaplama açısından daha verimli hale gelmiştir. Aynı model hem görüntü hem de metin sınıflandırma yapabildiği için farklı görevler eş zamanlı gerçekleştirilebilir. Her sınıf için ayrı model eğitimi yerine tek model eğitimi yapıldığından eğitim süreci kolaylaşmaktadır. Tasarımda tek bir üretici ağ olmasına rağmen sınıf sayısı kadar ayrıştırıcı ağ bulunmaktadır. Ayrıştırıcı ağlar eşzamanlı olarak güncellenir.

Bai ve diğ. [60], küçük ve bulanık yüz görüntüleri sorunu üzerinde yoğunlaşmışlardır. Önerdikleri GAN tabanlı yaklaşımda süper çözünürlük bir ön işlem olarak kullanılmıştır. Üretici ağ, yüz görüntülerini süper çözünürlük ağı ile öncelikle büyütür ve ardından iyileştirme ağı ile detaylar belirginleştirilir. Ayıt edici ağın görevi ise gerçek ve sahte görüntüleri ayırt etmenin yanında yüz görüntülerini ve yüz olmayan görüntüleri sınıflandırmaktır. Böylece üretici ağ, yeni ve daha net yüzler üretme konusunda teşvik edilir. Bu model, WIDER FACE veri seti üzerinde test edilmiş ve tatmin edici sonuçlara ulaşarak görsellerdeki küçük ve net olmayan yüzlerin tespiti konusunda yeni bir bakış açısı kazandırmıştır.

Huang ve diğ. [61] yaptıkları çalışma ile Face Conditional Generative Adversarial Network (FCGAN) adıyla geliştirilen mimari ile insan yüzleri üzerinde 4x ölçekli süper çözünürlük uygulaması gerçekleştirmişlerdir. Oluşturulan ağ yapısı ile hizalama, anlamsal bilgi girişi gibi herhangi bir ön işleme gerek duyulmamaktadır. Atlamalı katman bağlantıları (skip connections) içeren bir otomatik kodlayıcı içeren yapısı ile eğitim sürecini kolaylaştırır ve özelliklerin daha etkili bir şekilde iletilmesini mümkün hale getirir. Ayrıca üretilen bu modelin şapka ve gözlük gibi aksesuarların varlığından etkilenmediği, yüz ifadeleri ve aydınlatma koşullarındaki değişimlere karşı da uyumlu olduğu ifade edilmiştir.

Yand ve diğ. [62], görsellerdeki küçük ve detayları belli olmayan insan yüzleri üzerinde yaptıkları çalışmalarında bulanık insan yüzlerini, artırım ve arıtım alt ağlarını kullanarak daha detaylı hale getirmişlerdir. Yapılan bir diğer yenilik ise ayrıştırıcı ağa kazandırılan gerçek ve üretilen veri ayırma yeteneğinin yanında, doğal görseller kullanılması sebebiyle ilgili görselde örneklenen alanın yüz olup olmadığını ayırabilecek becerinin geliştirilmesidir. Bu çalışmada kullanılan veri seti, doğrudan insan yüzleri üzerinde çalışılması için geliştirilmemiş olması sebebiyle ayrıştırıcı ağda bu işlemin yapılması zorunlu hale gelmiştir.

Zhang ve diğ. [63] tarafından yapılan süper çözünürlük yaklaşımlarındaki bulanıklık ve görsel üzerindeki nesnelerin kenarlarında görülen yumuşak detay sorununu gidermek için GAN tabanlı önerdikleri yöntemde algısal yitim fonksiyonu kullanılmış, üretici ve ayrıştırıcı ağ ayrı

ayrı optimize edilmiştir. Model MOS metriğiyle değerlendirilmiştir. PSNR gibi metriklerle değerlendirilen geleneksel yöntemlerin kalite bakımından eksik kaldığı vurgulanmış ve önerilen yöntemin, farklı ve yüksek büyütme faktörlerinde bile iyi sonuçlar verebildiğini göstermişlerdir. Çalışma daha çok yüz görüntülerine odaklanmış ve CelebA veriseti üzerinde çalışılmıştır. PSNR gibi metriklerle değerlendirilen geleneksel yöntemlerin kalite bakımından eksik kaldığı vurgulanmış ve önerilen yöntemin, farklı ve yüksek büyütme faktörlerinde bile iyi sonuçlar verebildiğini göstermişlerdir.

Sharma ve Kumar [64] Üretici ağ üzerinde yaptığı güncelleme ile dikkat çeken "Super Resolution with Inception Network" (SRINet) isimli ağ tasarımında doğrusal filtreler yerine ağın derinliğini artırmak için daha karmaşık filtreler kullanırken daha fazla hesaplama zamanına ihtiyaç duymamaktadır. İki aşamalı yükseltme faktörü ile birlikte yoğun atlamalı bağlantı (dense skip connection) yaklaşımı, üretici ağ üzerinde yapılan önemli değişikliklerden biri olmuştur.

Liang ve diğ. [34] Görüntü iyileştirme, renkli ve gri tonlamalı görsellerde gürültü arındırma, JPEG sıkıştırma dokusu azaltma gibi alanlarda iyi sonuçlar veren SwinIR isimli çalışmada kalıntılı (residual) Swin Transformer katmanları kullanılmıştır. Önerilen model, üç ana aşamadan geçilerek süper çözünürlük uygular. Öncelikle kenarlar, köşeler, doku, renk gibi düşük seviye özellikler çıkarılır. Ardından derin özellik çıkarımı, kalıntılı Swin Transformer katmanları aracılığıyla gerçekleştirilir. Bu katmanlar, yerel dikkat mekanizmaları sayesinde daha detaylı bir işleme gerçekleştirebilir. Son olarak derin özellikler yeniden yapılandırılır ve görsel oluşturulur. Klasik transformer tabanlı yöntemlerde daha genel bir dikkat mekanizması kullanılır, piksellerin tüm görüntü ile ilişkisi kurulurdu ancak bunun sonucunda daha fazla parametre ve beraberinde daha yüksek hesaplama karmaşıklığı getirirdi. Bu çalışmada küçük ve sabit boyutlu pencereler kullanılarak dikkat mekanizması yerelleştirilmiş, parametre sayısı azaltılmış ve hesaplama yükü de buna bağlı olarak düşürülmüştür. Bunun yanında klasik transformer modellerinden ayrılan en büyük özellik, kalıntılı katmanların kullanılmasıyla katman paylaşımı ve parametrelerin yeniden kullanımının sağlanmasıdır.

2.2. RENK UZAYLARI

Renk uzayları, bir rengin elde edilmesinde kullanılabilecek bileşenleri tanımlamak amacıyla geliştirilmiş, renkleri betimleyen matematiksel modellerdir. Görüntünün işleneceği ya

da basılacağı ortamın özelliklerine göre uygun bir renk uzayının seçilmesi, gerçeğe en yakın renklerin elde edilmesi açısından büyük önem taşımaktadır [65].

Diaz ve diğ. [66], RGB renk uzayı ile çalışıldığında, aynı görüntünün farklı cihazlarla elde edilmesi durumunda verilerin farklılık gösterebileceğini belirtmiş ve bunun görüntü işleme süreçlerinde bazı sorunlara yol açtığını vurgulamışlardır. Bu nedenle, Uluslararası Aydınlatma Komisyonu (Commission Internationale de L'Éclairage – CIE), cihaz kalibrasyon protokollerini kolaylaştırmak amacıyla CIE-XYZ adlı standart bir renk uzayı tanımlamıştır. Bu standardizasyona ek olarak, insan görsel sisteminin avantajlarını dijital ortama uyarlamak üzere CIELab renk uzayı geliştirilmiştir.

Wang ve diğ. [67] gerçekleştirdikleri çalışmada, RGB renk uzayının diğer renk uzaylarına kıyasla daha sık kullanıldığını belirtmişler ve önceki modellerde YCbCr (veya YCC) renk uzayının Y bileşeni üzerinde yapılan iyileştirmelere değinmişlerdir. RGB dışındaki renk uzaylarında yer alan aydınlık (luminance) ekseni kullanılarak eğitilen modellerin, başarı oranı üzerinde anlamlı farklar yaratabileceği ortaya konmuştur [6, 68, 69]. John ve diğ. [67] ise YCbCr ve CMYK renk uzaylarının daha iyi PSNR sonuçları ürettiğini göstermiş; ayrıca çözünürlük iyileştirme süreçlerinde CIELab renk uzayının da çözünürlük iyileştirme çalışmalarında kullanılabileceğini ifade etmişlerdir.

Tez çalışması kapsamında, RGB ile karşılaştırılarak incelenen renk uzayları akromatik eksene sahip olmaları açısından YCbCr ve CIELab olarak seçilmiştir.

2.2.1. RGB

RGB renk uzayı kırmızı (red), yeşil (green) ve mavi (blue) renklerinin baş harflerinden türetilmiştir. Commission Internationale de l'Éclairage (CIE) tarafından 1931 yılında standart hale getirilmiştir ancak bunun öncesinde trikromatik (3-renkli) renk teorisi 1802 yılında Thomas Young [70] tarafından ortaya atılmış, 1852 yılında Hermann von Helmholtz [71] tarafından geliştirilmiştir. Bu teori, insan gözünün 3 farklı ışık dalga boyunu algılayan fotoreseptörlerin varlığına dayandırılmıştır [72].

RGB renk uzayının kullanımı, özellikle dijital ekranların varlığı sebebiyle oldukça yaygınlaşmış, matematiksel modellemesinin kolaylığı ve diğer renk uzaylarına kolaylıkla dönüştürülebilmesi, benimsenmesindeki en büyük destek noktası olmuştur. Bu renk uzayının her bir renk bileşeni (kırmızı, yeşil ve mavi) 8 bit derinliğinde olduğundan [0, 255] kapalı

aralığında 2^8 = 256 farklı renk tonundan oluşmakta, üç renk bileşeni olduğundan dolayı da toplamda 256^3 = 16.777.216 adet farklı renk modellenebilmektedir [43]. 8-bit renk derinliği insan gözünün algı kapasitesine kıyasla oldukça yeterli oluşu, donanımsal açıdan kolay işlenebilir olması (1 byte = 8 bit) ve hesaplama maliyetinin en uygun seviyede tutulabilmesi amacıyla yeterli görülmüş ve RGB üzerine geliştirilen ilk standart bu şekilde tanımlanmıştır [73].

2.2.2. YCbCr

YCbCr, renkli görüntülerde renk bilgisini temsil etmek için kullanılan bir renk uzayı modelidir. RGB (kırmızı, yeşil, mavi) renk uzayından türetilmiştir ve özellikle dijital video, TV yayınları, JPEG/MPEG sıkıştırmaları gibi medya uygulamalarında yaygın olarak kullanılır. Bu nedenle, bu iki renk modeli arasında dönüşüm kaçınılmazdır. RGB'den YCbCr renk uzayına dönüşüm denklem (2.9)'da, YCbCr'den RGB'ye dönüşüm ise denklem (2.10)'da gösterilmiştir [69, 70].

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 0{,}299 & 0{,}587 & 0{,}114 \\ -0{,}169 & -0{,}331 & 0{,}499 \\ 0{,}499 & -0{,}418 & -0{,}0813 \end{bmatrix} \text{x} \begin{bmatrix} R \\ G \\ B \end{bmatrix} + \begin{bmatrix} 0 \\ 128 \\ 128 \end{bmatrix} \tag{2.9}$$

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} 1 & 0 & 1{,}402 \\ 1 & -0{,}344 & -0{,}714 \\ 1 & 1{,}772 & 0 \end{bmatrix} \text{x} \begin{bmatrix} Y \\ Cb - 128 \\ Cr - 128 \end{bmatrix} \tag{2.10}$$

Luminance (Y) bileşeninin ayrı işlenebilir olması, çözünürlük iyileştirme ve sıkıştırma uygulamalarında büyük kolaylık sunar. Bu renk uzayında görüntü bileşenleri Y (aydınlık), Cb (mavi farkı), Cr (kırmızı farkı) bileşenlerine ayrılmıştır. [69].

2.2.3. CIELab

CIELab renk uzayı (CIE L*a*b* olarak da ifade edilir.) renk uzayı, algısal doğruluk üzerine inşa edilmiştir. RGB renk uzayındaki sayısal farklar, insan gözünün algılama kapasitesindeki sınırlılık nedeniyle tam olarak hissedilemez. Bu yüzden CIELab renk uzayı, sayısal farkları algısal fark olacak şekilde kurgulanmıştır. İki renk arasındaki fark ΔE ile ölçülür. ΔE hesaplaması için çeşitli formüller mevcuttur. İlk hesaplama, 1976 yılında CIE tarafından denklem (2.11)'de tanımlandığı haliyle, Öklid mesafesi kullanarak hesaplanır [74]. Bu formül, hesaplama açısından oldukça basittir ancak algısal doğruluk sınırlıdır. Bu formülde L*, a* ve b* bileşenleri, CIELab renk uzayı eksenlerini ifade etmektedir.

$$\Delta E_{76} = \sqrt{(L_1^* - L_2^*)^2 + (a_1^* - a_2^*)^2 + (b_1^* - b_2^*)^2} \tag{2.11}$$

Denklem (2.11)'e göre kullanılan değişkenler şu şekildedir:

- L*: Lightness (aydınlık) bileşeni
- a*: Yeşil–Kırmızı ekseni
- b*: Mavi–Sarı ekseni

İnsan algısına göre daha iyi sonuçlar veren bir diğer hesaplama, yine CIE tarafından 1995 yılında denklem (2.12)'de görüldüğü gibi tanımlanmıştır [75]. ΔE_{76}'ya göre insan algısına daha yakın sonuçlar verir.

$$\Delta E_{94} = \sqrt{\left[\left(\frac{\Delta L*}{k_L \cdot S_L}\right)^2 + \left(\frac{\Delta C*}{k_C \cdot S_C}\right)^2 + \left(\frac{\Delta H*}{k_H \cdot S_H}\right)^2\right]} \tag{2.12}$$

Denklem (2.12)'de geçen parlaklık (ΔL*) denklem (2.13)'te, renk doygunluğu (ΔC*) denklem (2.14)'te ve renk tonu (ΔH*) denklem (2.15)'te gösterilmiştir.

$$\Delta L^* = L_1^* - L_2^* \tag{2.13}$$

$$\begin{aligned} C^* &= a^{*2} + b^{*2} \\ \Delta C^* &= C_1^* - C_2^* \end{aligned} \tag{2.14}$$

$$\Delta H^* = \sqrt{(\Delta a^*)^2 + (\Delta b^*)^2 - (\Delta C^*)^2} \tag{2.15}$$

Denklem (2.12)'de bahsedilen k_L, k_C ve k_H sabitleri parametrik tolerans faktörleridir ve uygulamaya göre değişiklik gösterir. S_L, S_C ve S_H değerleri ise algısal dengeleme faktörü olarak kullanılan ölçek fonksiyonlarıdır ve renk farklarının normalizasyonu için kullanılır. Genellikle denklem (2.16)'da gösterildiği gibi hesaplanır.

$$\begin{aligned} S_L &= 1 \\ S_C &= 1 + 0.045 * C_1^* \\ S_H &= 1 + 0.015 * C_1^* \end{aligned} \tag{2.16}$$

İnsan gözünün renk farkı algısına en yakın sonucu ölçen ΔE formülü, yine CIE tarafından 2000 yılında tanımlanmıştır. Denklem (2.17)'de gösterilen formülasyonda insan algısına göre yapılan normalizasyonlar dikkat çeker. $\Delta L'$ ile iki renk arasındaki parlaklık farkının normalizasyonu denklem (2.18), $\Delta C'$ ile normalize edilmiş doygunluk denklem (2.19)'da ve $\Delta H'$ ile normalize edilmiş ton farkları da denklem (2.20)'de tanımlandığı haliyle artık hesaplamaya dahil edilmiştir. Böylece insan algısının limitleri de formül içerisinde tanımlanmıştır. Bunların yanında R_T ile ton ve doygunluk arasındaki farkın dönüşüm derecesi sayesinde düzeltme faktörü uygulanır [76, 77].

$$\Delta E_{00} = \sqrt{\left(\frac{\Delta L'}{(k_L \cdot S_L)}\right)^2 + \left(\frac{\Delta C'}{(k_C \cdot S_C)}\right)^2 + \left(\frac{\Delta H'}{(k_H \cdot S_H)}\right)^2 + R_T \cdot \left(\frac{\Delta C'}{(k_C \cdot S_C)}\right) \cdot \left(\frac{\Delta H'}{(k_H \cdot S_H)}\right)} \tag{2.17}$$

$$\Delta L' = L_2 - L_1 \tag{2.18}$$

$$\begin{aligned} a_1' &= (1+G) * a_1 \\ a_2' &= (1+G) * a_2 \\ C_1' &= \sqrt{(a_1')^2 + b_1^2} \\ C_2' &= \sqrt{(a_2')^2 + b_2^2} \\ \Delta C' &= C_2' - C_1' \end{aligned} \tag{2.19}$$

$$\begin{aligned} h' &= \arctan\left(\frac{b}{a'}\right) \\ \Delta h' &= h_2' - h_1' \\ \Delta H' &= 2 * \sqrt{C_1' * C_2'} * sin\left(\frac{\Delta h'}{2}\right) \end{aligned} \tag{2.20}$$

ΔE_{76} ile sadece geometrik fark hesaplanırken ΔE_{94} ile algısal ölçüm mekanizması geliştirilmiştir. Böylece geliştirilen ölçüm ile insan algısının sınırları dışındaki sonuçlara da yanıt vermekte ve dolayısıyla insan gözünün algılayamadığı tonlar hesaplamaya etki etmeye devam etmektedir. ΔE_{00} ile insan algısının sınırları da normalizasyon yöntemiyle formüle dahil edilmiş ve böylece, özellikle mavi tonlarda ortaya çıkan farklılık giderilmiştir [77].

ΔE = 1 ise, insan gözünün aradaki farklı anlayamayacağı varsayılır. Bu değer 2-3 aralığında ise fark edilebilir seviyede olduğunu ifade eder. Şekil 2.7'da görüldüğü gibi, bu değer arttıkça renkler birbirinden daha farklı görünürler.

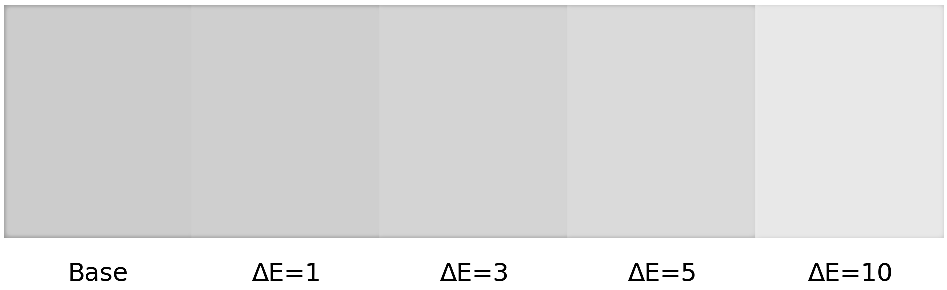

Şekil 2.7: CIELab renk uzayında farklı ΔE değerleri ile algısal ayırt edilebilirlik

2.3. VERİ SETLERİ

Çözünürlük iyileştirme çalışmalarında sıklıkla kullanılan ve bu tez çalışması kapsamında da yararlanılan veri setleri bu başlık altında tanıtılmıştır. Bahsedilen veri setleri, algoritmaların matematiksel performanslarının yanında görsel değerlendirmelerine de imkân vermektedir.

Tablo 2.1 incelendiğinde veri setlerinin içerdiği görüntü sayıları, ortalama çözünürlük değerleri, görsellerin çözünürlüklerine ve adetlerine göre hesaplanmış entropi değerleri verilmiştir. Set5 veri setinde çok düşük çeşitlilik bulunmaktadır. Set14 veri seti biraz daha çeşitlidir ancak sadece basit testleri gerçekleştirmek ve hızlı sonuca ulaşmak için kullanılabilir. BSD100 veri setinde farklı çözünürlükte doğal sahneler vardır. Urban100 veri setinde daha karmaşık sahneler, daha büyük çözünürlükte görsellere rastlanır ancak buna rağmen sınırlı sayıda varyasyona sahiptir. Bu veri setleri içerisinde en yüksek çeşitlilik DIV2K veri setinde görülmektedir. Hem farklılık hem de yüksek çözünürlük anlamında, bahsedilen veri setleri arasında gerçek dünyaya en yakın veri setidir.

Tablo 2.1: Kullanılan veri setleri ve istatistiki veriler

Veriseti	Görüntü Sayısı	Ortalama Çözünürlük	Çeşitlilik Değerleri (Entropi)
Set5	5	288 x 288	1,61
Set14	14	276 x 276	2,64
BSD100	100	321 x 481	4,61
Urban100	100	1024 x 768	4,59
DIV2K (açık erişim)	900	2040 x 1080	6,67

Çözünürlük değerleri bakımından farklılıkların ortaya konulduğu bu analizde, içerdikleri görsellerin boyutları bakımından birbirinden en çok ayrışan veri setinin DIV2K veri seti olduğu görülmektedir. Entropi hesaplanırken her bir görseldeki toplam piksel sayısı elde edilmiş ve bu değerler üzerinden denklem (2.21)'de verilen formül ile hesaplama yapılmıştır [78].

$$H(x) = -\sum_{i=1}^{n} p_i \log\left(p_i\right) \tag{2.21}$$

Entropi diğer bir deyişle "safsızlık" ölçüsüdür, küme içindeki değerlerin birbirinden ne kadar ayrıştığını ortaya koyar. Değer yükseldikçe verilerin farklılaşma miktarı, yani çeşitliliği artar.

Birçok veri setinin hazırlanmasında bikübik indirgeme yöntemi kullanılır. Bu yöntemin sıkça kullanılma nedenlerinin başında kontrol edilebilir bir bozulma sunması gelmektedir. Örneğin, x4 indirgeme faktörü için birbirine komşu 16 pikselin ortalama değerleri alınır ve bu değerler, aynı indirgeme faktörü ve aynı görsel kullanıldığında hep aynı düşük çözünürlüklü görseli üretecektir. Geliştirilen metotların karşılıklı değerlendirilebilmesi amacıyla gürültü ve sıkıştırma bozulmaları gibi sorunların bertaraf edilmesi amacıyla bikübik indirgeme sıklıkla kullanılmıştır. Rad ve diğ. [79], gerçek dünya görüntü bozulmalarındaki karmaşıklık sebebiyle bikübik indirgeme yöntemiyle elde edilen düşük ve yüksek çözünürlüklü görüntü çiftleri sayesinde daha kararlı ve genellenebilir süper çözünürlük modelleri geliştirilebildiğini savunmuşlardır.

2.3.1. Set5

Set5 [80] veri seti, süper çözünürlük çalışmalarının performans ölçeklendirmesi için kullanılan ilk dönem veri setleri arasında yer almaktadır. Set5 veri setinde birbirinden farklı sahnelere ait 5 adet görsel bulunmaktadır. Seçilen görseller, insan gözünün doku ve kenar algısını test edecek şekilde seçilmiştir ancak Set14 veri setine göre daha az sayıda ve çözünürlükte görseller içerir, böylece geliştirilen yöntemlerin hızlı analizlerinde ön plana çıkmaktadır. Set5 veri seti içerisindeki görsellerin genişlik, yükseklik ve adetlerine göre dağılım grafiği Şekil 2.8'de verilmiştir.

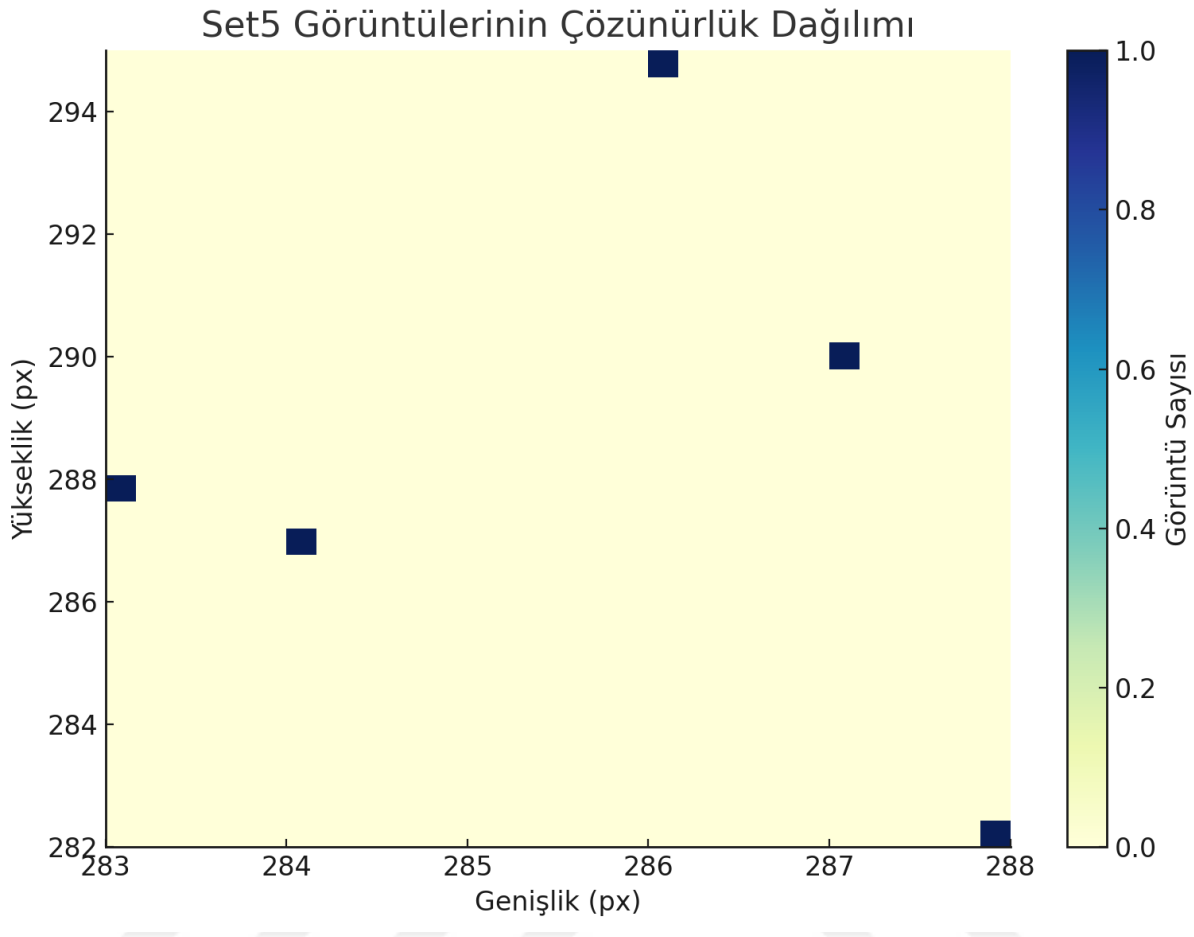

Şekil 2.8: Set5 veri seti içerisindeki görsellerin çözünürlük-frekans dağılımı

2.3.2. Set14

Set14 [81] veri setinde birbirinden bağımsız 14 adet görsel bulunmaktadır. Kenar belirginliği ve doku yoğunluğu farklarını net bir şekilde ortaya koyabilmek amacıyla görseller çeşitlendirilmiştir. Girdi olarak kullanılan düşük çözünürlüklü görseller, bikübik indirgeme yöntemiyle x2, x3 ve x4 indirgeme faktörleriyle elde edilirler. Set14 veri seti içerisindeki görsellerin genişlik, yükseklik ve adetlerine göre dağılım grafiği Şekil 2.9'da verilmiştir.

Kronolojik olarak bakıldığında, Set5 veri setinden daha önce ortaya çıkmıştır.

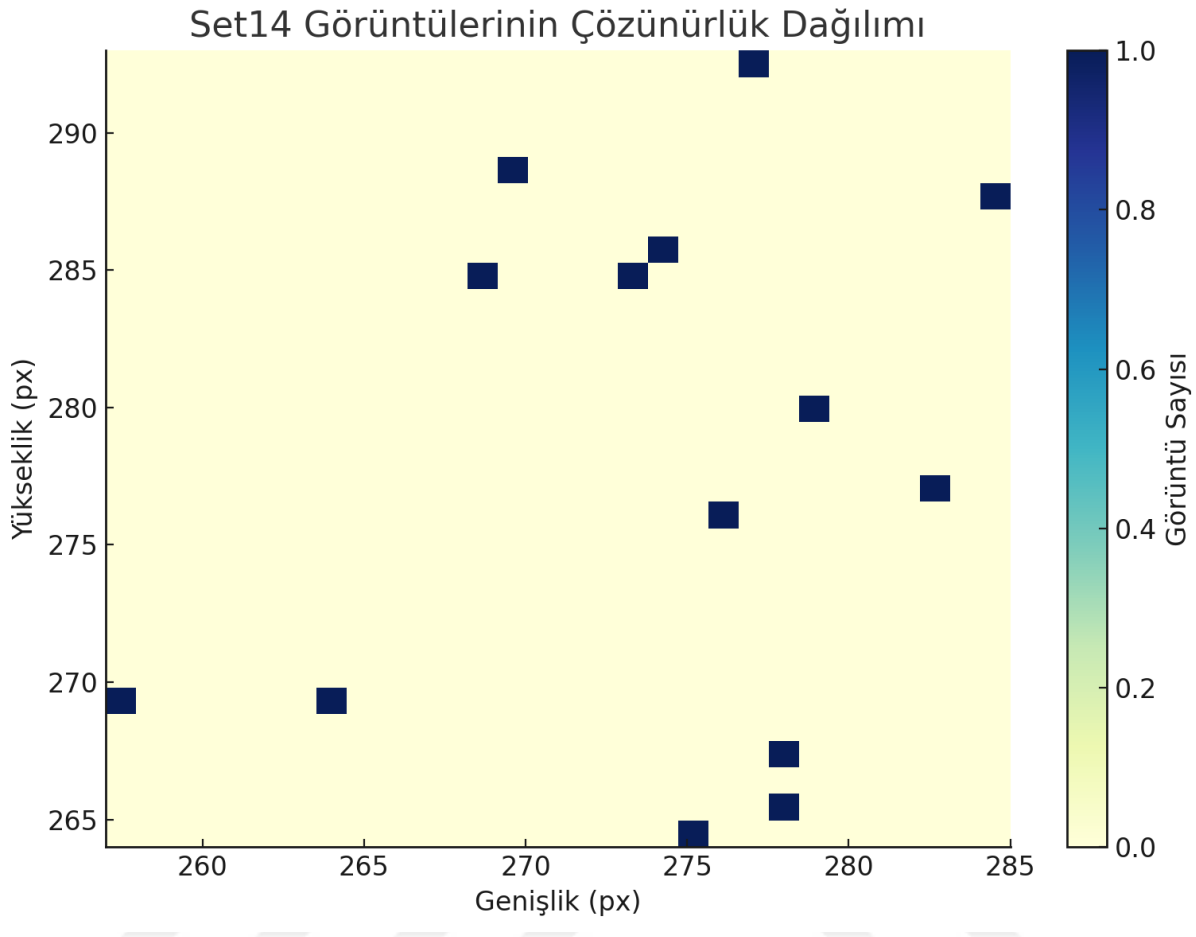

Şekil 2.9: Set14 veri seti içerisindeki görsellerin çözünürlük-frekans dağılımı

2.3.3. BSD100

Herhangi bir teması olmayan, birbirinden farklı alanlarda çekilmiş 100 farklı sahneye ait fotoğraflardan oluşmaktadır. Görüntü bölütleme ve sınır tespit algoritmalarının test edilebilmesi için geliştirilmiştir. Orijinal hali ile olan BSD300 [82] veri setinden türetilmiştir ancak süper çözünürlük yöntemlerini değerlendirmek için, bu görseller arasından seçilerek oluşturulan BSD100 veri seti geniş anlamda kabul görmüştür. Set5 ve Set14'e göre daha fazla sayıda ve yüksek çözünürlükte görsel barındırır, bu açıdan bakıldığında gerçek dünya problemlerini diğer iki veri setine göre daha iyi bir şekilde temsil edebilir. x2, x3 ve x4 faktörleriyle bikübik indirgeme kullanılarak düşük çözünürlüklü görseller üretilmiştir. Gerçek dünya problemlerini daha iyi temsil edebilmek için kullanılmaktadır [82]. BSD100 veri seti içerisindeki görsellerin genişlik, yükseklik ve adetlerine göre dağılım grafiği Şekil 2.10'da verilmiştir.

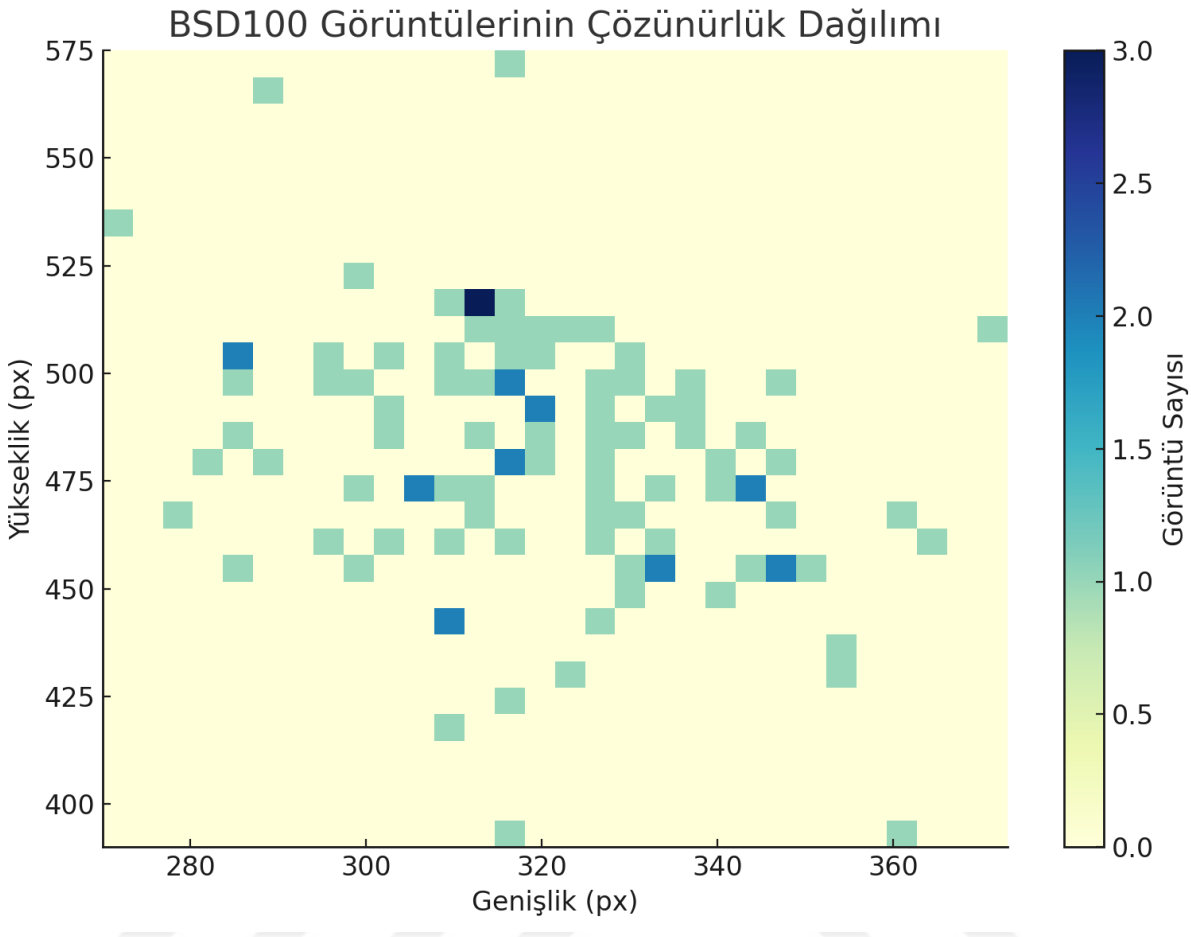

Şekil 2.10: BSD100 veri seti içerisindeki görsellerin çözünürlük-frekans dağılımı

2.3.4. Urban100

Şehir manzaraları teması dahilinde 100 adet görsel içeren bir veri setidir. Bu veri setinde mimari yapılar, merdivenler, pencereler, çatılar ve bazı görsellerde ise mimari yapılar ve insanlar gibi unsurlar göze çarpar. Bu veri seti ile geliştirilen yöntemlerin, geometrik mimari yapı süper-çözünürlüğü alanında başarısı test edilir. Set5 ve Set14 veri setlerine kıyasla daha karmaşık ve yüksek çözünürlüklü içeriklere sahiptir. x2, x3 ve x4 faktörleriyle bikübik indirgeme kullanılarak düşük çözünürlüklü görseller üretilmiştir [83]. Urban100 veri seti içerisindeki görsellerin genişlik, yükseklik ve adetlerine göre dağılım grafiği Şekil 2.11'da verilmiştir.

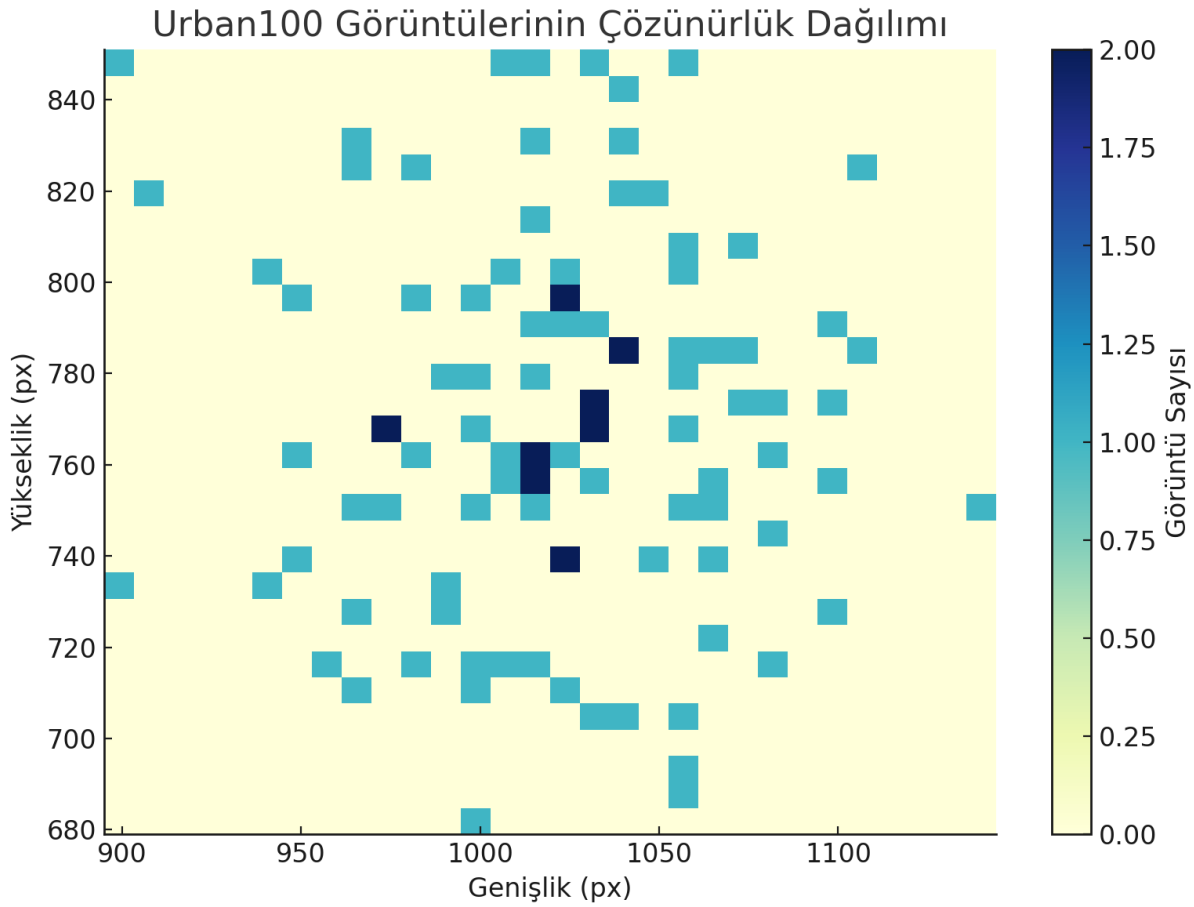

Şekil 2.11: Urban100 veri seti içerisindeki görsellerin çözünürlük-frekans dağılımı

2.3.5. DIV2K

Yüksek kaliteli eğitim ve değerlendirme görsellerinden oluşur. 1.000 adet görsel içerir. Görsellerin tamamı 2K çözünürlüğe yakındır ve gerçek dünya problemlerini temsil konusunda önceki veri setlerinden daha başarılıdır. JPEG sıkıştırma bozulmalarını bertaraf edebilmek için diğer veri setleri gibi JPEG yerine PNG formatında oluşturulmuştur. x2, x3, x4 ve x8 indirgeme faktörlerini içerir. Görseller genellikle 1920x1080 ila 2100x1150 arasında değişmektedir. Önceki veri setlerine göre bilinmeyen indirgeme yöntemi ("unkown" etiketli görseller) içeren düşük-çözünürlüklü görsellere sahip olduğu için gerçek dünya problemlerini temsil etme konusunda bahsedilen diğer veri setlerine göre daha gerçekçidir. DIV2K veri seti içerisindeki görsellerin genişlik, yükseklik ve adetlerine göre dağılım grafiği Şekil 2.12'da verilmiştir.

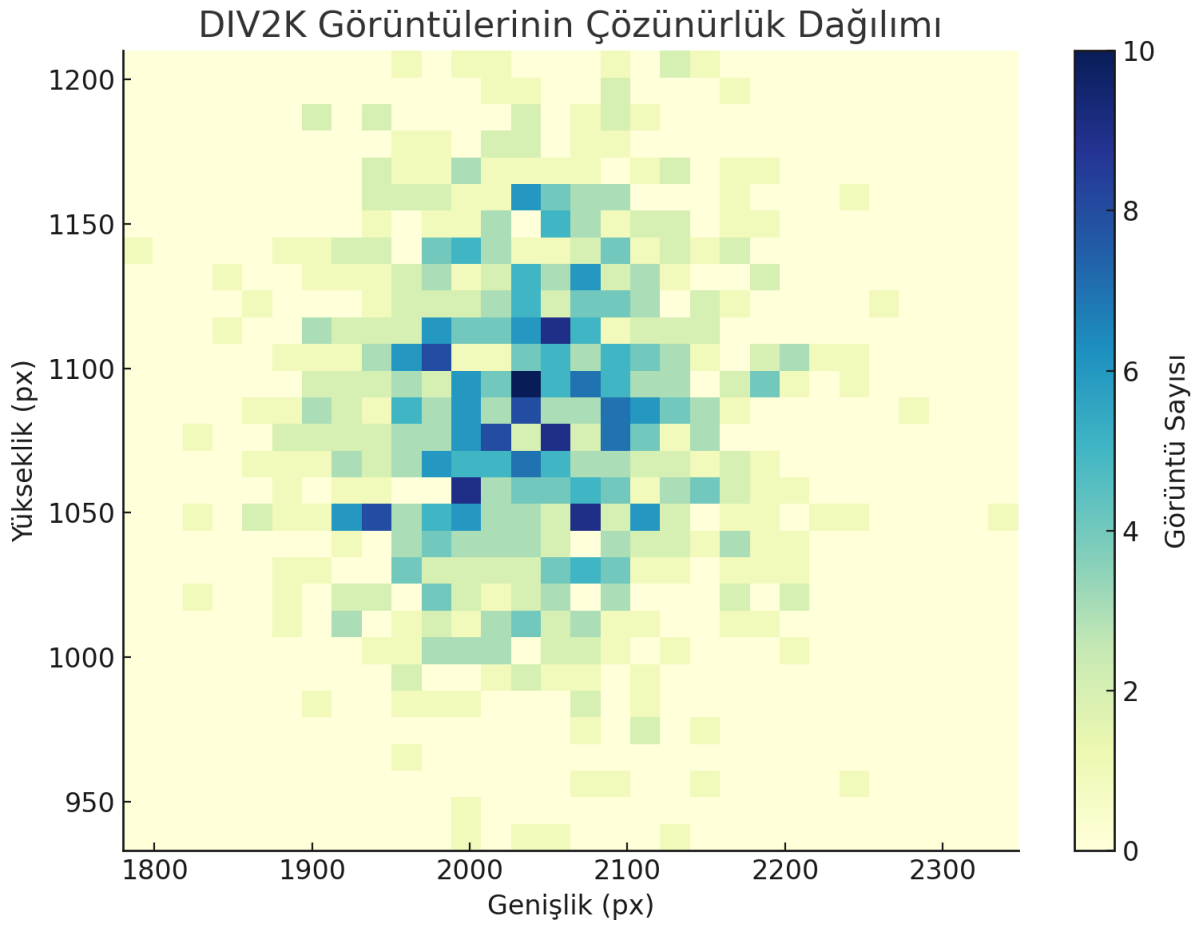

Şekil 2.12: DIV2K veriseti içerisindeki görsellerin çözünürlük-frekans dağılımı

2.4. ÇÖZÜNÜRLÜK İYİLEŞTİRMEDE KULLANILAN KALİTE ÖLÇÜMLERİ

Çözünürlük iyileştirme işleminin başarısı ölçülürken orijinal görsel ile çözünürlüğü iyileştirilen görsele uygulanan Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index (SSIM), Mean Opinion Score (MOS), Adaptive – Deep Image Structure and Texture Similarity (A-DISTS) ve Learned Perceptual Image Patch Similarity (LPIPS) gibi yöntemlerden yararlanılır.

Seif ve Androutsos [84] tek görüntü süper çözünürlük problemlerini çözmede ortalama karesel hataya dayalı, karesel hatayı merkeze alan yitim fonksiyonlarının ve dolayısıyla benzer mantıkla çalışan kalite metriklerinin yetersizliklerini sorgulamıştır. Karesel hata tabanlı yöntemlerin görseldeki nesnelerin kenar detayları konusunda iyi sonuçlar vermekten uzak olduğu, dolayısıyla başarılı bir süper çözünürlük sonucu elde etmek için sadece kalite metriklerinin değil yitim fonksiyonlarının da kenar tabanlı bir yaklaşımla kullanılması gerektiğini ifade etmişlerdir.

Çözünürlük artırma (resolution enhancement) çalışmalarında, önceki çalışmalarla karşılaştırma yapılabilmesi amacıyla PSNR ve SSIM metrikleri hâlâ kullanılmaktadır. Bununla birlikte, yerel dokuların ve insan algısının değerlendirilmesine en yakın sonuçları veren A-DISTS ve LPIPS sonuçlarına da yer verilmiştir. Literatürde uzun süredir kullanılan ve standart hale gelmiş görsel karşılaştırma metriklerinden olan SSIM ve PSNR, başarılı sonuçlar ortaya koyan bazı tekniklerde insan algısına zıt sonuçlar vermektedir. Bu yüzden hem yapay sinir ağı tabanlı görsel iyileştirme yöntemlerinde daha iyi bir optimizasyon gerçekleştirmek hem de oluşturulan görsellerin gerçekliğe ne kadar yaklaştığının tespitinin yapılabilmesi amacıyla yine yapay sinir ağı temelli yaklaşımlar ortaya çıkmaktadır. Yapısal ve dokusal benzerliğin birleşimi fikriyle geliştirilmiş bir metrik olan DISTS (Deep Image Structure and Texture Similarity) [85], bunu temel alarak geliştirilen A-DISTS (Adaptive-DISTS) [86] ve tamamen farklı bir yaklaşım içeren LPIPS [87] ile insan yorumlamasına oldukça yakın sonuçlara ulaşılmıştır.

2.4.1. Peak Signal-to-Noise Ratio (PSNR)

PSNR (Peak Signal-to-Noise Ratio), bir görüntünün maksimum olası sinyal gücü ile görüntü kalitesini etkileyen gürültü bozulması arasındaki oranı ifade eder. Bu oran, her pikseldeki ortalama kare hata (MSE) ile yakından ilişkilidir. [0, ∞) aralığında değer alabilir. Daha yüksek PSNR değeri, iki görüntünün birbirine daha benzer olduğunu gösterir [50, 88].

PSNR, özellikle görüntü sıkıştırma süreçlerinde sıkıştırma kalitesini ölçmek için kullanılan basit yapısı nedeniyle yaygın bir şekilde kullanılmaktadır. Video görüntüleri gibi dijital medya üzerinde bu yöntem halen etkili bir karşılaştırma aracı olarak değerlendirilmektedir [89]. Bunun yanı sıra PSNR, süper çözünürlük algoritmalarının performansını değerlendirmek için en güvenilir yöntemlerden biri olarak kabul edilir. Analog sistemlerde yaygın şekilde kullanılan bu metrik, sonuçları desibel (dB) cinsinden ifade eder.

PSNR hesaplamasında ilk olarak, ortalama karesel hata (MSE) hesaplanır. Bu işlem, denklem (2.22) ile gerçekleştirilir [90]:

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2 \tag{2.22}$$

m ve *n*, giriş görüntüsünün satır ve sütunlarını ifade ederken, *I* giriş görüntüsünü, *K* ise süper çözünürlük işlemi sonucunda elde edilen görüntüyü temsil etmektedir. İki görüntünün her

pikseli için toplam karesel hata hesaplanır. Elde edilen MSE değerinden yola çıkarak PSNR değeri denklem (2.23)'teki gibi hesaplanır.

$$PSNR = 10 \,.\log_{10}\left(\frac{MAX_I^2}{MSE}\right) \tag{2.23}$$

Burada MAX_I, görüntüde olası maksimum piksel değerini (genellikle 255) temsil eder. PSNR, süper çözünürlük algoritmalarının kalitesini ölçmek için nesnel bir metrik sağlamasının yanı sıra, sıkıştırma sonrası veri kaybını değerlendirme açısından da geniş bir uygulama alanına sahiptir.

MAX_I, doğrudan görüntünün bit derinliğine bağlıdır. Bit derinliği b olan görüntüler için MAX_I değeri, (2.24) numaralı denklemde gösterildiği şekilde elde edilebilir.

$$L = MAX_I = 2^b - 1 \tag{2.24}$$

2.4.2. Structural Similarity Index (SSIM)

Bu metrik, iki görüntü arasındaki yapısal benzerliği ölçmek için kullanılır. Hesaplama, görüntülerin parlaklık, kontrast ve yapı gibi özellikleri dikkate alınarak yapılır [91]. İnsan görsel algısını daha iyi taklit etmesi nedeniyle, görüntü kalitesini değerlendirmede PSNR'ye göre daha güvenilir kabul edilir. Özellikle süper çözünürlük, sıkıştırma kalitesi ve görüntü bozulmalarını değerlendirme gibi uygulamalarda yaygın şekilde kullanılmaktadır. [-1, 1] aralığında değer alır. Daha yüksek bir SSIM (Structural Similarity Index Measure) değeri, görüntülerin birbirine daha benzer olduğunu ifade eder. SSIM, iki görüntü arasındaki farklılıkları, parlaklık, kontrast ve yapı özelliklerine odaklanarak tespit eder. Parlaklık, kontrast ve yapı denklemleri sırasıyla denklem (2.25), (2.26) ve (2.27)'de gösterilmiştir [50].

$$l(x,y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \tag{2.25}$$

$$c(x,y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \tag{2.26}$$

$$s(x,y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \tag{2.27}$$

Bu denklemlerde C_1, C_2 ve C_3 sabitleri, belirsizliklerin önüne geçmek için kullanılır. Özellikle $\mu_x^2 + \mu_y^2$ sonucunun sıfıra yaklaşması durumunda bu sabitler hesaplamayı dengeler. Sabitler (2.28)'te görüldüğü şekilde tanımlanır:

$$C_1 = (K_1 L)^2$$
$$C_2 = (K_2 L)^2 \quad (2.28)$$
$$C_3 = \frac{C_2}{2}$$

Burada K1 ve K_2, 1'den küçük sabit sayılardır; L ise PSNR hesaplamasında da belirtilen bit derinliğini (MAX_I) temsil eder.

SSIM, parlaklık, kontrast ve yapı değerlerinin ağırlıklı ortalaması olarak denklem (2.29)'te gibi ifade edilir.

$$SSIM(x,y) = \left[l(x,y)^{\alpha} \cdot c(x,y)^{\beta} \cdot s(x,y)^{\gamma}\right] \quad (2.29)$$

Genel formülü basitleştirmek için α, β ve γ değerleri 1 olarak kabul edildiğinde, SSIM denklem (2.30)'daki hale gelir. μ görüntünün ortalama değeri, σ standart sapması, σ_{xy} ise görüntülerin kovaryansıdır.

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2.30)$$

2.4.3. Mean Opinion Score (MOS)

Mean Opinion Score (MOS), birden beşe kadar numaralandırılmış puan değerleriyle gerçekleştirilen öznel bir değerlendirme ortalamasıdır ve kullanıcı deneyimini ölçmek için yaygın olarak kullanılan bir metriktir. Özellikle telekomünikasyon sektöründe, ses kalitesi, video kalitesi ve genel kullanıcı memnuniyeti gibi parametrelerin değerlendirilmesinde kullanılır. Süper çözünürlük çalışmalarında ise MOS, bireylerin belirli bir görüntü üzerinde yaptığı değerlendirmelerin aritmetik ortalaması olarak hesaplanır ve görüntü kalitesinin algısal boyutunu ölçmeyi amaçlar [91–94]. Bu yaklaşım, kullanıcıların algısal yargılarını doğrudan ölçtüğü için objektif metriklerden farklı bir perspektif sunar. MOS'un görüntü kalitesi karşılaştırmalarında insan algısını objektif metriklere göre daha iyi yansıttığını göstermiştir. Daha yüksek bir MOS değeri, değerlendirme yapılan görüntülerin referans görüntüye olan

benzerliğinin artmasıyla ilişkilidir, bu da süper çözünürlük algoritmalarının başarısını doğrulamak için güçlü bir metrik olarak kullanılmasını sağlar [95].

2.4.4. Adaptive - Deep Image Structure and Texture Similarity (A-DISTS)

DISTS, görüntüdeki dokuları göz ardı ederek tüm görüntü üzerinde genel bir yargıya varabilmektedir. Bu göz ardı etme sorununu aşmak amacıyla, yerel doku ayrıntılarını uyarlanabilir bir yaklaşımla daha iyi analiz edebilmek için A-DISTS geliştirilmiştir.

DISTS içerisinde kullanılan VGG sinir ağı, boyut açısından yeterli duyarlılığı sunmamaktadır. Bu nedenle, VGG sinir ağının evrişim filtreleri, her bir filtrenin L2 normu 1 olacak şekilde yeniden normalize edilmiştir. Böylece, tüm evrişim filtrelerinin benzer aralıklarda tepki vermesi sağlanarak istatistiksel karşılaştırmaların daha kolay yapılabilmesi amaçlanmıştır. A-DISTS ile denklem (2.31) ile formüle edilen dağılım indeksi (dispersion index) adı verilen istatistiksel bir özellik kullanılmaktadır. Denklem (2.32)'de, $\tilde{p}_k^{(i)}$ ifadesi X ve Y görüntüleri arasındaki farkı hesaplamak için kullanılmakta olup, k'ncı parçanın i'nci boyutundaki desen olasılığını ifade etmektedir. Bu ölçüm, [0, 1] aralığında bir değer üretmektedir. Değerin sıfıra yakınsaması, görsellerin daha benzer olduğunu ifade eder [85].

$$A - DISTS(X,Y) = 1 - \frac{1}{N}\sum_{i=0}^{M}\sum_{j=0}^{N_i} S(\tilde{X}_j^{(i)}, \tilde{Y}_j^{(i)}) \tag{2.31}$$

$$S\left(\tilde{X}_j^{(i)}, \tilde{Y}_j^{(i)}\right) = \frac{1}{K_i}\sum_{k=1}^{K_i}\left(\tilde{p}_k^{(i)} l\left(\tilde{x}_{j,k}^{(i)}, \tilde{y}_{j,k}^{(i)}\right) + \tilde{q}_k^{(i)} s\left(\tilde{x}_{j,k}^{(i)}, \tilde{y}_{j,k}^{(i)}\right)\right) \tag{2.32}$$

2.4.5. Learned Perceptual Image Patch Similarity (LPIPS)

Bir diğer önemli algısal metrik ise Öğrenilmiş Algısal Görüntü Parça Benzerliği (Learned Perceptual Image Patch Similarity – LPIPS) ölçütüdür. Zhang ve diğ. [87] tarafından geliştirilen LPIPS, insan görsel benzerlik yargılarıyla yüksek düzeyde uyum sağlamak üzere tasarlanmıştır. Bu metrik, görüntüler arasındaki algısal benzerliği nicel olarak değerlendirmek için, önceden eğitilmiş evrişimsel sinir ağlarının ara katmanlarından elde edilen derin özellikleri kullanır. Söz konusu özellikler, hem düşük düzeydeki görsel öznitelikleri (örneğin kenarlar ve dokular) hem de yüksek düzeydeki anlamsal yapıları yakalayabilmektedir. İki görüntü için, ilgili katman l'den elde edilen öznitelik haritaları $f_l(x_1)$ ve $f_l(x_2)$ normalleştirilir ve L2

uzaklıkları denklem (2.33)'te gösterildiği şekilde hesaplanır. Burada, w_l insan algısıyla uyumlu olacak şekilde optimize edilen öğrenilmiş ağırlıkları temsil etmektedir. Katmanlar boyunca yapılan katkıların birleştirilmesiyle, toplam LPIPS uzaklığı denklem (2.34)'te ifade edildiği üzere elde edilir. Bu metrik, süper çözünürlük ve görüntü sıkıştırma gibi çeşitli görevlerde doğrulanmış olup, PSNR ve SSIM gibi geleneksel metriklere kıyasla insan değerlendirmeleriyle daha yüksek düzeyde örtüşme göstermiştir. Farklı mimariler (örneğin AlexNet, VGG, SqueezeNet) kullanılarak LPIPS, hesaplama verimliliği ile algısal doğruluğu dengelemiş ve bilgisayarla görme alanında algısal benzerlik değerlendirmesi için sağlam bir araç hâline gelmiştir [87]. Tez çalışması kapsamında, yöntem çıktılarının değerlendirilmesinde önceden tanımlanmış VGG ağ modeli kullanılmıştır. [0, 1] aralığında değer alır ve sıfıra yaklaştıkça görüntülerin daha benzer olduğu ifade edilir.

$$d_l(x_1, x_2) = ||w_l \odot (f_l(x_1) - f_l(x_2))||_2^2 \tag{2.33}$$

$$LPIPS(x_1, x_2) = \sum_l d_l(x_1, x_2) \tag{2.34}$$

PSNR ve SSIM değerlerinin artması, görüntülerin birbiriyle daha uyumlu olduğu sonucunu ortaya koyarken; DISTS ve A-DISTS ile sıfıra yakın sonuçlar, görüntülerin daha uyumlu olduğunu göstermektedir.

3. YÖNTEM

Tez çalışması kapsamında odak piksel duyarlı bir süper çözünürlük yöntemi önerilmiş ve sonuçları incelendiğinde farklı bir yaklaşımla incelenen renk uzayı değişikliğinin süper çözünürlüğe etkilerine de bu başlık altında yer verilmiştir. Önerilen yöntem olan Lanzcos interpolasyonu üzerinde kenar-duyarlı uygulanan adaptif Diamond-Eye matrisi tanıtılmıştır. Üç aşamalı uygulanan bu yöntem ile sınırlı alanda uygulanan Diamond-Eye matrisinin PSNR, SSIM, A-DISTS ve LPIPS yöntemlerinin tamamında çalışılan veri setleri üzerinde olumlu sonuçları gösterilmiştir.

Tez çalışması kapsamında yapılan her iki yaklaşım için de çözünürlük artırma alanında sıklıkla kullanılan Set5 [80], Set14 [81], BSD100 [82], Urban100 [83] ve bilinmeyen bozulma içeren DIV2K [96] veri setleri kullanılmıştır.

3.1. KENAR-DUYARLI ODAK PİKSELLERE UYGULANAN DIAMOND-EYE MATRİSİ İLE SÜPER ÇÖZÜNÜRLÜK

Yöntemin başarısını artırmak adına, görüntünün tamamına aynı işlemlerin uygulanması yerine çözünürlük artırma işleminden sonra, yöntemin uygulanacağı alanlar belirlenmiştir. Set5, Set14, BSD100, Urban100 ve DIV2K veri setleri üzerinde çeşitli çözünürlük iyileştirme algoritma ve yöntemleri denendikten sonra orijinal görseller ile aralarındaki farkları tespit edebilmek için Şekil 3.1'de de görüldüğü gibi fark görselleri üretilmiştir. Gri tonlamalı üretilen bu fark görsellerinde siyah alanların anlamı fark yok demekken renk beyaza döndükçe farkın açıldığı anlamı taşımaktadır. Böylece başarılı olduğu kabul edilen yöntemlerde renk histogramına göre siyaha yatkınlık, çözünürlük iyileştirme yönteminin daha başarılı olduğunu da görsel olarak göstermektedir. Fark görselleri incelendiğinde, sorunlu alanların çoğunlukla görüntüdeki nesnelerin kenarlarında olduğu keşfedilmiştir. Farklı çözünürlük iyileştirme yöntemlerinin tamamında, farklı miktarlarda olsa da sorunlu kısımların kenar kısımlarda toplanması sebebiyle kenarlara odaklanan bir algoritma geliştirilmiştir.

3.1.1. Fark Görsellerinin Oluşturulması

Fark görselleri, bu çalışmanın süper çözünürlükteki sorunlu alanların fark edilmesi için gerçekleştirilen ilk aşamadır. Yöntemin doğrudan bir parçası olmamasına karşın problemin fark edilmesindeki katkısı nedeniyle yöntemin geliştirilmesindeki dayanak noktası olmuştur. Fark görseli, düşük çözünürlüklü girdi görselinin her pikseli için ayrı ayrı hesaplanır. RGB görüntüler üzerinde fark piksellerini hesaplarken her bir renk ekseni için farklar elde edilir ve bu eldelerin toplamı, fark pikselinin değerini temsil eder. Fark görselleri orijinal görseller ve bahsedilen yöntemlerin çıktılarına bakılarak elde edilmiş ve Şekil 3.1'de gösterilen sonuçlara ulaşılmıştır. Bu şekil üzerinde, siyahtan beyaza doğru renk açıldıkça pikseller arasındaki farklılaşmanın arttığı anlamı çıkarılmaktadır. Görsellerinin daha vurgulu gösterilmesi için parlaklık %40 artırılmış, kontrast %40 azaltılmıştır.

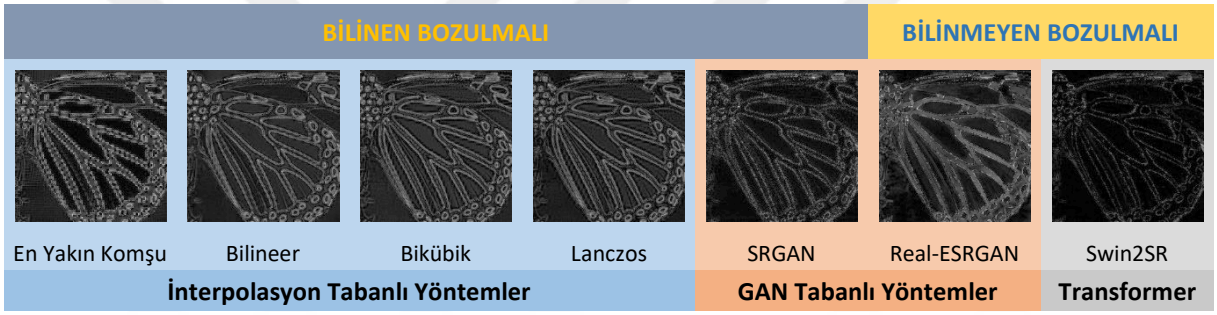

Şekil 3.1: Çözünürlük iyileştirme süreçleri sonunda iyileştirilen görsel çıktısı ile orijinal görsel arasındaki farkların görsel üzerinde gösterimi

İnceleme yapılan en başarılı yöntemlerden olan Swin2SR üzerinde dahi fark piksellerinin görsellerdeki nesnelerin kenarlarında toplanması, süper çözünürlük çalışmalarında başarılı olmak için odaklanılması gereken ilk kısımlar olarak tespit edilmiş ve bu tez çalışmasında önerilen yöntemin çıkış noktası olmuştur.

Fark görselleri üzerinde, piksel değerinin 255'i aşma ihtimaline karşılık tüm değerleri etkileyecek bir normalizasyon işlemi yapmak yerine 255'i aşan değerlerin tümü, maksimum fark değeri olacak şekilde 255 olarak kabul edilmiştir. Az miktarda karşılaşılması muhtemel aşırı uç değerlerin genel yatkınlığı etkilememesi adına böyle bir yöntem benimsenmiştir.

3.1.2. Odak Piksellerin Elde Edilmesi

Oluşturulan fark görselleri üzerinde nesnelerin kenarlarını temsil etmek ve düzeltmelerin öncelikle bu piksellere uygulanmasını sağlamak için odak piksel çıkarımı gerçekleştirilir. Önerilen yöntemin temel uygulama adımları Şekil 3.2'de gösterilmiştir.

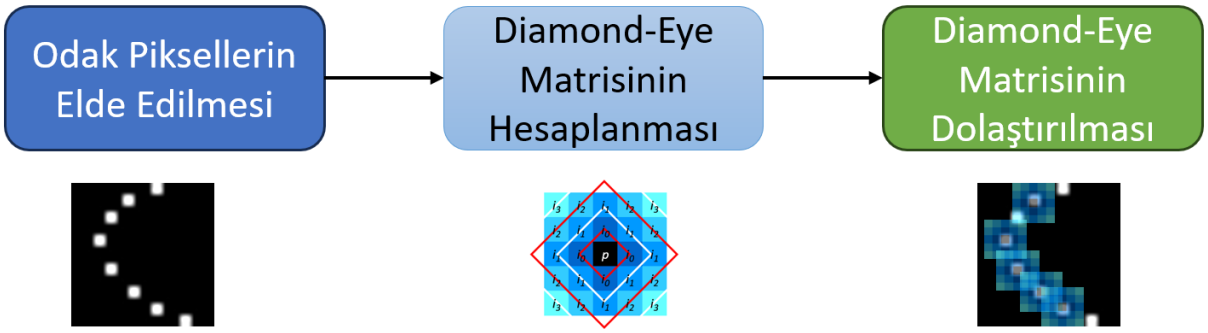

Şekil 3.2: Önerilen yöntemin temel uygulama adımları

İşlem adımları şu şekildedir:

1. Düşük çözünürlüklü görüntü, Lanczos interpolasyonu kullanılarak istenilen büyütme faktörü kadar büyütülür.

2. Düşük çözünürlüklü görüntü, gri tonlama görüntüsüne dönüştürülür.

3. Görüntüye (3.1) ve (3.2) ile belirtilen keskinleştirme filtreleri uygulanır.

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix} \tag{3.1}$$

$$\begin{bmatrix} 0 & -2 & 0 \\ -2 & 11 & -2 \\ 0 & -2 & 0 \end{bmatrix} \tag{3.2}$$

4. Kenarları korumak ve gürültüyü azaltmak için keskinleştirilmiş görüntülere, bilateral kernel (3.2) uygulanır [97]. Tespit edilen odak piksellerdeki gürültülerin azaltılması, geliştirilen yöntemin uygulanacağı asıl kısımları belirlemede büyük öneme sahiptir.

5. Kenarları daha fazla vurgulamak ve odak piksellerdeki gürültüyü daha da azaltmak için Sobel filtresi, Şekil 3.3-(b) [1]'de görülen şekli elde etmek için uygulanır [43]. Denklem (3.5)'te yapılan değişiklik ile hem hesaplama maliyetini azaltmak hem de odak pikselleri elde etmede ortalama değerlere yakınsama yapmak adına gerçek büyüklük yerine yaklaşık büyüklük yöntemi kullanılmış ve bu çalışmada denklem (3.3) ve (3.4)'teki değerlerin ağırlıklı ortalaması alınmıştır [98].

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} x\ m \tag{3.3}$$

$$G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} x\ m \tag{3.4}$$

$$G = \frac{|G_x|}{2} + \frac{|G_y|}{2} \tag{3.5}$$

6. Fark görüntüsünün denklem (3.6) ve denklem (3.7)'de olduğu gibi standart sapma değerleri hesaplanır.

$$\mu = \frac{1}{w\ .\ h} \sum_{i=1}^{w} \sum_{j=1}^{h} m[i,j] \tag{3.6}$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^{w} \sum_{j=1}^{h} (m[i,j] - \mu)^2}{w\ .\ h}} \tag{3.7}$$

7. Eşik değerinin altındaki pikseller (3.7) içinde devre dışı bırakılmak üzere, (3.8)'deki kural işletilerek 0 değeri alır. Dinamik eşik değer tanımlaması sayesinde parlaklık ve kontrast değişimlerine eşik değerin uyum sağlaması istenmiştir. Yapısal bileşenlerin detaylarının korunmasına yardımcı olmak için yüksek varyansa sahip bölgelerde düşük eşik, düşük varyanslı bölgelerde yüksek eşik üretilir.

$$m[i,j] = 0, \quad m[i,j] < \mu - \left(\frac{\sigma}{\mu}\right)^2 \tag{3.8}$$

Geliştirme sürecinde siyaha yakın pikseller daha iyi sonuçlar verir. Odak alanını daraltmak için, eşik değerinin altındaki pikseller, denklem (3.8)'de tanımlı kurala göre sıfıra ayarlanarak Şekil 3.3 (b)'de görülen hale getirilir. Burada amaç, düşük fark oluşturması muhtemel piksellerin etkisini ortadan kaldırarak ana noktalara odaklanmaktır.



Şekil 3.3: Odak piksellerin çıkartılması

Sobel filtresinde, yatay ve dikey olarak görünen kenarlar için matrisler ayrı şekilde düzenlenmiştir. Bu matrisler giriş görüntüsüne bağımsız olarak uygulanabilir ve her yönde piksel değerini ölçebilir. Bu değerler, kenarların mutlak değerini ve yönünü (açıyı) bulmak için denklem (3.5) kullanarak birleştirilir.

3.1.3. Önerilen Çözünürlük İyileştirme Matrisi: Diamond-Eye

Odak pikseller elde edildikten sonra odak piksel değerleri düşükten yükseğe doğru sıralanır ve filtre düşük değerli piksellerden başlayarak görüntü üzerinde dolaştırılır. Amaç, daha düşük değerli piksellerin gerçek renk bilgisini daha iyi temsil etmektir. Bu nedenle, kenar çizgiler boyunca bir iyileştirme yapılacaksa, filtre önce sınır çizgiler boyunca uygulanır.

Geliştirilen matris, odak pikseller üzerinde evrişim yapmak için tanımlanmıştır. Biyolojik olarak göze benzeyen bu yaklaşımda göz bebeği ve irisi temsil eden bir tanımlama yapılmıştır. *p* ile ifade edilen matris elemanı, matrisin merkezinde bulunur ve göz bebeğini temsil ederken *i* değerleri, göz bebeğini çevreleyen iris ile ilişkilidir. "Diamond-Eye" (d-Eye) adlı matris 5x5 boyutunda tanımlanmış, Şekil 3.4'te gösterilmiştir.

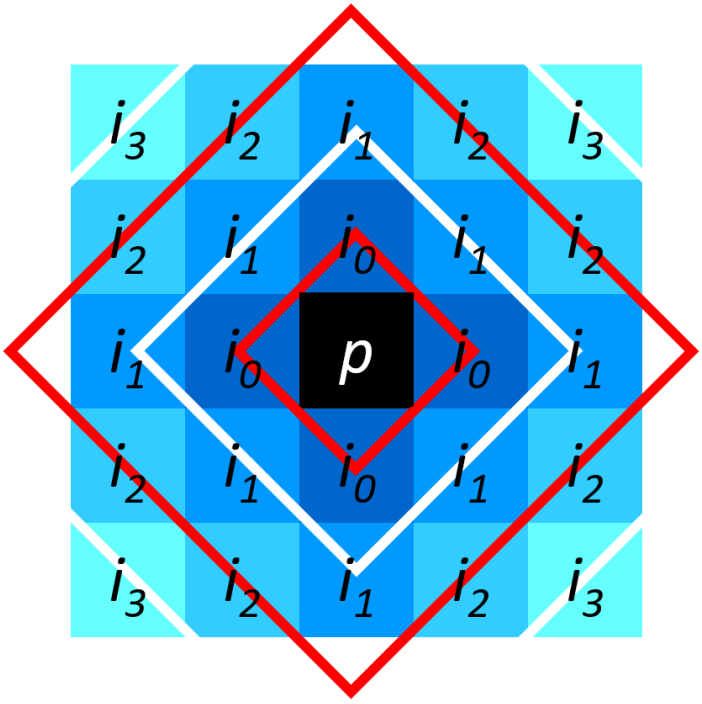

Şekil 3.4: Diamond-Eye (d-Eye) matrisi

Laplacian filtresi, bir görüntünün ikinci türevlerini hesaplayan ikinci dereceden bir türev işlemcisidir. Bu, genellikle kenarlara karşılık gelen yoğunluk değişikliklerinin olduğu bölgeleri tanımlamaya yardımcı olur. Laplacian filtresini bir keskinleştirme filtresine dönüştürmek, orijinal görüntüyü Laplacian filtresi ile filtrelenmiş görüntüye eklemeyi içerir. Bu dönüşüm, tüm matris içindeki elemanların toplamının "1" olduğundan emin olmak için "identity" matrisin Laplacian filtresine eklenmesiyle gerçekleştirilir [99]. Bu durumda yeni filtre matrisinin elemanları toplamı, birim matris sebebiyle 1'e eşitlenir. Benzer şekilde, bu bakış açısından hareketle, önerilen d-Eye matris elemanlarının toplamı "1" olacak şekilde korunur.

d terimi, matrisin sınırlarını aşmadan içine, kesintisiz ve tam olarak sığan elmas şeklindeki çizgilerin sayısını belirtir. Şekil 3.4'te görülen 5x5 boyutundaki d-Eye matrisi için d değeri 2'dir ve *p* değeri, *d*'ye bağlı olarak denklem (3.9)'da görüldüğü gibi hesaplanır.

$$p = (d+1)^d \tag{3.9}$$

$$iris[i] = \begin{cases} \dfrac{1-p}{d^{d^{i+1}}}, & i = 0 \\ -\dfrac{iris[i-1]}{d^{d^{i+1}}}, & i > 0 \end{cases} \tag{3.10}$$

Tüm iris değerlerini aldıktan sonra, *p* iris değerlerine ve tekrar sayılarına göre güncellenecektir. Ancak her bir elemanın çarpanı, göz bebeği *p*'ye olan uzaklıkla ilgili olacak şekilde her bir iris elemanın indisi olan *i* ve matriste tekrarlama sayısı *f(iris[i])* ile denklem (3.11)'de görüldüğü gibi çarpılır.

$$p = p - \sum_{i=0}^{\mathrm{d+1}} i * iris[i] * f(iris[i]) \tag{3.11}$$

Matristeki tüm elemanların toplamını 1'e eşitlemek için, d-Eye'ın tüm elemanları denklem (3.12) ve (3.13) kullanılarak normalize edilir.

$$\alpha = \frac{1}{p + \sum_{i=0}^{\mathrm{d+1}} iris[i] * f(iris[i])} \tag{3.12}$$

$$dEye = \alpha * dEye \tag{3.13}$$

3.1.4. Odak Pikseller Üzerinde Diamond-Eye Matrisinin Uygulanması

Görüntü üzerinde iyileştirme, yalnızca odak piksellerin işaret ettiği noktalarda, odağın çevresindeki pikseller dikkate alınarak uygulanır. Burada odak pikseller matrisi, iyileştirme ihtiyacı olan yerleri ifade etmenin yanında iyileştirme derecesi ile ilgili verileri keşfedebileceğimiz verileri de barındırır.

1. Odak piksel değerleri küçükten büyüğe sıralanır.
2. d-Eye matrisinin odaklanacağı pikselin koordinatları alınır.
3. Belirtilen piksel odak noktada olacak şekilde odak ve çevre pikseller okunur, bölgesel fark matrisi *D* oluşturulur.
4. Fark matrisinde değeri sıfır olan piksellere 1 eklenir (bölme hatasını engellemek için).
5. Fark matrisi D'deki her bir elemanın tersi alınır, D_w elde edilir.

$$D_w = \frac{1}{D} \tag{3.14}$$

6. Matrisin tüm elemanlarının toplamı 1 olacak şekilde normalize edilir. Bunun sebebi, odak piksel ve çevresinde RGB renk uzayının uç değerlerini aşma ihtimalini ortadan kaldırmaktır.

$$D_w = \frac{D_w}{\sum_i^m \sum_j^n D_{w_{i,j}}} \tag{3.15}$$

7. Matrisin standart sapması ile d-Eye matrisinin içine tam sığan karo sayısı olan *d* denklem (3.18)'de yer alır ve w_s skalar sayısı elde edilir. Bu sayı, d-Eye matrisi karşısında fark matrisinin ağırlık değeri olarak kullanılır.

$$\sigma_{D_w} = \sqrt{\frac{1}{mn}\sum_i^m \sum_j^n \left(D_{w_{i,j}} - \mu_w\right)^2} \tag{3.16}$$

$$\mu_w = \frac{1}{mn}\sum_i^m \sum_j^n D_{w_{i,j}} \tag{3.17}$$

$$w_s = \sigma_{D_w} . 2^d \tag{3.18}$$

8. Uygulanacak filtrenin değerleri ağırlıklandırma oranında güncellenir (modified filter).

$$F_m = w_s * D_w + (1 - w_s) * dEye \tag{3.19}$$

9. Filtre, odak piksel matrisinin ilgili pikseline uygulanır.

3.2. RENK UZAYI DÖNÜŞÜMÜNÜN SÜPER ÇÖZÜNÜRLÜK ÜZERİNDEKİ ETKİSİNİN İNCELENMESİ

Tez çalışmasının odaklandığı bir diğer nokta ise renk uzaylarının süper çözünürlük üzerindeki etkisini araştırmaktır.

Renk uzayları, bir rengin hangi bileşenlerle temsil edilebileceğini tanımlamak amacıyla matematiksel olarak oluşturulmuş modellerdir. Görüntünün işleneceği ya da basılacağı ortamın özelliklerine bağlı olarak uygun renk uzayının seçilmesi, gerçekçi renklerin elde edilmesi açısından büyük önem taşımaktadır [65]. Çoğu çözünürlük artırma çalışması, kırmızı, yeşil ve

mavi renk bileşenlerinin şiddetine dayalı olarak modellenen RGB renk uzayıyla gerçekleştirilse de renk ekseniyle birlikte akromatik bilgiyi de içeren renk uzaylarının, çözünürlük iyileştirme çalışmalarında başarılı sonuçlar verdiği görülmektedir [6, 67, 68].

Z. Wang ve diğ. [68] çalışmasında, RGB renk uzayının diğerlerine kıyasla daha sık kullanıldığı, ancak önceki modellerde YCbCr (ya da YCC) renk uzayının yalnızca Y bileşeni üzerinde yapılan iyileştirmelerin öne çıktığı belirtilmektedir. RGB dışında, parlaklık (luminance) eksenine sahip farklı renk uzaylarında eğitilen modellerin başarı açısından belirgin farklar yaratabildiği ortaya konmuştur. John ve diğ. [67] (2016), YCbCr ve CMYK renk uzaylarının PSNR açısından daha başarılı sonuçlar verdiğini; ayrıca CIELab renk uzayının da çözünürlük artırma çalışmalarında kullanılabileceğini ifade etmektedir. Dong ve diğ. [6] ise, YCbCr uzayında yalnızca Y kanalına odaklanmanın, tüm kanallarla yapılan eğitimlere kıyasla daha iyi performans sağladığını vurgulamakla birlikte, en yüksek başarıyı RGB renk uzayının sunduğunu göstermişlerdir. Benzer şekilde, Gong ve diğ. [100], süper çözünürlük süreçlerinde sınıflandırılmış sözlük öğrenimi yönteminin kullanılmasını önermekte; bu bağlamda, CIELab renk uzayındaki L* koordinatına ve YIQ sistemindeki Y bileşenine dikkat çekmektedir.

Tek görüntü üzerinden çözünürlük artırma (Single-Image Super-Resolution – SISR) teknikleri, düşük çözünürlüklü bir görüntünün çözünürlüğünü yükseltmeyi amaçlayan ve birçok görüntü işleme uygulaması açısından kritik öneme sahip yöntemlerdir. SISR çalışmalarında yaygın olarak benimsenen bir yaklaşım, RGB formatındaki görüntülerin YCbCr veya CIELab gibi alternatif renk uzaylarına dönüştürülmesidir. Bu dönüşümün görüntü kalitesini artırdığı varsayılmakta olsa da bu yaklaşımın etkinliği hâlâ netlik kazanmamıştır. Bu belirsizlik, çalışmamızın temel motivasyonunu oluşturmaktadır.

Önceki çalışmalar çoğunlukla PSNR ve SSIM gibi sayısal metrikler üzerinden değerlendirme yaparken, bu çalışmada renk uzayı dönüşümlerinin algısal kalite üzerindeki etkileri ayrıntılı biçimde ele alınmıştır. Uygulama sürecimizde, görüntü iyileştirme teknikleri yalnızca RGB renk uzayında uygulanmakta; ardından elde edilen sonuçlar YCbCr ve CIELab renk uzaylarına dönüştürülerek, orijinal görüntülerle karşılaştırılmaktadır. Bu yaklaşım sayesinde, metriklerde gözlemlenen artışların gerçekten algılanabilir görsel iyileştirmelere karşılık gelip gelmediği analiz edilmektedir.

Bu tez çalışması, çözünürlük artırma işlemlerinin doğrudan farklı renk uzaylarında yürütülmesi yerine, giriş ve çıkış görüntülerinin RGB formatında işlenip yalnızca son aşamada

dönüştürülmesi ilkesine dayanmaktadır. Bu yöntemle yapılan incelemeler, renk uzayı dönüşümünün çözünürlük artırma sürecinden bağımsız olarak gerçekleştirildiğinde, metriklerde iyileşme yaratabiliyor gibi görünse de, bunun doğrudan görsel kaliteye yansımayabileceğini ortaya koymaktadır.

Şekil 3.5'te de görüldüğü üzere, analiz sürecinde, süper çözünürlük işlemi öncelikle RGB renk uzayında gerçekleştirilmiş, ardından elde edilen sonuçlar farklı renk uzaylarına dönüştürülmüş ve kalite metrikleri karşılaştırılmıştır. Elde edilen bulgular, görsel kalitesinde bir iyileşme olmamasına rağmen, RGB'den YCbCr veya CIELab renk uzaylarına geçiş yapıldığında kalite metriklerinde daha yüksek değerlere ulaşılabildiğini göstermektedir.

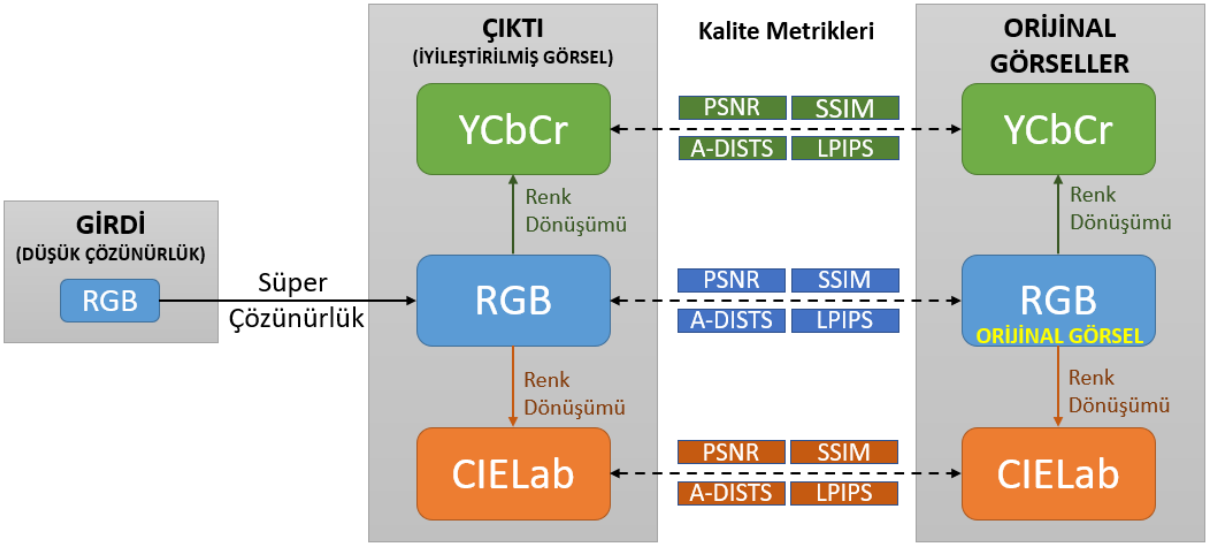

Şekil 3.5: Renk uzayı dönüşümünün süper çözünürlük üzerinde etkisinin incelendiği şematik gösterim

Çalışma kapsamında, yalnızca RGB renk uzayı kullanılarak iyileştirilen görüntüler alternatif renk uzaylarına dönüştürülmüş ve Set5, Set14, BSD100, Urban100 ve DIV2K veri kümelerindeki gerçek görüntüler ile karşılaştırılmıştır. Elde edilen sonuçlar, RGB dışındaki renk uzaylarında çalışmanın görsel kalite üzerinde anlamlı bir farka sebep olmadığını ortaya koymuştur. Bununla birlikte, yalnızca renk uzayı dönüşümüne dayalı olarak PSNR ve SSIM gibi geleneksel metriklerde, ayrıca A-DISTS ve LPIPS gibi derin öğrenme temelli metriklerde de daha yüksek skorlar elde edilebilmektedir.

3.2.1. Karşılaştırmada Kullanılan Yöntemlerin Gerçekleştirme Detayları

Tez çalışması kapsamında karşılaştırma amacıyla yararlanılan metotların ve modellerin detayları bu başlık altında verilmiştir.

3.2.1.1. İnterpolasyon Metotlarının Gerçekleştirme Detayları

Bilineer interpolasyon deneylerinde, eksik değerin elde edilmesinde ağırlıklı ortalama yöntemi kullanılmaktadır; bikübik interpolasyon deneylerinde ise hedef pikselin çevresindeki 4x4 piksellik komşuluk, kübik polinom açılımına dayalı olarak değerlendirilmektedir; Lanczos interpolasyon deneylerinde ise, 4x4 komşuluğu kullanan pencereli sinc fonksiyonu uygulanmıştır.

3.2.1.2. SRGAN Hiper-parametreleri ve Model Detayları

SRGAN üretici (generator) ağı, her biri 64 öznitelik haritası (feature map) içeren 3×3 evrişim katmanlarından oluşan 16 artık (residual) bloktan meydana gelmektedir. Aktivasyon fonksiyonu olarak Parametrik ReLU (PReLU) kullanılmakta olup, bu fonksiyon negatif girişlerin eğimini uyarlanabilir şekilde öğrenerek ağın öğrenme kapasitesini artırmakta ve standart ReLU'ya kıyasla model esnekliğini ve performansını iyileştirmektedir. Görüntü çözünürlüğünü artırmak amacıyla, iki adet alt-piksel evrişim (sub-pixel convolution) katmanı kullanılmaktadır.

Ayrıca, ayrımcı (discriminator) ağı 3×3 çekirdek boyutuna sahip 8 evrişim katmanından oluşmakta; öznitelik haritası sayısı her katmanda iki katına çıkacak şekilde 64'ten başlayarak 512'ye kadar artmaktadır. Ayrımcı ağda aktivasyon fonksiyonu olarak Leaky ReLU (α=0.2) tercih edilmiştir. Bu fonksiyon, negatif girişler için küçük fakat sıfırdan farklı bir gradyan sağlayarak "ölü ReLU" (dying ReLU) problemini azaltmakta ve ağın negatif aktivasyonlar altında da öğrenme gerçekleştirmesine olanak tanımaktadır [101].

Optimizasyon işlemi, öğrenme oranı ilk 100.000 iterasyon boyunca 10^{-4}, sonraki 100.000 iterasyon için ise 10^{-5} olacak şekilde ayarlanmış Adam algoritması (β_1=0.9) ile gerçekleştirilmiştir. Kayıp fonksiyonu, önceden eğitilmiş bir VGG ağının yüksek düzeyli öznitelik haritalarına dayalı içerik kaybını (perceptual/content loss) ve ayrımcının süper çözünürlükle üretilen görüntüleri gerçek yüksek çözünürlüklü görüntülerden ayırt etme yeteneğine dayalı çekişmeli kaybı bir araya getirmektedir.

Eğitim sırasında her mini yığın (mini-batch), ImageNet veri kümesinden elde edilen ve her biri 96×96 çözünürlüğünde olan 16 görüntü içermektedir. Eğitimin daha istikrarlı bir şekilde ilerlemesini sağlamak ve yerel optimumlara takılmayı önlemek amacıyla, üretici ağ başlangıçta ortalama kare hata (MSE) kaybı ile önceden eğitilmiş olan SRResNet modeli ile başlatılmıştır. Bu dikkatli yapılandırılmış mimari sayesinde SRGAN, düşük çözünürlüklü girişler ile yüksek

çözünürlüklü çıktılar arasında gerçekçi geçişler sağlayarak foto-gerçekçi süper çözünürlük (SR) görüntüler üretmeyi başarmaktadır [52].

3.2.1.3. Real-ESRGAN Hiper-parametreleri ve Model Detayları

Real-ESRGAN modeli, gerçek dünya görüntülerinde karşılaşılan karmaşık bozulmaları ele alabilmek amacıyla geliştirilmiş, rafine bir mimariye ve dikkatle ayarlanmış hiperparametrelere sahip bir yapay sinir ağıdır. Üretici (generator) ağ, Residual-in-Residual Dense Block (RRDB) mimarisini benimserken; ayrıştırıcı (discriminator) ağ, spektral normalizasyon içeren U-Net tabanlı bir yapı kullanmaktadır. Bu tasarım, yerel ayrıntıların daha hassas bir şekilde ayırt edilmesini sağlamakta ve eğitim sürecinin daha kararlı ilerlemesine katkı sunmaktadır.

Model, iki aşamalı bir eğitim süreciyle optimize edilmektedir: İlk aşamada, PSNR odaklı bir yaklaşımla yalnızca L1 kaybı kullanılırken; ikinci aşamada L1, algısal (perceptual) ve GAN kayıpları bir araya getirilmekte ve bu kayıplara sırasıyla {1, 1, 0.1} ağırlıkları verilmektedir. Eğitim sürecinde optimizasyon için Adam algoritması (β_1=0.9, β_2=0.999) kullanılmakta; öğrenme oranı birinci aşamada 2×10^{-4}, ikinci aşamada ise 10^{-4} olarak belirlenmiştir. Toplamda birinci aşamada 1.000.000, ikinci aşamada ise 400.000 iterasyon gerçekleştirilmiştir.

Wang ve diğ. [31]; modelin eğitimi, yüksek çözünürlüklü 256×256 piksellik görüntü parçaları kullanılarak gerçekleştirilmekte olup bu görüntüler DIV2K ve Flickr2K gibi veri kümelerinden alınmaktadır. Ayrıca, Gauss ve Poisson gürültüleri, JPEG sıkıştırması ve sinc filtreleri gibi ögeler içeren ikinci dereceden bozulma modeli uygulanarak eğitim verisi daha gerçekçi hâle getirilmektedir. Eğitimin kararlılığını artırmak ve görsel keskinliği iyileştirmek amacıyla, Üssel Hareketli Ortalama (Exponential Moving Average – EMA) ve gerçek görüntülerin keskinleştirilmesi gibi ek tekniklerden de yararlanılmaktadır. Bu dikkatli yapılandırma sayesinde Real-ESRGAN, gerçek dünya senaryolarında yüksek düzeyde sağlamlık ve görsel kalite sunmaktadır.

3.2.1.4. Swin2SR Hiper-parametreleri ve Model Detayları

Swin2SR modeli, sıkıştırılmış görüntülerin süper çözünürlük ve restorasyon işlemlerine yönelik optimize edilmiş gelişmiş bir mimariyi temel almaktadır. Bu model, her biri 6 Swin Transformer katmanı içeren toplam 6 Residual Swin Transformer Block'tan oluşur. Her bir

Transformer katmanı, pencere boyutu 8 olan dikkat (attention) mekanizmasına sahiptir ve 180 kanal ile 6 dikkat başlığı (attention head) kullanmaktadır.

Modelin eğitimi sırasında temel amaç fonksiyonu olarak L1 kaybı kullanılmakta; bu kayba ek olarak yardımcı (auxiliary) ve yüksek frekanslı (high-frequency) kayıp fonksiyonları da dahil edilerek düşük çözünürlüklü görüntülerin daha hassas şekilde geri kazanılması ve ince ayrıntıların korunması sağlanmaktadır. Eğitim süreci, DIV2K ve Flickr2K veri kümeleri üzerinde, 192 piksellik yüksek çözünürlüklü görüntü parçaları kullanılarak gerçekleştirilmekte ve dönme (rotation) ile yansıtma (flipping) gibi standart veri artırma (augmentation) tekniklerinden yararlanılmaktadır.

Optimizasyon işlemi, başlangıç öğrenme oranı 2×10^{-4} olacak şekilde, Adam algoritması ($\beta_1=0.9$, $\beta_2=0.999$) ile yürütülmektedir. Model, çözünürlük artırma işlemini pixel shuffle mekanizması ile etkin biçimde gerçekleştirmekte olup, yaklaşık 12 milyon parametrelik kompakt yapısıyla, yoğun sıkıştırılmış görüntülerden yüksek kaliteli çıktılar elde etmede rekabetçi bir performans sergilemektedir [33].

4. BULGULAR

Tez çalışması kapsamında yapılan her iki yaklaşım için de çözünürlük artırma alanında sıklıkla kullanılan Set5, Set14, BSD100, Urban100 ve bilinmeyen bozulma içeren DIV2K veri setlerinde yer alan görseller ile gerçek dünyadan elde edilmiş yüksek çözünürlüklü görseller ve bu görsellerin sentetik olarak oluşturulmuş düşük çözünürlüklü karşılıklarından oluşmaktadır [23]. Böylece hem süper çözünürlük için önerilen yöntem hem de renk uzayının süper çözünürlük üzerindeki etkisi olabilecek en geniş kapsamda test edilmiştir.

4.1. DIAMOND-EYE MATRİSİNİN SÜPER ÇÖZÜNÜRLÜK ÜZERİNDEKİ BULGULARI

İnterpolasyon yöntemleri arasında iyi sonuçlara ulaşılabilen Lanczos interpolasyon çıktıları baz alınarak kenar-duyarlı odak pikseller üzerinde konumlandırılan Diamond-Eye matrisi dolaştırılarak başarı artırılmıştır.

Önerilen yöntemin sonuçları Şekil 4.1'de gösterilmiştir. Şekil 4.1 incelendiğinde önerilen yöntemin, görseldeki nesnelerin kenarlarında veya yüksek frekanslı geçişlerde, yani renk geçişinin keskin olduğu kısımlarda Lanczos interpolasyona göre daha iyi sonuçlar verdiği görülmektedir.

Önerilen yöntemi karşılaştırmalı değerlendirmek için literatürde sıkça kullanılan ve geliştirilen yönteme de dayanak teşkil eden Lanczos interpolasyonu seçilmiştir. Bu seçimin arkasında daha az bulanıklık, daha keskin kenarlar ve yüksek frekansları daha iyi koruması bulunmaktadır [9, 43].

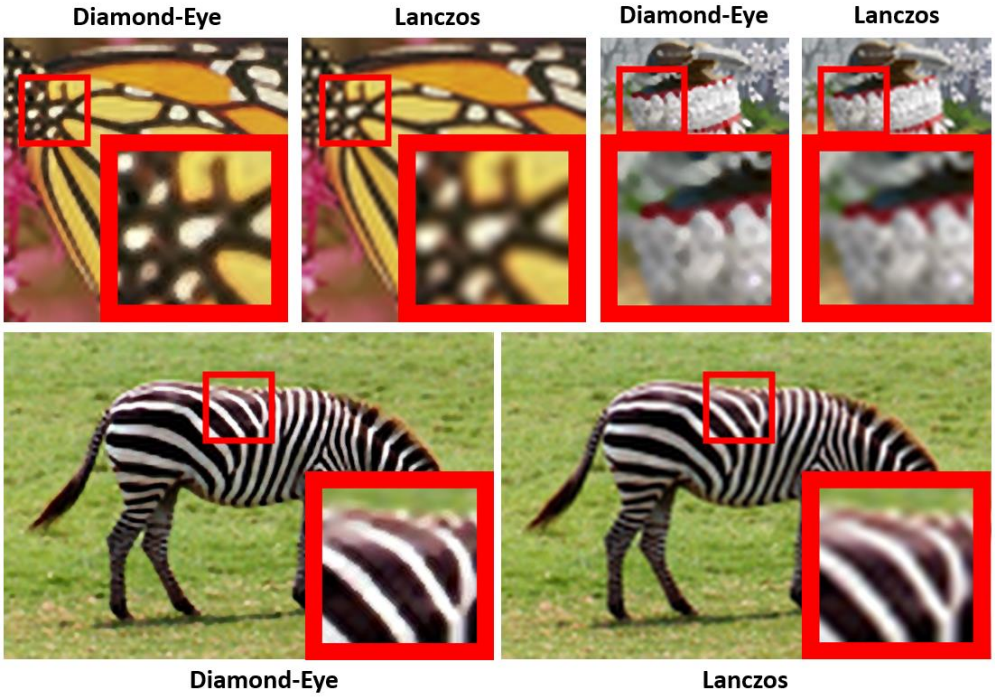

Şekil 4.1: Örnek görseller üzerinde önerilen yöntem ile Lanczos interpolasyon çıktılarının karşılaştırması

PSNR, SSIM, A-DISTS ve LPIPS sonuçlarına göre, her bir metrik için en başarılı beşer görsel sırasıyla Tablo 4.1, Tablo 4.2, Tablo 4.3 ve Tablo 4.4'te sadece Lanczos interpolasyonu uygulandıktan sonraki metrik sonuçları ile Lanczos interpolasyonu sonrasında odak-piksellerin işaret ettiği kısımlara uygulanan d-Eye matrisi sonrası metrik sonuçları ve bu sonuçlar arasındaki yüzdesel değişim miktarları sunulmuştur.

Tablo 4.1: PSNR sonuçlarına göre en başarılı 5 görsel

VERİ SETİ	DOSYA	PSNR		
		Lanczos	d-Eye	Başarı Değişimi
Urban100	img_043.png	21,215	23,684	11,64%
Urban100	img_081.png	27,178	29,506	8,56%
DIV2K	0821.png	25,831	28,035	8,53%
Urban100	img_025.png	25,148	26,781	6,49%
Urban100	img_040.png	18,36	19,531	6,37%

Tablo 4.2: SSIM sonuçlarına göre en başarılı 5 görsel

VERİ SETİ	DOSYA	SSIM		
		Lanczos	d-Eye	Başarı Değişimi
Urban100	img_095.png	0,302	0,328	8,73%
Urban100	img_063.png	0,412	0,442	7,12%
Urban100	img_040.png	0,681	0,73	7,07%
Urban100	img_072.png	0,585	0,625	6,78%
Urban100	img_011.png	0,556	0,591	6,33%

Tablo 4.3: A-DISTS sonuçlarına göre en başarılı 5 görsel

VERİ SETİ	DOSYA	A-DISTS		
		Lanczos	d-Eye	Başarı Değişimi
DIV2K	0821.png	0,837	0,787	5,93%
Set14	pepper.png	0,848	0,805	5,08%
Set14	zebra.png	0,849	0,807	4,97%
BSD100	147091.png	0,788	0,753	4,35%
BSD100	361010.png	0,849	0,812	4,32%

Tablo 4.4: LPIPS sonuçlarına göre en başarılı 5 görsel

VERİ SETİ	DOSYA	LPIPS		
		Lanczos	d-Eye	Başarı Değişimi
Urban100	img_081.png	0,207	0,175	15,72%
Set5	bird.png	0,195	0,17	13,12%
Set5	butterfly.png	0,328	0,289	11,75%
Urban100	img_004.png	0,352	0,315	10,62%
BSD100	143090.png	0,31	0,28	9,73%

Tablo 4.5'te de görüldüğü gibi, d-Eye matrisi ile Set5, Set14, BSD100, Urban100 ve DIV2K veri setlerinin tamamında olumlu sonuçlara ulaşılmıştır. Veri setlerinin içerdiği her bir görsel için ayrıntılı sonuçlar Set5 için Tablo Ek-1 (bkz. S.76), Set14 için Tablo Ek-2 (bkz. S.76), BSD100 için Tablo Ek-3 (bkz. S.76), Urban100 için Tablo Ek-4 (bkz. S.78) ve DIV2K için Tablo Ek-5 (bkz. S.80)'te gösterilmiştir.

Tablo 4.5: Çözünürlük iyileştirme işleminin öncesi ve sonrasındaki PSNR, SSIM, A-DISTS ve LPIPS değerleri ile başarı değişim oranları

VERİ SETLERİ	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
Set5	27,121	27,786	%2,45	0,801	0,821	%2,50	0,812	0,810	%0,25	0,280	0,259	%7,50
Set14	24,484	24,905	%1,72	0,696	0,712	%2,30	0,832	0,822	%1,20	0,367	0,356	%3,00
BSD100	24,854	25,150	%1,19	0,672	0,688	%2,38	0,809	0,203	%0,74	0,388	0,382	%1,55
Urban100	21,918	22,330	%1,88	0,661	0,681	%3,03	0,744	0,741	%0,40	0,380	0,372	%2,11
DIV2K	26,986	27,631	%2,39	0,776	0,789	%1,68	0,757	0,752	%0,66	0,359	0,349	%2,79
Ortalama Başarı Değişimi			**%1,93**			**%2,38**			**%0,65**			**%3,39**

4.2. AKROMATİK EKSENE SAHİP YCbCr VE CIELab RENK UZAYLARININ SÜPER ÇÖZÜNÜRLÜK ÜZERİNDEKİ BULGULARI

Geliştirilmiş görüntülerin kalitesi PSNR ve SSIM ölçütlerine göre değerlendirildiğinde, Ledig ve diğ. [52] çalışmalarında belirttiği üzere, bu metriklerin piksel bazlı farklara dayanması ve algısal ayrıntıları yeterince yansıtamaması nedeniyle çeşitli yöntemlerde bazı tutarsızlıkların öne çıktığı görülmektedir. Bununla birlikte, dönüştürücü (transformer) tabanlı yaklaşımlar açısından bakıldığında, PSNR ve SSIM metriklerinin beklenildiği şekilde işlev gördüğü gözlemlenmektedir. Niteliksel olarak yapılan değerlendirmelerde ise Tablo 4.6'de de görüldüğü gibi, görüntülerin çoğunda Swin2SR modelinin daha başarılı sonuçlar ürettiği gözlemlenmektedir.

Set5 veri kümesinde en yakın komşu, lineer, bikübik ve Lanczos interpolasyonları ile SRGAN, Real-ESRGAN ve Swin2SR yöntemleri kullanılarak elde edilen iyileştirilmiş görüntüler Şekil 4.2, Şekil 4.3 ve Şekil 4.4'te gösterilmiştir.

“

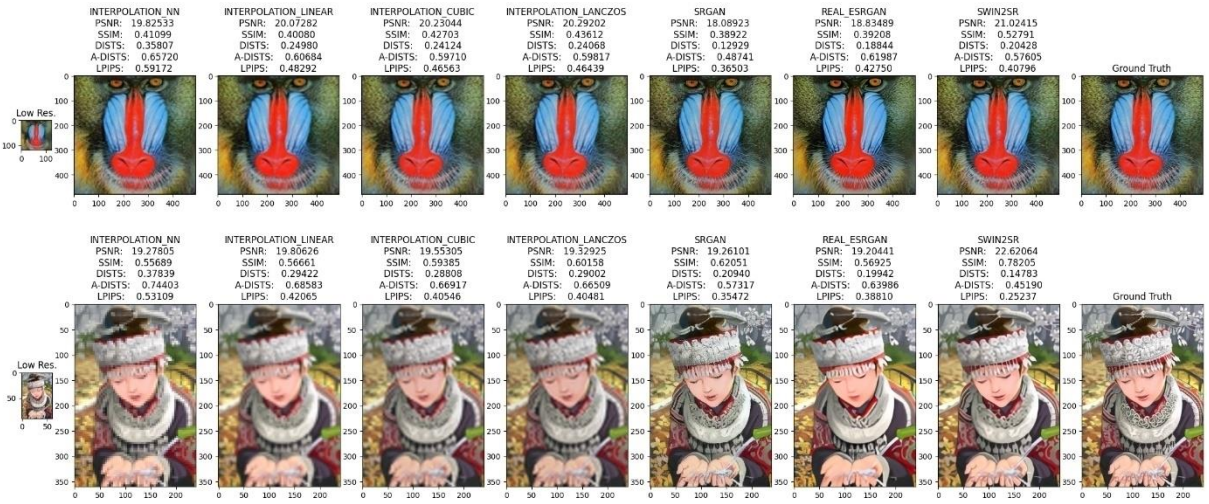

Şekil 4.2: Set14 veri kümesindeki baboon.png ve comic.png görüntüleri üzerinde gerçekleştirilen interpolasyon, SRGAN, Real-ESRGAN ve Swin2SR sonuçları

Real-ESRGAN modelinde kullanılan ağ, tamamen sentetik ve gürültüsüz verilerle eğitilmiştir. Bu nedenle, görüntülerdeki nesne kenarlarını net bir şekilde ortaya koyabilmesine rağmen, bazı durumlarda “güzellik filtresi” etkisiyle görüntüleri yumuşattığı ve bu süreçte ayrıntıların kaybolduğu gözlemlenmektedir. Ayrıca, *baboon* görüntüsü özelinde DISTS ve A-DISTS metrikleri arasında bir uyumsuzluk dikkat çekmektedir. Bu durum, yerel desenleri daha hassas biçimde değerlendirebilen A-DISTS metriğinin, DISTS’e kıyasla daha iyi optimize edilmiş olmasından kaynaklanmaktadır. Doku ayrıntılarının belirleyici olduğu bu tür görüntülerde, başarım ölçütü olarak A-DISTS’in daha uygun bir metrik olduğu söylenebilir.

Öte yandan, RGB renk uzayında eğitilerek elde edilen SRGAN ve Real-ESRGAN çıktıları YCbCr renk uzayına dönüştürüldüğünde, yalnızca PSNR ve SSIM değerlerinde gözle görülür bir artış yaşandığı, bu artışın ise doğrudan renk uzayı dönüşümünden kaynaklandığı görülmektedir.

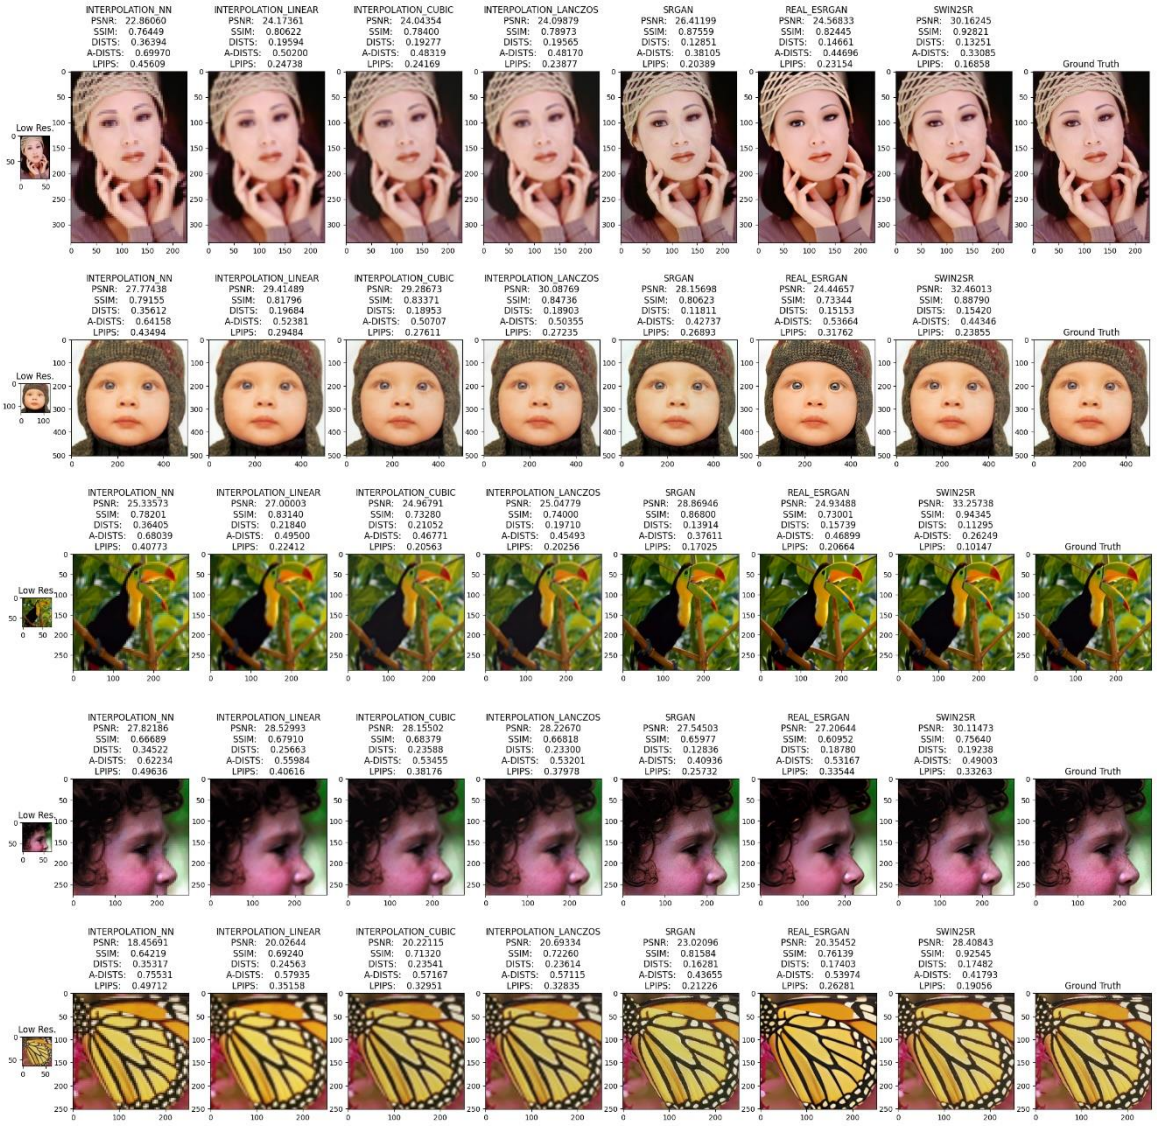

Şekil 4.3: Set5 veri kümesi üzerindeki interpolasyon, SRGAN, Real-ESRGAN ve Swin2SR sonuçları

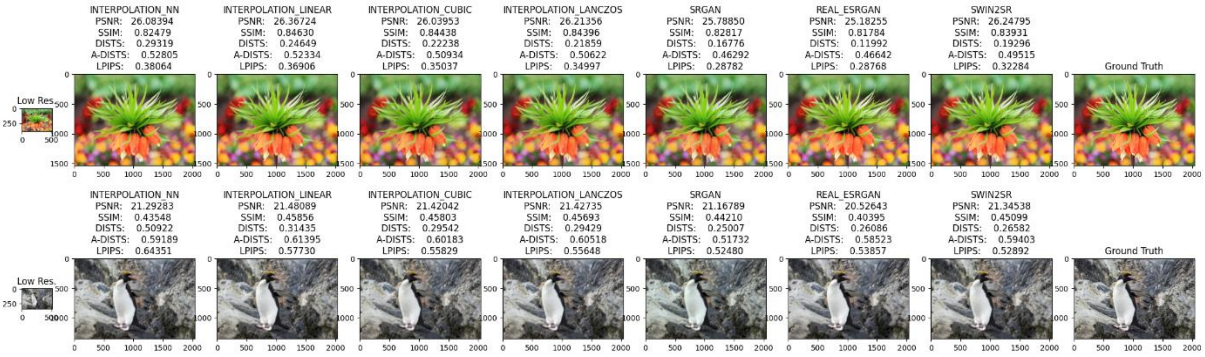

Şekil 4.4: DIV2K veri kümesi üzerindeki interpolasyon, SRGAN, Real-ESRGAN ve Swin2SR sonuçları

Tablo 4.6, veri kümelerine uygulanan yöntemlere göre YCbCr ve CIELab renk uzaylarına dönüştürmeden önce ve sonra hesaplanan PSNR, SSIM, DISTS, A-DISTS ve LPIPS değerlerinin ortalamalarını göstermektedir. PSNR ve SSIM değerlerinin yüksek olması daha iyi sonuçlara işaret ederken; DISTS, A-DISTS ve LPIPS metriklerinde ise daha düşük değerler daha iyi görüntü kalitesini ifade etmektedir. Veri kümesi ve kalite metriği bazında en iyi skorlar kalın gösterilmiştir.

Tablo 4.6: Görsellerin YCbCr ve CIELab renk uzaylarına dönüştürülmeden önce ve sonra elde edilen kalite değerlendirme puanları [102]

Veriseti	Metod	Dönüşüm Öncesi (RGB)					Dönüşüm Sonrası Başarı Değişimi (%)									
							YCbCr					CIELab				
		PSNR	SSIM	DISTS	A-DISTS	LPIPS	PSNR	SSIM	DISTS	A-DISTS	LPIPS	PSNR	SSIM	DISTS	A-DISTS	LPIPS
Set5	İnterpolasyon – NN	29.03	0.86	0.26	0.48	0.34	18.7%	18.2%	28.3%	29.1%	26.7%	17.8%	18.1%	28.1%	27.8%	28.3%
	İnterpolasyon - Lineer	30.44	0.89	0.21	0.42	0.28	17.9%	16.3%	5.2%	20.6%	8.4%	17.0%	16.1%	8.0%	21.2%	13.0%
	İnterpolasyon - Bikübik	30.04	0.89	0.20	0.39	0.26	18.6%	19.1%	6.4%	23.6%	10.5%	18.5%	18.7%	8.9%	24.1%	15.0%
	İnterpolasyon - Lanczos	30.34	0.90	0.19	0.38	0.25	18.4%	18.8%	8.7%	25.2%	12.8%	18.3%	18.4%	11.0%	25.7%	16.9%
	SRGAN	31.44	0.90	0.09	0.23	**0.14**	17.3%	12.0%	36.8%	43.0%	36.8%	16.9%	11.3%	39.6%	44.7%	40.9%
	Real-ESRGAN	28.81	0.85	0.14	0.37	0.21	18.5%	16.5%	13.5%	26.7%	21.0%	17.8%	16.3%	19.5%	29.3%	25.1%
	Swin2SR	**35.57**	**0.94**	**0.11**	**0.24**	**0.14**	15.2%	6.4%	31.1%	38.6%	32.0%	14.5%	6.1%	34.6%	41.0%	36.2%
Set14	İnterpolasyon – NN	27.07	0.82	0.26	0.50	0.37	20.1%	26.9%	25.2%	24.4%	25.6%	19.5%	26.9%	25.6%	24.0%	25.5%
	İnterpolasyon - Lineer	27.75	0.83	0.24	0.49	0.35	19.6%	25.8%	-5.2%	15.7%	10.2%	19.1%	25.8%	-4.5%	15.3%	10.7%
	İnterpolasyon - Bikübik	27.31	0.84	0.24	0.47	0.33	20.1%	25.7%	-4.3%	17.8%	11.3%	20.1%	25.8%	-3.5%	17.4%	11.5%
	İnterpolasyon - Lanczos	27.11	0.84	0.23	0.46	0.33	20.3%	25.4%	-3.3%	18.8%	12.0%	20.3%	25.4%	-2.9%	18.2%	12.1%
	SRGAN	28.36	0.83	**0.12**	0.34	**0.22**	19.4%	23.5%	20.5%	28.3%	26.8%	19.1%	22.8%	21.2%	28.3%	27.6%
	Real-ESRGAN	27.80	0.81	0.15	0.44	0.27	19.5%	25.3%	3.8%	18.5%	17.0%	19.1%	25.3%	3.8%	19.1%	17.6%
	Swin2SR	**31.50**	**0.89**	0.14	**0.34**	**0.22**	16.8%	14.0%	11.5%	26.3%	22.8%	16.5%	14.0%	9.9%	26.2%	22.5%
BSD100	İnterpolasyon – NN	25.85	0.83	0.28	0.51	0.41	22.0%	43.5%	25.2%	21.6%	24.7%	21.1%	43.3%	24.8%	20.2%	24.2%
	İnterpolasyon - Lineer	26.75	0.86	0.27	0.49	0.37	21.3%	38.7%	-4.6%	16.9%	11.6%	20.5%	38.3%	-3.5%	16.2%	11.1%
	İnterpolasyon - Bikübik	26.43	0.87	0.26	0.47	0.36	21.5%	36.8%	-4.9%	18.0%	9.8%	20.8%	36.4%	-4.1%	17.2%	9.0%
	İnterpolasyon - Lanczos	26.50	0.87	0.26	0.47	0.35	21.5%	36.1%	-4.0%	18.8%	10.7%	20.8%	35.7%	-3.5%	18.0%	10.1%
	SRGAN	28.09	0.84	**0.12**	**0.32**	**0.22**	20.2%	34.4%	27.4%	31.0%	27.6%	19.3%	32.6%	25.4%	30.2%	26.9%
	Real-ESRGAN	28.25	0.85	0.16	0.41	0.27	19.8%	34.7%	13.6%	24.0%	22.6%	19.1%	34.1%	13.4%	23.4%	22.1%
	Swin2SR	**31.33**	**0.91**	0.17	0.36	0.25	17.8%	21.7%	14.8%	27.5%	25.2%	17.0%	21.3%	15.4%	26.9%	25.2%
Urban100	İnterpolasyon – NN	25.33	0.81	0.26	0.47	0.36	22.5%	31.6%	21.4%	21.2%	22.1%	21.6%	32.1%	20.6%	20.5%	21.9%
	İnterpolasyon - Lineer	25.84	0.82	0.26	0.46	0.35	22.0%	31.4%	1.1%	17.8%	12.9%	21.1%	31.7%	1.1%	17.5%	13.6%
	İnterpolasyon - Bikübik	25.13	0.82	0.25	0.44	0.33	22.7%	35.2%	1.7%	18.9%	14.6%	22.1%	35.4%	1.6%	18.5%	14.9%
	İnterpolasyon - Lanczos	25.12	0.82	0.25	0.44	0.33	22.7%	34.7%	2.4%	19.4%	15.0%	22.1%	34.8%	2.2%	19.0%	15.1%
	SRGAN	26.93	0.84	**0.11**	0.33	0.21	21.1%	19.7%	29.2%	29.8%	30.9%	20.2%	18.5%	28.3%	30.1%	31.1%
	Real-ESRGAN	25.69	0.82	0.13	0.38	0.25	22.0%	24.5%	12.7%	23.4%	21.2%	21.1%	24.9%	12.6%	24.0%	22.1%
	Swin2SR	**30.55**	**0.91**	**0.11**	**0.29**	**0.18**	18.0%	11.1%	26.0%	30.9%	29.2%	17.2%	11.0%	26.1%	31.6%	30.6%
DIV2K	İnterpolasyon – NN	22.93	0.57	0.41	0.59	0.54	18.1%	40.3%	28.9%	17.0%	20.6%	18.8%	40.3%	26.3%	16.5%	17.7%
	İnterpolasyon - Lineer	23.20	0.58	0.30	0.61	0.51	17.8%	37.5%	-2.5%	17.7%	14.0%	18.5%	37.1%	-3.5%	14.8%	10.8%
	İnterpolasyon - Bikübik	22.80	0.57	0.28	0.59	0.49	18.4%	41.9%	-1.6%	18.3%	13.5%	19.1%	41.5%	-2.0%	16.2%	9.9%
	İnterpolasyon - Lanczos	22.95	0.58	0.28	0.59	0.49	19.0%	41.0%	0.3%	19.4%	14.2%	18.8%	43.7%	-0.9%	16.5%	10.9%
	SRGAN	23.00	0.57	0.23	**0.53**	**0.44**	18.3%	41.7%	4.4%	18.0%	16.2%	18.8%	41.3%	2.5%	27.7%	13.1%
	Real-ESRGAN	22.33	0.54	**0.21**	0.58	**0.44**	16.9%	47.0%	10.8%	10.9%	14.4%	19.5%	46.6%	4.9%	18.8%	10.3%
	Swin2SR	**23.29**	**0.59**	0.25	0.58	0.46	36.7%	38.7%	2.9%	22.2%	14.9%	18.5%	37.5%	1.1%	19.4%	10.8%
						ORTALAMA BAŞARI (%):	**20.0%**	**28.5%**	**10.9%**	**22.8%**	**18.9%**	**19.2%**	**28.3%**	**11.1%**	**23.0%**	**18.9%**

5. TARTIŞMA

5.1. DIAMOND-EYE MATRİSİ KULLANIMININ ETKİLERİ

Bu tez çalışmasının, öncelikle görsellerde bulunan nesnelerin kenarlarına odaklanmasını sağlayan çalışmalara aşağıda değinilmiştir. Bahsedilen çalışmalar, süper çözünürlük işlemi sonucunda bozulmaların genellikle kenarlarda ve karmaşık desenin yoğun olduğu alanlarda olduklarını tespit etmişlerdir. Tez çalışması kapsamında gerçekleştirilen deneylerle de desteklenen bu tespit neticesinde görsellerdeki nesnelerin kenarlarına odaklanılmasını sağlayan bir algoritma önerilmiştir.

Lee ve diğ. [103] tek görüntülü süper çözünürlükte sıklıkla gözlemlenen doku kayıpları ve yapısal bozulmalara dikkat çekmiştir. Yapısal bilgilerin daha iyi korunması amacıyla kenar profil maskeleri oluşturulur. Eğitim sürecinde çıktı ile orijinal görsel arasındaki fark alınarak maske oluşturulur ve ardından bu maskeye ReLU uygulanarak görseldeki nesnelerin ana hatları çıkarılır. Burada amaç, nesnelerin kenarlarına dikkat edilmesini sağlamaktır.

Chen ve diğ. [104] süper çözünürlükte bölgesel farklılara dikkat çekmektedirler. Yama tabanlı süper çözünürlük yöntemlerinden ilham alarak "Smoothness Similarity and Edge-Direction based Interpolation (SSEDI)" adını verdikleri yeni bir yöntem geliştirmişlerdir. Görselden çıkarılan referans yamalar ile pürüzsüzlük benzerliği ve kenar yönü dikkate alınarak görüntü bölgelerine özel süper çözünürlük gerçekleştirmişlerdir. Hangi özelleştirilmiş süper çözünürlük algoritmasını uygulayacaklarını seçmek için adaptif bir füzyon algoritması önermişlerdir. Böylece düz, kenar veya düzenli yapılar için ayrı algoritmaların kullanılması mümkün hale gelmiştir. Böylece görselin tamamında, bölgesel karakteristiklere dikkat eden bir süper çözünürlük algoritması geliştirmişlerdir.

Nazeri ve diğ. [105] görüntüdeki eksik nesneleri tamamlama fikrinden yola çıkarak, süper çözünürlük sürecini de görüntüdeki eksik verileri tamamlı bakış açısıyla ele almışlar ve görüntü tamamlama odaklı bir çalışma gerçekleştirmişlerdir. Bu çalışmada nesnelerin kenar bilgilerinin korunmasını temel bir gereklilik olarak görmüşler ve kenar bilgilerini korumayı ön plana çıkaran bir algoritma geliştirmişlerdir. x2, x4 ve x8 yükseltme faktörleriyle yaptıkları çalışmalarda kenar ve içerik bilgisinin birlikte değerlendirilerek optimize edildiği bir derin

öğrenme yaklaşımıdır. Süper çözünürlük problemini, görseldeki üzerinde bir eksiklik olduğunu varsayarak görseldeki nesneyi tamamlama sorunu gibi ele almaktadır.

Vishnukumar ve diğ. [106] kenar koruma odaklı bir süper çözünürlük algoritması geliştirerek hem görsel kaliteyi hem de kenar netliğini eş zamanlı iyileştirmeyi amaçlamaktadırlar. Klasik yöntemlerdeki kenar bulanıklığı sorununu çözme odaklı geliştirdikleri algoritma ile hem kendi örneklerinden öğrenme hem de öz-örneklerinin yeniden örneklenmesiyle fark katmanı oluşturulur. Gaussian fonksiyonu ile hesaplanan katmanların ağırlıklı ortalaması ile elde edilen bilgilerle kenar bilgisi korunmuş, daha net görüntüler elde edilmiştir.

Bu tez çalışması kapsamında hem geleneksel kabul edilen interpolasyon yöntemleri hem de daha yenilikçi ve güncel olan GAN ve transformer tabanlı sinir ağı mimarileri ile yapılan deneylerde, öncelikle süper çözünürlük sürecinde görsellerin hangi kısımlarında sorunlar yaşandığı tespit edilmiştir. Farklı yöntemlerle yapılan testler sonucunda, ortak nokta denilebilecek bir sonuca ulaşılmıştır: Şekil 3.1'de de görüldüğü gibi, görsellerde yer alan nesnelerin kenar hatları, süper çözünürlük yöntemlerinde daha fazla çalışma gerektiren alanlardır ve bu alanlarda orijinal görsel ve uygulanan yöntemlerin çıktıları arasında farklılıklar daha yüksektir.

Sorunun belirlenmesiyle birlikte, görsellerdeki nesnelerin kenar hatlarını temsil edebilecek adaptif bir yöntem geliştirilmiştir. Böylece önerilen yöntem, kesin matematiksel bir yönteme dayanmasının yanında veriye de duyarlı olacak şekilde çalışan bir kimliğe bürünmüştür.

Önerilen yöntemde bir interpolasyon metodunun seçilmesinin sebebi matematiksel modele dayalı, girdi ve çıktı arasında kuralları net olan bir yöntem üzerinden gidilerek yöntemin başarısını daha net bir şekilde tartışabilmektir. Lanczos interpolasyonu seçilmesindeki temel neden ise yüksek frekans bileşenlerini korumada bikübik ve bilineer interpolasyonlara göre daha başarılı olması, kenar detaylar ve ince yapılar üzerinde daha az bulanıklık oluşturması öne çıkmaktadır [9]. Yüksek frekans detayları özelinde başarılı sonuçlar ortaya koyması sebebiyle tercih edilen Lanczos interpolasyonu ile Moirè ve basamaklama (aliasing) tipi bozulmaların üstesinden daha kolay gelinmektedir. Basamaklama bozulmaları, örnekleme frekansının yetersizliğinde karşılaşılan bir durumdur. Dijital görüntülerde ise çözünürlük yetersizliği

durumlarında ortaya çıkar. Moirè etkisi ise periyodik yapıların üst üste binmesi sonucu yüksek frekanslı örüntülerde dalgalanma etkisi olarak göze çarpar [107].

Alanda kenar keskinleştirme üzerine kurgulanan filtrelere benzer nitelikteki keskinleştirme filtrelerinden biri olan, 5x5 boyutundaki merkez ağırlıklı genişletilmiş yüksek frekans filtresi olarak (5.1)'de gösterilen yüksek merkez ağırlıklı ve negatif çevre ağırlıklı filtre ile yapılan karşılaştırma neticesinde elde edilen sonuçlar Tablo 5.1'de gösterilmiştir. Bu matriste, Diamond-Eye matrisinde olduğu gibi matristeki veriler normalize edilerek kullanılmıştır ve kenar iyileştirme matrislerinde görülen "1"e eşleme durumu görülmektedir [43, 108].

$$\begin{bmatrix} -1 & -1 & -1 & -1 & -1 \\ -1 & 2 & 2 & 2 & -1 \\ -1 & 2 & 8 & 2 & -1 \\ -1 & 2 & 2 & 2 & -1 \\ -1 & -1 & -1 & -1 & -1 \end{bmatrix} * \frac{1}{8} \tag{5.1}$$

Tablo 4.5 ve Tablo 5.1 birlikte incelendiğinde, odak pikseller üzerinde çalıştırılan adaptif Diamond-Eye matrisinin PSNR, SSIM ve LPIPS metriklerine göre daha başarılı sonuçlara ulaştığı gözlemlenmektedir.

Tablo 5.1: Kenar-duyarlı uygulanan merkez ağırlıklı keskinleştirme filtresi ile elde edilen sonuçların Lanczos interpolasyonu ile karşılaştırmalı sonuçlar

VERİ SETLERİ	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	Matris (5.1)	Başarı Değişimi	Lanczos	Matris (5.1)	Başarı Değişimi	Lanczos	Matris (5.1)	Başarı Değişimi	Lanczos	Matris (5.1)	Başarı Değişimi
Set5	27,121	27,496	%1,38	0,801	0,819	%2,25	0,812	0,807	%0,62	0,280	0,268	%4,29
Set14	24,484	24,717	%0,95	0,696	0,712	%2,30	0,832	0,817	%1,80	0,367	0,362	%1,36
BSD100	24,854	24,99	%0,55	0,672	0,689	%2,53	0,809	0,800	%1,11	0,388	0,388	%0,00
Urban100	21,918	22,168	%1,14	0,661	0,680	%2,87	0,744	0,741	%0,40	0,380	0,374	%1,58
DIV2K	26,755	27,143	%1,45	0,770	0,783	%1,69	0,765	0,761	%0,52	0,359	0,352	%1,95
Ortalama Başarı Değişimi			**%1,09**			**%2,33**			**%0,89**			**%1,84**

5.2. RENK UZAYI DÖNÜŞÜMÜNÜN ETKİLERİ

Bu tez çalışması, RGB verisinin farklı renk uzaylarına dönüştürülmesinin çift yönlü etkisini incelemekte; yalnızca değerlendirme metriklerindeki nicel değişimleri değil, aynı zamanda bu değişimlerin insan algısıyla olan ilişkisini de ön plana çıkarmaktadır. Bulgular, bazı dönüşümlerin belirli metriklerde iyileşme sağladığını ancak bu iyileşmelerin algısal

anlamda her zaman karşılık bulmadığını ortaya koymaktadır. Bu durum, gelecekteki araştırmalarda insan merkezli değerlendirmelerin mutlaka göz önünde bulundurulması gerektiğini vurgulamaktadır. Elde edilen sonuçlar, mevcut literatürde önemli bir boşluğu işaret ederek, hesaplamalı doğruluk ile algısal geçerliliği dengeleyen yeni yöntemlerin geliştirilmesi gerekliliğine dikkat çekmektedir.

Süper çözünürlük çalışmalarında PSNR ve SSIM metriklerini iyileştirmek amacıyla YCbCr renk uzayının etkili bir seçenek olduğunu vurgulamıştır. Bizim bulgularımız da bu görüşleri desteklemekte; YCbCr renk uzayına yapılan dönüşümlerin söz konusu metriklerde daha yüksek skorlar elde edilmesini sağladığını göstermektedir. Ancak, önceki çalışmalarda da belirtildiği gibi, bu sayısal iyileşmeler algısal görüntü kalitesinde belirgin bir artışa karşılık gelmemektedir. CIELab renk uzayına yapılan dönüşümlerde elde edilen sonuçlar ise John ve diğ. [67]'nin bu renk uzayının çözünürlük iyileştirmede potansiyel taşıdığı yönündeki değerlendirmeleriyle örtüşmektedir. Bununla birlikte, deneysel verilerimiz göstermektedir ki bu tür dönüşümlerin sağladığı katkılar büyük ölçüde metrik odaklıdır ve görsel sadakat açısından anlamlı bir iyileşme sunmamaktadır [82].

Dong ve diğ. [6], YCbCr renk uzayı yalnızca aydınlık (luminance) bileşeni üzerinde işlem yapılmasına olanak tanıyarak, algısal iyileştirmeyi hedefleyen süper çözünürlük uygulamaları için önemli bir avantaj sunduğunu tespit etmişlerdir. Bu yaklaşım hem hesaplama yükünü azaltmakta hem de renk bileşenlerinde oluşabilecek bozulmaların önüne geçmektedir.

Xu ve diğ. [109], renk kanalı kısıtlamalarını L2/3 seyrek düzenleme ile birleştiren bir süper çözünürlük yeniden yapılandırma yöntemi önermektedir. Bu çalışmada, düşük çözünürlüklü görüntüler YCbCr renk uzayına dönüştürülmekte; parlaklık (Y) kanalı seyrek modelle iyileştirilirken, renk (Cb ve Cr) kanalları ise renk bozulmalarını azaltacak şekilde düzenlenmektedir. Önemle belirtilmelidir ki bu çalışma yalnızca Tablo 5.2'de listelenen beş görüntüye x2 büyütme faktörü uygulanarak gerçekleştirilmiş ve PSNR ile SSIM değerlendirmeleri yalnızca Y kanalı üzerinden yapılmıştır.

Tablo 5.2. Xu ve diğ. [109] tarafından önerilen yöntem ile bikübik interpolasyonun YCbCr renk uzayında x2 büyütme faktörüyle elde edilen sonuçları

Görsel	PSNR			SSIM		
	Bikübik İnterpolasyon	**Xu ve diğ.** [109]	**Başarı Değişimi**	**Bikübik İnterpolasyon**	**Xu ve diğ.** [109]	**Başarı Değişimi**
Flowers	30,38	33,40	%9,9	0,898	0,938	%4,5
Comic	26,06	27,92	%7,1	0,851	0,908	%6,7
Butterfly	27,42	31,19	%13,7	0,915	0,958	%4,7
Skiing	32,00	34,33	%7,3	0,931	0,953	%2,4
Bike	25,66	27,92	%8,8	0,850	0,913	%7,4

Bu tez çalışmasındaki tüm deneylerde çözünürlük artırma işlemi RGB renk uzayında gerçekleştirilmiş, başarı ölçümleri ise tabloda belirtilen renk uzaylarına dönüşüm öncesi ve sonrasında hesaplanmıştır. Bu sayede, farklı renk uzaylarının başarı değerleri üzerindeki etkileri, iyileştirme aşamasına müdahale etmeden incelenmiştir. RGB renk uzayındaki bir görüntünün YCbCr veya CIELab renk uzayına dönüştürülmesi görüntü kalitesinde gerçek bir değişikliğe yol açmasa da kalite değerlendirme metriklerini olumlu yönde etkileyebilmektedir. Ancak, mevcut metrikler Tek Görüntü Süper Çözünürlük (SISR) yöntemlerinin farklı renk uzaylarındaki etkilerini değerlendirmede yetersiz kalmaktadır. Bu nedenle, farklı renk uzaylarında başarıyı etkili şekilde değerlendirebilecek alternatif metriklere ihtiyaç vardır. Bu tür metrikler geliştirilmeden renk uzayı dönüşümlerinin etkilerini sağlıklı bir şekilde analiz etmek mümkün değildir.

Renk uzayları arasındaki değer aralıklarının tam olarak örtüşmemesi nedeniyle, interpolasyon ve derin öğrenme tabanlı mimarilerde başarı yüksek görünmektedir. Bu uyumsuzluk, bazı metriklerin değerleri olduğundan daha olumlu değerlendirmesine neden olabilmektedir. Renk uzaylarının uç değerleri ve alabilecekleri olası farklı değer sayıları Tablo 5.3'te gösterilmiştir.

Bir RGB görüntüsünü, daha geniş bir değer aralığına sahip olan RGB renk uzayından, daha dar bir aralıkta çalışan YCbCr renk uzayına dönüştürmek, mümkün olan renk kombinasyonlarının sayısını 16.581.375'ten 11.137.500'e düşürür. Görüntü kalitesinde, uygulanan teknik dışında herhangi bir iyileşme olmasa da bu azalmayla birlikte değerlendirme metrikleri açısından kalite artmış gibi görünmektedir. Benzer bir durum CIELab renk uzayında da gözlemlenmektedir. RGB'den CIELab'a dönüşüm yapıldığında, bu kez olası değer sayısı 4.932.941'e kadar düşmektedir.

Tablo 5.3. RGB, YCbCr ve CIELab renk uzaylarına ait eksenlerin değer aralıkları [110]

	RGB			**YCbCr**			**CIELab**		
	R	**G**	**B**	**Y**	**Cb**	**Cr**	**L***	**a***	**b***
En Yüksek Değer	255	255	255	235	240	240	100	110	110
En Düşük Değer	0	0	0	16	16	16	0	-110	-110
Farklı Değer Sayısı	256	256	256	220	225	225	101	221	221
Renk Uzayının Alabileceği En Fazla Değer Sayısı	**16.777.216**			**11.137.500**			**4.932.941**		

Bu tür renk uzayı dönüşümlerinin değerlendirme metrikleri üzerindeki etkisi, görüntü işleme alanındaki diğer uygulamalarda da benzer biçimde araştırılabilir.

Tüm bu değerlendirmelere rağmen, RGB dışındaki iki renk uzayı karşılaştırıldığında, YCbCr uzayı, RGB'ye göre doğrusal dönüşüm özelliği ve aydınlık (Y) kanalının ayrı işlenebilmesi sayesinde hesaplama açısından daha verimlidir. Bu durum, renk doğruluğundan ziyade yapısal doğruluğun önemli olduğu görevlerde YCbCr'yi ideal hale getirir. Bununla birlikte, CIELab renk uzayının insan algısıyla daha uyumlu olması, yüksek renk doğruluğunun istendiği uygulamalar için uygun hale getirir; ancak bu da daha yüksek hesaplama maliyetiyle sonuçlanır. Bu nedenle, YCbCr genellikle gerçek zamanlı işlemlerde tercih edilirken, CIELab daha çok çevrimdışı süreçlerde, algısal kaliteye öncelik verilen uygulamalarda kullanılır.

6. SONUÇ VE ÖNERİLER

Günümüz dünyasında donanım maliyetini düşürmek amacıyla daha küçük görüntü sensörlerinin kullanımı, depolama alanını etkin kullanmak amacıyla kaydedilirken küçültülen veya sıkıştırılan görüntüler, veri aktarımı sürecinde bant genişliğinin daha etkili kullanılmak istenmesi gibi sebeplerle görüntü çözünürlükleri düşürülmektedir. Ancak bazı durumlarda, bu görüntülerin tekrar kullanımı aşamasında görüntünün orijinal kalitesine yakın bir kaliteye dönmek gerekmektedir. Donanımsal sınırları aşmak, veri ekonomisini daha iyi yönetmek ve görüntü üzerine kurgulanacak sistemin başarısını sınırlamamak adına süper çözünürlük yöntemlerine ihtiyaç duyulmaktadır.

Düşük çözünürlüklü görselin iyileştirilmesi için eksik verilerin aslına uygun bir şekilde hesaplanması gerekmektedir. Bu eksik verilerin aslına uygun olarak tespit edilmesi, süper çözünürlük işleminin başarısını artırmaktadır.

Tez çalışması kapsamında, hem süper çözünürlük başarısını artıran bir yöntem önerisi hem de sonuçlarıyla ilgi çekici olan renk uzaylarının incelendiği bir araştırma yer almıştır.

6.1. DIAMOND-EYE MATRİSİNİN ETKİLİLİĞİ

Bu tez çalışmasında, düşük çözünürlüklü görsellerin yüksek kaliteye sahip sürümlerinin elde edilmesini hedefleyen süper çözünürlük algoritmaları detaylı biçimde incelenmiş, alanda mevcut sorunlar analiz edilerek özgün bir çözüm yaklaşımı sunulmuştur. Literatürde sıklıkla karşılaşılan detay kaybı problemi, bu çalışmanın temel çıkış noktası olarak benimsenmiş ve kenar-duyarlı adaptif bir yöntem geliştirilmiştir. Görsellerdeki bu kayıpların çoğunlukla görsellerdeki nesnelerin kenarlarında, doku geçişlerinde ve ani renk geçişlerinde olduğu gözlemlenmiştir. Tez çalışmasının temel çalışma alanı, bahsedilen yüksek frekanslı verilere odaklanarak öncelikle yüksek frekanslı verilerin aslına uygun bir şekilde tespit edilmesi olmuştur.

Yüksek frekanslı verilerin tespit edilmesi için interpolasyon tabanlı yöntemlerde, SRGAN ve Real-ESRGAN isimli derin sinir ağı mimarilerinde, transformer tabanlı bir yöntem olan Swin2SR üzerinde yapılan deneylerde, görsel üzerindeki başarısı düşük alanların

genellikle yüksek frekanslı verilerin bulunduğu kısımlarda olduğu fark edilmiştir. Bu yüzden, problem alanını daraltmak adına yüksek frekanslı veriler üzerinde çalışılmasını sağlayan "odak piksel" tespiti yapılmıştır. Odak pikseller üzerinde, adaptif bir şekilde dolaştırılan Diamond-Eye matrisi, Lanczos interpolasyonunu temel alarak geliştirilmiştir ve diğer yöntemlere de uyarlanabilir niteliktedir. Farklı çözünürlük ve sahne içeriğine sahip veri setleri (Set5, Set14, BSD100, Urban100, DIV2K) üzerinde gerçekleştirilen testlerde, yöntem hem klasik metrikler (PSNR, SSIM) hem de algısal metrikler (A-DISTS, LPIPS) açısından başarılı sonuçlar üretmiştir. Adaptif yapısı ve ağırlık parametrelerinin yöntemlere göre optimize edilebilir nitelikte olması, özellikle bilinen bozulmalı süper çözünürlük çalışmalarının başarılarına olumlu katkı sağlayabilir. Ancak bununla birlikte, DIV2K veri setindeki düşük çözünürlüklü görüntüler üzerinde de başarılı sonuçlara ulaşılmıştır. Yalnızca görüntüdeki odak piksellerin işaret ettiği kısıtlı bir alanda uygulanmasına rağmen sağlanan başarı artışı tatmin edici düzeydedir.

Önerilen Diamond-Eye matrisi, gelecek çalışmalarda görselin yerel ve genel özelliklerine göre, tanımlanan iris bağıntıları kullanılarak adaptif ağırlıklandırmanın yanında adaptif boyut yaklaşımıyla uygulanabilir. Görüntünün yerel özellikleri değerlendirilirken SAM (Segment Anything Model) gibi başarılı bölümleme yöntemleri kullanılarak belirli bir dokuya veya bölgeye, yerel özelliklerle uyumlu olacak şekilde farklı ağırlıklarda ve gerekirse farklı boyutlarda Diamond-Eye matrisi uygulanabilir. Önerilen matrisin temel özelliklerinden biri, boyut değiştiğinde matris elemanlarının da değişebilir nitelikte olmasıyla boyut ve ağırlıklandırma bakımından da adaptif kimliğe sahip olmasıdır. Bunun yanında odak piksel değerlerine göre değişen iris değerleri ve iris değerlerinin çapraz geçişli konumlandırılmasıyla kenarlardaki yataylık-dikeylik özelliklerine tek matris ile yüksek uyum sağlanmıştır.

Kenar-duyarlı odak pikseller üzerinde çalışan adaptif Diamond-Eye matrisi tıbbi görüntüleme, uydu sistemleri, güvenlik sistemleri gibi farklı alanlarda da uygulanabilir.

6.2. RENK UZAYI DÖNÜŞÜMÜ

Bu çalışma, renk uzayı dönüşümleri ile süper çözünürlük teknikleri arasındaki ilişkiyi ele alarak sayısal değerlendirme metrikleri ile algısal kalite arasındaki dengeyi ortaya koymaktadır. Çözünürlük artırma uygulamalarında RGB renk uzayı hâlen standart olarak

kullanılmakla birlikte akromatik bileşen içeren renk uzaylarıyla çalışmak merak uyandıran bir alandır.

Bu çalışmada RGB renk uzayında süper-çözünürlük yapılmış, işlem başarısı ise farklı renk uzayları üzerinde ölçülmüştür. YCbCr ve CIELab gibi akromatik (renksizlik) ekseni içeren renk uzaylarına yapılan dönüşümlerin etkisi; interpolasyon yöntemleri, SRGAN, Real-ESRGAN, Swin2SR gibi farklı yöntemler üzerinde incelenmiştir. Tez çalışması kapsamında gerçekleştirilen yaklaşım ile iyileştirme sürecinin RGB renk uzayında yapılmasına ve ölçümlerin hedef renk uzaylarında yapılmasına rağmen iyileştirme sonrasında yapılan bu dönüşümler hem piksel bazlı hem de algısal tabanlı kalite metriklerinde belirgin değişimlere yol açmaktadır. Bu durum, farklı renk uzaylarında çalışmanın gerçekten algılanan görüntü kalitesini etkileyip etkilemediği ya da yalnızca sayısal sonuçları mı değiştirdiği sorusunu gündeme getirmektedir.

Gelecekteki çalışmalar, kalite değerlendirme yöntemlerinin daha tutarlı hale getirilmesine ve hem algısal hem de hesaplama açısından avantaj sağlayabilecek hibrit yaklaşımların geliştirilmesine odaklanabilir.

KAYNAKLAR

[1]. Yue, L., Shen, H., Li, J., Yuan, Q., Zhang, H., ve Zhang, L., 2016, Image super-resolution: The techniques, applications, and future, *Signal processing*, 128, 389-408.

[2]. Candès, E. J. ve Fernandez-Granda, C., 2014, Towards a mathematical theory of super-resolution, *Communications on pure and applied Mathematics.*, 67 (6), 906-956.

[3]. Bashir, S. M. A., Wang, Y., Khan, M., ve Niu, Y., 2021, A comprehensive review of deep learning-based single image super-resolution, *PeerJ Computer Science*, 7, 1-56.

[4]. Zhang, K., Gao, X., Tao, D., ve Li, X., 2013, Single image super-resolution with multiscale similarity learning, *IEEE transactions on neural networks and learning systems*, 24 (10), 1648-1659.

[5]. Wang, Z., Liu, D., Yang, J., Han, W., ve Huang, T., 2015, Deep Networks for Image Super-Resolution with Sparse Prior, *2015 IEEE International Conference on Computer Vision (ICCV)*, 370-378.

[6]. Dong, C., Loy, C. C., He, K., ve Tang, X., 2016, Image Super-Resolution Using Deep Convolutional Networks, *IEEE transactions on pattern analysis and machine intelligence*, 38 (2), 295-307.

[7]. Yang, W., Zhang, X., Tian, Y., Wang, W., Xue, J.-H., ve Liao, Q., 2019, Deep Learning for Single Image Super-Resolution: A Brief Review, *IEEE Transactions on Multimedia*, 21 (12), 3106-3121.

[8]. Keys, R., 1981, Cubic convolution interpolation for digital image processing, *IEEE transactions on acoustics, speech, and signal processing*, 29 (6), 1153-1160.

[9]. Duchon, C. E., 1979, Lanczos filtering in one and two dimensions, *Journal of Applied Meteorology and Climatology*, 18 (8), 1016-1022.

[10]. Pan, C., 2001, Gibbs phenomenon removal and digital filtering directly through the fast Fourier transform, *IEEE Transactions on Signal Processing*, 49 (2), 444-448.

[11]. Irani, M. ve Peleg, S., 1991, Improving resolution by image registration, *CVGIP: Graphical models and image processing*, 53 (3), 231-239.

[12]. Freedman, G. ve Fattal, R., 2011, Image and video upscaling from local self-examples, *ACM Transactions on Graphics (TOG)*, 30 (2), 1-11.

[13]. Sun, J., Xu, Z., ve Shum, H.-Y., 2008, Image super-resolution using gradient profile prior, *2008 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, 1-8.

[14]. Kim, K. I. ve Kwon, Y., 2010, Single-image super-resolution using sparse regression and natural image prior, *IEEE transactions on pattern analysis and machine intelligence*, 32 (6), 1127-1133.

[15]. Xiong, Z., Sun, X., ve Wu, F., 2010, Robust web image/video super-resolution, *IEEE transactions on image processing*, 19 (8), 2017-2028.

[16]. Freeman, W. T., Jones, T. R., ve Pasztor, E. C., 2002, Example-based super-resolution, *IEEE Computer graphics and Applications*, 22 (2), 56-65.

[17]. Yang, J., Wright, J., Huang, T., ve Ma, Y., 2008, Image super-resolution as sparse representation of raw image patches, *2008 IEEE conference on computer vision and pattern recognition*, IEEE, 1-8.

[18]. Yang, J., Wright, J., Huang, T. S., ve Ma, Y., 2010, Image super-resolution via sparse representation, *IEEE transactions on image processing*, 19 (11), 2861-2873.

[19]. Maiseli, B. ve Abdalla, A. T., 2024, Seven decades of image super-resolution: achievements, challenges, and opportunities, *EURASIP Journal on Advances in Signal Processing*, 2024 (1), 78.

[20]. Kim, S. P. ve Su, W.-Y., 1993, Recursive high-resolution reconstruction of blurred multiframe images, *IEEE Transactions on Image Processing*, 2 (4), 534-539.

[21]. Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A. C., ve Lo, W.-Y., 2023, Segment anything, *Proceedings of the IEEE/CVF international conference on computer vision*, 4015-4026.

[22]. Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., ve Gelly, S., 2020, An image is worth 16x16 words: Transformers for image recognition at scale, *arXiv preprint arXiv:2010\.11929*.

[23]. Su, H., Li, Y., Xu, Y., Fu, X., ve Liu, S., 2024, A review of deep-learning-based super-resolution: From methods to applications, *Pattern Recognition*, 157, 110935.

[24]. Liu, A., Liu, Y., Gu, J., Qiao, Y., ve Dong, C., 2022, Blind image super-resolution: A survey and beyond, *IEEE transactions on pattern analysis and machine intelligence*, 45 (5), 5461-5480.

[25]. Pan, M., 2002, A novel blind super-resolution technique based on the improved Poisson maximum a posteriori algorithm, *International Journal of Imaging Systems and Technology*, 12 (6), 239-246.

[26]. Rajan, D. ve Chaudhuri, S., 2002, Super-Resolution Imaging Using Blur as a Cue, *Super-Resolution Imaging*, 632, S. Chaudhuri, Ed., The International Series in Engineering and Computer Science, vol. 632. , Boston: Kluwer Academic Publishers, 107-129.

[27]. Yagle, A. E., 2003, Blind superresolution from undersampled blurred measurements, *advanced signal processing algorithms, architectures, and implementations XIII*, SPIE, 299-309.

[28]. Vrigkas, M., Nikou, C., ve Kondi, L. P., 2014, Robust maximum a posteriori image super-resolution, *Journal of Electronic Imaging*, 23 (4), 043016.

[29]. Wang, H., Rivenson, Y., Jin, Y., Wei, Z., Gao, R., Günaydın, H., Bentolila, L. A., Kural, C., ve Ozcan, A., 2019, Deep learning enables cross-modality super-resolution in fluorescence microscopy, *Nature methods*, 16 (1), 103-110.

[30]. Qin, F. Q., Zhu, L. H., Cao, L. L., ve Yang, W. N., 2013, Single-Image Super Resolution Reconstruction with Pepper and Salt Noise, *Applied Mechanics and Materials*, 427, 1817-1821.

[31]. Wang, X., Xie, L., Dong, C., ve Shan, Y., 2021, Real-esrgan: Training real-world blind super-resolution with pure synthetic data, *Proceedings of the IEEE/CVF International Conference on Computer Vision*, Montreal, BC, Canada, 1905-1914.

[32]. Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Qiao, Y., ve Change Loy, C., 2018, Esrgan: Enhanced super-resolution generative adversarial networks, *Proceedings of the European conference on computer vision (ECCV) workshops*, Munich, Germany.

[33]. Conde, M. V., Choi, U.-J., Burchi, M., ve Timofte, R., 2023, Swin2SR: Swinv2 transformer for compressed image super-resolution and restoration, *Proceedings of the European Conference on Computer Vision (ECCV) Workshops*, Tel Aviv, Israil: Springer, 669-687.

[34]. Liang, J., Cao, J., Sun, G., Zhang, K., Van Gool, L., ve Timofte, R., 2021, SwinIR: Image restoration using swin transformer, *Proceedings of the IEEE/CVF International Conference on Computer Vision*, Montreal, BC, Kanada, 1833-1844.

[35]. Ur, H. ve Gross, D., 1992, Improved resolution from subpixel shifted pictures, *CVGIP: Graphical models and image processing*, 54 (2), 181-186.

[36]. Gerchberg, R. W., 1974, Super-resolution through error energy reduction, *Optica Acta: International Journal of Optics*, 21 (9), 709-720.

[37]. Thévenaz, P., Blu, T., ve Unser, M., 2000, Image interpolation and resampling, *Handbook of medical imaging, processing and analysis*, 1 (1), 393-420.

[38]. Demirel, H. ve Anbarjafari, G., 2011, IMAGE Resolution Enhancement by Using Discrete and Stationary Wavelet Decomposition, *IEEE Transactions on Image Processing*, 20 (5), 1458-1460.

[39]. Fadnavis, S., 2014, Image interpolation techniques in digital image processing: an overview, *International Journal of Engineering Research and Applications*, 4 (10), 70-73.

[40]. Han, D., 2013, Comparison of commonly used image interpolation methods, *Proceedings of the 2nd International Conference on Computer Science and Electronics Engineering*, Hangzhou, China, 1556-1559.

[41]. Lyche, T., Manni, C., ve Speleers, H., 2018, Foundations of Spline Theory: B-Splines, Spline Approximation, and Hierarchical Refinement, *Splines and PDEs: From Approximation Theory to Numerical Linear Algebra*, 2219, T. Lyche, C. Manni, ve H. Speleers, Ed., Lecture Notes in Mathematics, vol. 2219. , Cham: Springer International Publishing, 1-76.

[42]. Burger, W. ve Burge, M. J., 2008, Introduction to Spectral Techniques, *Principles of Digital Image Processing: Core Algorithms*, 1st ed., W. Burger ve M. J. Burge, Ed., London, UK: Springer, 313-342.

[43]. Gonzalez, R. C. ve Woods, R. E., 2008, *Digital image processing*, Pearson education india.

[44]. Parsania, P. S. ve Virparia, P. V., 2016, A comparative analysis of image interpolation algorithms, *International Journal of Advanced Research in Computer and Communication Engineering*, 5 (1), 29-34.

[45]. Haris, M., Shakhnarovich, G., ve Ukita, N., 2019, Recurrent back-projection network for video super-resolution, *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 3897-3906.

[46]. Zheng, H., Ji, M., Wang, H., Liu, Y., ve Fang, L., 2018, Crossnet: An end-to-end reference-based super resolution network using cross-scale warping, *Proceedings of the European conference on computer vision (ECCV)*, 88-104.

[47]. Tai, Y., Yang, J., Liu, X., ve Xu, C., Eki. 2017, MemNet: A Persistent Memory Network for Image Restoration, *2017 IEEE International Conference on Computer Vision (ICCV)*, 4549-4557.

[48]. Pham, C.-H., Tor-Díez, C., Meunier, H., Bednarek, N., Fablet, R., Passat, N., ve Rousseau, F., 2019, Multiscale brain MRI super-resolution using deep 3D convolutional networks, *Computerized Medical Imaging and Graphics*, 77, 101647.

[49]. Hu, X., Mu, H., Zhang, X., Wang, Z., Tan, T., ve Sun, J., Haz. 2019, Meta-SR: A Magnification-Arbitrary Network for Super-Resolution, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 1575-1584.

[50]. Hüsem, H. ve Orman, Z., 2020, A survey on image super-resolution with generative adversarial networks, *Acta Infologica*, 4 (2), 139-154.

[51]. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., ve Bengio, Y., 2014, Generative Adversarial Nets, *Advances in Neural Information Processing Systems*, Curran Associates, Inc.

[52]. Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., ve Wang, Z., 2017, Photo-realistic single image super-resolution using a generative adversarial network, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4681-4690.

[53]. Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B., ve Fu, Y., 2018, Image super-resolution using very deep residual channel attention networks, *Proceedings of the European conference on computer vision (ECCV)*, 286-301.

[54]. Liu, B. ve Chen, J., 2021, A Super Resolution Algorithm Based on Attention Mechanism and SRGAN Network, *IEEE Access*, 9, 139138-139145.

[55]. Lim, B., Son, S., Kim, H., Nah, S., ve Mu Lee, K., 2017, Enhanced deep residual networks for single image super-resolution, *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 136-144.

[56]. Kim, J., Lee, J. K., ve Lee, K. M., Haz. 2016, Accurate Image Super-Resolution Using Very Deep Convolutional Networks, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1646-1654.

[57]. Li, J., Liang, X., Wei, Y., Xu, T., Feng, J., ve Yan, S., 2017, Perceptual generative adversarial networks for small object detection, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1222-1230.

[58]. Wu, B., Duan, H., Liu, Z., ve Sun, G., 2017, SRPGAN: perceptual generative adversarial network for single image super resolution, *arXiv preprint arXiv:1712.05927*.

[59]. Motamed, S. ve Khalvati, F., 2021, Multi-class generative adversarial networks: improving one-class classification of pneumonia using limited labeled data, *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, 3817-3822.

[60]. Bai, Y., Zhang, Y., Ding, M., ve Ghanem, B., 2018, Finding tiny faces in the wild with generative adversarial network, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 21-30.

[61]. Huang, B., Chen, W., Wu, X., Lin, C.-L., ve Suganthan, P. N., 2018, High-quality face image generated with conditional boundary equilibrium generative adversarial networks, *Pattern Recognition Letters*, 111, 72-79.

[62]. Yang, S., Luo, P., Loy, C.-C., ve Tang, X., 2016, Wider face: A face detection benchmark, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 5525-5533.

[63]. Zhang, D., Shao, J., Hu, G., ve Gao, L., 2017, Sharp and real image super-resolution using generative adversarial network, *International Conference on Neural Information Processing*, Springer, 217-226.

[64]. Sharma, S. ve Kumar, V., 2021, An efficient image super resolution model with dense skip connections between complex filter structures in Generative Adversarial Networks, *Expert Systems with Applications*, 186, 115780.

[65]. Yilmaz, İ., Güllü, M., Baybura, T., ve Erdoğan, A. O., 2002, Renk Uzayları ve Renk Dönüşüm Programı (RDP), *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 2 (2), 19-35.

[66]. Diaz-Cely, J., Arce-Lopera, C., Mena, J. C., ve Quintero, L., 2019, The effect of color channel representations on the transferability of convolutional neural networks, *Science and information Conference*, Springer, 27-38.

[67]. John, N., Viswanath, A., Sowmya, V., ve Soman, K. P., 2016, Analysis of various color space models on effective single image super resolution, *Intelligent Systems Technologies and Applications*, 1st ed., 384, S. Berretti, S. M. Thampi, ve P. R. Srivastava, Ed., Advances in Intelligent Systems and Computing, vol. 384. , Cham, Switzerland: Springer, 529-540.

[68]. Wang, Z., Chen, J., ve Hoi, S. C. H., 2021, Deep Learning for Image Super-Resolution: A Survey, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43 (10), 3365-3387.

[69]. Gopinathan, S. ve Gayathri, M. S., 2016, A study on image enhancement techniques using YCbCr color space methods, *International Journal of Advanced Engineering Research and Science*, 3 (8), 105-112.

[70]. Young, T., 1802, II. The Bakerian Lecture. On the theory of light and colours, *Philosophical Transactions of the Royal Society of London*, 92, 12-48.

[71]. von Helmholtz, H., 1852, *Ueber die Theorie der zusammengesetzten Farben: physiologisch-optische Abhandlung*, Unger.

[72]. Palus, H., 1998, Representations of colour images in different colour spaces, *The Colour Image Processing Handbook*, S. J. Sangwine ve R. E. N. Horne, Ed., Boston, MA: Springer US, 67-90.

[73]. Wyszecki, G. ve Stiles, W. S., 2000, *Color science: concepts and methods, quantitative data and formulae*, John Wiley & Sons.

[74]. 1976, Colorimetry, Commission Internationale de l'Éclairage, Viyana, 15:1976.

[75]. 1995, Industrial color-difference evaluation, Commission Internationale de l'Éclairage, Viyana, 116-1995.

[76]. 2001, Improvement to industrial colour-difference evaluation, Commission Internationale de l'Éclairage, Viyana, 142:2001.

[77]. Sharma, G., Wu, W., ve Dalal, E. N., 2005, The CIEDE2000 color-difference formula: Implementation notes, supplementary test data, and mathematical observations, *Color Research & Application*, 30 (1), 21-30.

[78]. Shannon, C. E., 1948, A mathematical theory of communication, *The Bell system technical journal*, 27 (3), 379-423.

[79]. Rad, M. S., Yu, T., Musat, C., Ekenel, H. K., Bozorgtabar, B., ve Thiran, J.-P., 2021, Benefiting from bicubically down-sampled images for learning real-world image super-resolution, *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 1590-1599.

[80]. Bevilacqua, M., Roumy, A., Guillemot, C., ve Alberi-Morel, M. L., 2012, Low-complexity single-image super-resolution based on nonnegative neighbor embedding, *Proceedings of the 23rd British Machine Vision Conference (BMVC)*, Surrey, UK, 1-10.

[81]. Zeyde, R., Elad, M., ve Protter, M., 2012, On Single Image Scale-Up Using Sparse-Representations, *Curves and Surfaces*, 6920, J.-D. Boissonnat, P. Chenin, A. Cohen, C. Gout, T. Lyche, M.-L. Mazure, ve L. Schumaker, Ed., Berlin, Heidelberg: Springer Berlin Heidelberg, 711-730.

[82]. Martin, D., Fowlkes, C., Tal, D., ve Malik, J., 2001, A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics, *Proceedings Eighth IEEE International Conference on Computer Vision*, Vancouver, BC, Canada, 416-423.

[83]. Huang, J.-B., Singh, A., ve Ahuja, N., 2015, Single image super-resolution from transformed self-exemplars, *Proceedings of the IEEE conference on computer vision and pattern recognition*, Boston, MA, USA, 5197-5206.

[84]. Seif, G. ve Androutsos, D., 2018, Edge-based loss function for single image super-resolution, *2018 IEEE International conference on acoustics, speech and signal processing (ICASSP)*, IEEE, 1468-1472.

[85]. Ding, K., Ma, K., Wang, S., ve Simoncelli, E. P., 2020, Image quality assessment: Unifying structure and texture similarity, *IEEE transactions on pattern analysis and machine intelligence*, 4 (5), 2567-2581.

[86]. Ding, K., Liu, Y., Zou, X., Wang, S., ve Ma, K., 2021, Locally Adaptive Structure and Texture Similarity for Image Quality Assessment, *Proceedings of the 29th ACM*

International Conference on Multimedia, Virtual Event, China: Association for Computing Machinery, 2483-2491.

[87]. Zhang, R., Isola, P., Efros, A. A., Shechtman, E., ve Wang, O., 2018, The unreasonable effectiveness of deep features as a perceptual metric, *Proceedings of the IEEE conference on computer vision and pattern recognition*, Salt Lake City, UT, USA, 586-595.

[88]. Dosselmann, R. ve Yang, X. D., 2005, Existing and emerging image quality metrics, *Canadian Conference on Electrical and Computer Engineering*, Saskatoon, SK, Canada: IEEE, 1906-1913.

[89]. Huynh-Thu, Q. ve Ghanbari, M., 2008, Scope of validity of PSNR in image/video quality assessment, *Electronics letters*, 44 (13), 800-801.

[90]. Jain, A. K., 1989, *Fundamentals of digital image processing*, Prentice-Hall, Inc.

[91]. Wang, Z., Bovik, A. C., Sheikh, H. R., ve Simoncelli, E. P., 2004, Image quality assessment: from error visibility to structural similarity, *IEEE transactions on image processing*, 13 (4), 600-612.

[92]. 2006, Vocabulary for performance and quality of service, ITU-T, Rec. P.10.

[93]. Yuan, M. L., Chua, G. G., Farbiz, F., ve Rahardja, S., 2011, Eye contact with a virtual character using a vision-based head tracker, *Computer and Information Sciences*, 62, E. Gelenbe, R. Lent, G. Sakellari, A. Sacan, H. Toroslu, ve A. Yazici, Ed., Lecture Notes in Electrical Engineering, vol. 62. , Dordrecht: Springer Netherlands, 217-225.

[94]. Zhang, L., Zhang, L., Mou, X., ve Zhang, D., 2011, FSIM: A feature similarity index for image quality assessment, *IEEE transactions on Image Processing*, 20 (8), 2378-2386.

[95]. Dong, C., Loy, C. C., He, K., ve Tang, X., 2014, Learning a Deep Convolutional Network for Image Super-Resolution, *Computer Vision – ECCV 2014*, 8692, D. Fleet, T. Pajdla, B. Schiele, ve T. Tuytelaars, Ed., Lecture Notes in Computer Science, vol. 8692. , Cham: Springer International Publishing, 184-199. Erişim: 13 Aralık 2024. [Çevrimiçi]. Erişim adresi: http://link.springer.com/10.1007/978-3-319-10593-2_13

[96]. Agustsson, E. ve Timofte, R., 2017, Ntire 2017 challenge on single image super-resolution: Dataset and study, *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, Honolulu, HI, USA, 126-135.

[97]. Tomasi, C. ve Manduchi, R., 1998, Bilateral filtering for gray and color images, *Sixth international conference on computer vision (IEEE Cat. No. 98CH36271)*, IEEE, 839-846.

[98]. Furnari, A., Farinella, G. M., Bruna, A. R., ve Battiato, S., 2017, Distortion adaptive Sobel filters for the gradient estimation of wide angle images, *Journal of Visual Communication and Image Representation*, 46, 165-175.

[99]. Rosenfeld, A., 1976, *Digital picture processing*, Academic press.

[100]. Gong, R., Wang, Y., Cai, Y., ve Shao, X., 2017, How to deal with color in super resolution reconstruction of images, *Optics express*, 25 (10), 11144-11156.

[101]. Erdemir, E., Dragotti, P. L., ve Gündüz, D., 2020, Privacy-aware time-series data sharing with deep reinforcement learning, *IEEE Transactions on Information Forensics and Security*, 16, 389-401.

[102]. Hüsem, H., Aydın, Z. G., ve Demir, Ö., Analysis of the Impact of RGB-to-Achromatic Color Space Transformations on Single-Image Superresolution Performance, *Black Sea Journal of Engineering and Science*, 8 (2), 50-51.

[103]. Lee, J., Yun, I., ve Kim, J., 2021, Edge profile super resolution, *IEEE Access*, 9, 121305-121315.

[104]. Chen, Y.-W., Ding, J.-J., ve Chen, P.-H., 2019, Region Adaptive Mode Selection Algorithms for Image Super-Resolution, *2019 IEEE 2nd International Conference on Information Communication and Signal Processing (ICICSP)*, IEEE, 347-351.

[105]. Nazeri, K., Thasarathan, H., ve Ebrahimi, M., 2019, Edge-informed single image super-resolution, *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*,

[106]. Vishnukumar, S., Nair, M. S., ve Wilscy, M., 2014, Edge preserving single image super-resolution with improved visual quality, *Signal Processing*, 105, 283-297.

[107]. Saveljev, V., Kim, S.-K., ve Kim, J., 2018, Moiré effect in displays: a tutorial, *Optical Engineering*, 57 (3), 030803-030803.

[108]. Knyazev, A., 2015, Edge-enhancing filters with negative weights, *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, IEEE, 260-264.

[109]. Xu, Z., Ma, Q., ve Yuan, F., 2020, Single color image super-resolution using sparse representation and color constraint, *Journal of Systems Engineering and Electronics*, 31 (2), 266-271.

[110]. Yang, Y., Yuhua, P., ve Zhaoguang, L., 2007, A fast algorithm for YCbCr to RGB conversion, *IEEE Transactions on Consumer Electronics*, 53 (4), 1490-1493.

EKLER

Tablo Ek-1: Set5 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
baby.png	30,963	31,474	1,65%	0,856	0,868	1,41%	0,793	0,792	0,08%	0,270	0,261	3,35%
bird.png	28,668	29,293	2,18%	0,873	0,883	1,21%	0,831	0,829	0,17%	0,195	0,170	13,12%
butterfly.png	21,318	22,469	5,40%	0,727	0,773	6,23%	0,780	0,778	0,32%	0,328	0,289	11,75%
head.png	29,127	29,334	0,71%	0,712	0,724	1,74%	0,812	0,812	0,04%	0,377	0,364	3,60%
woman.png	25,527	26,361	3,26%	0,840	0,857	2,00%	0,846	0,837	0,98%	0,229	0,209	8,78%

Tablo Ek-2: Set14 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	D-Eye	Başarı Değişimi
baboon.png	20,362	20,425	0,31%	0,440	0,455	3,54%	0,812	0,811	0,11%	0,464	0,477	-2,65%
barbara.png	23,764	24,018	1,07%	0,678	0,697	2,70%	0,826	0,826	-0,03%	0,375	0,365	2,83%
bridge.png	23,307	23,523	0,93%	0,592	0,609	2,89%	0,794	0,792	0,30%	0,527	0,523	0,81%
coastguard.png	23,888	24,010	0,51%	0,500	0,517	3,41%	0,763	0,760	0,34%	0,438	0,450	-2,90%
comic.png	20,485	20,811	1,59%	0,628	0,652	3,89%	0,862	0,860	0,31%	0,403	0,376	6,72%
face.png	29,120	29,296	0,60%	0,710	0,721	1,60%	0,822	0,819	0,43%	0,379	0,362	4,53%
flowers.png	24,081	24,637	2,31%	0,731	0,748	2,40%	0,867	0,852	1,75%	0,366	0,345	5,92%
foreman.png	26,425	26,897	1,79%	0,849	0,863	1,72%	0,838	0,841	-0,41%	0,279	0,257	7,99%
lenna.png	28,641	29,066	1,48%	0,765	0,775	1,34%	0,832	0,829	0,44%	0,325	0,320	1,27%
man.png	24,615	25,073	1,86%	0,684	0,703	2,71%	0,821	0,810	1,35%	0,450	0,435	3,19%
monarch.png	26,644	27,520	3,29%	0,883	0,895	1,37%	0,799	0,797	0,25%	0,312	0,295	5,48%
pepper.png	27,523	27,915	1,43%	0,768	0,775	0,97%	0,848	0,805	5,08%	0,323	0,316	2,18%
ppt3.png	20,603	21,335	3,56%	0,803	0,834	3,79%	0,919	0,909	1,13%	0,241	0,229	4,80%
zebra.png	23,316	24,137	3,52%	0,710	0,730	2,86%	0,849	0,807	4,97%	0,252	0,237	5,94%

Tablo Ek-3: BSD100 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
101085.png	21,787	22,041	1,17%	0,508	0,528	3,86%	0,849	0,846	0,34%	0,444	0,441	0,69%
101087.png	25,618	25,965	1,35%	0,766	0,784	2,32%	0,891	0,880	1,23%	0,317	0,299	5,57%
102061.png	24,030	24,231	0,84%	0,758	0,771	1,77%	0,777	0,762	1,86%	0,385	0,376	2,47%
103070.png	28,237	28,553	1,12%	0,812	0,824	1,42%	0,844	0,838	0,72%	0,302	0,292	3,38%
105025.png	24,270	24,439	0,70%	0,674	0,688	2,11%	0,847	0,849	-0,25%	0,357	0,368	-3,32%
106024.png	30,215	30,599	1,27%	0,862	0,869	0,81%	0,804	0,832	-3,55%	0,310	0,283	8,63%
108005.png	23,860	24,158	1,25%	0,669	0,686	2,46%	0,831	0,816	1,89%	0,356	0,340	4,37%
108070.png	21,345	21,473	0,60%	0,525	0,543	3,52%	0,791	0,782	1,04%	0,445	0,443	0,36%
108082.png	25,131	25,409	1,11%	0,738	0,752	1,95%	0,843	0,828	1,75%	0,347	0,351	-1,06%
109053.png	27,189	27,441	0,93%	0,763	0,777	1,83%	0,826	0,826	-0,04%	0,357	0,333	6,61%
119082.png	21,010	21,486	2,27%	0,591	0,615	4,15%	0,839	0,837	0,29%	0,395	0,377	4,52%
12084.png	25,061	25,296	0,94%	0,673	0,690	2,56%	0,773	0,774	-0,24%	0,350	0,336	3,88%
123074.png	27,844	28,144	1,08%	0,776	0,792	1,99%	0,804	0,804	0,04%	0,333	0,341	-2,55%
126007.png	26,176	26,520	1,31%	0,760	0,775	1,98%	0,793	0,803	-1,19%	0,315	0,307	2,33%

Tablo Ek-3: BSD100 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
130026.png	23,140	23,345	0,89%	0,621	0,638	2,62%	0,788	0,771	2,09%	0,455	0,459	-0,76%
134035.png	21,417	21,830	1,93%	0,650	0,676	3,96%	0,832	0,826	0,72%	0,406	0,405	0,36%
14037.png	30,943	31,192	0,80%	0,842	0,850	0,97%	0,819	0,823	-0,47%	0,290	0,271	6,50%
143090.png	29,583	29,742	0,54%	0,853	0,858	0,57%	0,768	0,766	0,33%	0,310	0,280	9,73%
145086.png	23,039	23,501	2,01%	0,643	0,658	2,48%	0,796	0,777	2,40%	0,380	0,367	3,43%
147091.png	23,449	23,767	1,36%	0,747	0,760	1,76%	0,788	0,753	4,35%	0,386	0,383	0,66%
148026.png	19,605	19,908	1,54%	0,559	0,586	4,85%	0,783	0,781	0,27%	0,436	0,430	1,25%
148089.png	21,416	21,621	0,96%	0,535	0,554	3,58%	0,816	0,814	0,28%	0,457	0,455	0,27%
156065.png	23,256	23,381	0,54%	0,523	0,541	3,42%	0,799	0,798	0,09%	0,480	0,487	-1,53%
157055.png	23,907	24,282	1,56%	0,718	0,738	2,85%	0,854	0,851	0,36%	0,331	0,300	9,40%
159008.png	24,509	24,943	1,77%	0,752	0,768	2,13%	0,841	0,844	-0,31%	0,330	0,336	-2,03%
160068.png	24,802	25,149	1,40%	0,799	0,817	2,26%	0,785	0,782	0,39%	0,307	0,302	1,68%
16077.png	25,306	25,599	1,16%	0,678	0,693	2,31%	0,806	0,802	0,49%	0,405	0,398	1,78%
163085.png	27,266	27,468	0,74%	0,767	0,781	1,75%	0,819	0,818	0,14%	0,307	0,303	1,20%
167062.png	27,292	27,958	2,44%	0,824	0,833	1,07%	0,847	0,841	0,80%	0,376	0,368	2,24%
167083.png	18,195	18,337	0,78%	0,462	0,481	4,06%	0,804	0,790	1,76%	0,504	0,488	3,22%
170057.png	27,408	27,617	0,76%	0,768	0,781	1,64%	0,791	0,790	0,14%	0,310	0,316	-1,91%
175032.png	19,333	19,406	0,38%	0,372	0,393	5,80%	0,801	0,800	0,18%	0,511	0,533	-4,34%
175043.png	23,038	23,253	0,93%	0,613	0,634	3,47%	0,801	0,799	0,21%	0,430	0,459	-6,77%
182053.png	22,081	22,238	0,71%	0,695	0,714	2,77%	0,761	0,757	0,55%	0,391	0,377	3,39%
189080.png	29,872	30,453	1,95%	0,835	0,836	0,14%	0,813	0,797	2,01%	0,322	0,312	3,16%
19021.png	24,429	24,809	1,55%	0,673	0,691	2,65%	0,784	0,774	1,33%	0,430	0,423	1,69%
196073.png	26,315	26,399	0,32%	0,446	0,466	4,63%	0,717	0,720	-0,38%	0,630	0,600	4,77%
197017.png	25,710	26,004	1,14%	0,656	0,670	2,12%	0,823	0,817	0,78%	0,394	0,379	3,87%
208001.png	26,075	26,387	1,20%	0,659	0,678	2,87%	0,823	0,814	1,15%	0,371	0,358	3,55%
210088.png	28,122	29,302	4,20%	0,857	0,876	2,19%	0,842	0,840	0,26%	0,235	0,218	7,07%
21077.png	23,831	24,332	2,10%	0,654	0,675	3,26%	0,836	0,808	3,32%	0,448	0,429	4,11%
216081.png	23,355	23,681	1,39%	0,638	0,656	2,86%	0,840	0,833	0,87%	0,401	0,393	1,93%
219090.png	24,232	24,502	1,11%	0,691	0,705	2,02%	0,811	0,804	0,93%	0,444	0,426	3,89%
220075.png	24,520	25,127	2,48%	0,808	0,824	1,97%	0,855	0,825	3,56%	0,285	0,260	8,60%
223061.png	22,718	22,858	0,61%	0,616	0,635	3,03%	0,750	0,752	-0,25%	0,400	0,408	-2,19%
227092.png	31,634	31,877	0,77%	0,822	0,831	1,13%	0,789	0,791	-0,22%	0,360	0,337	6,26%
229036.png	20,488	20,774	1,40%	0,538	0,561	4,21%	0,850	0,834	1,98%	0,468	0,460	1,63%
236037.png	23,082	23,222	0,61%	0,594	0,611	2,77%	0,806	0,807	-0,04%	0,389	0,400	-2,91%
24077.png	22,312	22,810	2,24%	0,766	0,785	2,57%	0,866	0,840	3,05%	0,322	0,305	5,28%
241004.png	29,696	29,953	0,86%	0,793	0,804	1,43%	0,825	0,839	-1,68%	0,329	0,313	4,77%
241048.png	22,987	23,156	0,73%	0,572	0,587	2,67%	0,819	0,811	0,93%	0,427	0,425	0,56%
253027.png	20,284	20,566	1,39%	0,639	0,656	2,62%	0,812	0,798	1,69%	0,341	0,333	2,39%
253055.png	29,987	30,216	0,76%	0,794	0,804	1,25%	0,836	0,832	0,53%	0,306	0,279	9,06%
260058.png	30,656	30,798	0,46%	0,748	0,762	1,81%	0,712	0,713	-0,13%	0,406	0,383	5,73%
271035.png	24,665	25,058	1,60%	0,680	0,701	3,10%	0,830	0,822	0,96%	0,380	0,373	1,72%
285079.png	22,722	23,136	1,82%	0,601	0,622	3,43%	0,861	0,848	1,52%	0,434	0,418	3,61%
291000.png	19,646	19,735	0,45%	0,381	0,397	4,29%	0,804	0,796	0,97%	0,476	0,479	-0,61%
295087.png	25,561	25,728	0,65%	0,679	0,698	2,70%	0,782	0,780	0,28%	0,357	0,351	1,67%
296007.png	30,226	30,360	0,44%	0,752	0,767	1,92%	0,705	0,708	-0,40%	0,416	0,395	5,08%
296059.png	28,262	28,521	0,91%	0,719	0,730	1,55%	0,796	0,801	-0,60%	0,374	0,357	4,38%
299086.png	29,754	29,933	0,60%	0,763	0,776	1,75%	0,773	0,773	0,06%	0,367	0,339	7,52%
300091.png	26,326	26,564	0,90%	0,734	0,748	1,94%	0,770	0,762	1,03%	0,387	0,367	5,14%
302008.png	26,924	27,962	3,86%	0,904	0,916	1,30%	0,866	0,864	0,29%	0,234	0,227	2,94%
304034.png	22,430	22,571	0,63%	0,622	0,637	2,41%	0,808	0,808	-0,05%	0,370	0,378	-2,24%
304074.png	23,708	24,023	1,33%	0,563	0,580	3,13%	0,818	0,805	1,63%	0,484	0,490	-1,13%
306005.png	25,714	26,075	1,40%	0,748	0,763	2,03%	0,830	0,819	1,34%	0,356	0,349	2,09%
3096.png	33,996	34,723	2,14%	0,958	0,957	-0,06%	0,753	0,751	0,31%	0,291	0,267	8,18%
33039.png	18,979	19,209	1,21%	0,533	0,556	4,37%	0,827	0,828	-0,05%	0,512	0,505	1,51%
351093.png	20,785	20,957	0,82%	0,598	0,618	3,24%	0,879	0,876	0,28%	0,417	0,427	-2,19%
361010.png	25,309	25,809	1,98%	0,721	0,735	1,99%	0,849	0,812	4,32%	0,331	0,322	2,67%
37073.png	27,001	27,232	0,85%	0,712	0,722	1,38%	0,807	0,804	0,30%	0,399	0,389	2,42%
376043.png	23,390	23,600	0,90%	0,552	0,570	3,37%	0,863	0,856	0,77%	0,419	0,434	-3,44%
38082.png	25,569	25,672	0,41%	0,574	0,590	2,84%	0,774	0,770	0,50%	0,441	0,466	-5,61%
38092.png	24,084	24,307	0,92%	0,655	0,671	2,49%	0,801	0,798	0,34%	0,362	0,374	-3,19%
385039.png	21,354	21,685	1,55%	0,602	0,620	2,98%	0,857	0,845	1,37%	0,425	0,415	2,39%
41033.png	28,011	28,284	0,98%	0,729	0,741	1,66%	0,778	0,781	-0,43%	0,365	0,372	-1,95%

Tablo Ek-3: BSD100 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
41069.png	21,985	22,101	0,53%	0,427	0,444	4,04%	0,752	0,751	0,09%	0,519	0,545	-5,08%
42012.png	27,270	27,633	1,33%	0,769	0,782	1,63%	0,829	0,827	0,15%	0,375	0,362	3,39%
42049.png	26,076	26,640	2,16%	0,871	0,869	-0,25%	0,829	0,829	-0,07%	0,326	0,330	-1,27%
43074.png	28,225	28,344	0,42%	0,787	0,798	1,31%	0,758	0,754	0,52%	0,323	0,307	4,82%
45096.png	32,505	32,881	1,16%	0,905	0,908	0,31%	0,811	0,806	0,58%	0,272	0,263	3,53%
54082.png	26,444	26,565	0,45%	0,666	0,683	2,51%	0,810	0,808	0,17%	0,403	0,389	3,60%
55073.png	20,383	20,522	0,69%	0,457	0,476	4,12%	0,755	0,752	0,38%	0,498	0,519	-4,22%
58060.png	19,443	19,563	0,62%	0,533	0,555	4,04%	0,781	0,778	0,41%	0,470	0,466	0,85%
62096.png	22,212	22,681	2,11%	0,681	0,700	2,82%	0,780	0,753	3,43%	0,403	0,396	1,77%
65033.png	22,990	23,217	0,99%	0,515	0,533	3,40%	0,825	0,802	2,80%	0,409	0,416	-1,56%
66053.png	25,362	25,581	0,86%	0,630	0,647	2,63%	0,804	0,800	0,46%	0,397	0,400	-0,95%
69015.png	27,825	28,214	1,40%	0,756	0,771	2,00%	0,853	0,852	0,11%	0,318	0,329	-3,68%
69020.png	25,387	25,525	0,54%	0,525	0,539	2,79%	0,814	0,812	0,17%	0,447	0,466	-4,36%
69040.png	23,203	23,307	0,45%	0,587	0,606	3,25%	0,806	0,806	-0,07%	0,438	0,440	-0,45%
76053.png	27,126	27,335	0,77%	0,645	0,664	2,91%	0,783	0,777	0,80%	0,395	0,390	1,18%
78004.png	23,387	23,801	1,77%	0,636	0,659	3,51%	0,823	0,803	2,42%	0,414	0,388	6,24%
8023.png	27,620	27,997	1,37%	0,846	0,856	1,29%	0,777	0,779	-0,28%	0,266	0,263	1,46%
85048.png	23,042	23,406	1,58%	0,627	0,649	3,40%	0,859	0,851	0,95%	0,379	0,374	1,14%
86000.png	23,153	23,404	1,08%	0,705	0,724	2,74%	0,815	0,815	-0,08%	0,328	0,315	4,12%
86016.png	20,494	20,539	0,22%	0,281	0,298	6,11%	0,669	0,668	0,18%	0,616	0,627	-1,81%
86068.png	25,386	25,474	0,35%	0,507	0,524	3,40%	0,775	0,778	-0,38%	0,517	0,507	1,88%
87046.png	23,967	24,227	1,08%	0,736	0,749	1,65%	0,849	0,835	1,69%	0,321	0,325	-1,17%
89072.png	24,184	24,616	1,79%	0,646	0,670	3,75%	0,829	0,827	0,28%	0,424	0,412	2,73%
97033.png	22,297	22,741	1,99%	0,636	0,660	3,75%	0,847	0,821	3,06%	0,461	0,429	6,92%

Tablo Ek-4: Urban100 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
img_001.png	23,908	24,356	1,88%	0,663	0,684	3,23%	0,781	0,775	0,79%	0,450	0,435	3,39%
img_002.png	23,088	23,479	1,69%	0,691	0,714	3,35%	0,774	0,772	0,28%	0,338	0,336	0,80%
img_003.png	20,608	20,813	0,99%	0,550	0,566	2,97%	0,825	0,822	0,44%	0,456	0,445	2,30%
img_004.png	20,063	20,534	2,35%	0,697	0,726	4,18%	0,748	0,749	-0,12%	0,352	0,315	10,62%
img_005.png	22,395	23,228	3,72%	0,826	0,857	3,69%	0,713	0,713	0,07%	0,274	0,268	2,06%
img_006.png	19,346	19,603	1,33%	0,511	0,533	4,44%	0,787	0,780	0,79%	0,451	0,447	0,92%
img_007.png	25,085	25,748	2,65%	0,776	0,794	2,22%	0,846	0,834	1,44%	0,304	0,296	2,64%
img_008.png	18,697	18,896	1,07%	0,541	0,563	3,98%	0,751	0,747	0,45%	0,426	0,426	-0,19%
img_009.png	29,515	29,773	0,87%	0,838	0,842	0,51%	0,768	0,766	0,19%	0,345	0,334	3,16%
img_010.png	22,441	22,729	1,29%	0,774	0,783	1,15%	0,737	0,732	0,63%	0,375	0,374	0,36%
img_011.png	14,755	15,270	3,49%	0,556	0,591	6,33%	0,698	0,696	0,19%	0,427	0,410	4,14%
img_012.png	20,817	21,053	1,13%	0,626	0,647	3,23%	0,722	0,721	0,16%	0,380	0,375	1,15%
img_013.png	25,025	25,480	1,82%	0,704	0,726	3,13%	0,775	0,773	0,22%	0,353	0,337	4,50%
img_014.png	20,163	20,308	0,72%	0,586	0,605	3,09%	0,733	0,733	-0,03%	0,400	0,394	1,67%
img_015.png	21,977	22,463	2,21%	0,596	0,621	4,26%	0,716	0,718	-0,27%	0,413	0,415	-0,34%
img_016.png	24,495	25,353	3,50%	0,822	0,840	2,11%	0,551	0,555	-0,74%	0,275	0,264	3,70%
img_017.png	22,247	22,459	0,95%	0,731	0,746	2,11%	0,784	0,783	0,13%	0,334	0,325	2,71%
img_018.png	23,315	23,593	1,19%	0,624	0,641	2,64%	0,721	0,713	1,10%	0,361	0,374	-3,50%
img_019.png	18,028	18,507	2,65%	0,647	0,675	4,38%	0,709	0,703	0,80%	0,421	0,418	0,70%
img_020.png	19,283	19,501	1,13%	0,623	0,644	3,46%	0,768	0,761	0,98%	0,395	0,410	-3,74%
img_021.png	26,495	27,046	2,08%	0,700	0,720	2,86%	0,670	0,670	0,04%	0,368	0,352	4,55%
img_022.png	23,939	24,095	0,65%	0,701	0,718	2,41%	0,795	0,792	0,39%	0,421	0,408	3,05%
img_023.png	25,399	26,257	3,38%	0,830	0,857	3,28%	0,666	0,667	-0,14%	0,222	0,207	6,70%
img_024.png	17,011	17,182	1,01%	0,481	0,500	3,87%	0,750	0,752	-0,22%	0,394	0,386	1,91%
img_025.png	25,148	26,781	6,49%	0,781	0,803	2,81%	0,732	0,732	-0,02%	0,370	0,363	1,83%
img_026.png	24,139	24,329	0,79%	0,560	0,569	1,52%	0,617	0,622	-0,83%	0,495	0,492	0,54%
img_027.png	25,526	25,853	1,28%	0,717	0,733	2,26%	0,734	0,730	0,66%	0,422	0,403	4,50%

Tablo Ek-4: Urban100 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
img_028.png	27,424	27,909	1,77%	0,803	0,813	1,36%	0,733	0,726	0,88%	0,437	0,413	5,60%
img_029.png	21,679	22,088	1,89%	0,687	0,704	2,42%	0,798	0,778	2,50%	0,359	0,352	2,10%
img_030.png	20,215	20,494	1,38%	0,633	0,656	3,71%	0,704	0,698	0,84%	0,353	0,344	2,58%
img_031.png	21,570	21,812	1,12%	0,703	0,724	3,08%	0,812	0,806	0,76%	0,404	0,392	2,91%
img_032.png	24,771	25,031	1,05%	0,742	0,758	2,11%	0,775	0,773	0,19%	0,373	0,356	4,53%
img_033.png	22,805	23,065	1,14%	0,646	0,654	1,35%	0,681	0,683	-0,30%	0,405	0,399	1,63%
img_034.png	19,778	20,083	1,54%	0,517	0,538	4,10%	0,777	0,766	1,37%	0,446	0,440	1,44%
img_035.png	22,214	22,652	1,97%	0,721	0,751	4,16%	0,725	0,724	0,17%	0,346	0,325	6,20%
img_036.png	24,288	25,021	3,02%	0,793	0,814	2,64%	0,749	0,749	0,01%	0,368	0,350	4,77%
img_037.png	22,643	22,942	1,32%	0,710	0,730	2,76%	0,775	0,768	0,80%	0,389	0,389	0,03%
img_038.png	23,465	23,666	0,85%	0,504	0,522	3,60%	0,691	0,685	0,89%	0,406	0,412	-1,50%
img_039.png	19,712	19,962	1,27%	0,595	0,618	3,73%	0,722	0,719	0,47%	0,398	0,400	-0,44%
img_040.png	18,360	19,531	6,37%	0,681	0,730	7,07%	0,650	0,649	0,17%	0,312	0,317	-1,45%
img_041.png	19,896	20,719	4,13%	0,692	0,730	5,49%	0,792	0,783	1,08%	0,404	0,382	5,60%
img_042.png	23,853	24,536	2,86%	0,781	0,802	2,65%	0,704	0,703	0,09%	0,322	0,314	2,65%
img_043.png	21,215	23,684	11,64%	0,752	0,794	5,57%	0,767	0,735	4,10%	0,336	0,319	5,03%
img_044.png	25,629	26,099	1,83%	0,728	0,747	2,56%	0,692	0,691	0,10%	0,280	0,286	-2,07%
img_045.png	19,837	20,166	1,66%	0,557	0,573	2,89%	0,559	0,559	-0,12%	0,352	0,370	-5,22%
img_046.png	21,389	21,525	0,64%	0,692	0,709	2,47%	0,752	0,744	1,05%	0,379	0,372	1,90%
img_047.png	18,730	18,956	1,20%	0,660	0,683	3,50%	0,736	0,731	0,59%	0,359	0,361	-0,47%
img_048.png	17,155	17,556	2,34%	0,697	0,727	4,36%	0,691	0,692	-0,16%	0,314	0,310	1,18%
img_049.png	19,256	19,744	2,53%	0,605	0,629	4,06%	0,790	0,773	2,08%	0,427	0,415	2,86%
img_050.png	22,437	22,666	1,02%	0,680	0,696	2,35%	0,786	0,788	-0,17%	0,437	0,430	1,52%
img_051.png	23,669	23,933	1,12%	0,752	0,768	2,10%	0,804	0,803	0,14%	0,330	0,323	2,21%
img_052.png	22,736	23,255	2,28%	0,724	0,744	2,72%	0,790	0,789	0,07%	0,344	0,320	7,04%
img_053.png	19,116	19,344	1,19%	0,619	0,637	2,99%	0,860	0,843	1,91%	0,397	0,383	3,41%
img_054.png	18,609	18,773	0,88%	0,549	0,570	3,80%	0,778	0,778	0,00%	0,476	0,476	0,02%
img_055.png	23,645	24,177	2,25%	0,746	0,760	1,89%	0,646	0,647	-0,27%	0,297	0,278	6,45%
img_056.png	21,090	21,453	1,72%	0,639	0,659	3,11%	0,811	0,803	0,96%	0,392	0,377	3,67%
img_057.png	25,090	25,789	2,79%	0,785	0,797	1,62%	0,769	0,759	1,34%	0,365	0,349	4,35%
img_058.png	21,372	21,779	1,90%	0,735	0,750	2,13%	0,788	0,781	0,82%	0,304	0,307	-0,90%
img_059.png	19,160	19,289	0,68%	0,646	0,659	1,99%	0,711	0,709	0,38%	0,399	0,396	0,84%
img_060.png	19,728	19,814	0,44%	0,461	0,475	2,84%	0,770	0,770	0,03%	0,474	0,482	-1,63%
img_061.png	21,664	21,910	1,13%	0,653	0,676	3,61%	0,762	0,759	0,43%	0,385	0,371	3,62%
img_062.png	18,648	18,989	1,83%	0,661	0,688	4,15%	0,738	0,732	0,71%	0,328	0,320	2,54%
img_063.png	16,893	17,254	2,14%	0,412	0,442	7,12%	0,696	0,692	0,61%	0,447	0,462	-3,20%
img_064.png	23,826	24,046	0,92%	0,719	0,734	1,97%	0,770	0,768	0,24%	0,361	0,343	5,13%
img_065.png	22,503	22,712	0,93%	0,631	0,647	2,55%	0,784	0,784	-0,01%	0,381	0,377	1,10%
img_066.png	20,140	20,346	1,02%	0,571	0,591	3,48%	0,728	0,729	-0,12%	0,438	0,426	2,74%
img_067.png	15,783	16,243	2,92%	0,698	0,729	4,55%	0,749	0,758	-1,18%	0,325	0,315	3,26%
img_068.png	26,009	26,554	2,10%	0,764	0,786	2,96%	0,743	0,742	0,21%	0,272	0,278	-1,93%
img_069.png	21,776	22,015	1,10%	0,635	0,653	2,90%	0,769	0,765	0,57%	0,370	0,368	0,55%
img_070.png	20,259	20,393	0,66%	0,537	0,556	3,42%	0,770	0,769	0,13%	0,447	0,451	-1,03%
img_071.png	24,456	24,606	0,61%	0,536	0,552	3,11%	0,710	0,711	-0,12%	0,449	0,446	0,67%
img_072.png	15,640	16,106	2,98%	0,585	0,625	6,78%	0,764	0,762	0,27%	0,388	0,385	0,82%
img_073.png	18,300	18,432	0,72%	0,482	0,501	4,12%	0,826	0,824	0,33%	0,470	0,457	2,77%
img_074.png	20,758	20,887	0,62%	0,570	0,588	3,17%	0,697	0,695	0,24%	0,368	0,363	1,27%
img_075.png	25,573	25,993	1,64%	0,782	0,783	0,16%	0,751	0,746	0,65%	0,362	0,357	1,58%
img_076.png	20,204	20,383	0,88%	0,637	0,655	2,98%	0,761	0,758	0,31%	0,420	0,403	4,06%
img_077.png	20,691	20,823	0,64%	0,615	0,631	2,73%	0,785	0,783	0,30%	0,440	0,427	2,93%
img_078.png	24,766	25,075	1,24%	0,663	0,682	2,86%	0,747	0,735	1,49%	0,391	0,384	1,61%
img_079.png	22,594	22,801	0,91%	0,601	0,620	3,22%	0,786	0,783	0,43%	0,458	0,440	3,82%
img_080.png	31,515	31,825	0,98%	0,907	0,911	0,43%	0,726	0,734	-1,09%	0,281	0,270	3,94%
img_081.png	27,178	29,506	8,56%	0,882	0,903	2,33%	0,722	0,716	0,81%	0,207	0,175	15,72%
img_082.png	26,725	27,608	3,31%	0,865	0,878	1,60%	0,757	0,740	2,24%	0,266	0,255	4,29%
img_083.png	19,394	19,682	1,48%	0,567	0,590	4,06%	0,793	0,783	1,30%	0,415	0,409	1,38%
img_084.png	25,370	25,629	1,02%	0,722	0,736	2,02%	0,762	0,758	0,54%	0,380	0,370	2,67%
img_085.png	24,776	25,229	1,83%	0,847	0,862	1,66%	0,765	0,753	1,65%	0,337	0,319	5,24%
img_086.png	26,884	27,168	1,05%	0,824	0,832	1,02%	0,739	0,737	0,25%	0,286	0,279	2,37%
img_087.png	21,766	22,338	2,63%	0,725	0,746	2,98%	0,729	0,748	-2,58%	0,320	0,309	3,34%
img_088.png	17,371	17,554	1,06%	0,446	0,468	4,97%	0,814	0,808	0,72%	0,492	0,479	2,54%
img_089.png	24,283	24,527	1,00%	0,630	0,649	3,14%	0,806	0,803	0,32%	0,391	0,383	2,12%

Tablo Ek-4: Urban100 veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
img_090.png	29,494	30,057	1,91%	0,883	0,891	0,97%	0,744	0,773	-3,90%	0,281	0,267	5,00%
img_091.png	20,533	20,819	1,39%	0,533	0,557	4,35%	0,725	0,718	1,06%	0,459	0,439	4,34%
img_092.png	15,366	15,451	0,55%	0,444	0,465	4,81%	0,705	0,706	-0,17%	0,502	0,506	-0,81%
img_093.png	22,699	23,667	4,27%	0,799	0,830	3,92%	0,663	0,667	-0,64%	0,296	0,286	3,67%
img_094.png	24,181	24,465	1,17%	0,679	0,698	2,76%	0,806	0,803	0,35%	0,398	0,384	3,71%
img_095.png	17,513	17,702	1,08%	0,302	0,328	8,73%	0,699	0,697	0,26%	0,528	0,543	-2,81%
img_096.png	20,279	20,307	0,14%	0,698	0,713	2,10%	0,653	0,655	-0,24%	0,337	0,344	-2,33%
img_097.png	21,778	22,054	1,27%	0,657	0,679	3,31%	0,746	0,747	-0,03%	0,382	0,362	5,27%
img_098.png	18,372	18,512	0,76%	0,419	0,439	4,81%	0,788	0,782	0,73%	0,480	0,482	-0,39%
img_099.png	20,561	20,727	0,81%	0,573	0,593	3,44%	0,735	0,737	-0,31%	0,378	0,369	2,26%
img_100.png	19,804	20,442	3,22%	0,558	0,584	4,72%	0,749	0,756	-0,90%	0,437	0,412	5,53%

Tablo Ek-5: DIV2K veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
0801.png	28,064	28,338	0,97%	0,821	0,831	1,20%	0,765	0,764	0,12%	0,324	0,337	-4,07%
0802.png	33,565	34,014	1,34%	0,887	0,892	0,51%	0,795	0,791	0,45%	0,214	0,208	2,57%
0803.png	34,154	34,853	2,05%	0,943	0,943	-0,03%	0,722	0,718	0,52%	0,227	0,206	9,22%
0804.png	25,714	26,198	1,88%	0,740	0,757	2,38%	0,842	0,841	0,18%	0,349	0,337	3,47%
0805.png	27,819	28,037	0,79%	0,760	0,772	1,63%	0,682	0,680	0,38%	0,430	0,410	4,63%
0806.png	26,474	26,740	1,01%	0,828	0,840	1,50%	0,728	0,722	0,86%	0,336	0,311	7,57%
0807.png	19,545	19,664	0,61%	0,480	0,499	4,01%	0,731	0,724	0,97%	0,484	0,490	-1,13%
0808.png	25,656	25,944	1,12%	0,780	0,796	2,04%	0,707	0,700	1,05%	0,364	0,357	1,66%
0809.png	30,933	31,212	0,90%	0,839	0,849	1,17%	0,724	0,724	0,04%	0,307	0,303	1,36%
0810.png	26,008	26,198	0,73%	0,755	0,775	2,64%	0,660	0,660	0,00%	0,400	0,404	-1,01%
0811.png	28,294	28,532	0,84%	0,767	0,780	1,70%	0,670	0,670	0,03%	0,397	0,393	0,99%
0812.png	25,888	26,271	1,48%	0,757	0,773	2,06%	0,767	0,765	0,27%	0,389	0,380	2,20%
0813.png	29,207	29,656	1,54%	0,850	0,858	0,93%	0,845	0,832	1,49%	0,305	0,298	2,08%
0814.png	26,802	27,098	1,10%	0,872	0,882	1,06%	0,799	0,797	0,35%	0,292	0,284	2,63%
0815.png	32,142	32,531	1,21%	0,907	0,912	0,55%	0,772	0,769	0,39%	0,318	0,303	4,84%
0816.png	29,997	30,351	1,18%	0,810	0,825	1,80%	0,795	0,794	0,12%	0,404	0,386	4,42%
0817.png	30,454	30,845	1,28%	0,867	0,876	0,98%	0,768	0,768	-0,02%	0,293	0,283	3,29%
0818.png	26,899	27,379	1,79%	0,865	0,878	1,46%	0,797	0,783	1,84%	0,317	0,299	5,54%
0819.png	26,693	26,992	1,12%	0,781	0,796	1,92%	0,828	0,827	0,16%	0,309	0,299	3,48%
0820.png	21,952	22,481	2,41%	0,694	0,715	2,96%	0,822	0,814	0,93%	0,367	0,355	3,34%
0821.png	25,831	28,035	8,53%	0,831	0,863	3,76%	0,837	0,787	5,93%	0,261	0,242	7,09%
0822.png	28,412	28,847	1,53%	0,818	0,832	1,71%	0,804	0,803	0,10%	0,292	0,276	5,62%
0823.png	24,578	24,883	1,24%	0,771	0,787	2,04%	0,777	0,769	1,00%	0,400	0,387	3,34%
0824.png	25,567	25,970	1,58%	0,840	0,847	0,93%	0,812	0,811	0,10%	0,330	0,319	3,16%
0825.png	25,068	25,603	2,13%	0,759	0,774	2,08%	0,835	0,823	1,44%	0,356	0,333	6,33%
0826.png	23,129	23,372	1,05%	0,709	0,726	2,34%	0,803	0,792	1,43%	0,417	0,404	3,22%
0827.png	30,690	30,951	0,85%	0,851	0,856	0,61%	0,685	0,684	0,10%	0,408	0,391	4,23%
0828.png	16,624	16,829	1,24%	0,652	0,674	3,36%	0,635	0,639	-0,61%	0,332	0,352	-5,97%
0829.png	26,081	26,204	0,47%	0,521	0,537	3,06%	0,705	0,696	1,20%	0,489	0,479	2,02%
0830.png	23,732	23,924	0,81%	0,695	0,712	2,46%	0,759	0,756	0,40%	0,401	0,385	3,86%
0831.png	27,085	27,768	2,52%	0,805	0,822	2,14%	0,821	0,818	0,37%	0,327	0,307	6,04%
0832.png	28,014	28,708	2,48%	0,832	0,845	1,58%	0,822	0,809	1,58%	0,298	0,290	2,77%
0833.png	30,453	31,007	1,82%	0,876	0,880	0,37%	0,759	0,767	-1,12%	0,319	0,308	3,23%
0834.png	24,579	24,839	1,06%	0,749	0,769	2,57%	0,815	0,811	0,48%	0,343	0,327	4,50%
0835.png	22,330	22,453	0,55%	0,571	0,589	3,10%	0,738	0,737	0,07%	0,490	0,486	0,80%
0836.png	23,388	23,749	1,55%	0,715	0,730	2,15%	0,831	0,823	0,90%	0,351	0,340	3,30%
0837.png	24,054	24,520	1,94%	0,751	0,773	2,89%	0,846	0,842	0,57%	0,355	0,335	5,83%
0838.png	37,212	37,385	0,46%	0,904	0,908	0,45%	0,606	0,605	0,25%	0,384	0,366	4,82%
0839.png	28,363	28,618	0,90%	0,813	0,831	2,22%	0,671	0,669	0,35%	0,304	0,290	4,69%
0840.png	27,299	27,642	1,26%	0,793	0,806	1,67%	0,790	0,789	0,16%	0,367	0,348	5,11%

Tablo Ek-5: DIV2K veri setindeki görseller üzerinde uygulanan iyileştirme işleminin PSNR, SSIM, A-DISTS ve LPIPS ölçümleri

DOSYA	PSNR			SSIM			A-DISTS			LPIPS		
	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi	Lanczos	d-Eye	Başarı Değişimi
0841.png	26,484	26,798	1,19%	0,815	0,829	1,77%	0,792	0,790	0,34%	0,370	0,359	2,96%
0842.png	28,634	28,893	0,90%	0,840	0,852	1,41%	0,775	0,774	0,20%	0,368	0,361	2,05%
0843.png	37,409	37,905	1,33%	0,975	0,974	-0,05%	0,454	0,453	0,37%	0,077	0,074	4,17%
0844.png	38,625	39,474	2,20%	0,979	0,978	-0,11%	0,765	0,766	-0,06%	0,196	0,181	7,65%
0845.png	21,625	21,891	1,23%	0,676	0,695	2,83%	0,667	0,675	-1,11%	0,422	0,417	1,19%
0846.png	22,427	22,860	1,93%	0,712	0,732	2,77%	0,772	0,773	-0,13%	0,361	0,347	3,84%
0847.png	25,395	25,868	1,87%	0,759	0,775	2,10%	0,836	0,822	1,64%	0,320	0,309	3,53%
0848.png	25,261	25,654	1,56%	0,693	0,705	1,74%	0,805	0,782	2,89%	0,404	0,396	1,85%
0849.png	19,840	20,324	2,44%	0,655	0,679	3,69%	0,809	0,788	2,54%	0,437	0,419	4,19%
0850.png	26,953	27,358	1,50%	0,784	0,797	1,74%	0,815	0,806	1,17%	0,369	0,352	4,70%
0851.png	27,011	27,343	1,23%	0,850	0,857	0,87%	0,686	0,663	3,36%	0,348	0,341	1,90%
0852.png	29,126	29,365	0,82%	0,811	0,828	2,04%	0,743	0,725	2,43%	0,380	0,362	4,75%
0853.png	31,462	32,016	1,76%	0,911	0,918	0,71%	0,676	0,665	1,62%	0,256	0,249	2,79%
0854.png	23,610	23,960	1,48%	0,696	0,716	2,80%	0,802	0,797	0,63%	0,415	0,400	3,54%
0855.png	28,321	28,549	0,80%	0,728	0,741	1,79%	0,713	0,710	0,37%	0,490	0,483	1,55%
0856.png	23,433	23,653	0,94%	0,664	0,685	3,22%	0,705	0,704	0,11%	0,413	0,408	1,02%
0857.png	34,180	34,313	0,39%	0,790	0,790	0,09%	0,672	0,669	0,50%	0,540	0,526	2,64%
0858.png	27,277	27,567	1,06%	0,753	0,768	2,00%	0,758	0,744	1,89%	0,381	0,374	1,66%
0859.png	24,306	24,561	1,05%	0,644	0,662	2,73%	0,757	0,757	0,00%	0,445	0,443	0,56%
0860.png	19,829	20,004	0,88%	0,576	0,597	3,73%	0,756	0,753	0,38%	0,417	0,410	1,53%
0861.png	21,351	21,631	1,31%	0,654	0,675	3,15%	0,733	0,725	0,99%	0,441	0,419	4,98%
0862.png	32,580	32,718	0,42%	0,815	0,825	1,16%	0,642	0,643	-0,11%	0,466	0,458	1,80%
0863.png	32,339	32,540	0,62%	0,894	0,900	0,68%	0,774	0,772	0,25%	0,343	0,331	3,61%
0864.png	28,884	29,168	0,98%	0,757	0,773	2,12%	0,772	0,772	-0,03%	0,417	0,396	5,05%
0865.png	26,467	26,672	0,78%	0,738	0,753	2,01%	0,746	0,747	-0,04%	0,443	0,418	5,49%
0866.png	24,519	24,647	0,52%	0,785	0,796	1,40%	0,751	0,751	0,03%	0,344	0,331	3,96%
0867.png	26,432	26,825	1,49%	0,791	0,806	1,92%	0,785	0,784	0,10%	0,342	0,325	4,93%
0868.png	29,885	30,303	1,40%	0,940	0,942	0,27%	0,710	0,709	0,14%	0,188	0,188	-0,02%
0869.png	22,891	23,025	0,59%	0,767	0,783	2,04%	0,711	0,709	0,35%	0,380	0,394	-3,76%
0870.png	27,381	27,631	0,91%	0,823	0,833	1,14%	0,819	0,819	-0,01%	0,276	0,278	-0,83%
0871.png	29,828	30,302	1,59%	0,866	0,877	1,23%	0,840	0,839	0,12%	0,287	0,272	5,23%
0872.png	22,668	22,960	1,29%	0,644	0,661	2,76%	0,826	0,825	0,17%	0,393	0,399	-1,54%
0873.png	22,872	23,139	1,17%	0,676	0,696	2,85%	0,803	0,799	0,46%	0,404	0,381	5,71%
0874.png	28,392	28,709	1,12%	0,744	0,758	1,83%	0,813	0,815	-0,27%	0,391	0,371	5,18%
0875.png	22,585	23,017	1,91%	0,574	0,600	4,42%	0,841	0,826	1,76%	0,418	0,400	4,25%
0876.png	21,533	21,651	0,55%	0,527	0,547	3,76%	0,678	0,673	0,81%	0,477	0,481	-0,75%
0877.png	35,974	36,579	1,68%	0,945	0,945	0,09%	0,902	0,903	-0,10%	0,203	0,197	2,58%
0878.png	29,288	29,959	2,29%	0,858	0,869	1,31%	0,794	0,792	0,28%	0,340	0,328	3,56%
0879.png	25,619	25,883	1,03%	0,817	0,826	1,17%	0,710	0,703	0,85%	0,324	0,316	2,50%
0880.png	30,964	31,281	1,02%	0,889	0,901	1,38%	0,759	0,759	-0,08%	0,375	0,369	1,76%
0881.png	25,102	25,281	0,71%	0,753	0,771	2,45%	0,763	0,763	0,06%	0,388	0,367	5,40%
0882.png	31,840	32,336	1,56%	0,936	0,935	-0,13%	0,746	0,734	1,59%	0,271	0,248	8,76%
0883.png	25,217	25,513	1,18%	0,705	0,724	2,59%	0,772	0,768	0,39%	0,377	0,385	-2,17%
0884.png	24,308	24,626	1,31%	0,676	0,694	2,66%	0,829	0,823	0,63%	0,415	0,402	3,35%
0885.png	21,995	22,103	0,49%	0,537	0,552	2,84%	0,670	0,670	-0,05%	0,461	0,473	-2,76%
0886.png	33,873	34,429	1,64%	0,909	0,911	0,22%	0,673	0,661	1,78%	0,404	0,384	5,08%
0887.png	24,109	24,438	1,36%	0,736	0,753	2,37%	0,706	0,695	1,55%	0,388	0,396	-1,92%
0888.png	27,989	28,562	2,05%	0,844	0,854	1,16%	0,824	0,817	0,80%	0,294	0,285	3,34%
0889.png	27,847	28,433	2,10%	0,866	0,877	1,21%	0,843	0,836	0,85%	0,249	0,243	2,74%
0890.png	24,709	24,845	0,55%	0,720	0,739	2,69%	0,803	0,803	0,08%	0,383	0,373	2,58%
0891.png	24,034	24,496	1,92%	0,722	0,739	2,42%	0,811	0,805	0,68%	0,364	0,350	3,84%
0892.png	25,724	26,230	1,97%	0,812	0,829	2,02%	0,684	0,685	-0,16%	0,319	0,310	2,92%
0893.png	31,339	31,578	0,76%	0,801	0,804	0,38%	0,739	0,740	-0,04%	0,417	0,412	1,14%
0894.png	29,660	30,062	1,35%	0,862	0,874	1,31%	0,768	0,763	0,65%	0,307	0,290	5,26%
0895.png	19,845	19,975	0,66%	0,535	0,556	3,93%	0,819	0,818	0,11%	0,478	0,479	-0,20%
0896.png	34,191	35,129	2,74%	0,928	0,927	-0,08%	0,672	0,671	0,17%	0,347	0,346	0,37%
0897.png	21,134	21,364	1,09%	0,655	0,671	2,55%	0,626	0,624	0,26%	0,410	0,404	1,52%
0898.png	32,089	32,614	1,64%	0,893	0,897	0,41%	0,637	0,629	1,35%	0,332	0,327	1,48%
0899.png	26,624	27,401	2,92%	0,833	0,842	1,03%	0,741	0,742	-0,16%	0,256	0,257	-0,10%
0900.png	24,539	25,041	2,04%	0,784	0,800	2,03%	0,850	0,833	1,96%	0,351	0,339	3,42%

İNTİHAL RAPORU İLK SAYFASI



Hürkal_HÜSEM

ORİJİNALLİK RAPORU

%4	%3	%3	%2
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

TÜM KAYNAKLARI EŞLEŞTİR (SADECE SEÇİLİ OLAN KAYNAĞI YAZDIR)

%2

★ Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK)

Öğrenci Ödevi

Alıntıları çıkart	Kapat	Eşleşmeleri çıkar	Kapat
Bibliyografyayı Çıkart	üzerinde		