

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DERİN ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK TEKNİKLERİ  
KULLANARAK JPEG SIKIŞTIRMA KAYBININ İYİLEŞTİRİLMESİ**

**YÜKSEK LİSANS TEZİ**

**Muhammet BOLAT**

**Bilişim Uygulamaları Anabilim Dalı**

**Bilgi ve Haberleşme Mühendisliği Programı**

**OCAK 2024**



**DERİN ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK TEKNİKLERİ  
KULLANARAK JPEG SIKIŞTIRMA KAYBININ İYİLEŞTİRİLMESİ**

**YÜKSEK LİSANS TEZİ**

**Muhammet BOLAT  
(708191019)**

**Bilişim Uygulamaları Anabilim Dalı**

**Bilgi ve Haberleşme Mühendisliği Programı**

**Tez Danışmanı: Prof. Dr. Lutfiye DURAK ATA  
Eş Danışman: Dr. Öğr. Üyesi Nurullah ÇALIK**

**OCAK 2024**



**ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL**

**RECOVERING JPEG COMPRESSION LOSS VIA  
DEEP LEARNING-BASED SUPER RESOLUTION TECHNIQUES**

**M.Sc. THESIS**

**Muhammet BOLAT  
(708191019)**

**Applied Informatics**

**Information and Communications Engineering Programme**

**Thesis Advisor: Prof. Dr. Lutfiye DURAK ATA  
Co Advisor: Dr. Öğr. Üyesi Nurullah ÇALIK**

**JANUARY 2024**



İTÜ, Lisansüstü Eğitim Enstitüsü'nün 708191019 numaralı Yüksek Lisans Öğrencisi Muhammet BOLAT, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DERİN ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK TEKNİKLERİ KULLANARAK JPEG SIKIŞTIRMA KAYBININ İYİLEŞTİRİLMESİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

**Tez Danışmanı :** **Prof. Dr. Lütfiye DURAK ATA** .....  
İstanbul Teknik Üniversitesi

**Eş Danışman :** **Dr. Öğr. Üyesi Nurullah ÇALIK** .....  
İstanbul Medeniyet Üniversitesi

**Jüri Üyeleri :** **Prof. Dr. Ender Mete EKŞİOĞLU** .....  
İstanbul Teknik Üniversitesi

**Prof. Dr. Behçet Uğur TÖREYİN** .....  
İstanbul Teknik Üniversitesi

**Doç. Dr. Nihan KAHRAMAN** .....  
Yıldız Teknik Üniversitesi

**Teslim Tarihi :** **8 Aralık 2023**

**Savunma Tarihi :** **29 Ocak 2024**





*Sevdiklerime,*



## ÖNSÖZ

Tez danışmanım Prof. Dr. Lütfiye Durak Ata ve eş danışmanım Dr. Nurullah Çalık'a yüksek lisans eğitimim boyunca sunduğu rehberlik, yönlendirme ve teşvik için içten teşekkürlerimi ifade etmek isterim. Yüksek lisans ders ve tez sürecimde onlarla birlikte çalışma fırsatına sahip olduğum için kendimi şanslı hissediyorum. Ayrıca tez çalışmam boyunca yardımlarını esirgemeyen ICRG (Information and Communications Research Group) ailesi ve Dr. Mehmet Başaran'a minnettarlığımı ifade etmek isterim. En önemlisi, yaşamımın her aşamasında sonsuz sevgi, destek ve güvenlerini sunan aile üyelerime en derin teşekkürlerimi ifade etmek isterim.

Ocak 2024

Muhammet BOLAT  
(Yazılım Mühendisi)



## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖNSÖZ</b> .....	<b>ix</b>
<b>İÇİNDEKİLER</b> .....	<b>xi</b>
<b>KISALTMALAR</b> .....	<b>xiii</b>
<b>ÇİZELGE LİSTESİ</b> .....	<b>xv</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>xvii</b>
<b>ÖZET</b> .....	<b>xix</b>
<b>SUMMARY</b> .....	<b>xxiii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Problemin Tanımı .....	3
1.2 Tezin Amacı .....	4
1.3 Tez Planı .....	5
1.4 Literatür Özeti .....	6
<b>2. DERİN ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK</b> .....	<b>11</b>
2.1 Yinelemeli Öğrenme .....	12
2.1.1 Derin yinelemeli evrişimli ağ (DRCN) .....	13
2.1.2 Çok derin yinelemeli artık ağ (DRRN) .....	14
2.1.3 Gömülü blok artık ağ (EBRN) .....	15
2.2 Artık Öğrenme .....	17
2.2.1 Çok derin süper çözünürlük (VDSR) .....	17
2.2.2 Geliştirilmiş ve çok-ölçekli derin süper çözünürlük (EDSR ve MDSR) .....	19
2.2.3 Süper çözünürlük yoğun ağ (SRDenseNet) .....	21
2.3 Çok Ölçekli Öğrenme .....	24
2.3.1 Çok ölçekli artık ağ (MSRN) .....	24
2.3.2 Çok ölçekli özellik birleşme artık ağ (MSFFRN) .....	26
2.3.3 Verimli uzun menzilli dikkat ağı (ELAN) .....	27
2.4 Dikkat Mekanizması .....	28
2.4.1 Artık kanal dikkat mekanizması (RCAN) .....	28
2.4.2 Bütünsel dikkat ağı (HAN) .....	30
2.4.3 İkinci dereceden derin sinir ağı (SAN) .....	31
2.5 Geri Besleme Mekanizması .....	32
2.5.1 Derin geri-yansıtma ağı (DBPN) .....	32
2.5.2 Yoğun derin geri-yansıtma ağı (D-DBPN) .....	33
2.5.3 Süper çözünürlük geri bildirim ağı (SFRBN) .....	34
2.6 Frekans Bilgi Tabanlı Modeller .....	35
2.6.1 Frekans duyarlı dinamik ağ (FADN) .....	36
2.6.2 Dinamik filtre ve çoklu spektral dikkat mekanizması (DFSA) .....	37
<b>3. JPEG GÖRÜNTÜ SIKIŞTIRMA</b> .....	<b>39</b>
3.1 Sıkıştırma Adımları .....	40
3.1.1 RGB - YCrYb renk uzay dönüşümü .....	41
3.1.2 Alt örnekleme .....	42
3.1.3 Ayırık kosinüs dönüşümü .....	43

3.1.4	Nicemleme matrisi ve kalite deęeri .....	43
3.1.5	Huffman kodlama yntemi .....	44
3.2	Geri Elde Etme Adımları .....	45
<b>4.</b>	<b>DENEYSSEL SONUÇLAR .....</b>	<b>47</b>
4.1	Kalite Metrikleri .....	47
4.1.1	PSNR .....	47
4.1.2	SSIM.....	47
4.2	Veri Kmeleri .....	48
4.2.1	ImageNet .....	48
4.2.2	Set5 .....	49
4.2.3	Set14.....	50
4.2.4	BSDS100 .....	50
4.2.5	BSDS200 .....	51
4.2.6	General100 .....	51
4.3	SRCNN Eęitim Sonuları .....	52
4.4	VDSR Eęitim Sonuları .....	57
4.5	SRDenseNet Eęitim Sonuları .....	61
4.6	Sonuların Karşılařtırılması .....	65
<b>5.</b>	<b>SONUÇLAR VE GELECEK ALIŐMALAR .....</b>	<b>69</b>
5.1	zet ve Katkılar.....	69
5.2	Gelecekteki alıŐmalar .....	71
<b>KAYNAKLAR.....</b>		<b>73</b>
<b>ZGEMİŐ .....</b>		<b>79</b>

## KISALTMALAR

<b>SÇ</b>	: Süper Çözünürlük
<b>DÇ</b>	: Düşük Çözünürlük
<b>YÇ</b>	: Yüksek Çözünürlük
<b>K</b>	: Kalite Faktörü
<b>SRCNN</b>	: Süper Çözünürlük Evrişimsel Sinir Ağı
<b>VDSR</b>	: Çok Derin Süper Çözünürlük
<b>SRDenseNet</b>	: Süper Çözünürlük Yoğun Ağ
<b>SSIM</b>	: Yapısal Benzerlik İndeksi
<b>PSNR</b>	: Tepe Sinyal Gürültü Oranı
<b>MSE</b>	: Ortalama Kareler Hatası
<b>ADAM</b>	: Uyarlanabilir Moment Tahmini
<b>CNN</b>	: Evrişimli Sinir Ağı



## ÇİZELGE LİSTESİ

	<u>Sayfa</u>
<b>Çizelge 4.1 :</b> K = 10, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO). . . . .	<b>68</b>
<b>Çizelge 4.2 :</b> K = 20, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO). . . . .	<b>68</b>
<b>Çizelge 4.3 :</b> K = 30, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO). . . . .	<b>68</b>
<b>Çizelge 4.4 :</b> K = 40, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO). . . . .	<b>68</b>
<b>Çizelge 4.5 :</b> K = 50, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO). . . . .	<b>68</b>





## ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 1.1 : Çalışmanın genel yapısı. ....	5
Şekil 2.1 : DRCN modelinin mimarisi. ....	13
Şekil 2.2 : Inference yineleme modelinin mimarisi. ....	13
Şekil 2.3 : Atlamalı katman - DRCN modelinin mimarisi. ....	14
Şekil 2.4 : DRRN modelinin karşılaştırılması. ....	15
Şekil 2.5 : EBRN modelinin mimarisi. ....	16
Şekil 2.6 : VDSR modelinin mimarisi. ....	19
Şekil 2.7 : EDSR modelinin mimarisi. ....	20
Şekil 2.8 : Çok ölçekli EDSR(MDSR) modelinin mimarisi. ....	21
Şekil 2.9 : SRDenseNet modelinin mimarisi. ....	22
Şekil 2.10 : Dense blok yapısı. ....	23
Şekil 2.11 : MSRN modelinin mimarisi. ....	25
Şekil 2.12 : MSRB blok yapısı. ....	26
Şekil 2.13 : MSFFRN modelinin mimarisi. ....	27
Şekil 2.14 : ELAN modelinin mimarisi. ....	27
Şekil 2.15 : RCAN modelinin mimarisi. ....	29
Şekil 2.16 : HAN modelinin mimarisi. ....	30
Şekil 2.17 : SAN modelinin mimarisi. ....	31
Şekil 2.18 : DBPN modelinin mimarisi. ....	33
Şekil 2.19 : D-DBPN modelinin mimarisi. ....	33
Şekil 2.20 : SRFBN modelinin mimarisi. ....	35
Şekil 2.21 : SRFBN FB bloğunun yapısı. ....	35
Şekil 2.22 : FADN ağ mimarisi. ....	36
Şekil 2.23 : FADB yapısı. ....	37
Şekil 2.24 : MMCA modülünün yapısı. ....	38
Şekil 2.25 : RCAN (a) ve DFSA(b) modelinin yapısı. ....	38
Şekil 3.1 : JPEG sıkıştırma algoritması. ....	41
Şekil 4.1 : ImageNet veri kümesi örnek görüntüler. ....	49
Şekil 4.2 : Set5 veri kümesi örnek görüntüler. ....	49
Şekil 4.3 : Set14 veri kümesi örnek görüntüler. ....	50
Şekil 4.4 : BSDS100 veri kümesi örnek görüntüler. ....	50
Şekil 4.5 : BSDS200 veri kümesi örnek görüntüler. ....	51
Şekil 4.6 : General100 veri kümesi örnek görüntüler. ....	51
Şekil 4.7 : Farklı K değerinde SRCNN kayıp fonksiyon sonuçları. ....	53
Şekil 4.8 : Farklı K değerinde SRCNN PSNR metrik sonuçları. ....	53
Şekil 4.9 : Farklı K değerinde SRCNN SSIM metrik sonuçları. ....	53
Şekil 4.10 : Set5 veri kümesi bebek görüntüsü SRCNN çıktısı. ....	54
Şekil 4.11 : Set5 veri kümesi çocuk görüntüsü SRCNN çıktısı. ....	54

<b>Şekil 4.12</b> : Set5 veri kümesi kelebek görüntüsü SRCNN çıktısı.....	<b>55</b>
<b>Şekil 4.13</b> : BSDS100 veri kümesi bina görüntüsü SRCNN çıktısı. ....	<b>55</b>
<b>Şekil 4.14</b> : BSDS100 veri kümesi zebra görüntüsü SRCNN çıktısı. ....	<b>56</b>
<b>Şekil 4.15</b> : Farklı K değerinde VDSR kayıp fonksiyon sonuçları. ....	<b>58</b>
<b>Şekil 4.16</b> : Farklı K değerinde VDSR PSNR metrik sonuçları. ....	<b>58</b>
<b>Şekil 4.17</b> : Farklı K değerinde VDSR SSIM metrik sonuçları.....	<b>58</b>
<b>Şekil 4.18</b> : Set5 veri kümesi bebek görüntüsü VDSR çıktısı. ....	<b>59</b>
<b>Şekil 4.19</b> : Set5 veri kümesi çocuk görüntüsü VDSR çıktısı. ....	<b>59</b>
<b>Şekil 4.20</b> : Set5 veri kümesi kelebek görüntüsü VDSR çıktısı. ....	<b>60</b>
<b>Şekil 4.21</b> : BSDS100 veri kümesi bina görüntüsü VDSR çıktısı. ....	<b>60</b>
<b>Şekil 4.22</b> : BSDS100 veri kümesi zebra görüntüsü VDSR çıktısı. ....	<b>61</b>
<b>Şekil 4.23</b> : Farklı K değerinde SRDenseNet kayıp fonksiyon sonuçları. ....	<b>62</b>
<b>Şekil 4.24</b> : Farklı K değerinde SRDenseNet PSNR metrik sonuçları. ....	<b>62</b>
<b>Şekil 4.25</b> : Farklı K değerinde SRDenseNet SSIM metrik sonuçları.....	<b>63</b>
<b>Şekil 4.26</b> : Set5 veri kümesi bebek görüntüsü SRDenseNet çıktısı. ....	<b>63</b>
<b>Şekil 4.27</b> : Set5 veri kümesi çocuk görüntüsü SRDenseNet çıktısı. ....	<b>64</b>
<b>Şekil 4.28</b> : Set5 veri kümesi kelebek görüntüsü SRDenseNet çıktısı. ....	<b>64</b>
<b>Şekil 4.29</b> : BSDS100 veri kümesi bina görüntüsü SRDenseNet çıktısı. ....	<b>65</b>
<b>Şekil 4.30</b> : BSDS100 veri kümesi zebra görüntüsü SRDenseNet çıktısı.....	<b>65</b>

## DERİN ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK TEKNİKLERİ KULLANARAK JPEG SIKIŞTIRMA KAYBININ İYİLEŞTİRİLMESİ

### ÖZET

Bilgisayar biliminde bant genişliğinin etkin kullanımı, özellikle resim, video, ses gibi büyük verilerin iletilmesiyle giderek daha fazla önem kazanmaktadır. Bant genişliği, iletim hattı üzerinden bir saniyede iletilen maksimum veri miktarını temsil eden bir terimdir. Aynı zamanda, belirli bir iletim ortamında bir işaretin kapladığı frekans aralığı olarak da tanımlanır. Bu bakış açısıyla, bant genişliği, veri iletimi için kullanılabilen spektrumu temsil eder. Bant genişliği genellikle bit/saniye (bit per second, bps) veya daha yüksek birimlerle ölçülür. Büyük boyutlara sahip verilerin iletilmesi, iletişim kanalının kapasitesini önemli ölçüde meşgul etmektedir. Bir internet kullanıcısı, yüksek kaliteli bir video izlerken kesinti ve veri kaybı yaşamamak için geniş bant genişliğine ihtiyaç duyar. Ancak bir e-posta gönderirken, veriyi iletmek için daha düşük bir bant genişliği yeterli olabilir. MRI taramalarında bir hastanın binlerce görüntüsü çekilir ve bu görüntüler birleştirilerek üç boyutlu sonuçlar elde edilir. Ancak bu görüntüleri bir yerden başka bir yere iletmek, veri boyutu büyüdükçe gereken iletim kapasitesini artırır ve bu durum zorlu ve maliyetli bir görev haline gelir. Bu nedenle, veri iletimi sırasında gecikmeleri ve kayıpları önlemek için bant genişliği kullanımının optimize edilmesi gerekmektedir.

Bant genişliğinin etkin kullanılması amacıyla veri sıkıştırma teknikleri büyük önem taşımaktadır. Sıkıştırmanın performansı, iletilecek veri miktarını, dolayısıyla kullanılacak bant genişliğini doğrudan etkilemektedir. Veri sıkıştırma, bilgisayar üzerinde saklanan verilerin, tekrarlanan ve gereksiz bilgilerini ortadan kaldırıp kodlama işlemi yaparak kapladığı alanı azaltma işlemidir. Bu işlem, dosya boyutlarını düşürerek daha verimli bir şekilde depolamak ve iletim hattını verimli bir şekilde kullanmak için tercih edilir. Veri sıkıştırma, iki farklı tekniği içerir: kayıplı ve kayıpsız. Kayıplı sıkıştırma, kullanıcının tercihine göre sıkıştırma oranının özelleştirilebileceği bir veri sıkıştırma tekniğidir. Bu teknik, veri boyutunu azaltmak için önemsiz, tekrarlı veya insan algısına etkisi düşük olan belirli veri parçalarının atılması veya kodlanması yoluyla gerçekleşir. Kayıplı sıkıştırma algoritmaları kullanıldığında, bazı veri parçaları kalıcı olarak kaybolur ve geri getirilemez. İnsan gözü ve kulağı, veri kaybını her zaman fark edemeyebilir, ancak özellikle yüksek sıkıştırma oranları kullanıldığında kayıplar daha belirgin hale gelebilmektedir. Bu nedenle, kayıplı sıkıştırma genellikle görüntü, video ve ses dosyalarını sıkıştırmak için kullanılır. Kayıpsız sıkıştırma, kullanıcının tercihine bırakılmayan, özelleştirilemeyen bir sıkıştırma tekniğidir. Bu teknik, veri boyutunu azaltmak için tekrarlı olan verileri azaltıp kodlama yöntemiyle sıkıştırma yapmasıyla sağlanır. Bu yöntemde herhangi bir veri kaybolmaz. Verinin kaybolacağı noktada sıkıştırma devam etmez ve orijinal veri geri elde edilmeye çalışıldığında herhangi bir kayıp söz konusu olmaz. Kayıpsız sıkıştırma, tüm verinin

önemli olduğu ve asla kaybolması beklenmediği durumlarda kullanılır. Bu yöntem, metin gibi önemli verilerin olduğu alanlarda kullanılır. Metin verileri, orijinal biçiminde kurtarılmalıdır. Kayıp oluştuğunda ise anlamını kaybeder. Kayıplı ve kayıpsız tüm sıkıştırma teknikleri veri boyutunu belirli bir oranda azalttığından dolayı bant genişliğini daha efektif kullanılmasına olanak tanımaktadır. Bu nedenle, bant genişliğinin etkin kullanılması adına sıkıştırma teknikleri önemini korumaktadır.

Web sayfaları ve diğer dijital platformlarda görüntülerin daha hızlı yüklenmesi adına sıkıştırılması gerekmektedir. Bu yüzden kayıplı sıkıştırma tekniği olarak Birleşmiş Fotoğraf Uzmanları Grubu (Joint Photographic Experts Group, JPEG), kayıpsız olarak Taşınabilir Ağ Grafikleri (Portable Network Graphic, PNG) gibi teknikler tercih edilmektedir. PNG, JPEG'e kıyasla görüntü kalitesini korurken belirli oranda sıkıştırma yapar. Ancak bu tür algoritmaların dosya boyutları genellikle JPEG ile kıyaslandığında daha büyük olmaktadır. Bu nedenle, web üzerinde hızlı yükleme ve daha az bant genişliği kullanımı gibi faktörler göz önünde bulundurulduğunda, JPEG sıkıştırması tercih edilmektedir. Sonuç olarak, web tabanlı uygulamalarda daha küçük dosya boyutları ve hızlı yükleme süreleri elde etmek adına bir miktar görüntü kalitesi kaybı kabul edilmektedir.

Işık koşulları, donanım yetersizliği, kayıplı veri sıkıştırma veya haberleşme kanallarında maruz kalınan gürültüler gibi faktörlerden dolayı görüntüler düşük çözünürlüklü olabilmektedir. Süper çözünürlük problemi, bilgisayar biliminde düşük çözünürlüklü bir görüntüyü yüksek çözünürlüklü bir görüntüye dönüştürmeyi amaçlamaktadır. Günümüzde, uydu görüntüleri, uzaktan algılama, tıbbi görüntüleme gibi bir çok alanda yüksek çözünürlüklü görüntüler elde etmek için kullanılır. Herhangi bir sebepten dolayı kalite kaybı yaşayan görüntüler, süper çözünürlük yöntemleri kullanılarak görüntü kalitesi belirli bir oranda arttırılabilmektedir.

Son yıllarda, süper çözünürlük alanında derin öğrenme tabanlı bir çok çalışma yapılmış ve bir çok model ortaya atılmıştır. Bu modellerin performansları, kalite (benchmark) veri kümelerinde yüksek başarılarla imza atmıştır. Derin öğrenme, makine öğreniminin bir uzantısı olan yapay sinir ağlarına dayalı olarak geliştirilmiş bir kavramdır. Yapay sinir ağları, hesaplama birimleri olarak kullandığı yapay nöronlarla insan beyninin düşünme biçimini taklit eder; yapay sinir ağı yapısı, bu nöronların bağlanma şeklini yansıtır. Derin öğrenmenin amacı, altta yatan özelliklerin hiyerarşik bir temsilini öğrenerek verilerin özellik dağılımını belirlemektir. Süper çözünürlük problemini derin öğrenme ile inceleyen çalışmalarda interpolasyon tabanlı düşük çözünürlüklü görüntüler üzerinde iyileştirme sağlamayı konu almaktadır. Ancak, sıkıştırılmış ve kayıp yaşanmış düşük çözünürlüklü görüntüler üzerinde herhangi bir etkisi incelenmemiştir. Derin öğrenme tabanlı yaklaşımlarda elde edilen sonuçlar, farklı türdeki görüntülerin geri kazanımları için araştırma konusu olmaktadır. Süper Çözünürlük Evrişimli Sinir Ağ (Super Resolution Convolutional Neural Network, SRCNN) modeli, süper çözünürlük problemini derin öğrenme yaklaşımıyla inceleyen ilk çalışması olarak kabul edilir. İlkel olarak tanımlanabilecek bu modelin içerisinde 3 katmanlı evrişimli sinir ağı bulunmaktadır. Çok Derin Süper Çözünürlük (Very Deep Super Resolution, VDSR) modeli, SRCNN modelinin daha derin öğrenme yapısına sahip ve artık blok eklenmiş versiyonu olarak geliştirilmiştir. Derin ağ yapısı sayesinde daha yüksek çözünürlüğe sahip sonuçlar üretmektedir. VDSR, süper

özünürlük alanındaki arařtırmalarda ve uygulamalarda büyük bir etki yaratmıř ve bu alanda bir dönüm noktası olarak kabul edilmiřtir. Süper özünürlük Yoęun Aę (Super Resolution Dense Network, SRDenseNet) modeli, ierisinde barındırdıęı yoęun bloklar sayesinde ok fazla sayıda özellik ıkarımı yapabilmektedir. Ayrıca bu blokların her birinin birbirleri arasında artık öęrenme teknięinin kullanılması model performansını daha bařarılı hale getirmiřtir. SRDenseNet modeli bu yüzden SRCNN ve VDSR modellerine göre daha karmařık ve daha fazla matematiksel iřlemi barındırmaktadır.

Bu tez kapsamında, görüntü sıkıřtırma iřlemi iin en ok tercih edilen JPEG yönteminden kaynaklanan kayıpların, derin öęrenme tabanlı süper özünürlük modellerinden olan SRCNN, VDSR ve SRDenseNet kullanılarak geri kazanımı incelenmiřtir. Farklı kalite seviyelerinde sıkıřtırılmıř görüntülerle bir eęitim veri kümesi oluřturularak inceleme gerekleřtirilmiřtir. Eęitim ařamasında ImageNet veri kümesi kullanılırken, test ařamalarında ise süper özünürlük problemlerinde kullanılan kalite test (benchmark) verilerinden olan SET5, SET14, BSDS100, BSDS200 ve General100 veri kümeleri kullanılmıřtır. alıřmanın sonucunda süper özünürlük yöntemlerinin JPEG sıkıřtırma kayıplarını geri kazanma potansiyeline sahip olduęunu göstermektedir. Ayrıca, süper özünürlük yöntemlerinin görüntü kalitesini artırmada ve sıkıřtırma kayıplarını azaltmada etkili bir özüm olabileceęini vurgulamaktadır. Gelecekteki alıřmalarda farklı veri kümesi ve modellerin kullanılmasıyla daha ayrıntılı analizler yapılabilir ve bu konuda daha fazla bilgi saęlanabilir.



## **RECOVERING JPEG COMPRESSION LOSS VIA DEEP LEARNING-BASED SUPER RESOLUTION TECHNIQUES**

### **SUMMARY**

The effective utilization of bandwidth in computer science is increasingly crucial, particularly with the transmission of large data such as images, videos, and audio. Bandwidth is a term representing the maximum amount of data transmitted per second over a communication channel. It is also defined as the frequency range covered by a signal in a specific transmission channel. From this perspective, bandwidth represents the spectrum available for data transmission. Bandwidth is typically measured in bits per second (bps) or higher units. The transmission of large-sized data significantly occupies the capacity of the communication channel. An internet user, for instance, requires high bandwidth to avoid interruptions and data loss while watching a high-quality video. However, when sending an email, lower bandwidth may be sufficient for data transmission. In MRI scans, a patient's thousands of images are captured, and these images are combined to obtain three-dimensional results. However, transmitting these images from one location to another increases the required transmission capacity as the data size grows, turning it into a challenging and costly task. Therefore, optimizing the use of bandwidth is crucial during data transmission to prevent delays and losses.

Effective utilization of bandwidth is crucial, and for this purpose, data compression techniques have a significant role. The performance of compression directly influences the amount of data to be transmitted and, consequently, the bandwidth to be used. Data compression is the process of reducing the space occupied by stored data on a computer by eliminating repeated and unnecessary information through encoding. This process is preferred to efficiently store data by reducing file sizes and to use the transmission channel more effectively. Data compression involves two different techniques: lossy and lossless. Lossy compression is a data compression technique where the compression ratio can be customized based on the user's preference. In this technique, certain data parts that are considered insignificant, repetitive, or have a low impact on human perception are either discarded or encoded to reduce the data size. When lossy compression algorithms are used, some data parts are permanently lost and cannot be recovered. Human eyes and ears may not always recognise data loss, but especially when high compression ratios are used, the losses can become more noticeable. Therefore, lossy compression is commonly used for compressing image, video, and audio files. On the other hand, lossless compression is a compression technique that is not customizable and does not allow the user to specify the compression ratio. This technique reduces data size by compressing repetitive data through encoding without any loss of data. Compression stops at the point where data loss would occur, and when an attempt is made to recover the original data, no loss is experienced. Lossless compression is used in situations where all data is

considered important, and loss is never expected. This method is employed in areas where critical data, such as text, needs to be preserved in its original form. Text data must be recovered in its original format; otherwise, it loses its meaning when loss occurs. Both lossy and lossless compression techniques enable more effective use of bandwidth by reducing data size. Therefore, compression techniques remain crucial for the efficient use of bandwidth.

Images need to be compressed for faster loading on web pages and other digital platforms. Therefore, lossy compression techniques such as the Joint Photographic Experts Group (JPEG) are preferred. Additionally, lossless techniques like Portable Network Graphics (PNG) are also used. PNG maintains image quality compared to JPEG but compresses to a certain extent. However, file sizes with such algorithms are generally larger than those of JPEG. Therefore, considering factors like quick loading and reduced bandwidth usage on the web, JPEG compression is preferred. As a result, in web-based applications, a certain loss in image quality is accepted to achieve smaller file sizes and faster loading times.

Lighting conditions, hardware limitations, lossy data compression, or noise faced in communication channels can result in low-resolution images. The super-resolution problem in computer science aims to convert a low-resolution image into a high-resolution image. In various fields today, such as satellite imagery, remote sensing, and medical imaging, high-resolution images are used. Images that experience a loss in quality for any reason can have their image quality improved to a certain extent using super-resolution methods.

In recent years, numerous studies in the field of super-resolution have been announced based on deep learning, resulting in the proposal of various models. These models have demonstrated high performance on benchmark datasets. Deep learning is a concept developed as an extension of machine learning, relying on artificial neural networks. Artificial neural networks, the way the human brain thinks, using artificial neurons as computational units, and the structure of an artificial neural network reflects the connectivity of these neurons. The goal of deep learning is to learn a hierarchical representation of underlying features and determine the feature distribution of the data. Research in super-resolution using deep learning has focused on improving interpolation-based low-resolution images. However, the impact of these approaches on compressed and lossy low-resolution images has not been extensively explored. Results obtained from deep learning-based approaches are still a subject of research for the recovery of different types of images. The Super-Resolution Convolutional Neural Network (SRCNN) model is considered the first study to investigate the super-resolution problem with a deep learning approach. This model, which can be considered primitive, consists of a 3-layer convolutional neural network. The Very Deep Super Resolution (VDSR) model was developed as a deeper learning structure with added residual blocks, evolving from the SRCNN model. Due to its deep network structure, VDSR produces results with higher resolution. VDSR has had a significant impact on research and applications in the super-resolution field and is considered a turning point in this area. The Super Resolution Dense Network (SRDenseNet) model, with its dense blocks, can perform a large number of feature extractions. Additionally, the use of the residual learning technique between these

blocks has enhanced the model's performance. Therefore, the SRDenseNet model is more complex and involves more mathematical processing compared to the SRCNN and VDSR models.

In the scope of this thesis, the recovery of losses created from the widely preferred JPEG method for image compression has been investigated using deep learning-based super-resolution models, namely SRCNN, VDSR, and SRDenseNet. An investigation was included by creating a training dataset with compressed images at different quality levels. During the training phase, the ImageNet dataset is used, while benchmark datasets commonly used in super-resolution problems, including SET5, SET14, BSDS100, BSDS200, and General100, were used during the testing phases. The results of the study demonstrate the potential of super-resolution methods to recover losses caused by JPEG compression. Additionally, it emphasizes that super-resolution methods could be an effective solution for enhancing image quality and reducing compression losses. Future studies may extend more detailed analyses by using different datasets and models, providing further insights into this matter.





## 1. GİRİŞ

Teknolojinin gelişimiyle birlikte fotoğraf, video ve ses dosyalarının çözünürlüğü artmakta ve daha kaliteli veriler üretilmektedir. Bu kalite artışı, verilerin boyutunun da aynı oranda artmasına neden olmakta, bu da daha büyük bellek alanlarının gerekliliğini ortaya koymaktadır. Bellekteki alanın artması bu verilerin başka bir ortama aktarılabilmesi için bant genişliğine olan ihtiyacı ve kapasiteyi artırır [1]. Bant genişliği, bir haberleşme kanalı üzerinde belirli bir aralıkta iletilen veri miktarını ve aynı zamanda haberleşme kanalındaki işaretin frekans uzayındaki spektrumunu temsil eder [2]. Genellikle bant genişliği, bit/saniye (bit per second, bps) birimiyle ölçülür. İnternet teknolojilerinde, bir kullanıcı yüksek kaliteli video seyrederken kesinti yaşamamak için daha hızlı bir internet altyapısına, dolayısıyla bant genişliğine ihtiyaç duymaktadır. Ancak kullanıcı, mesaj ya da e-posta gönderirken aynı hızda bant genişliğine ihtiyaç duymaz. Biyomedikal MRI görüntü taramaları yapılırken hastanın binlerce tomografisi çekilir ve böylece üç boyutlu görüntüler elde edilir. Bu görüntüler, ana sunucuya gönderilirken bellekte kapladığı alandan dolayı yüksek bant kapasitesine ihtiyaç duyulmaktadır. Veriler büyüdükçe iletim zorlu ve maliyetli bir hal almaya başlar. Bu nedenle, veri iletimi öncesi, gecikmeleri ve kayıpları önlemek için gönderilecek verilerin sıkıştırılarak optimize edilmesi gerekmektedir.

Bant genişliğinin verimli kullanımı için veri sıkıştırma teknikleri tercih edilmektedir. Kullanılacak yöntemin kalitesi, bant genişliğini doğrudan etkilemekte ve maliyeti düşürmektedir. Ancak sıkıştırma sırasında oluşan kayıplar göz önünde alındığında, yöntemin seçimi kritik bir öneme sahip olmaktadır. Veri sıkıştırma, verilerin tekrarlanan ve insan algısının fark edemeyeceği parçaları atarak, kodlama yöntemiyle farklı bir veriyle temsil edilmesi işlemidir. Veri sıkıştırma kayıplı ve kayıpsız olmak üzere ikiye ayrılmaktadır [3,4]. Kayıplı sıkıştırma tekniği, kullanıcının sıkıştırma oranını belirleyebileceği bir yöntemdir. Bu teknik, veri sıkıştırma sırasında insan algısının fark edemeyeceği detayları ortadan kaldırarak sıkıştırma işlemi yapmaktadır.

Ancak sıkıştırma arttıkça insan algısı tarafından fark edilebilir ve geri dönüşü olmayan kayıplar meydana gelebilmektedir. Bu nedenle kayıplı sıkıştırma yöntemleri resim, video, ses gibi verilerde sıklıkla tercih edilmektedir. Kayıpsız sıkıştırma yöntemlerinde ise kullanıcı tarafından ayarlanamayan bir sıkıştırma oranı sunar. Veri kaybını istenmeyen durumlarda tercih edilir. Örneğin metin verilerinde oluşabilecek kayıp, insan algısı tarafından kolayca fark edilebilir ve metnin anlamını bozabilir. Kayıplı ve kayıpsız bütün sıkıştırma tekniklerinde belirli bir oranda sıkıştırma elde edildiği için bant genişliği daha verimli kullanılmış olur.

Web sayfalarını hızlı bir şekilde yüklenmesi, kullanıcılar tarafından arzu edilen bir durumdur. Her sayfada çok sayıda görsel öge bulunduğundan, bu öğelerin yüklenmesi genellikle zaman alabilmektedir. Kullanıcıların internet sağlayıcılarından satın aldığı bant genişliği düşükse, bu durum daha da uzun sürmektedir. Web teknolojilerinde, kayıplı sıkıştırma tekniği olarak Birleşmiş Fotoğraf Uzmanları Grubu (Joint Photographic Experts Group, JPEG), kayıpsız sıkıştırma tekniği olarak da Taşınabilir Ağ Grafikleri (Portable Network Graphic, PNG) tercih edilmektedir. JPEG tekniği, kullanıcı tarafından belirlenebilen bir sıkıştırma oranı sunar ve yüksek derecede sıkıştırma sağlar. Ancak bu durum, görüntülerde kalıcı kayıplara neden olur. PNG ise tam tersi bir yaklaşıma sahiptir. Sıkıştırma oranı kullanıcı tarafından belirlenemez ve sıkıştırma performansı JPEG'e göre daha düşüktür. Sonuç olarak, internet teknolojilerinde kayıp yaşanması göze alınarak JPEG kayıplı sıkıştırma tekniği tercih edilir. Bu sayede görseller daha hızlı yüklenir ve bant genişliği daha verimli bir şekilde kullanılır.

Işık koşulları, donanım yetersizliği, kayıplı veri sıkıştırma, bant genişliğinin yetersizliği, gürültü gibi sebeplerden dolayı yüksek çözünürlüğe sahip görüntüler düşük çözünürlüklü hale gelebilmektedir. Süper çözünürlük problemi, kayıp yaşanan görüntüyü tekrar yüksek çözünürlüklü görüntü haline getirmeyi amaçlamaktadır. Tıbbi görüntüleme, uydu görüntülemesi, uzaktan algılama, nesne tanıma gibi birçok alanda süper çözünürlük problemiyle karşılaşılmaktadır.

Süper çözünürlük problemini inceleyen birçok çalışma, derin öğrenme yaklaşımlarını kullanmıştır. Kalite verileri üzerinde yapılan testler, istatistiksel yöntemlere kıyasla

daha başarılı sonuçlar elde edildiğini göstermektedir. Derin öğrenme, temelde yapay sinir ağları modelleri oluşturarak insan beyninin nöronlarının bağlanma şekillerini taklit eden bir makine öğrenmesi alt dalıdır. Süper çözünürlük ve derin öğrenme yaklaşımlarında, interpolasyon tabanlı düşük çözünürlüklü görüntüler kullanılarak, bu görüntülerdeki kayıpların giderilmesi amaçlanmıştır. Ancak, sıkıştırma kaybını inceleyen çok az sayıda çalışma bulunmaktadır. Bu nedenle, derin öğrenme tabanlı yaklaşımlar, sıkıştırma gibi farklı türdeki kayıpların geri kazanımı için araştırma konusu olmaktadır.

Süper çözünürlüklü görüntüyü elde etmek için temel olarak iki farklı yöntem bulunmaktadır. Tek görüntülü süper çözünürlük ve çoklu görüntülü süper çözünürlük.

Tek görüntülü süper çözünürlük yönteminde yüksek çözünürlüklü görüntü elde edebilmek için tek bir düşük çözünürlüklü görüntü kullanılan tekniktir.

Çoklu Görüntülü Süper Çözünürlük yönteminde ise aynı sahnenin birden fazla düşük kaliteli görüntüsü kullanılarak süper çözünürlüklü görüntü elde etmeyi amaçlamaktadır. Bu tekniğin kullanımı için görüntülerin aynı sahneyi kullanması ve hizalanma yapılması gerekmektedir.

## **1.1 Problemin Tanımı**

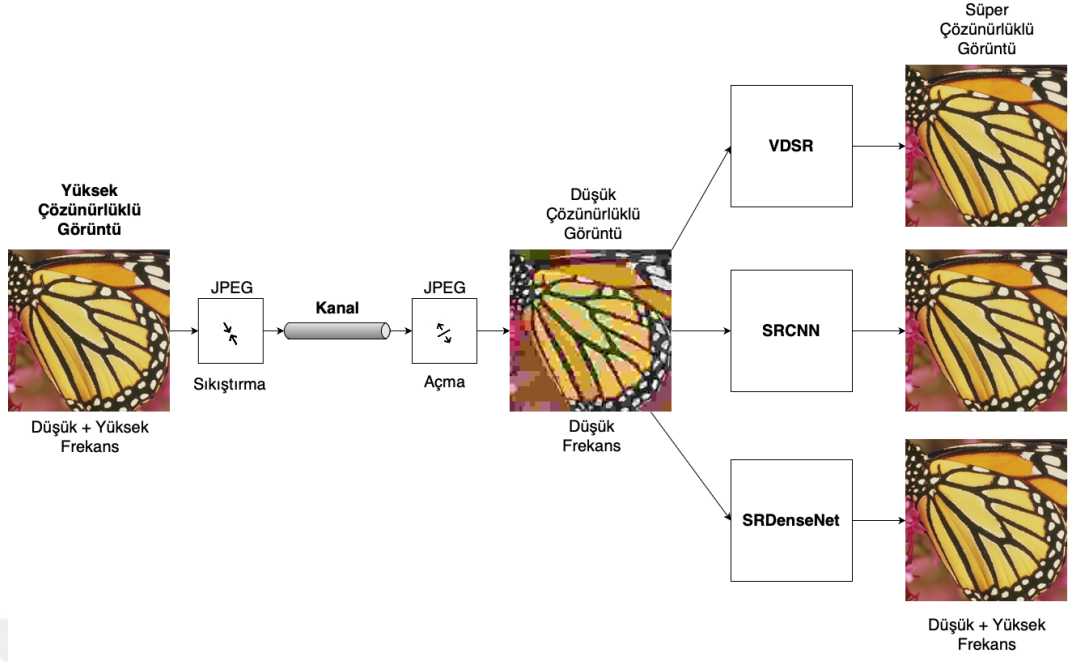
Yüksek kaliteli görüntü transferi talep edildiğinde, iletilen veri miktarının artması nedeniyle iletim hızının yavaşlamaması için bant genişliği artırılmalıdır. Yüksek veri iletim hızları sunan 5G ve 6G gibi teknolojilerin gelişmesine rağmen, yüksek bant genişliği kullanımı maliyeti büyük ölçüde arttırmaktadır [5,6]. Bu nedenle, kanalın etkili bir şekilde kullanılabilmesi için görüntülerin boyutunu azaltmak gereklidir. Bu amaçla birçok sıkıştırma yöntemi kullanılmaktadır. Kayıplı sıkıştırma algoritması olan JPEG, istenilen sıkıştırma düzeyini sunabilmektedir. Ancak sıkıştırma oranı arttıkça, görüntülerde kalıcı kayıplar meydana gelebilmektedir. Görüntü kalitesinde oluşan kayıplar nedeniyle istenilen sıkıştırma düzeyi seçilemez ve bant genişliği verimli kullanılamaz.

## 1.2 Tezin Amacı

Çalışma kapsamında, bant genişliğinin verimli kullanılması amacıyla kayıplı sıkıştırma algoritması olan JPEG'in kullanımı üzerine odaklanılmaktadır. Bu bağlamda, sıkıştırma öncesinde orijinal görüntü, düşük ve yüksek frekans bileşenleriyle yüksek çözünürlüklü görüntüyü oluşturmakta ve JPEG sıkıştırma algoritmasıyla görüntü, frekans uzayındaki kosinüs işaretleriyle temsil edilerek iletim hattından geçmektedir. Çalışmanın genel yapısı Şekil 1.1'de gösterilmiştir. Çalışmada, orijinal görüntü yerine sıkıştırılmış görüntü kanala iletilerek kanal bant genişliği verimli bir şekilde kullanılmaya çalışılmıştır.

Alıcı tarafta, kosinüs işaretleri zaman uzayına çevrilerek, yüksek frekans bileşenleri kaybedilmiş, yapaylıklar oluşmuş, düşük çözünürlüklü görüntü elde edilmiştir. Elde edilen bu düşük çözünürlüklü görüntü, eğitilmiş modeller kullanılarak, görüntülerde oluşan yapaylıkların giderilmesi ve yüksek frekans bileşenlerinin geri kazanılması amaçlanmaktadır.

Bu çerçevede, derin öğrenme yaklaşımlarından olan SRCNN, VDSR ve SRDenseNet modelleri, rastgele, normal dağılıma sahip parametreler verilerek JPEG görüntüleriyle eğitilecektir [7]–[9]. Sıkıştırma oranları değiştirilerek, modellerin yüksek frekans bileşenleri geri kazanılması ve yapaylıkların giderilmesi incelenmiştir. PSNR ve SSIM metrikleri ve sıkıştırma oranlarına dayanarak, modeller karşılaştırılmıştır. Bu çalışma, bant genişliği verimliliği bağlamında JPEG sıkıştırma algoritmasının iyileştirilmesine yönelik derin öğrenme temelli yöntemlerin etkinliği değerlendirilmiştir.



**Şekil 1.1 :** Çalışmanın genel yapısı.

### 1.3 Tez Planı

Bu tez toplamda 4 bölümden oluşmaktadır. Bölüm 1’de süper çözünürlük, veri sıkıştırma ve derin öğrenme kavramları ele alınmıştır. Bu bölümde, problemin tanımı ve tezin amacı açıklanmış, ayrıca literatürdeki ilgili çalışmalar incelenmiştir.

Bölüm 2’de derin öğrenme tabanlı süper çözünürlük modelleri detaylı bir şekilde ele alınmıştır. Farklı öğrenme tekniklerinin yanı sıra bu teknikleri uygulayan örnek modellerin ayrıntıları da incelenmiştir.

Bölüm 3’te JPEG sıkıştırma algoritmasının matematiksel temelleri ele alınmış ve adımları ayrıntılı bir şekilde açıklanmıştır.

Bölüm 4’te ise elde edilen sonuçlara odaklanılmıştır. Eğitim ve test süreçlerinde kullanılan veri kümeleri, metrikler ve kullanılan modellerin eğitim aşamasındaki deneyimler detaylı bir şekilde ele alınmıştır. Ayrıca, kullanılan parametreler ve modellerin performansları üzerinde yapılan tartışmalar sunulmuştur.

Bölüm 5'te tez kapsamında yapılamayan ve tezden doğan gelecekteki çalışmalardan ve literatüre olan katkılardan bahsedilmiştir.

#### 1.4 Literatür Özeti

Süper çözünürlük alanında yapılmış olan çalışmaların büyük bir çoğunluğunda, interpolasyon teknikleri ile elde edilmiş düşük çözünürlüğe sahip görüntüler incelenmiştir. İnterpolasyon yöntemi, görüntü boyutunu arttırma ve azaltma işleminde pikseller arası pürüzsüz ve yumuşak bir geçiş sağlamak için kullanılan bir tekniktir [10]. Örneğin kübik interpolasyon yönteminde bir pikseli hesaplarken, komşu 4 piksel değerlerini bir polinomsal ifade ile hesaplayarak elde eder. Bu işlem sırasında görüntülerde kayıplar meydana gelmektedir. Literatürdeki çalışmaların büyük bir çoğunluğu sentetik olarak kayıp oluşturmak için bu tekniği kullanır ve bu kaybı geri kazanmayı hedefler.

Gürültü giderme, bulanıklaştırma ve ton eşleme gibi teknikler kullanılarak 2016 yılında bir çalışma yapılmıştır [11]. Bu çalışmada, JPEG görüntülerinin yukarı ölçeklenmesi ve sıkıştırma sırasında oluşan gürültüyü azaltmak için Gürültü Tabanlı Telafi (Noise Base Compensation , NBC) adlı bir teknik kullanılmıştır. Çalışmada, düşük çözünürlüklü görüntü, JPEG ile sıkıştırılmış ve geri açılmıştır. Bu aşamada oluşan kayıplardan dolayı, görüntüler üzerinde yapaylıklar meydana gelmiştir. Gürültülü görüntüdeki pikseller ton haritalamasına işlemine tabi tutulur. Gözlemlenen piksel değerleri alt kümelerine ayrılır ve her bir alt kümenin sapması, optimize edilmiş bir telafi değeri ile düzeltilir. Görüntüler, NBC tekniğiyle büyütülür. Önerilen yöntemle elde edilen iyileştirme, PSNR ve SSIM değerlendirme ölçütleriyle doğrulanmıştır. Bu yöntemde herhangi bir derin öğrenme yaklaşımı kullanılmamış ve performans bakımından derin öğrenme tekniklerine kıyasla geride kalmıştır.

Evrişimli sinir ağlarının gelişimi GPU işlemcili makinelerin gelişimiyle hız kazanmıştır. Süper çözünürlük probleminin yanı sıra, nesne takibi, segmentasyon, sınıflandırma alanlarında kendini ispatlamıştır [7]. Sıkıştırılmış görüntülerde oluşan kayıpların kazanılması adına derin evrişimli sinir ağlarının kullanımının araştırıldığı Derin Evrişimli Sinir Ağı Kullanarak Sıkıştırılmış Süper Çözünürlük

(Super-Resolution of Compressed Images Using Deep Convolutional Neural Networks, CISRDCNN) isimli çalışma 2017 yılında yayınlanmıştır [12]. Bu çalışmada, üç farklı sinir ağı modeli bulunmaktadır. Sıkıştırılmış görüntülerdeki blokajları kaldırmak için DBCNN adlı modele girdi sağlanmış ve çıktı olarak blokajları giderilmiş görüntüler elde edilmiştir. Blokaj giderme işlemi, görüntülerde sıkıştırma nedeniyle oluşan yapaylıkları azaltmayı amaçlamaktadır. Bu işlem sonucunda elde edilen görüntüler, bir sonraki model olan USCNN'e girdi olarak verilerek yukarı ölçeklendirilmiş görüntüler üretilmiştir. Görüntülerin yukarı ölçeklendirilmesi nedeniyle interpolasyon yöntemine ihtiyaç duyulmamıştır. Ardından, elde edilen görüntüler QECNN modeline girdi olarak verilerek, görüntü kalitesinin artırılması işlemi gerçekleştirilmiştir. Bu çalışmada kullanılan üç model, ayrı ayrı eğitilmiştir. Daha sonra bu üç model birleştirilerek ince ayarlama işlemiyle birlikte eğitilmiştir. Modelin sonuçları, kalite değerleri 10, 20 ve 30 için test edilmiş ve sonuçlar incelenmiştir.

JPEG2000 yöntemi kullanılarak düşük bit hızıyla sıkıştırılmış verilerde istenmeyen yapaylıkları azaltmak için yumuşak kod (soft decoding) çözme tekniği kullanılan bir çalışma yayınlanmıştır [13]. JPEG2000, JPEG tekniğinin gelişmiş bir versiyonu olarak kabul edilmektedir. JPEG'de kullanılan kosinüs dönüşümü yerine dalgacık dönüşümü kullanılmaktadır [14]. 2017 yılında yayınlanan bu çalışmada, farklı bit hızları için ayrı ayrı modeller oluşturulmuştur. Her bir görüntü, en yakın bit hızına sahip modele eğitim verisi olarak sunulmuş ve toplamda 10 farklı model oluşturulmuştur. Evrişimli sinir ağı tabanlı modellerde, 3x3 filtre boyutu kullanılarak her katmanda 64 filtre oluşturulmuştur. Modelin derinliği, 25 olarak belirlenmiş ve her katmanda toplu normalleştirme uygulanmıştır. Test aşamasında farklı bit hızlarına sahip görüntüler kullanılmış ve model seçimlerinde bit hızları temel alınmıştır. Bu sayede her bir görüntünün sıkıştırıldığı bit hızına en yakın modeli tercih ederek yüksek çözünürlüklü hale gelmeye çalışmıştır. Değerlendirme kriteri olarak PSNR ve SSIM metrikleri tercih edilmiş ve çalışmanın sonucu olarak ortalama 2.3 dB bir kazanç sağlandığı belirtilmiştir [15]. Ayrıca, düşük ve yüksek çözünürlüklü görüntülerin aynı PSNR değerine sahip olduğu yani iyileşme sağlanamadığı durumda % 20 bit hızında avantaj sağlandığı belirlenmiştir. 2020 yılında yayınlanan bir başka çalışmada,

JPEG2000 algoritmasıyla, çok zamanlı ve çok spektral görüntülerin sıkıştırılması ve sıkıştırma sırasında kaybedilen bileşenlerin geri kazanımı üzerine durulmuştur [16]. Uydu üzerinden alınmış görüntülerin, farklı bit/piksel oranları kullanılarak farklı sıkıştırma hızlarında, VDSR tekniğinin kayıpları geri kazanımı incelenmiştir. JPEG2000 sıkıştırma için Kakadu kodlayıcı ve VDSR modeli oluşturma için PyTorch kütüphanesinden yararlanılmıştır. Çalışmada 0.2, 0.4 ve 0.6 bit/piksel değerleriyle sıkıştırılmış görüntüler için ayrı ayrı modeller eğitilmiştir. Tüm sonuçlarda 1 dB dolaylarında bir iyileşme kaydedildiği belirtilmiştir. JPEG2000 ile sıkıştırılmış çoklu spektral görüntülerin derin öğrenme tabanlı süper çözünürlük modellerinden olan SRResNet, EDSR ve WDSR ile kayıpların giderilmesi incelendiği bir başka çalışma 2021 yılında yayınlanmıştır [17]. Çalışmada eğitim veri seti için 1.6, 3.2, 4.8 ve 6.4 bit/piksel sıkıştırma hızları kullanılmıştır. Bu şekilde toplam 672 görüntü kullanılmıştır. Sonuçlar karşılaştırıldığında EDSR modeli bütün sıkıştırma oranlarında en iyi sonucu vermiş ve ortalama 1 dB değerinde bir kazanç sağlanmıştır.

JPEG sıkıştırma tekniğinin işlem yükü azaltmak ve performansını iyileştirmek için Birleşmiş Fotoğraf Uzmanları Grubu tarafından JPEG Geliştirilmiş Aralık (Joint Photographic Experts Group Extended Range, JPEG XR) yöntemi ortaya atılmıştır [18]. Bu yöntem her piksel değeri için 8 bitten daha fazla saklama imkanı sunmaktadır. Genişletilmiş aralık (Extended Range, XR) tanımı, değişken bit esnekliğinden gelmektedir. JPEG XR, JPEG'e kıyasla daha yüksek çözünürlüklü görüntülerin sıkıştırılması için tercih edilmektedir [19]. Ancak bu yöntem de kayıplı sıkıştırma algoritması olarak sınıflandırılmakta ve görüntülerde sıkıştırma oranlarına göre bir miktar kayıp oluşmaktadır. 2022 yılında yapılan bir çalışmada, JPEG XR sıkıştırma yönteminin SRCNN ve FSRCNN modelleri üzerindeki etkisi incelenmiştir [20]. FSRCNN modeli, eğitim ve test aşamalarında SRCNN modeline göre daha hızlı sonuçlar elde etmektedir. Bu nedenle, bu çalışmada bu iki modelin performansları karşılaştırılmıştır. Çalışmada, daha büyük bir sıkıştırma oranı elde edilen JPEG XR yöntemi üzerinde durulmuştur. SRCNN ve FSRCNN modelleri kullanılarak eğitim veri kümesi oluşturulmuş ve kübik interpolasyon yöntemiyle aşağı örnekleme yapılan (2X, 3X, 4X) ve JPEG XR algoritmasıyla sıkıştırılmış verilerden elde edilmiştir. FSRCNN modelinde ayrıca yukarı ölçekleme katmanları da bulunmaktadır. Bu

sayede görüntünün boyutu, süper çözünürlük modelleri sayesinde orijinal genişliğine dönmektedir. PSNR ve SSIM ölçütlerine göre, FSRCNN ve SRCNN yöntemlerinin başarılı sonuçlar elde ettiğini gösterilmektedir.

Sıkıştırma sonucunda görüntülerde bulanıklaşma ve yapaylıklar oluşabilmektedir. JPEG yönteminde kullanılan kosinüs dönüşümü ve nicemleme matrisi yüzünden kullanılan matris boyutlarında yapaylıklar meydana gelmektedir. Evrişimli sinir ağı tabanlı DPW-SDNET yöntemi tam olarak bu yapaylıkları ortadan kaldırmak üzere 2018 yılında önerilmiştir [21]. Bu yöntemde, iki farklı evrişimli sinir ağı modelinden oluşmaktadır. Birinci model (W-SDNET), dalgacık dönüşümüyle oluşturulan görüntülerle eğitilirken, ikinci model (P-SDNET) ise alt örnekleme ile indirgenmiş ve sıkıştırılmış görüntülerle eğitilmektedir. W-SDNET modeline giriş görüntüsü, 1. seviye 2 boyutlu ayrık dalgacık dönüşümüyle elde edilen görüntünün 4 alt dalgacık bant katsayısından oluşmaktadır. Elde edilen 2 boyutlu ve 4 kanallı görüntü, modele giriş olarak verilmektedir. P-SDNET modelinde ise sıkıştırılmış görüntü aşağı ölçeklendirilerek 4 farklı alt görüntü oluşturulmakta ve modelin giriş görüntüsü 2 boyutlu ve 4 kanallı olmaktadır. Evrişimli sinir ağlarının çıktıları birleştirilerek süper çözünürlüklü görüntü oluşturulmaktadır. Çalışmada ARCNN, TNRD ve DnCNN-3 modelleri kullanılmış ve sonuçlar karşılaştırılmıştır. Elde edilen sonuçlara göre, önerilen yöntem en yüksek başarı oranını sunmaktadır. Sonuçlar, kalite değerleri 10, 20, 30 ve 40 için test edilmiştir. 2020 yılında, JPEG sıkıştırma sırasında oluşan yapaylıkları azaltmayı hedefleyen bir başka çalışma yayınlanmıştır. Gelişmiş Derin Süper Çözünürlük (Enhanced Deep Super Resolution, EDSR) modelinin kullanıldığı bu çalışmada, modele 2 farklı görüntü verilmektedir [22]. Birinci görüntü, JPEG ile sıkıştırılmış ve yüksek frekans bileşenleri atılmış görüntüyü temsil etmektedir. İkinci görüntü ise kübik interpolasyon yöntemiyle düşük çözünürlük elde edilmiş görüntüdür. İkinci görüntünün frekans uzayında yüksek frekans bileşenleri hala korunmuş ve sadece uzamsal uzayda çözünürlük kaybı yaşanmıştır. Bu çalışmada farklı bir kayıp fonksiyonu kullanılmış ve bu fonksiyon sayesinde modelin performansı arttırılmıştır. Ayrıca, önerilen yöntem, 3 farklı sıkıştırma oranı (Kalite Faktörü: 50, 70, 80) ile denemeler yapılmıştır.

İnterpolasyon tabanlı sentetik kayıplar üzerine oluşturulan modellerin farklı sıkıştırma kayıplarına verdiği tepkiler araştırma konusu olmaktadır. JPEG yöntemi kullanılarak sıkıştırılan görüntü kayıplarının geri kazanımı için SRCNN, VDSR ve DnCNN modelleri üzerinde 2019 yılında bir çalışma yapılmıştır [23]. Bu çalışmada, görüntüler öncelikle uzamsal ve frekans uzayında aşağı ölçeklenmiş ve daha sonra frekans uzayında aşağı ölçeklenmiş görüntüler uzamsal uzaya dönüştürülerek mevcut uzamsal görüntü ile birleştirilmiştir. Ardından, görüntü JPEG sıkıştırma algoritması kullanılarak kodlanmıştır. Alıcı tarafında, kodlanmış görüntü kayıplı bir şekilde tekrar elde edilmiştir, bu işlem için yine JPEG algoritması kullanılmıştır. Düşük çözünürlüklü elde edilen görüntüler ARCNN, DuCNN ve SCN modellerine ön işleme uygulanarak modellere girdi olarak verilmiştir. Bu çalışmada, sıkıştırma oranı sabit olarak kabul edilmiş ve bu değer hakkında bilgi verilmemiştir. Bu nedenle, eğitilmiş modellerin farklı sıkıştırma oranlarında performansları incelenmemiştir.

JPEG algoritmasına alternatif olan diğer teknikler üzerinde oluşan sıkıştırma kaybının geri kazanımını inceleyen çalışmalar bulunmaktadır. Daha İyi Taşınabilir Grafikler (Better Portable Graphics, BPG) tekniği, JPEG algoritmasından daha başarılı sıkıştırma oranı sunmakta ve elde edilen görüntüler JPEG'e kıyasla daha kaliteli olmaktadır [24]. BPG sıkıştırma algoritmasındaki kayıpları azaltmak için SRGAN modeli kullanılarak bir çalışma yayınlanmıştır [25]. Eğitim için Mirflickr25k veri kümesinden yaklaşık 20 bin görüntü seçilmiş ve görüntüler 2x kübik interpolasyon yöntemiyle düşük çözünürlüğe indirgenmiştir. Sonrasında indirgenmiş görüntüler BPG yöntemiyle sıkıştırılmıştır. Sıkıştırma işlemi için 25 ve 35 gibi kalite değerleri kullanılmıştır. SRGAN modelinde yukarı ölçekleme işlemi gerekliliğinden dolayı üretici sinir ağının girişinde bulunan 2 yukarı ölçekleme katmanı kaldırılmıştır. Bu duruma istinaden, son katman ve 16 artık katman çıkarılmıştır. BPG sıkıştırmasında kullanılan dönüşüm bloklarının boyutlarına karşılık gelen kırılmış yamaların boyutu da 64x64 olarak değiştirilmiştir. Aynı çalışmada ESRGAN modeli de eğitilmiş ve sonuçlar incelenmiştir.

## 2. DERİN ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK

İletim hattındaki gürültü seviyesi, donanımın yetersizliği, sıkıştırma sırasında oluşan kayıp gibi çeşitli sebeplerden dolayı yüksek çözünürlüklü bir görüntü düşük çözünürlüklü hale gelebilmektedir. Bu görüntülerin çeşitli yöntemler ile iyileştirilip eski haline getirilmesi problemine süper çözünürlük denir [26]. Bu teknik, görüntü üzerinde çeşitli sebeplerden dolayı kaybedilen ayrıntıları geri kazanarak daha yüksek ve kaliteli görüntüler elde etmeyi amaçlar. Günümüzde, uydu görüntüleri, dijital fotoğraf makineleri, tıbbi görüntüleme gibi birçok alanda yüksek çözünürlüklü görüntüler elde etmek için kullanılmaktadır.

Süper çözünürlük yöntemleri tekli ve çoklu görüntülü olmak üzere ikiye ayrılmaktadır. Tek görüntü süper çözünürlük, yüksek çözünürlüklü görüntüyü elde etmek için tek bir düşük görüntü kullanmaktadır ve kullanılan modelin tek bir giriş görüntüsü olmaktadır. Çoklu görüntü süper çözünürlük yönteminde ise birden fazla düşük çözünürlüklü giriş görüntüsü kullanılmaktadır. Bu görüntüler aynı sahnenin farklı açılardan çekilmesi, aynı görüntünün farklı renk kanallarındaki temsilleri olabilir [27]. Bu yöntemde, düşük çözünürlüklü çoklu görüntüler birleştirilip yüksek çözünürlüklü tek bir görüntü elde edilmektedir.

Bilgisayar işlemcilerinin gelişimiyle birlikte derin öğrenme yaklaşımlarıyla ilgili birçok çalışma yayınlanmıştır. Özellikle nesne takibi, görüntü sınıflandırma, yapay görüntü üretme gibi alanlarda başarılı sonuçlar elde edilmiştir. Derin öğrenme kavramı, makine öğrenmesinin bir uzantısı olan yapay sinir ağlarına dayalı geliştirilmiş bir kavramdır. Yapay sinir ağları, içerisinde barındırdığı nöronlar ve bu nöronların birbirlerine bağlanma şekliyle insan beyninin bir taklidi olarak karşımıza çıkmaktadır. Bu yapının temel amacı, eğitilmek istenen verinin altında yatan özelliklerin bir temsilini ortaya çıkarmak ve belirli bölgelere odaklanarak anlam çıkarmaya dayanmaktadır. Bilgisayarlarda kullanılan GPU işlemcilerin sayesinde bu karmaşık yapılar daha hızlı bir şekilde eğitilmekte ve araştırma konusu olmaktadır.

Derin öğrenmedeki gelişmeler, süper çözümlülük probleminin de çözümünü sağlamış ve bu alanda birçok çalışma yapılmasının önünü açmıştır. Yapılan çalışmalarda çok farklı öğrenme paradigmaları ortaya atılmış ve her biri farklı bir yöntemle süper çözümlülük problemini çözmeye odaklanmıştır.


## 2.1 Yinelemeli Öğrenme

Yapay sinir ağının derinliğini ya da bir derinlikte bulunan nöron/filtre sayısını arttırmak, öğrenilebilir parametre sayısını arttıracığı için modelin de performansını arttırabilir. Ancak bir noktadan sonra fazla olan parametrelerden dolayı, eğitim aşamasında istenilen performans elde edilemeyebilir. Bu durumda model performansı doyumu ulaşır ya da daha kötü sonuçlar elde edilebilir [28,29].

Ağın büyümesi, parametre sayısını arttıracığından dolayı, öğrenme ve test aşamalarında hesaplama yükünü arttırır. Bu durumda, ağırlıklı olarak ağın genişlemesi yerine yinelemeli yapıları kullanmak, parametre sayısının fazlalığının önüne geçebilmektedir. Yinelemeli öğrenme, bir parametreyi birden çok kez kullanarak, işlem yükünü azaltmayı hedeflemektedir. Sinir ağlarında ise, bir nöron ya da filtrenin birden fazla kullanılması anlamına gelir. Bu yöntemde, filtrelerden oluşan bir katman bulunmakta ve bu katmanın çıktısı, geri besleme olarak aynı katmana girdi olarak verilmektedir. Bu sayede, yeni bir katman oluşturmak yerinde, aynı katman birden çok kez kullanılır ve sinir ağının parametre sayısı korunmuş olunur. Bu durumda, bilgi işleme yeteneği artar. Bu yaklaşım, daha az parametre kullanarak daha karmaşık işlevleri öğrenmeyi hedefler. Ağın büyümesi, tekrarlayan yapılar gibi farklı yöntemler, modelin performansını iyileştirmek için kullanılabilir.


### 2.1.1 Derin yinelemeli evrişimli ağ (DRCN)

Yinelemeli öğrenme paradigmasıyla Derin Yinelemeli Evrişimli Ağ (Deeply-Recursive Convolutional Network, DRCN) modeli 2016 yılında yayınlanmıştır [30]. Modelin mimarisi Şekil 2.1’de verilmiştir. Model, üç sinir ağının birleşiminden meydana gelmektedir.



Şekil 2.1 : DRCN modelinin mimarisi.


Gömülü (embedding) adı verilen birinci ağ, giriş görüntüleri olarak interpolasyon ve özellik çıkarım işlemlerini yerine getirmektedir. Gömülü ağdan çıkan görüntüler, girişim (interference) ağını besler ve özellik çıkarım işlemi burada da devam eder. Bu ağda yineleme işlemi toplam 16 katmanda temsil edilmektedir. Bu katmanların temsili Şekil 2.2’de verilmiştir. Her bir katman benzer evrişimsel ağ işlemlerine ve Doğrultucu Birim (Rectified Linear Unit, ReLU) sahiptir. Bu katmanlardaki öz-yineleme sayısı keyfi olarak verilebilir. Yineleme katmanlarının her biri ( $H_1, H_2, \dots, H_D$ ) birbirine bağlanarak, aynı öğrenilebilir parametre katsayılarını paylaşmaktadır. Yeniden yapılandırma (reconstruction) ağı, çok kanallı girişim ağının çıktılarını alarak orijinal görüntünün boyutunu ve kanal sayısını geri elde eder.



Şekil 2.2 : Inference yineleme modelinin mimarisi.

Ayrıca bu modelde kaybolan gradyen problemini aşarak modelin performansını arttırmak için atlamalı bağlantı eklenmiştir. Bu sayede giriş görüntüsü yeniden yapılandırma katmanının da giriş görüntüsü olmaktadır.

DRCN modeline, performansı artırmak ve kaybolan gradyen problemini önlemek için atlamalı katman eklenerek geliştirilmiştir. Inference aşında, filtreler tüm katmanlarda ortak olarak kullanılmış ve her bir katmanın çıktısı bir sonraki katmana giriş olarak verilmiştir. Ayrıca, bu çıktılar reconstruct ağına da girdi olarak verilmiştir. Şekil 2.3’de gösterildiği gibi, her bir filtre ortak bir şekilde kullanılmış ve böylece öğrenilecek parametre sayısı azaltılmıştır.



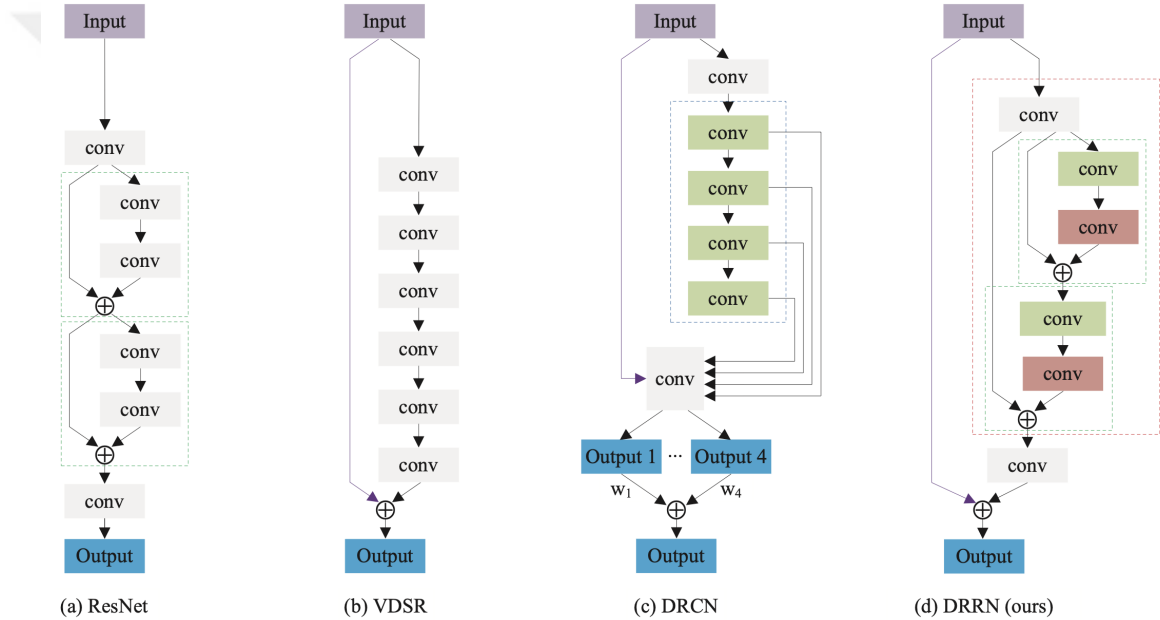
Şekil 2.3 : Atlamalı katman - DRCN modelinin mimarisi.

### 2.1.2 Çok derin yinelemeli artık ağ (DRRN)

Yinelemeli ve artık öğrenme paradigmasını destekleyen Çok Derin Yinelemeli Artık Ağ (Deep Recursive Residual Network, DRRN) evrimsel katmanlar barındırır [31]. DRCN modelinde 16 iken DRNN modelinde 52 katman bulunmakta ve derin ağ yapısı elde edilmektedir. DRCN ile DRRN arasında iki temel farklılık bulunmaktadır. DRCN’de, paylaşımlı ağırlık katsayıları evrimsel katmanlar arasında kullanılmaktadır, yani 16 katmanda da aynı katsayılar mevcuttur. DRRN modelinde ise yineleme birimleri bulunmakta ve katsayılar her bir birim için ortaktır. Yani bir başka yineleme birimi, diğer yineleme birimine ait ağırlık katsayısını kullanmaz. Diğer bir farklılık ise kaybolan gradyen problemidir. Her bir yineleme birimi bir öncekine bağlantısı bulunmakta ve geri-yayımlı işlemlerinde kaybolan gradyen probleminin önüne geçilmektedir.

DRRN modelinde katman sayısı artırılarak daha derin bir model ve daha başarılı sonuçlar elde edilmiştir. Ancak, ağırlık katsayılarında herhangi bir artış oluşmamıştır. Bu durum eğitim ve test sürelerini etkilememiştir.

Şekil 2.4’de modellerin mimarileri verilmiştir. ResNet modelinde bulunan yeşil kesik çizgili kutu "artık birim" olarak adlandırılmaktadır. DRCN modelinde bulunan mavi kesikli çizgi "yineleme modülünü" temsil etmektedir. DRRN modelinde yeşil kesikli çizgiler "yineleme bloklarını", kırmızı ise "küresel kimlik eşlemeyi" temsil etmektedir. Her bir küresel eşleme bloğunda 2 adet yineleme blokları bulunmaktadır. Kutular içerisindeki katmanlar ağırlık katsayılarını paylaşmaktadır.



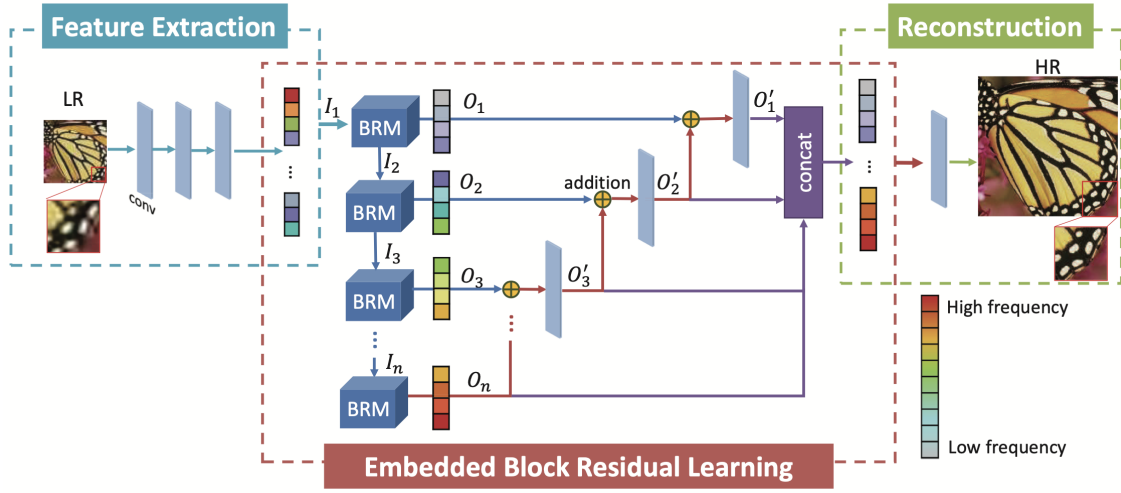
Şekil 2.4 : DRRN modelinin karşılaştırılması.

### 2.1.3 Gömülü blok artık ağ (EBRN)

Artık ve yinelemeli öğrenme paradigmasını destekleyen bir başka çalışma olarak Gömülü Blok Artık Ağ (Embedded Block Residual Network, EBRN) modeli ortaya atılmıştır [32].

Görüntülerdeki düşük ve yüksek frekans bilgileri farklı desenlere sahip olunmasından ilham alınarak, görüntü kalitesini artırmak için BRM adı verilen gömülü kalıntı

blokları oluşturulmuştur. BRM blokları, artık öğrenme tekniğini kullanmaktadır. Şekil 2.5’de EBRN modelinin mimarisi verilmiştir. Her bir BRM çıktısı bir önceki BRM çıktısıyla toplanıp mavi renkli bir bloğa gönderilmiştir. Görüntü üzerinde evrişimli sinir ağları kullanılarak özellik çıkarım işlemi yapılmakta ve elde edilen bu özellikler EBRN modülünü beslemektedir. EBRN içerisinde bulunan BRM blokları, evrişim işlemine sahip filtreleri temsil etmekte ve yinelemeli öğrenme tekniğini kullanmaktadır. Bu şekilde, daha az model parametresi kullanılmakta ve eğitim sırasında oluşan matematiksel işlem yükü azaltılmaktadır.



Şekil 2.5 : EBRN modelinin mimarisi.

## 2.2 Artık Öğrenme

Yapay sinir ağlarında sigmoid ve relu gibi aktivasyonlarının kullanılması, bu modellerdeki katman sayısının artışıyla kaybolan gradyen problemini doğurmaktadır. Aslında relu fonksiyonu relu problemi adında kendine özel bir kaybolan gradyen problemine sahiptir. Bir çok çalışma ve sunulan metotlar bu problemi çözmek için çözümler üretse de tam olarak istenilen sonuçlar elde edilememiştir [28]. Bu çözümlerden en etkili sayılabilecek ResNet modeli, katmanlar arası atlamalı bağlantılar kullanarak modellerin katman sayısını yüzler mertebesine çıkarabilmiştir [33]. Stokastik rastgele katman atma yöntemi, modeller üzerinde iyileşmeler sağlamış ve çok derin ağlarda gereksiz katmanların olduğunu kanıtlamıştır. FractalNets modeli ise farklı genişlik ve derinliklere sahip paralel modeller oluşturarak bu modeller arasına kısa bağlantılar eklemiştir [34]. DenseNet modeli ise paralel modellerin katmanlarını ağın diğer modellerinin katmanlarıyla birleştirerek atlamalı bağlantıların avantajlarını araştırmıştır [35]. Ayrıca, giriş görüntüsünden yeniden yapılandırma katmanına kadar uzanan uzun atlamalı bağlantı modelleri de mevcuttur. Ancak tek bir atlamalı bağlantı kullanımı, atlamalı bağlantıların avantajlarından tam olarak yararlanmayı engellemektedir. DRCN modelinde atlamalı bağlantı kullanımı zayıf kalmış ve düşük çözünürlüklü görüntülerin performansı istenen düzeye getirilememiştir [30]. En uygun yaklaşım, açıklanabilir düzeyde atlamalı bağlantıların kullanılması olmuştur.

### 2.2.1 Çok derin süper çözünürlük (VDSR)

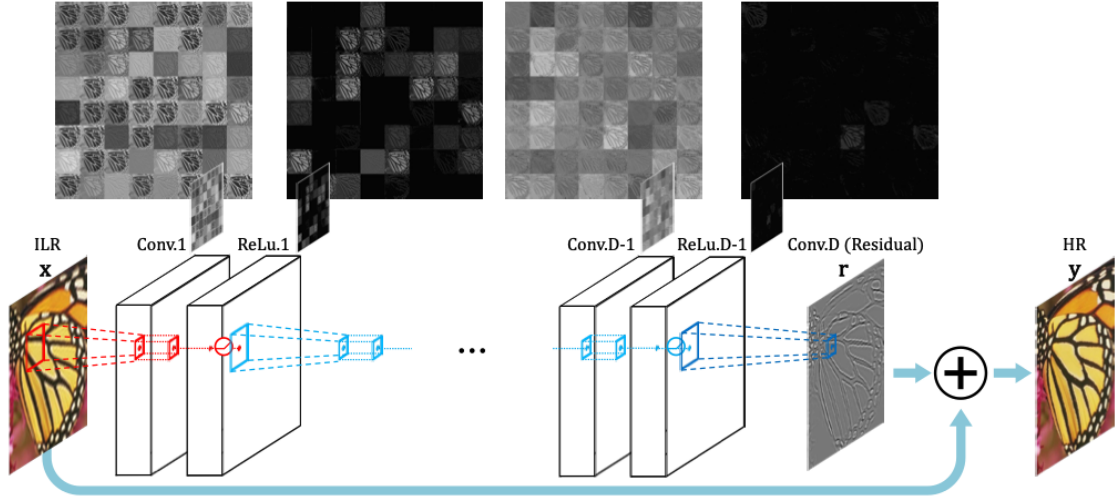
Derin öğrenme teknikleri kullanılarak tek görüntü süper çözünürlük modellerinde başarılı sonuçlar elde edilmiştir. Bu alanda ortaya atılmış ilk çalışma olarak kabul edilen SRCNN isimli model, görüntülerdeki yerel bölgelere odaklanmış, ancak görüntüler üzerindeki evrensel özellikleri gözden kaçırmıştır [7]. Ayrıca eğitim aşamasında kullanılan dönem (epoch) değerinin yüksek olmasından dolayı model çok fazla eğitim tekrarı (iteration) sonucunda hedefe kısmen ulaşabilmiştir. Bir diğer etken ise modelin ölçek bağımlısı olmasıdır. Tek bir ölçek ile küçültülmüş görüntülerle eğitilen model, sadece aynı ölçek ile tahmin için çalışabilmektedir. Sonrasında gelen

çalıřmalarda modellerin derinliđini arttırma yoluna gidilmiř ve bařarı oranı bir noktaya kadar getirilmiřtir.

VDSR modeli, derin ađ yapısı sayesinde grnt zerinde gzden kaan yerel ve evrensel zellikleri daha iyi bir řekilde yakalayabilmekte ve daha bařarılı sonular elde edebilmektedir [8]. Ayrıca yksek seviyede grnt leklemeye izin vermekte, bu sayede ok dřk znrlkl grntler zerinde de bařarılı sonular elde etmektedir.

Yakınsama aısından, VDSR modeli atlamalı bađlantı kullanımından dolayı daha iyi sonular vermektedir. ok sayıda katmandan oluřmasına ve parametre sayısı SRCNN'e gre 10.000 kat daha fazla olmasına rađmen, eđitim sreleri daha kısa surmektedir.

VDSR modeli, oklu lekli grntlerle eđitildiđinde bařarılı sonular vermektedir. Grnt lekleme iřlemi kullanıcı tarafından tanımlandıđından, her lek iin ayrı bir model eđitilmesine ihtiya duyulmamaktadır. Modelin mimarisi řekil 2.6'te verilmiřtir. Giriř ve ıkıř katmanları dıřında 20 evriřimsel ve ReLU katmanı kullanılmaktadır. Her bir filtre uzunluđu 3x3 olmak zere 20 katman boyunca 64 filtre bulunur. İlk katmanda grnt alınır ve herhangi bir iřlem uygulanmaz. Son katman ise geri kazanım (reconstruction) katmanı olarak kullanılır ve 3x3x64 boyutuna sahip tek bir filtre bulunur. Giriř grnts olarak dřk znrlkl grnt artık blok sayesinde ıktıya verilmektedir. ıkıřta bu grnt ile geri kazanım katmanının ıktısı birleřtirilmekte ve yksek znrlkl grnt elde edilmektedir.



Şekil 2.6 : VDSR modelinin mimarisi.

### 2.2.2 Geliştirilmiş ve çok-ölçekli derin süper çözünürlük (EDSR ve MDSR)

Artık öğrenme paradigmasına dayalı olarak yapılan çalışmada iki farklı yöntem önerilmiştir [36]. Tek bir ölçek üzerinde çalışan Geliştirilmiş Derin Artık Ağ (Enhanced Deep Residual Network, EDSR) ve çok ölçekli Çok-Ölçekli Derin Süper Çözünürlük (Multi-Scale Deep Super Resolution, MDSR).


EDSR ve MDSR, ResNet'e kıyasla farklı olarak yığın (batch) normalleştirme işlemini kaldırmıştır. Yığın normalleştirme işlemi, evrişimli sinir ağı modelinin hafıza kullanımını artırması nedeniyle kaldırılmış ve bu değişiklik bellek kullanımında %40'a varan bir kazanç sağlamıştır.

Modelin performansını artırmanın en basit yolu, öğrenilebilir parametre sayısını artırmaktır [37]. Ancak, özellik sayısını artırmak öğrenmeyi yavaşlatmaktadır. Bu sorunu çözmek için, Şekil 2.7'de verilen mimaride bulunan artık blokların içinde artık ölçekleme (residual scaling) işlemi yapılmaktadır.

EDSR modeli 2x ölçeklenmiş görüntüler ile eğitildiğinde, model parametreleri rastgele olarak başlatılmıştır. 3x ve 4x ölçek ile eğitildiğinde, daha önce 2x ölçek ile eğitilmiş parametreler yüklenmiş ve eğitim bu parametrelerin ilk değerleriyle başlamıştır. 4x ölçek ile eğitildiğinde ise, 2x ölçek model parametreleri başlangıç değeri olarak

alınmıştır. Bu şekilde transfer öğrenme yöntemi kullanılarak modellerin performansı artırılmıştır. Transfer öğrenme yöntemi, bir modelin ilk değerlerini, farklı bir modelin ara ya da son değerleriyle başlatılması işlemidir [38].


EDSR modeli Şekil 2.7’de verilmiştir. Model içerisinde ResBlock adı verilen artık bloklar bulunmaktadır. Bu blokların içerisinde evrişimli işlemlerin yanı sıra artık bloklar bulunmaktadır. Aynı zamanda ResBlock modülleri arasında da artık öğrenme tekniği kullanılmıştır.



Şekil 2.7 : EDSR modelinin mimarisi.

MDSR modeli, Şekil 2.8’de gösterilen bir yapıya sahiptir. Model, ölçekleme modüllerini içerir ve farklı ölçeklerde başarılı olabilmeye yeteneği kazandırılmıştır. MDSR modelinin EDSR modelinden tek farkı, modelin giriş ve çıkışında ölçeklendirme katmanlarının bulunmasıdır. Ön işlem modülleri, model ağının girişine yerleştirilmiştir ve farklı ölçekler için katmanlar içermektedir. Her bir ön işlem modülü, 2 adet artık blok içeren 5x5 boyutunda olup, farklı ölçeklerdeki verileri işlemek için tasarlanmıştır. MDSR modeli, EDSR modelinde olduğu gibi tek bir ölçek ile eğitildiğinde daha başarılı sonuçlar elde etmektedir. Bu nedenle, performans

açısından bakıldığında tek bir ölçekte EDSR modeli daha başarılıdır. Ancak farklı ölçekler için çalışıldığında, EDSR modelinin performansı düşmektedir.



Şekil 2.8 : Çok ölçekli EDSR(MDSR) modelinin mimarisi.

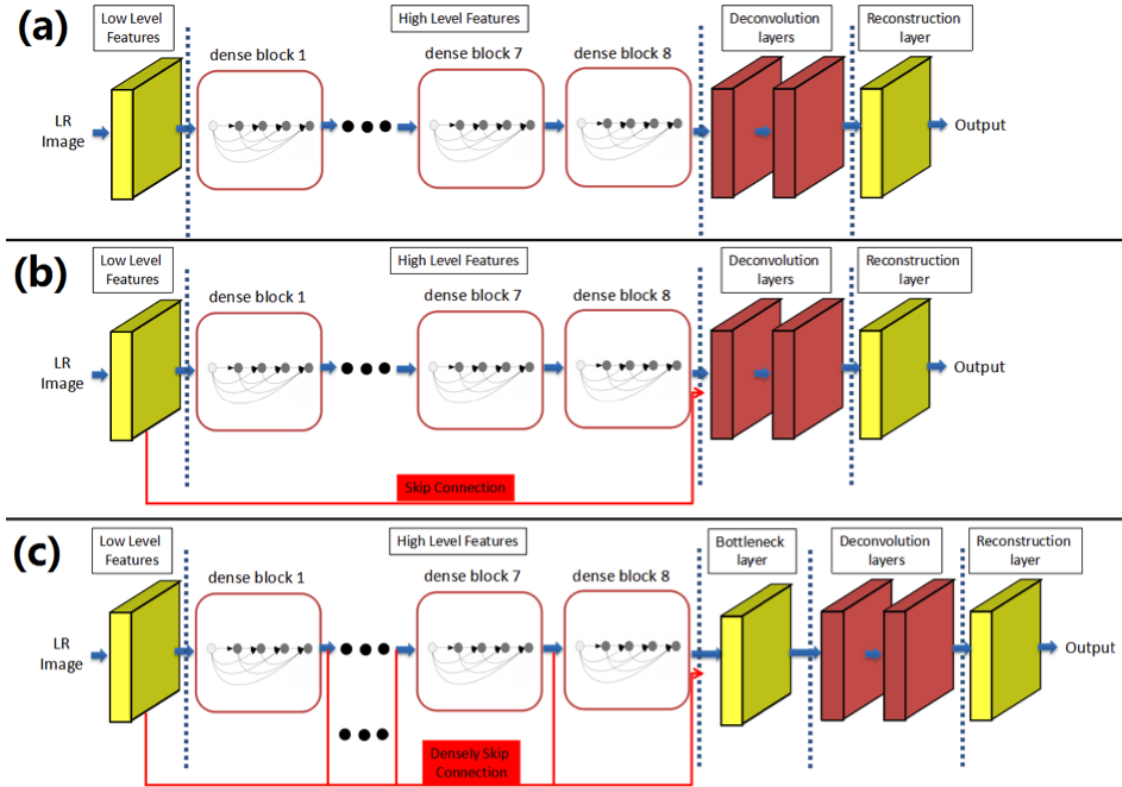
### 2.2.3 Süper çözünürlük yoğun ağ (SRDenseNet)

Derin ağlarda ortaya çıkan kaybolan gradyen problemini çözmek için yeni bir model olan SRDenseNet sunulmuştur [9]. Bu çalışmada, tek görüntü süper çözünürlük yöntemi olarak yoğun atlamalı bağlantılar kullanılmaktadır. Yoğun katmanlar sayesinde bilgiler tüm ağ boyunca kaybolmadan ilerleyebilmektedir. Ayrıca, özellik çıkarım görüntüleri bir önceki katmandan bir sonraki katmana aktarılırken kaybolmadan ilerlemektedir. Bu sayede çıkarılan özellikler, tüm katmanlara girdi olarak verilebilmekte ve özelliklerin kaybolmadan yüksek çözünürlüklü bir görüntü oluşturması sağlanmaktadır.

SRDenseNet modeli, Şekil 2.9'de görüldüğü gibi çeşitli alt modüllerden oluşmaktadır. Bu alt modüller düşük seviye özellik çıkarımı, yüksek seviye özellik çıkarımı, ters evrişimli katmanlar ve yeniden yapılandırma katmanlarından meydana gelmektedir.


Her evrişim ve ters evrişim katmanının ardından, doğrusal olmayan eşleme için ReLU katmanı kullanılmaktadır. Ayrıca, kayıp fonksiyonu olarak Ortalama Kare Hatası (Mean Squared Error, MSE) ve optimizasyon fonksiyonu olarak Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation, ADAM) kullanılmaktadır.

Düşük çözünürlüklü görüntü, düşük seviye özellik çıkarım katmanından geçtikten sonra yoğun bloklardan geçerek yüksek seviye özellik çıkarımı yapılır. ResNet mimarisinde çıkarılan özellikler toplanarak bir sonraki katmana girdi olarak verilirken, SRDenseNet modelinde özellik haritaları birleştirilerek bir sonraki katmana girdi olarak verilmektedir. SRDenseNet modelinde her blok içerisinde bir katmanın çıktısı, bir sonraki tüm katmanların girişlerine doğrudan atlamalı bağlantı oluşturur. Bu esneklik sayesinde bilgi, herhangi bir işleme tabi tutulmadan tüm ağ boyunca ilerleyebilmektedir. Bu özellik, özellik haritalarının diğer katmanlarda kullanılmasıyla birlikte daha az öğrenilebilir ağırlık katsayılarının kullanılmasına ve modelin eğitim ve test süresinin önemli ölçüde iyileştirilmesine olanak sağlar.



Şekil 2.9 : SRDenseNet modelinin mimarisi.

Yoğun blok yapısı Şekil 2.10'de gösterilmektedir. Her bir blokta 8 adet evrişimli katman bulunur. Her katmanda k sayıda nöron olduğunu varsayarsak, blok çıktısında toplamda 8k özellik çıkarımı gerçekleştirilir. Bu çalışmada k değeri 16 olarak kabul edilmiştir.



**Şekil 2.10 :** Dense blok yapısı.

SRCNN ve VDSR modellerinde, düşük çözünürlüklü görüntüyü yüksek çözünürlüklü hale getirmek için kübik interpolasyon yöntemi kullanılmıştır. Ardından, model boyunca yüksek boyutlu görüntü üzerinde işlemler yapılmış ve bu durum daha fazla ağırlık katsayısı kullanılmasına neden olmuştur. Bu da hesaplama yükünü artırmıştır. Ters evrişim operasyonu, evrişim işleminin tersi olarak düşünülebilir. Evrişim işlemleri sırasında görüntü boyutları küçülürken, ters evrişim işlemlerinde ise görüntü boyutu büyütülür. Ters evrişim işlemlerinin kullanımının 2 farklı avantajı vardır. İlk olarak, bu işlem modelin sonunda gerçekleştirildiği için büyük çoğunluğunda düşük çözünürlüklü görüntüler üzerinde işlemler yapılır ve hesaplama yükü azaltılır. İkinci olarak, modelin yeniden yapılandırma süreçlerini kendisi kontrol eder ve süreci hızlandırır.

Çalışmanın kapsamında 3 farklı model eğitilmiş ve sonuçlar gözlemlenmiştir. Şekil 2.9 (a)'da SRDenseNet\_H modelinde bloklar arasında atlamalı bağlantı kullanılmamıştır. Şekil 2.9 (b)'de SRDenseNet\_HL modelinde ise bloklar arasında VDSR modeline benzer şekilde düşük çözünürlüklü görüntü darboğaz (bottleneck) katmanına girdi olarak verilerek atlamalı bağlantı olarak kullanılmıştır. Son olarak, Şekil 2.9 (c)'de SRDenseNet\_All modelinde ise tüm yoğun bloklar arasına bağlantı eklenmiştir. SRDenseNet modeli tam olarak Şekil 12.9(c)'deki modele denk gelmektedir.

Yoğun bloklarda üretilen özellik görüntülerinin sayısı arttıkça, modelin işlem yükü de artmaktadır. Bu nedenle, çıkarılan özelliklerin bilinçli bir şekilde sınırlı sayıda çıkarılması önemlidir. Yeniden yapılandırma katmanına gelindiğinde, görüntünün boyutu tek bir özellik görüntüsüne indirgenmelidir. Bu nedenle darboğaz katmanı kullanılmış ve  $n$  adet özellik görüntüsünden 1 adet düşük boyutlu görüntü elde edilmiştir. Ardından  $3 \times 3$  ters evrişim işlemi ile görüntü yukarı ölçeklenmiş ve nihai süper çözünürlüklü, yüksek kaliteli görüntü elde edilmiştir.

### 2.3 Çok Ölçekli Öğrenme

Süper çözünürlük modellerinin aynı ölçeklendirmeye sahip görüntülerle eğitildiğinde, modelin performansının aynı ölçek üzerinde başarılı sonuçlar elde edeceği ortaya koyulmaktadır. Ancak, farklı bir ölçeğe sahip görüntülerle test edildiğinde, bu modeller genellikle başarısız olmaktadır. Bunun nedeni, modellerin öğrendikleri özelliklerin ölçek bağımlı olması ve farklı ölçeklerdeki detayları doğru bir şekilde yeniden oluşturamamalarıdır [39].


Bu sorunu çözmek için çok ölçekli öğrenme tekniği kullanılmaktadır. Bu teknik, modelin farklı ölçeklere sahip görüntülerle eğitilmesini içerir. Örneğin, eğitim veri kümesi farklı ölçeklerdeki görüntülerden oluşabilir veya görüntüler farklı ölçeklere indirgenerek eğitim için kullanılabilir. Bu şekilde, model farklı ölçeklerdeki detayları doğru bir şekilde kavramayı öğrenir ve daha genel, ölçek bağımsız temsili öğrenme yeteneği geliştirir.

Çok ölçekli öğrenme tekniği kullanılarak eğitilen süper çözünürlük modelleri, farklı ölçeklere sahip görüntülerle test edildiğinde daha iyi performans göstermektedir. Bu, kullanıcıların farklı ölçeklerdeki görüntüler üzerinde daha iyi sonuçlar elde etmelerini sağlar ve süper çözünürlük uygulamalarının genel kullanılabilirliğini artırır.

#### 2.3.1 Çok ölçekli artık ağ (MSRN)

Çok ölçekli öğrenme paradigmasını destekleyen, 2016 yılında yayınlanan Çok Ölçekli Artık Ağ (Multi Scale Residual Network, MSRN) modeli, evrişimli katmanlardaki filtre uzunluklarının farklı olduğu bir yapıya sahiptir. Bu sayede farklı

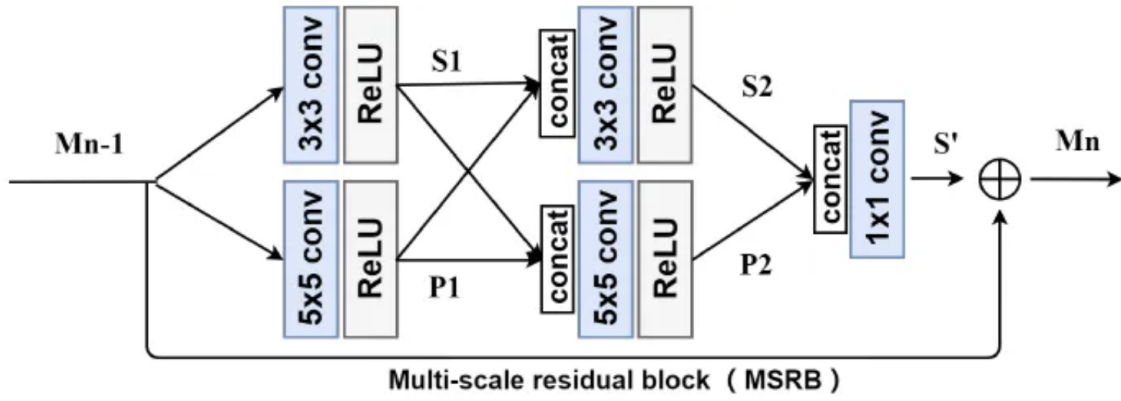
ölçeklerdeki görüntülere uyum sağlayabilmektedir [40]. Şekil 2.11’de MSRN modeli gösterilmektedir. Model, iki bölümden oluşmaktadır: özellik çıkarımı ve görüntü yeniden yapılandırma.



Şekil 2.11 : MSRN modelinin mimarisi.

Özellik çıkarımı bölümünde, Çok Ölçekli Artık Blok (Multi Scale Residual Block, MSRB) bulunmaktadır. MSRB blokları, artık ve farklı boyutlardaki evrişimli bloklardan meydana gelmektedir. Şekil 2.12’de görüldüğü gibi, her bir blokta bir adet artık katman bulunur ve her bir blok çıkışı darboğaz katmanına doğru yönlendirilir. Bu şekilde, her bir katmanın çıkışında farklı ölçeklerdeki özellikler kaybolmaz. MSRB bloğunun 1. katmanında 2 adet evrişimsel blok bulunur ve bunlar 3x3 ve 5x5 boyutlarındaki evrişim işlemlerine tabi tutulur. 1. katman çıktısında M adet özellik çıkarımı gerçekleştirilir. 2. katmanda ise 1. katmandaki gibi 3x3 ve 5x5 boyutlarındaki evrişimsel bloklar bulunur ve katmanın çıkışında 2M adet özellik çıkarım işlemi gerçekleştirilir. Ardından, tüm özellik haritaları birleştirilmek üzere darboğaz katmanına 1x1 boyutlu evrişimsel bloğa aktarılır ve 2M sayıdaki özellik haritası 1’e indirgenir.

Görüntü yeniden yapılandırma katmanında, sırasıyla evrişimli, EPSCN modeli kullanan piksel karıştırıcı ve evrişimsel katmanlar bulunmaktadır.



Şekil 2.12 : MSRB blok yapısı.

### 2.3.2 Çok ölçekli özellik birleşme artık ağ (MSFFRN)

Çok ölçekli öğrenme tekniğini temel alan Çok Ölçekli Özellik Birleşme Artık Ağ (Multi-Scale Feature Fusion Residual Network, MSFFRN) modeli 2020 yılında yayınlanmıştır. Model Şekil 2.13’de gösterilmiştir ve 5 bölümden oluşmaktadır: Sığ özellik çıkarımı, derin özellik çıkarımı, küresel özellik birleştirme, yukarı ölçekleme ve geri kazanım modülü [41].

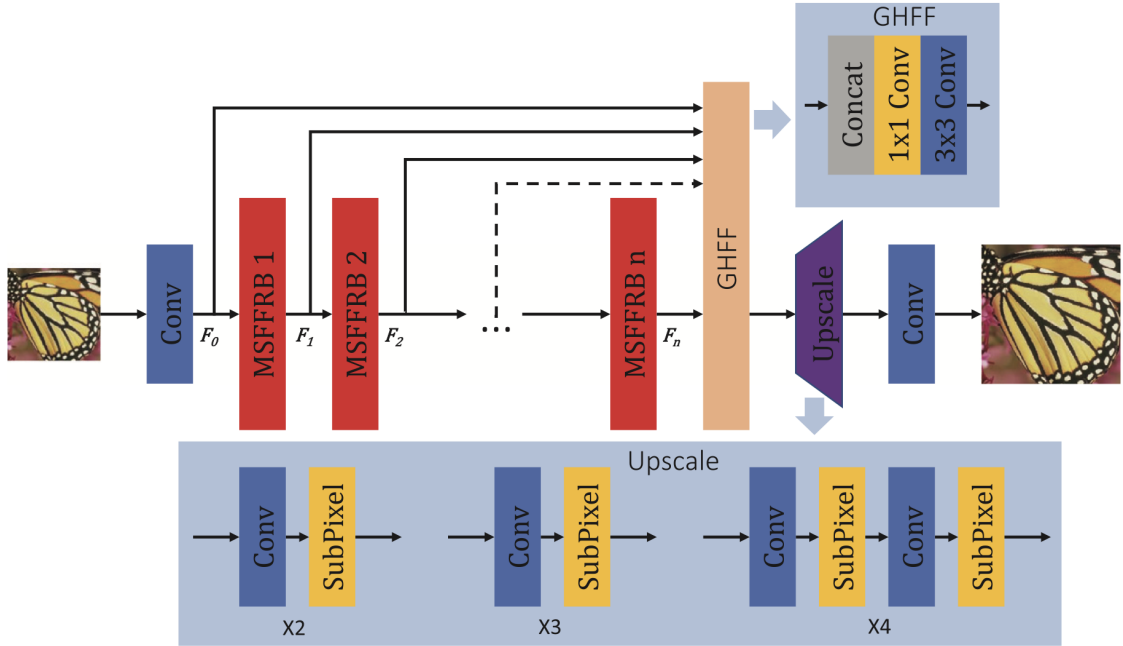
Sığ özellik çıkarımı bölümünde, düşük çözünürlüklü görüntü evrişimli katmanlardan geçer ve sonucunda  $F_0$  olarak ifade edilir.

Derin özellik çıkarımı bölümünde,  $F_0$  kullanılarak  $MSSFRB_1$ ,  $MSSFRB_2$ , ...,  $MSSFRB_n$  modüllerinden geçilir ve her bir MSSFRB bloğunun çıktısı bir sonraki katman için  $F_0$ ,  $F_1$ , ...,  $F_n$  olarak ayrılır.

Küresel özellik birleştirme katmanında GHFF, tüm MSFFRB katmanlarının çıktıları, 1x1 boyutlu evrişimsel işlem kullanılarak birleştirilir. Ardından, 3x3 boyutlu evrişimli bloklardan geçirilir ve yukarı ölçekleme katmanına iletilir.

Yukarı ölçekleme katmanında, görüntüler sırasıyla 2x, 3x ve 4x ölçeklendirilir ve ardından alt ölçekleme işlemine tabi tutulur. Bu şekilde, çoklu ölçekleme öğrenme modeli uygulanmış olur.


Geri kazanım modülünde, yukarı ölçekleme işlemine tabi tutulan görüntü özellikleri zaman uzayına geri dönüştürülerek yüksek çözünürlüklü görüntü elde edilir.



Şekil 2.13 : MSFFRN modelinin mimarisi.

### 2.3.3 Verimli uzun menzilli dikkat ağı (ELAN)

Verimli Uzun Menzilli Dikkat Ağı (Efficient Long-Range Attention Network, ELAN) modeli, çok ölçekli öğrenme modelini uygulamaktadır [42]. Şekil 2.14’de gösterildiği gibi içerisinde sığ özellik çıkarımı, derin özellik çıkarımı ve geri kazanım bileşenlerinden oluşmaktadır.



Şekil 2.14 : ELAN modelinin mimarisi.

Sığ özellik çıkarım bileşeni, 3x3 boyutlu evrişim işlemi kullanarak sığ bir şekilde özellik çıkarımı yapar. Sığ özellik çıkarımının sonucu, atlamalı bağlantıyla derin

özellik katmanının çıktısıyla toplanır ve yeniden yapılandırma katmanına giriş olarak verilir.

Derin özellik çıkarım bileşeni, birbirine sıralı olarak bağlı ELAB bloklarından oluşur. ELAB bloğunda, kaydırma işlemleri kullanılarak çok ölçekli öğrenme tekniği uygulanır.

Geri kazanım bileşeni ise, 3x3 boyutlu evrişimli katman ve piksel karıştırıcı bir ağ içerir. Bu bileşen, görüntünün yüksek çözünürlüklü hali için geri kazanım işlemini gerçekleştirir.

ELAN modeli, bu üç bileşenin bir araya gelmesiyle oluşur ve görüntülerin özellik çıkarımı, derin özellik çıkarımı ve geri kazanımı için etkili bir yapı sunar.

## **2.4 Dikkat Mekanizması**

Evrişimli sinir ağı modellerinin büyük bir kısmı, görüntülerdeki yerel özellikleri vurgulayarak evrensel özellikleri göz ardı etme eğilimindedir. Bu durum, ağların derinliğini artırarak çözülmeye çalışılsa da, bu yaklaşım çok fazla öğrenilebilir parametre oluşmasına ve eğitim sürelerinin uzamasına yol açmaktadır. Modelleri, öğrenmesi istenilen özelliklere odaklamak adına yönlendirilmesi gerekmektedir. Bunun için dikkat mekanizması olarak adlandırılan modelin odaklanması gereken önemli bölgeleri belirleme amacı ortaya çıkmıştır [43]. Bu mekanizma, modelleri belirli bir yönde öğrenmeye teşvik ederek görüntü kalitesini artırmayı hedefler. Bunu gerçekleştirmek için, mevcut sinir ağı mimarilerine bileşen veya blok olarak dikkat mekanizması eklenerek modellerin derinliği azaltılır.

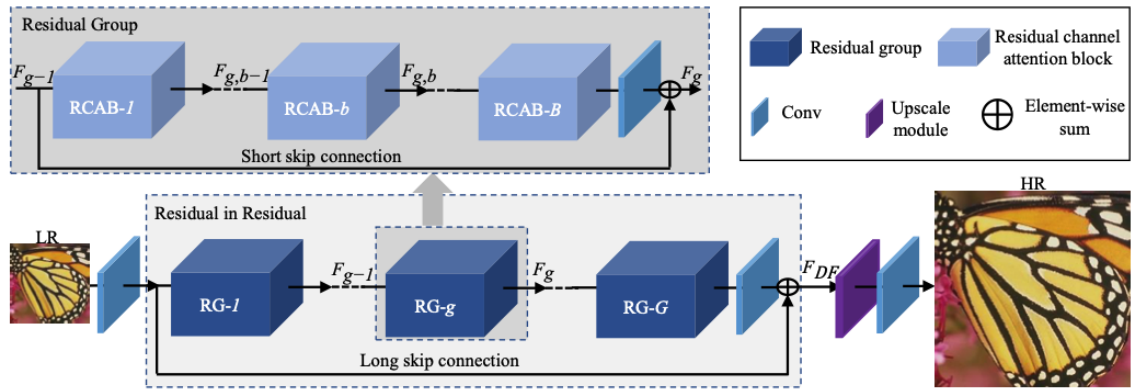
Kanal dikkat mekanizması, yerel olmayan, bağlamsal, frekans tabanlı gibi farklı tiplerde dikkat mekanizmaları bulunmaktadır. Bu mekanizmalar, modellerin dikkatini farklı şekillerde yönlendirerek daha iyi özellik çıkarımı sağlar.

### **2.4.1 Artık kanal dikkat mekanizması (RCAN)**

Geleneksel süper çözünürlük modelleri genellikle yerel özelliklere odaklanırken, küresel özellikleri gözden kaçırma eğilimindedir. Bu durum modelin performansını olumsuz etkileyebilir ve görüntülerdeki keskin geçişler veya belirli örüntüler

görmezden gelinir. Kanal dikkat mekanizması ise özellik çıkarım aşamasında kanallardaki yüksek bileşenlere odaklanır ve bu bileşenlerin asıl bilgiyi taşıdığını varsayar. Bu amaçla, modelin içine "küresel maksimum havuzlama" adı verilen bir katman eklenir ve bu katman sayesinde yüksek frekans bileşenlerine dikkat edilir. Artık Kanal Dikkat Mekanizması (Residual Channel Attention Networks, RCAN), çok derin bir ağ yapısına sahip olması için artık içinde artık blok yapısını kullanmaktadır [44]. Bu yapıda, birçok artık grup bloğu ve bu bloklar arasında uzun atlamalı bağlantılar bulunmaktadır. Her bir artık grup bloğunda ise kısa atlamalı bağlantılar mevcuttur.

Şekil 2.15’de RCAN modelinin mimarisi verilmiştir. Model, üç bölümden oluşmaktadır: sığ özellik çıkarımı, derin özellik çıkarımı ve yukarı ölçekleme katmanları.



Şekil 2.15 : RCAN modelinin mimarisi.

Sığ özellik çıkarım katmanında, temel evrişim işlemleri kullanılarak görüntülerin temel özellikleri çıkarılır.

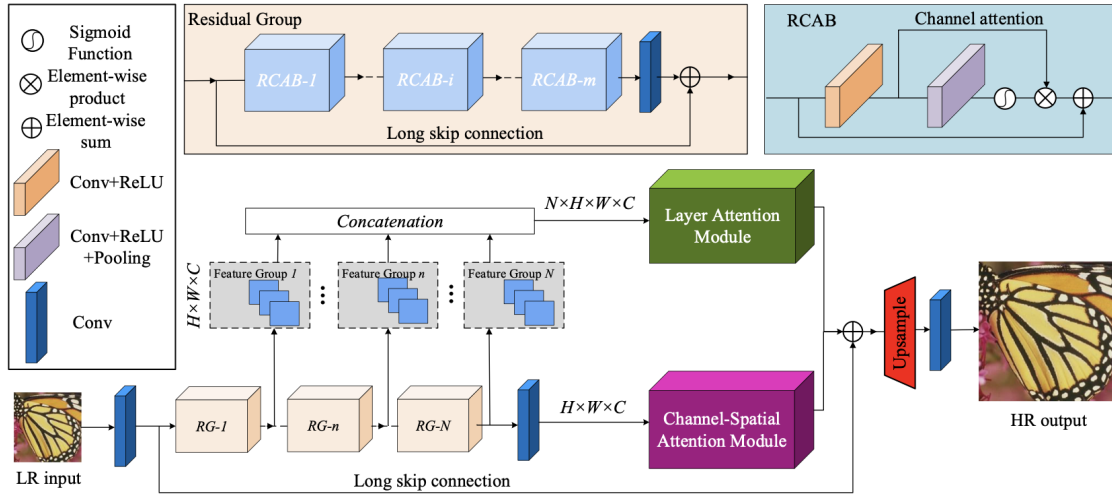
Derin özellik çıkarım katmanında ise artık bloklar ve uzun atlamalı bağlantılar bulunur. Her bir artık blok içerisinde artık kanal dikkat blokları ve kısa atlamalı bağlantılar yer alır. Dikkat blokları, evrişim katmanları ve evrensel dikkat mekanizmaları gibi bileşenler içerir.

RCAN modeli, bu bileşenlerin birleşimiyle oluşur ve sığ özellik çıkarımı, derin özellik çıkarımı ve yukarı ölçekleme işlemleriyle yüksek kalitede süper çözünürlüklü

görüntüler elde edilmesini sağlar. Yukarı ölçekleme katmanında görüntüler orijinal boyutlarına yükseltilir.

#### 2.4.2 Bütünsel dikkat ağı (HAN)

Kanal dikkat mekanizması, her katmandaki yoğun bilgiye sahip örüntüleri ve özellikleri korumak için etkili bir yöntem olduğu kanıtlanmıştır. Ancak, farklı katmanlar arasındaki ilişkiyi göz ardı eder ve her bir evrişim katmanlarını ayrı bir işlem olarak ele alır. Bu sorunu çözmek için, Bütünsel Dikkat Ağı (Holistc Attention Network, HAN) mimarisi önerilmiştir [45]. Bu mimaride bütünsel dikkat mekanizması kullanılmıştır. Bu ağda 4 farklı modül bulunmaktadır: Özellik çıkarım, katman dikkat modülü (Layer Attention Module, LAM), kanal-uzamsal dikkat modülü (Channel Spatial Attention Module, CSAM) ve geri kazanıp modülleri. Modelin mimarisi Şekil 2.16’de verilmiştir.



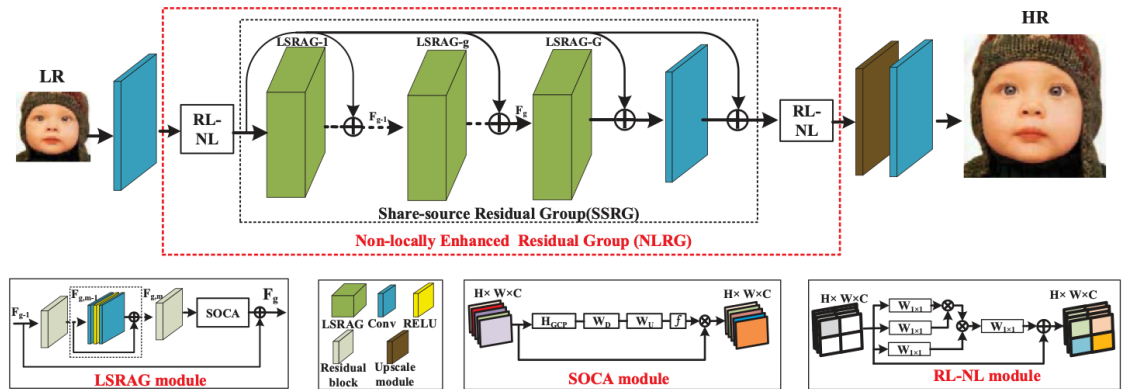
Şekil 2.16 : HAN modelinin mimarisi.

Özellik çıkarım katmanında, evrişimli işlemler ile düşük çözünürlüklü görüntüler üzerinde sığ özellik çıkarım işlemi yapılır. Daha ayrıntılı özellik çıkarım için bu katmanın çıktısı RCAN modeline verilmektedir. RCAN modelinde artık grup blokları (RG) bulunmaktadır. Her bir artık blok ardışık olarak yerleştirilmiş ve grup çıktısı bir sonraki modüle girdi olarak verilir. RCAN modelindeki RG’lerdeki kanallar birleştirilir ve bu görüntü LAM modeline girdi olarak verilir. LAM modülünde özellikler arasındaki ilişki incelenir ve bu farklılıklara dikkat edilir. CSAM modülü,

LAM modülü gibi her RG çıktısıyla değil, son RG bloğunun çıktısıyla ilgilenir. Bu durumda son bloktaki özelliklerin birbirleriyle ilişkisi incelenmektedir. LAM ve CSAM modül çıktıları birleştirilerek yukarı ölçekleme modülüne verilir ve orijinal görüntü boyutu elde edilmiş olunur.

### 2.4.3 İkinci dereceden derin sinir ağı (SAN)

Süper çözünürlük alanında ilk yapılan interpolasyon tabanlı çalışmalar, kural tabanlı, basit ve bazı uygulamalarda verimli sonuçlar üretebilmekteydi. İleri seviyede kabul edilen çalışmaların bir kısmı ise yerel olmayan ve seyrelti tabanlı yaklaşımlarla başarılı sonuçlar elde edebiliyordu. Ancak, görüntüler değiştiğinde, bu modellerin başarı oranları düşmekte ve algoritmalar çok uzun süreler harcamaktadır. Bu eksiklikleri gidermek amacıyla İkinci Dereceden Derin Sinir Ağı (Second Order Attention Network, SAN) modeli önerilmiş ve görüntülerde daha güçlü özellik çıkarımı ve korelasyon yakalanması hedeflenmiştir [46]. Modelin mimarisi Şekil 2.17’de verilmiştir. Bu çalışmanın sonucunda daha yüksek çözünürlüklü görüntü elde edilmesi amaçlanmıştır. Ayrıca SAN mimarisi içine, daha iyi özellik çıkarımı için İkinci Dereceden Kanal Dikkat Mekanizması (Second Order Channel Attention, SOCA) eklenmiştir. SOCA, SAN ağına bilgi içeren özelliklere daha fazla odaklanmayı ve öğrenme yeteneğini artırmayı sağlamaktadır.



Şekil 2.17 : SAN modelinin mimarisi.

SAN ağı içinde Evrensel Gelişmiş Artık Grup (NLRG) yapısı kullanılarak daha derin katmanların SAN'a eklenmesine imkân tanınmıştır. NLRG sayesinde, yerel olmayan evrensel derin özelliklerin çıkarılması sağlanmıştır. Ayrıca, atlamalı

bağlantıların bulunduğu artık blok yapısı sayesinde kaynak paylaşımı sağlanmış ve düşük çözünürlüklü görüntülerdeki bilgilerin bir sonraki katmanlara aktarılması sağlanmıştır. Bu durum, daha derin ağ yapılarının kullanılmasını mümkün kılmıştır.


## **2.5 Geri Besleme Mekanizması**

Geri besleme mekanizması, düşük çözünürlük ile yüksek çözünürlük görüntüler arasında ilişki kurarken öğrenme sürecinde kendi kendini düzeltme yeteneğine sahiptir. Bir önceki görüntüden elde edilen bilgi, bir sonraki görüntünün tahmin edilmesinde kullanılır. Özellikle video görüntülerinde, yüksek korelasyona sahip görüntüler arasında bir önceki görüntüdeki bilgi, bir sonraki görüntü için kullanılabilir. Geri besleme mekanizması ve yinelemeli öğrenme paradigması birbirlerine benzemektedir. Geri besleme mekanizmasında bulunan öğrenilebilir parametreler, kendi kendini düzeltebilme yeteneğine sahipken, yinelemeli öğrenmede parametreler farklı modüller arasında ortak olarak kullanılır. Bu nedenle, parametreler farklı modüller tarafından düzeltilir. Ayrıca, kullanılan parametre sayısı açısından bakıldığında geri besleme mekanizması daha karmaşıktır. Geri besleme mekanizmasında giriş ile çıkış arasında doğrudan haritalama işlemi bulunmamaktadır. Giriş görüntü bir önceki görüntü ile birlikte ağı beslemektedir.

### **2.5.1 Derin geri-yansıtma ağı (DBPN)**

Derin Geri-Yansıtma Ağı (Deep Back Projection Network, DBPN) ve Yoğun Derin Geri-Yansıtma Ağı (Dense - Deep Back Projection Network, D-DBPN) adı verilen iki farklı model önerilmiştir [47]. Bu modeller, geri bildirim mekanizmasıyla çalışan yinelemeli yukarı ve aşağı örnekleme katmanları içermektedir. Bu katmanlar arasında oluşan projeksiyon hataları, bir sonraki katmanlara geri bildirim yoluyla iletilmektedir. Şekil 2.18’de DBPN mimarisi gösterilmektedir. Düşük çözünürlüklü giriş görüntüsü, evrişim katmanından geçerek sığ özellik çıkarım işlemine tabi tutulur ve ardından yukarı ve aşağı ölçekleme bloklarından geçirilir. Her bir yukarı ölçekleme çıktısı birleştirilir ve tekrar evrişim katmanından geçerek süper çözünürlüklü görüntü oluşturulur. Yukarı ve aşağı ölçekleme katmanlarında oluşan hatalar, bir sonraki

katmana iletilir ve bu şekilde hatalar geri projeksiyon işlemiyle son katmana kadar ilerler. Her bir yukarı ve aşağı örnekleme bloğunda düşük çözünürlüklü görüntülerden süper çözünürlüklü görüntü oluşturulur ve adım adım model çıktısına doğru hatalar düzeltilir.

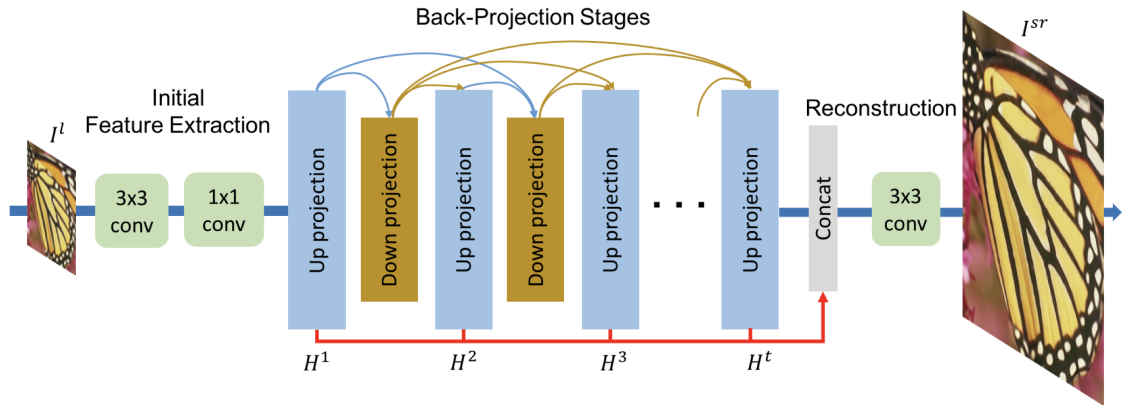


Şekil 2.18 : DBPN modelinin mimarisi.

### 2.5.2 Yoğun derin geri-yansıtma ağı (D-DBPN)

Yoğun Derin Geri-Yansıtma Ağı (Dense Deep Back Projection Network, D-DBPN) mimarisi üç bölümden oluşur: Sığ özellik çıkarımı, projeksiyon ve yeniden yapılandırma [47].

Şekilde 2.19'te görüleceği üzere sığ özellik çıkarım katmanında 3x3 ve 1x1 boyutlarında filtreler kullanılır ve evrişimli işleme tabi tutulur. Bu katmanın çıktısı projeksiyon katmanına girdi olarak verilir.



Şekil 2.19 : D-DBPN modelinin mimarisi.

Projeksiyon katmanında projeksiyon birimleri bulunur. Her bir birim içinde yukarı ve aşağı ölçekleme işlemleri gerçekleştirilir ve hata oranı hesaplanır. Her bir

projeksiyon biriminin çıktısı bir sonraki tüm birimlere girdi olarak verilir. Ayrıca projeksiyon birimlerinin yukarı ölçekleme operasyonlarıyla elde edilen görüntüler, yeniden yapılandırma katmanına verilir.

Yeniden yapılandırma katmanına, yukarı projeksiyon birim çıktıları birleştirilerek girdi olarak verilir. Bu katmanda 3x3 boyutunda evrişim işlemleriyle çıkarılan özellikler birleştirilir. Katmanın sonunda süper çözünürlüklü görüntü elde edilir.

### **2.5.3 Süper çözünürlük geri bildirim ağı (SFRBN)**

Geri bildirim mekanizmasına sahip yeni bir sinir ağı modeli olan Süper Çözünürlük Geri Bildirim Ağı (Super Resolution Feedback Network, SRFBN) önerilmiştir [48]. SRFBN, Tekrarlı Sinir Ağı (Recurrent Neural Network, RNN) modeline Geri Bildirim (Feedback, FB) bloklarının eklenmesiyle oluşturulmuştur.

FB blokları, sıralı yukarı ve aşağı örnekleme katmanlarına sahip olup yoğun atlamalı bağlantılar içermektedir. Bu sayede yüksek seviyede özellik çıkarımı yapabilme yeteneğine sahiptir.

Önerilen model üç bölümden oluşmaktadır: Düşük Çözünürlük Görüntü Özellik Çıkarım Bloğu (LRFB), Geri Bildirim Bloğu (FB) ve Yeniden Yapılandırma Bloğu (RB).

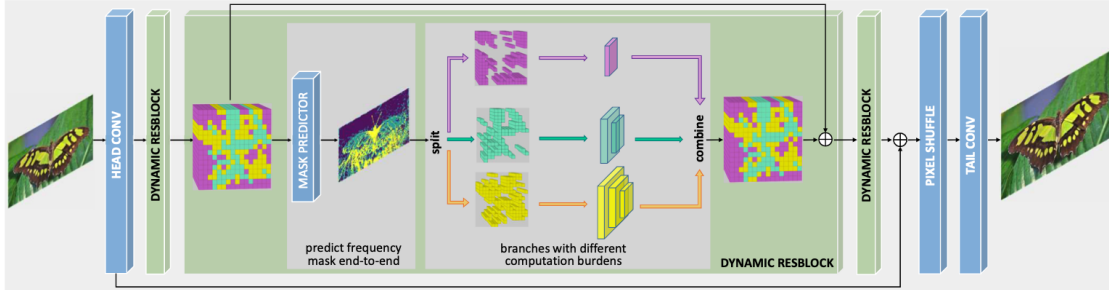
Model mimarisi Şekil 2.20'de gösterilmiştir. LRFB bölümünde, 2 adet evrişimli blok bulunmakta ve özellik çıkarım işlemi gerçekleştirilmektedir. FB bloklarının mimarisi ise Şekil 2.21'de verilmiştir. Geri besleme sayesinde FB bloğunun çıktısı, kendisine geri besleme olarak verilir ve bir sonraki görüntüyle birlikte FB bloğuna giriş yapılır. FB bloğu, sıralı olarak yukarı ve aşağı ölçeklemeler yaparak görüntülerdeki yüksek seviyede özellikleri çıkarmaya çalışır. Aynı zamanda, çok sayıda atlamalı katmanın bulunması nedeniyle modelin katman sayısı artmakta ve bilgiler bir sonraki katmana kolayca iletilmektedir. Geri kazanım bloğu, ters evrişimli işlemi kullanarak düşük çözünürlüklü görüntüyü yukarı ölçekleyerek toplar ve yüksek çözünürlüklü görüntüyü oluşturur.



### 2.6.1 Frekans duyarlı dinamik ağ (FADN)

Süper çözünürlük modelleri, görüntülerdeki yüksek frekans bileşenlerinden dolayı yüksek hesaplama yükü gerektirmektedir. Düşük çözünürlüklü görüntülerde ise bu yük daha az olmaktadır. Düşük frekans değerleri, uzamsal uzayda daha az bilgi içermektedir. Model eğitimi için sadece düşük frekans bileşenlerinden oluşan bir görüntü kullanıldığında, modelin performansı belirli bir düzeyde iyileşmektedir. Bu çalışmada, ayrık kosinüs dönüşümü kullanılarak çıkarılan frekans katsayılarının model eğitimi sırasında dikkate alınması için Frekans Duyarlı Dinamik Ağ (Frequency Attention Dynamic Network, FADN) modeli geliştirilmiştir [49]. FADN bloklarının içerisinde, görüntüler frekans uzayında farklı bir şekle dönüştürülmüş ve böylece modelin performansı artırılmıştır. Bununla birlikte, özellikle yüksek frekans bileşenleri nedeniyle hesaplama yükü artmıştır.

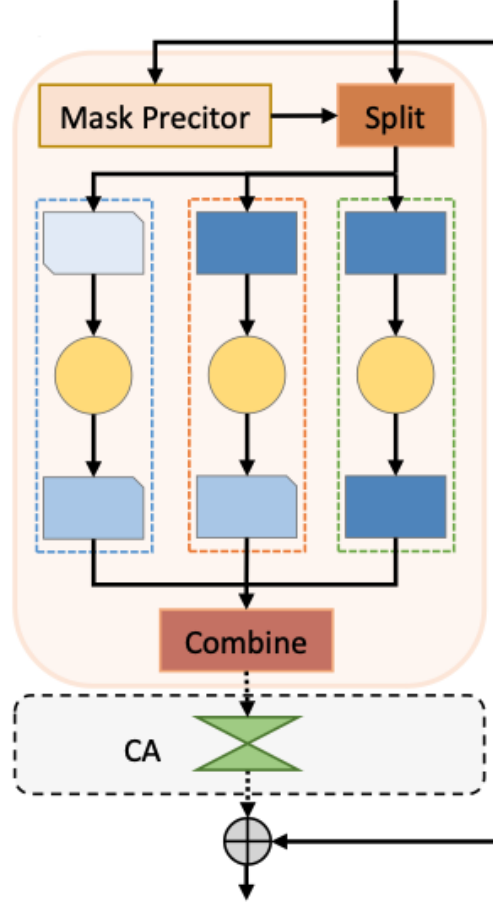
Şekil 2.22’de, modelin mimarisi görülmektedir ve model üç bölümden oluşmaktadır: özellik çıkarımı, Frekans Duyarlı Dinamik Blok (Frequency Attention Dynamic Block, FADB) ve geri kazanım.



Şekil 2.22 : FADN ağ mimarisi.

Özellik çıkarımı, model giriş kısmında evrişim katmanlarıyla gerçekleştirilir. FADB modeli Şekil 2.23’de gösterilmektedir. Görüntüler, ayrık kosinüs dönüşümü kullanılarak frekans uzayında kosinüs işaretleriyle temsil edilir. Düşük frekans, orta seviye frekans ve yüksek frekans katsayıları, üç farklı filtre kullanılarak çıkarılır. Bu işlem, tamamen statik filtreler kullanılarak gerçekleştirilir. Daha sonra, bu üç frekans katsayısı ayrı ayrı ters ayrık kosinüs dönüşümü kullanılarak uzamsal uzaya geri dönüştürülerek üç farklı görüntü elde edilir. Görüntüler sırasıyla 3x3 evrişimli katman,

ReLU katmanı ve 3 boyutlu derin evrişimli katmandan geçer. Elde edilen görüntüler birleştirilerek kanal dikkat mekanizmasına girdi olarak verilir ve çıktı, görüntü blok çıktısını temsil eder. FADB blokları, performansı artırmak için bir araya getirilerek bağlantılar oluşturur.



Şekil 2.23 : FADB yapısı.


Geri kazanım işlemi, modelin sonunda ters evrişim işlemleriyle gerçekleştirilir.

### 2.6.2 Dinamik filtre ve çoklu spektral dikkat mekanizması (DFSA)

Düşük çözünürlüklü görüntülerde frekans değerlerini dikkate alan Dinamik Filtre ve Çoklu Spektral Dikkat Mekanizması (Dynamic High-Pass Filtering and Multi-Spectral Attention, DFSA) modeli geliştirilmiştir [50]. Bu çalışmada, frekans bilgisi temel alan ve dikkat mekanizması paradigmasını içeren bir model üzerinde çalışılmıştır. Yeni bir yöntem olarak Matris Çok Spektral Kanal Dikkat (Matrix Multi Spectral Channel Attention, MMCA) ve Dinamik Yüksek Geçiren Filtre (High Pass Filter, HPF) modülleri oluşturulmuştur.

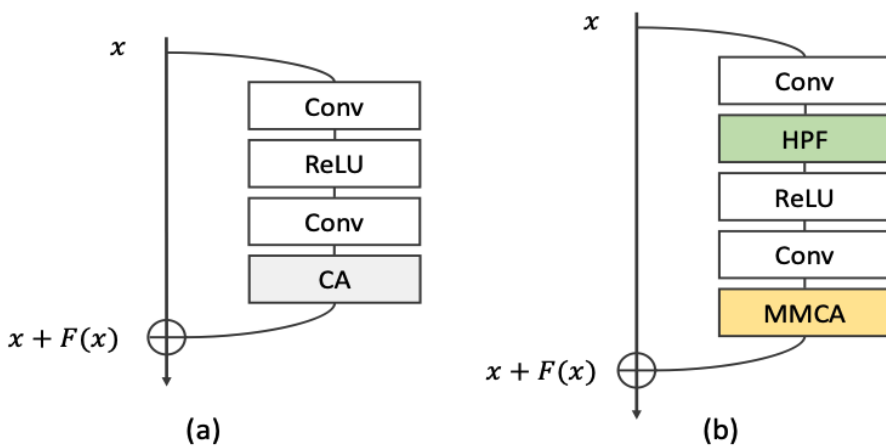
HPF modülü, düşük çözünürlüklü görüntünün her bir yerel bölgesi için ayrı bir filtre tasarlamaktadır. Bu filtreler, öğrenme sırasında tamamen oluşturulmakta ve her bir kanal için farklı olmaktadır. Bu sayede yüksek frekans bileşenleri modülden geçebilmektedir.

MMCA modülü, Şekil 2.24'de gösterilmiştir. Düşük çözünürlüklü görüntünün çıkarılan özellikleri bu modüle giriş olarak verilir ve görüntüler, kendi içinde ayrık kosinüs dönüşümüne (Discrete Cosine Transform, DCT) tabii tutulurlar. Ardından, görüntüler, DCT ile frekans uzayında kosinüs işaretleriyle temsil edilir. Sonrasında, görüntüler MLP katmanından geçer ve RCAN dikkat mekanizmasına girdi olarak verilir.



Şekil 2.24 : MMCA modülünün yapısı.

DFSA ağı, Şekil 2.25'de gösterilmiştir. RCAN modelinden farklı olarak, Conv ile ReLU katmanı arasına HPF bloğu ve modelin çıktısına MMCA kanal dikkat mekanizması eklenmiştir.



Şekil 2.25 : RCAN (a) ve DFSA(b) modelinin yapısı.

### 3. JPEG GÖRÜNTÜ SIKIŞTIRMA

Görüntü, video, ses gibi büyük verileri haberleşme kanalından iletmek, hız kritik sistemlerde oldukça maliyetlidir. Gönderilmek istenen verilerin kalitesi ve boyutu arttıkça, performansı koruyabilmek için daha geniş bant genişliğine sahip iletim kanalına ihtiyaç duyulmaktadır. Gerçek zamanlı videolar söz konusu olduğunda verileri sıkıştırmadan başka bir ortama iletmek imkânsız hale gelmektedir [51]. Bu nedenle veriler sıkıştırılır ve sıkıştırılmış veriler gönderilir. Alıcı tarafında, bu verilerin kayıpsız bir şekilde geri elde edilmesi kritik öneme sahiptir. Farklı sıkıştırma algoritmaları, kullanılan veri türüne bağlı olarak öne çıkmış ve her geçen gün yeni yöntemler geliştirilmektedir. Bu durum, veri sıkıştırma yöntemlerinin popülerliğini artırmaktadır.

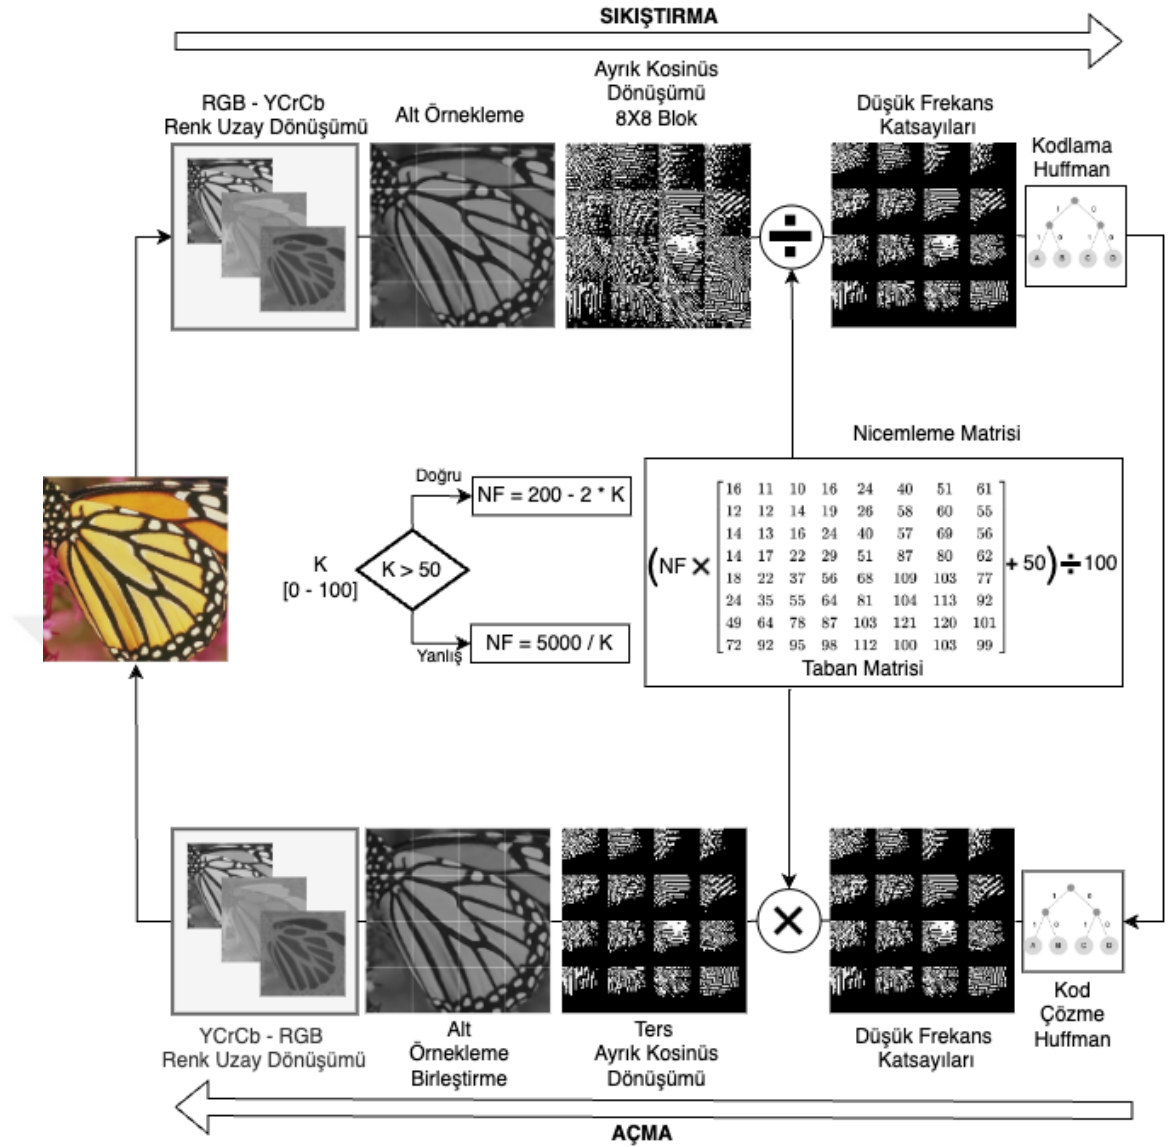
İnsan algıları, görüntü, video, ses gibi verilerde meydana gelen kayıpları belirli bir oranda fark edemez. Ancak, kritik olarak sınıflandırılan verilerde oluşan kayıp kolaylıkla fark edilir. Örneğin, metin verilerinde bir harfin yanlış gönderilmesi, metnin anlamını bozar ve bu kayıp insan tarafından kolayca algılanır. Sıkıştırma algoritmaları da bu temel üzerine kurulmuştur. Veri sıkıştırma yöntemleri, kayıplı ve kayıpsız olmak üzere iki gruba ayrılmıştır. Kayıpsız veri sıkıştırma yöntemlerinde, sıkıştırılan veriler hiç bozulmadan, herhangi bir kayıp yaşanmadan geri elde edilir. Bu yöntemler, kayıp yaşanmasının istenmediği verilerde tercih edilir. Kayıplı veri sıkıştırma yöntemlerinde ise verinin kalitesi belirli bir ölçüde bozularak sıkıştırma elde edilir. Örneğin, görüntü ya da video verileri için belirli bir oranda sıkıştırma elde edilmesi insan gözünde fark edilmeyebilir. Bu yöntemler, veri boyutunu önemli ölçüde azaltmak için kullanılırken, bazı veri kayıplarına da neden olabilmektedir.

Web teknolojilerinde yaşanan gelişmelerle birlikte, bant genişliğinin verimli kullanılması büyük önem kazanmıştır. Bir kullanıcının bir sayfayı ziyareti sırasında, çok sayıda görüntü yüklenmektedir. Bu görüntülerin hızlı yüklenmesi için sıkıştırılması ve belirli bir kayıp miktarının kabul edilebilir olması önemlidir

[52]. Örneğin, mobil cihazla giriş yapan bir kullanıcının genellikle kaliteli bir görüntüye ihtiyacı olmayabilir. Bu noktada, web tabanlı uygulamalardaki görüntülerin kayıplı sıkıştırılması için yaygın olarak kullanılan bir algoritma olan Birleşmiş Fotoğraf Uzmanları Grubu (Joint Photographic Experts Group, JPEG) ön plana çıkmaktadır. 1994 yılında standartlaştırılan bu algoritma, karmaşık ve yüksek çözünürlüklü görüntüleri yüksek oranda sıkıştırabilme yeteneğine sahiptir. Ancak, görüntü boyutunu küçültmek için yapılan sıkıştırma işlemleri sırasında belirli bir miktar kayıp oluşmaktadır. Kayıp istenmeyen durumlarda, Taşınabilir Ağ Grafikleri (Portable Network Graphic, PNG) algoritması tercih edilmektedir. PNG, JPEG'e kıyasla görüntü kalitesini koruyarak sıkıştırma yapabilir. Ancak, bu tür algoritmaların dosya boyutları genellikle JPEG ile kıyaslandığında daha büyük olabilmektedir [53]. Bu nedenle, internet üzerinde hızlı yükleme ve daha az bant genişliği kullanımı gibi faktörler göz önünde bulundurulduğunda, JPEG sıkıştırması tercih edilmektedir. Web tabanlı uygulamalarda daha küçük dosya boyutları ve hızlı yükleme süreleri elde etmek adına, bir miktar görüntü kalitesi kaybının kabul edilebilmesi önemlidir.

### **3.1 Sıkıştırma Adımları**

JPEG algoritmasının sıkıştırma adımları Şekil 3.1'te gösterilmiştir. Sıkıştırma algoritması sırasıyla RGB - YCrYb renk uzayı dönüşümü, alt örnekleme, ayrık kosinüs dönüşümü, nicemeleme matrisi normalleştirilmesi ve kanal kodlaması işlemlerini içermektedir.



Şekil 3.1 : JPEG sıkıştırma algoritması.

### 3.1.1 RGB - YCrYb renk uzay dönüşümü

Kırmızı-Yeşil-Mavi (Red-Green-Blue, RGB) renk uzayındaki kanallar arasındaki korelasyon, Parlaklık-Kırmızı-Mavi Bileşen (Luminance-Chrominance Blue-Chrominance Red, YCrCb) kanalları arasındakinden oldukça yüksektir. Bu durum, makine öğrenmesi alanında performansı etkileyerek öğrenmeyi güçlendirmektedir [54]. Gerçek zamanlı görüntü ve videolar, RGB renk uzayında temsil edilir. İnsan gözü, dış dünyada gördüğü nesnelerin renklerini en yakın şekilde

yansıttığı için görüntüler de bu renk uzayında saklanır. Bu yaklaşım, insan gözünün renkleri algılama biçimine dayanarak, görsel içeriğin doğru ve gerçekçi bir şekilde iletilmesini sağlar. YCrCb, Y, Cr ve Cb kanallarından oluşmaktadır. Y kanalı parlaklık anlamına gelir ve insan gözü parlaklıkta meydana gelen küçük değişikliklere duyarlıdır. Bu nedenle, Y kanalındaki kayıplar insan gözü tarafından kolayca algılanabilir. Cr ve Cb değerleri ise sırasıyla RGB'deki kırmızı ve mavi renklerin Y kanalı ile olan farkından meydana gelmektedir. Parlaklığın aksine, insan gözü renklere karşı daha az duyarlıdır. Bu nedenle, Cr ve Cb kanallarında daha yüksek sıkıştırma oranları kullanılabilir. Bu kanallardaki kayıplar, genellikle görüntünün kalitesini fazla etkilemez. Denklem 3.1'de RGB'den YCrCb renk uzayına dönüşümünün formülü verilmiştir. R, G, B değerleri sırasıyla RGB kanalındaki kırmızı, yeşil ve mavi piksel değerini temsil eder. Bu değerler 255 değeri ile bölünerek normalleştirilir. 0-1 arasında olan bu değerler sırasıyla 0.299, 0.587 ve 0.114 değeri ile çarpılarak YCbCr kanalındaki Y değerini elde eder. Cr ve Cb değerleri ise normalize edilen kırmızı ve mavi değerleri ile Y değerinin farkından meydana gelmektedir. Elde edilen farklar sırasıyla 0.713 ve 0.565 değeriyle çarpılır ve 0.5 değeri eklenir [55].

$$\begin{aligned}
 R' &= \frac{R}{255} \\
 G' &= \frac{G}{255} \\
 B' &= \frac{B}{255} \\
 Y &= 0.299 \cdot R' + 0.587 \cdot G' + 0.114 \cdot B' \\
 Cr &= (R' - Y) \cdot 0.713 + 0.5 \\
 Cb &= (B' - Y) \cdot 0.564 + 0.5
 \end{aligned} \tag{3.1}$$

### 3.1.2 Alt örnekleme

Alt örnekleme aşamasında, Y, Cr ve Cb kanalları için ayrı ayrı 8 x 8'lik bloklar şeklinde kesitlere ayrılır. Ardından, bir sonraki adım olarak ayrık kosinüs dönüşümüne geçilerek bu bloklar kullanılır. Her bir blok, bağımsız olarak sıkıştırılmak üzere tasarlanmıştır. Eğer görüntünün boyutu 8'in katlarından farklı ise, en yakın 8'in katına tamamlayacak şekilde piksel yüksekliği ve genişliği artırılır.

### 3.1.3 Ayırık kosinüs dönüşümü

JPEG sıkıştırma algoritması, görüntü piksellerinin frekans uzayında temsil etmek için zaman uzayında bulunan görüntü değerlerinin kosinüs işaretlerinin toplanması yöntemini kullanır. Bu yöntem, 1972 yılında ortaya atılan ayırık kosinüs dönüşümü (AKD) olarak bilinir ve haberleşme, işaret işleme, ses ve görüntü işleme, sıkıştırma alanlarında geniş bir şekilde kullanılmaktadır [56,57].

JPEG algoritmasında, görüntüler alt örnekleme adımında 8x8'lik bloklara bölünür. Bu bloklar daha sonra ayırık kosinüs dönüşümü ile frekans uzayında temsil edilir. Frekans uzayındaki işaret temsili, Denklem 3.2, 3.3, 3.4 eşitlikleri kullanılarak hesaplanır.

$$F(u, v) = C(u) \cdot C(v) \cdot \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \cdot \cos\left(\frac{(2x+1)u\pi}{2M}\right) \cdot \cos\left(\frac{(2y+1)v\pi}{2N}\right) \quad (3.2)$$

$$C(u) = \begin{cases} \frac{1}{\sqrt{M}}, & u = 1 \\ \frac{1}{2}, & u \neq 1 \end{cases} \quad (3.3)$$

$$C(v) = \begin{cases} \frac{1}{\sqrt{N}}, & v = 1 \\ \frac{1}{2}, & v \neq 1 \end{cases} \quad (3.4)$$

$F(u, v)$  çıkış frekans uzayında temsil edilen bilgi,  $F(x, y)$  zaman uzayındaki bilgiyi temsil etmektedir.  $x$  ve  $y$  değerleri zaman uzayındaki piksel konumlarına karşılık gelirken  $u$  ve  $v$ , ayırık kosinüs dönüşümünün frekans bileşenleridir.  $x, u = 0, 1, \dots, M-1$  ve  $y, v = 0, 1, \dots, N-1$  değerlerini alır.

### 3.1.4 Nicemleme matrisi ve kalite değeri

JPEG sıkıştırma algoritması, ayırık kosinüs dönüşümü ile elde edilen frekans katsayılarının bir kısmının atılmasıyla gerçekleştirilir. Her 8x8 bloktaki frekans katsayıları, nicemleme değerine bölünerek elde edilen sonuçtaki ondalık kısımlar kaybolur. Bu işlem için her frekans katsayısında karşılık gelen bir değer gereklidir. Bu nedenle, bu değerlerin oluşturduğu 8x8'lik bir nicemleme matrisi kullanılır.

JPEG sıkıştırma algoritmasında sıkıştırma oranı, kullanıcı tarafından ayarlanabilir. Sıkıştırma oranı arttıkça kayıplar da artar ve elde edilen görüntünün kalitesi düşer.

Kalite değeri (K), 0 ile 100 arasında bir değeri alabilir. K değeri 0'a yaklaştıkça sıkıştırma oranı artar ve görüntü kalitesi düşer.

Nicemleme faktörü, kalite değerine göre belirlenir. Denklem 3.5'de değışen K değerine göre nicemleme faktörünün nasıl hesaplanacağı gösterilmiştir.

$$NF = \begin{cases} 200 - 2K, & K > 50 \\ \frac{5000}{K}, & K \leq 50 \end{cases} \quad (3.5)$$

Taban matrisi, tüm 8x8 bloklar için sabit kabul edilir. Taban matrisi Denklem 3.6'de verilmiştir. Taban matrisindeki büyük satır ve sütun indislerinin değeri yüksek seçilir. Bu nedenle yüksek değeri görüntü üzerindeki yüksek frekans katsayılarını etkiler.

$$NF \cdot \begin{pmatrix} 16 & 11 & 10 & 16 & 24 & 40 & 51 & 61 \\ 12 & 12 & 14 & 19 & 26 & 58 & 60 & 55 \\ 14 & 13 & 16 & 24 & 40 & 57 & 69 & 56 \\ 14 & 17 & 22 & 29 & 51 & 87 & 80 & 62 \\ 18 & 22 & 37 & 56 & 68 & 109 & 103 & 77 \\ 24 & 35 & 55 & 64 & 81 & 104 & 113 & 92 \\ 49 & 64 & 78 & 87 & 103 & 121 & 120 & 101 \\ 72 & 92 & 95 & 98 & 112 & 100 & 103 & 99 \end{pmatrix} + 50 \quad (3.6)$$

100

Nicemleme faktörü, taban matrisi ile çarpılıp 50 eklenerek sonrasında 100'e bölünüp 8x8'lik sıkıştırma matrisi elde edilir.

8x8'lik frekans katsayıları matrisinde yüksek frekans bileşenleri büyük indislerde yer alırken, düşük frekans bileşenleri düşük indislerde yer almaktadır. Frekans katsayıları ile sıkıştırma matrisi oranlandığında yüksek frekans bileşenlerinin bulunduğu indislerde yüksek değeriyle bölünme nedeniyle kayıplar meydana gelir.

JPEG sıkıştırma algoritmasında kayıplar bu aşamada gerçekleşir ve geri dönülmez bir işlem olduğundan kayıplar geri getirilemez.

### 3.1.5 Huffman kodlama yöntemi

Nicemleme faktörü ile bölünmüş ve kayıp yaşanmış tam sayı frekans katsayıları, son olarak kayıpsız bilgi kodlaması algoritmasına tabii tutulur. Bu kodlama işlemi

sırasında Huffman kodlaması, aritmetik kodlama, RLE gibi algoritmalar kullanılabilir [58]. Bu çalışma kapsamında Huffman kodlama yöntemi tercih edilmiştir.

Huffman kodlaması, kayıpsız veri sıkıştırma algoritması olarak bilgi teorisinde kullanılır [59]. Bu kodlama yönteminde, karakterlerin kullanım frekanslarına bakılarak kodlama gerçekleştirilir. Sık kullanılan karakterler daha kısa veri bitleriyle temsil edilirken nadir kullanılan karakterler daha uzun veri bitleriyle temsil edilir. Sıkıştırılmış veriler alıcı tarafından kodlama haritasını bildiğinden dolayı herhangi bir kayıp yaşanmadan geri dönüştürülebilir.

Kodlama sırasında tüm karakterlerin eşit olasılıkta olduğu durumlarda, Huffman kodlaması verimli bir sıkıştırma sağlayamaz. Örneğin, rastgele değerlerden oluşturulmuş bir veri kümesinde bütün verilerin görülme sıklığı eşit olduğundan, Huffman kodlaması tüm bilgiyi aynı sayıda bit ile temsil etmek zorunda kalır.

### **3.2 Geri Elde Etme Adımları**

Sıkıştırılmış görüntünün orijinal hâline dönüştürülmesi için sıkıştırma yönteminin adım adım tersine çevrilmesi gerekmektedir. Huffman kodlaması kullanılarak kayıpsız bir şekilde sıkıştırılmış görüntülerin alıcı tarafında karakter frekans haritası kullanılarak frekans katsayıları geri elde edilir. Nicemleme matrisi ile frekans katsayıları, Denklem 3.5'e göre sıkıştırılmıştır. Geri açma aşamasında bu işlemin matematiksel olarak tam tersine çevrilmiş işlemler uygulanır. Ters ayırık kosinüs dönüşümü (TAKD) ile frekans uzayındaki katsayılar zaman uzayına dönüştürülür. Her 8x8'lik blok geri elde edildiğinde, görüntü kayıplı bir şekilde zaman uzayında elde edilmiştir.



## 4. DENEYSEL SONUÇLAR

### 4.1 Kalite Metrikleri

Düşük çözünürlüklü sıkıştırılmış ve kayıp yaşanmış görüntülerin, süper çözünürlük modelleri kullanıldıktan sonraki performansını ölçmek amacıyla çeşitli metriklere ihtiyaç duyulmaktadır. Tepe İşaret Gürültü Oranı (Peak Signal Noise Ratio, PSNR) ve Yapısal Benzerlik İndeksi (Structural Similarity Index, SSIM) metrikleri, iki görüntü arasındaki benzerlikleri ölçme konusunda kullanılmaktadır [15].

#### 4.1.1 PSNR

PSNR, görüntü ve ses işaretlerinin bozulmuş haliyle karşılaştırılması için kullanılan, görüntülerin piksel yoğunluklarına odaklanan bir metriktir. PSNR metriğinin denklemi Denklem 4.1'da verilmiştir. Performansı desibel (dB) cinsinden hesaplamak için, Ortalama Kareler Hatası (MSE - Mean Square Error) değeri kullanılarak logaritması alınmıştır. MSE değeri Denklem 4.2'de verilmiştir.

$$PSNR(f, g) = 10 \cdot \log_{10} \left( \frac{255^2}{MSE(f, g)} \right) \quad (4.1)$$

$$MSE(f, g) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (f_{ij} - g_{ij})^2 \quad (4.2)$$

#### 4.1.2 SSIM

SSIM metriği, insanın görsel algısına daha yakın sonuç verir. PSNR metriği gibi piksel yoğunluğuna odaklanmaz. Bu metriğin hesaplanması için üç farklı değere ihtiyaç vardır: Parlaklık, kontrast ve yapısal benzerlik.

Parlaklık benzerliği Denklem 4.3'de verilmiştir. İki görüntünün parlaklık bileşen değerlerinin benzerliğini ölçer. Bunun için iki görüntünün ortalama piksel değerleri çarpılır ve ortalama değerlerin karesinin toplamına bölünür. Kontrast benzerliği,

Denklem 4.4’de verilmiştir. İki görüntünün kontrast bileşenleri arasındaki benzerliği ölçer. Bunun için görüntülerin standart sapmalarının çarpım sonucunu, standart sapmaların karelerinin toplamına bölümüyle elde edilir. Yapısal benzerlik, Denklem 4.5’de verilmiştir. Görüntülerin yapısal bileşenlerinin benzerliğine odaklanır. Görüntülerin birlikte standart sapmalarının, ayrı standart sapmalarının çarpımının bölünmesiyle hesaplanır. Elde edilen parlaklık, yapısal ve kontrast değerlerinin çarpılmasıyla SSIM değeri elde edilir.

$$l(f, g) = \frac{2\mu_f\mu_g + C_1}{\mu_f^2 + \mu_g^2 + C_1} \quad (4.3)$$

$$c(f, g) = \frac{2\sigma_f\sigma_g + C_2}{\sigma_f^2 + \sigma_g^2 + C_2} \quad (4.4)$$

$$s(f, g) = \frac{\sigma_{fg} + C_3}{\sigma_f\sigma_g + C_3} \quad (4.5)$$

$$SSIM(f, g) = l(f, g) \cdot c(f, g) \cdot s(f, g) \quad (4.6)$$

## 4.2 Veri Kümeleri

Modeller eğitilirken ImageNet, test edilirken süper çözünürlük kalite test (benchmark) verilerinden olan SET5, SET14, BSDS100, BSDS200, General100 veri kümeleri kullanılmıştır.

### 4.2.1 ImageNet

ImageNet veri seti, süper çözünürlük modellerinin eğitim aşamasında kullanılmıştır [60]. Geniş bir görüntü havuzuna sahip olan bu veri kümesi içerisinde büyük ve çeşitli türde görüntülerden oluşmaktadır. Yaklaşık olarak 1.4 milyon görüntü içermekte olup her gün yeni görüntüler eklenmektedir. Bu veri havuzu, 2010 yılında düzenlenen "ImageNet Large Scale Visual Recognition Challenge" (ILSVRC) yarışması ile geniş çapta tanınmıştır. Kullandığımız modellerin eğitilmesi için, rastgele seçilen 50.000 fotoğraf kullanılmıştır. Bu veri seti, süper çözünürlük,

nesne tanıma, segmentasyon, sınıflandırma gibi çeşitli derin öğrenme yaklaşımlarında kullanılmaktadır. Bu veri kümesi, sadece araştırma amacıyla kullanmak istenildiğinde ücretsiz olarak sunulmaktadır. Ancak ticari kullanımlar için doğrudan kullanım uygun değildir.



**Şekil 4.1 :** ImageNet veri kümesi örnek görüntüler.

#### 4.2.2 Set5

Set5 veri kümesi, süper çözünürlük çalışmalarında yaygın olarak kullanılan bir veri kümesidir [9]. İçerisinde 5 adet düşük çözünürlüklü görüntü bulunmaktadır. Bu görüntüler, gerçek hayattan alınmış kelebek, bebek, zürafa gibi fotoğraflardan oluşmaktadır. Bu veri kümesi, süper çözünürlük algoritmalarının gerçek dünya örneklerinde nasıl bir sonuç üreteceğini göstermek amacıyla büyük önem taşımaktadır.



**Şekil 4.2 :** Set5 veri kümesi örnek görüntüler.

### 4.2.3 Set14

Set14 veri kümesi, Set 5 ile aynı verileri içeren ve üzerine 9 farklı görüntünün eklenmesiyle oluşturulmuş bir veri kümesidir [9]. Bu ilave görüntüler, tamamen gerçek dünyadan alınmış görüntülerden oluşmaktadır. Bu genişletilmiş veri kümesi, Set5 veri kümesinde olduğu gibi modellerin gerçek dünya senaryolarında nasıl performans göstereceğini değerlendirmek için kullanılmaktadır.



Şekil 4.3 : Set14 veri kümesi örnek görüntüler.

### 4.2.4 BSDS100

BSDS100 veri kümesi, 100 farklı görüntüden oluşmaktadır ve parazit giderme, görüntü segmentasyonu, kenar tespiti ve süper çözünürlük gibi alanlarda sıkça kullanılmaktadır [61]. Bu veri kümesi, gerçek dünyadan alınmış insan, doğa, gıda gibi çeşitli verileri içermektedir. Görüntüler, farklı uygulama alanlarında modellerin performansını değerlendirmek için kullanılmaktadır.



Şekil 4.4 : BSDS100 veri kümesi örnek görüntüler.

#### 4.2.5 BSDS200

BSDS200 veri kümesi, BSDS100'ün genişletilmiş halidir [61]. İçerisinde ekstradan 100 adet daha görüntü barındırmaktadır. Genişletilmiş olan bu veri kümesi modellerin performanslarını değerlendirmek için kullanılmaktadır.



Şekil 4.5 : BSDS200 veri kümesi örnek görüntüler.

#### 4.2.6 General100

General100 veri kümesi, özellikle süper çözünürlük çalışmaları için oluşturulmuştur. Bu veri kümesi, 100 adet BMP formatındaki görüntü içermektedir. Görüntülerin orijinal hali korunmuş ve herhangi bir sıkıştırma yöntemi uygulanmamıştır. Bu görüntüler, farklı çözünürlüklerde değişen boyutlara sahiptir, 710 x 710 ile 131 x 112 arasında değişmektedir. Bu görüntüler, gerçek dünyadan alınmış ve çeşitli sahneleri temsil eden görüntülerden oluşmaktadır. Bu veri kümesi, süper çözünürlük algoritmalarının performansını değerlendirmek için kullanılmaktadır.




Şekil 4.6 : General100 veri kümesi örnek görüntüler.


### 4.3 SRCNN Eğitim Sonuçları

SRCNN modeli eğitim aşamasında kullanılan hiper-parametre değerleri, orijinal çalışmadaki değerler ile benzer seçilmiştir. Modelin eğitim sırasında kullanılan hiper-parametre değerleri şu şekildedir: Görüntü boyutu 32 x 32, yığın (batch) uzunluğu 16 ve döngü sayısı (epoch) 10,000 olarak belirlenmiştir. Optimizasyon algoritması olarak Stokastik Gradyen Azaltma (Stochastic Gradient Descent, SGD) seçilmiştir. Eğitim adımı (learning rate) 0.001 olarak ayarlanmıştır ve L2 regülasyon parametre değeri (weight decay) 0.001 olarak kullanılmıştır. Kayıp fonksiyonu olarak MSE kullanılmıştır. Denklem 4.2’de MSE fonksiyonu verilmiştir.


SRCNN modelindeki öğrenilebilir parametre sayısı sınırlı olduğundan, eğitim sürecinde daha fazla döngü (epoch) değeri kullanılması tercih edilmiştir. Bu durum, her bir döngünün kısa sürmesine rağmen yüksek döngü sayısı nedeniyle uzun süren eğitim sürelerine yol açmıştır. Modelin her bir yineleme (iteration) için kayıp fonksiyonu değeri Şekil 4.7’de verilmiştir. PSNR ve SSIM değerlerinin her bir döngü değişimleri Şekil 4.8 ve 4.9’te verilmiştir. Her bir kalite değeri için oluşturulan görüntüler sadece ilgili model için test edilmiştir. Farklı kalite değeri için eğitilen modellere farklı kalite değeri ile sıkıştırılmış görüntüler ile test edildiğinde performansları aynı kalite değerine sahip modelden daha düşük ölçülmüştür. Bu durum, modellerin kalite değerlerine duyarlı olduğunu göstermektedir. PSNR ve SSIM metriklerine dayalı analizler, her bir öğrenme işlemi sırasında model performansının arttığını göstermektedir.



**Şekil 4.7 :** Farklı K değerinde SRCNN kayıp fonksiyon sonuçları.




**Şekil 4.8 :** Farklı K değerinde SRCNN PSNR metrik sonuçları.




**Şekil 4.9 :** Farklı K değerinde SRCNN SSIM metrik sonuçları.


Şekil 4.10, 4.11, 4.12, 4.13 ve 4.14'da, Set5 ve BSDS100 veri kümelerinden alınan örneklerin model üzerindeki performansı görülmektedir.




Şekil 4.10 : Set5 veri kümesi bebek görüntüsü SRCNN çıktısı.



Şekil 4.11 : Set5 veri kümesi çocuk görüntüsü SRCNN çıktısı.



Şekil 4.12 : Set5 veri kümesi kelebek görüntüsü SRCNN çıktısı.



Şekil 4.13 : BSDS100 veri kümesi bina görüntüsü SRCNN çıktısı.



**Şekil 4.14** : BSDS100 veri kümesi zebra görüntüsü SRCNN çıktısı.


Genel olarak, SRCNN modeli tüm kalite değerleri için başarılı sonuçlar üretmektedir. Ancak, elde edilen görüntülerde yapaylık belirtileri ortaya çıkmıştır. Eğitim işlemi belirli bir döngü (epoch) sayısı ile sınırlanmıştır. Şekil 4.8, 4.9 ve 4.7’teki grafiklerden görüleceği üzere, modelin performansını artırmak için daha yüksek bir döngü sayısının gerektiği görülmektedir. Ancak bu çalışmada, döngü sayısı 10,000 ile sınırlı tutulmuştur.

#### 4.4 VDSR Eğitim Sonuçları

VDSR modelinin orijinal çalışmasında kullanılan hiper-parametre değerlerine sadık kalınmıştır. Modelin eğitim sırasında kullanılan hiper-parametre değerleri şu şekildedir: Görüntü boyutu 41 x 41, yığın (batch) boyutu 16 ve döngü sayısı (epoch) 200 olarak belirlenmiştir. Optimizasyon algoritması olarak Stokastik Gradyen Azaltma (Stochastic Gradient Descent, SGD) seçilmiştir. Momentum değeri 0.9 ve L2 regülasyon parametresi (weight decay) 0.001 olarak kullanılmıştır. Kayıp fonksiyonu olarak MSE kullanılmıştır. Denklem 4.2’de MSE fonksiyonu verilmiştir. Eğitim adımı (learning rate) 0.01 olarak başlamış, dinamik olarak değiştirilmiştir. Her 4 döngü sonrasında eğitim adımı azaltılmış ve evrensel minimuma daha kısa adım uzunluklarıyla yaklaşılmaya çalışılmıştır.


VDSR modelinde öğrenilebilir parametre sayısı, SRCNN modeline göre oldukça yüksektir. Bu durum, modelin çok derin ve karmaşık olduğu anlamına gelmektedir. Katman ve derinlik sayısı fazlalığından dolayı katmanlarda bulunan filtrelerde farklı ve çok sayıda özellik çıkarımı yapılmaktadır. Bu durum, her bir eğitim döngüsünün uzun sürmesine neden olur. Çünkü her yineleme (iteration) sonucunda geri yayılım (back-propagation) işlemi sırasında çok sayıda katsayı güncellenmektedir. Ayrıca, eğitim ve test adımlarında çok fazla matematiksel işlem gerektiğinden modelin işlem hızını düşürmektedir. Modelin yineleme bazında kayıp fonksiyonunun değeri Şekil 4.15’de gösterilmiştir.

Modelin performansı PSNR ve SSIM metrikleri kullanılarak ölçülmüştür. Şekil 4.16 ve 4.17’te PSNR ve SSIM metriklerinin her bir döngü (epoch) için hesaplanan değerleri verilmiştir. Grafikler, 5 farklı K (Kalite Değeri) için sonuçları göstermektedir.




**Şekil 4.15 :** Farklı K değerinde VDSR kayıp fonksiyon sonuçları.

Her bir kalite değeri için farklı bir model eğitilmiş ve her bir modelde yalnızca o kalite değeri ile sıkıştırılmış görüntüler kullanılmıştır.



**Şekil 4.16 :** Farklı K değerinde VDSR PSNR metrik sonuçları.

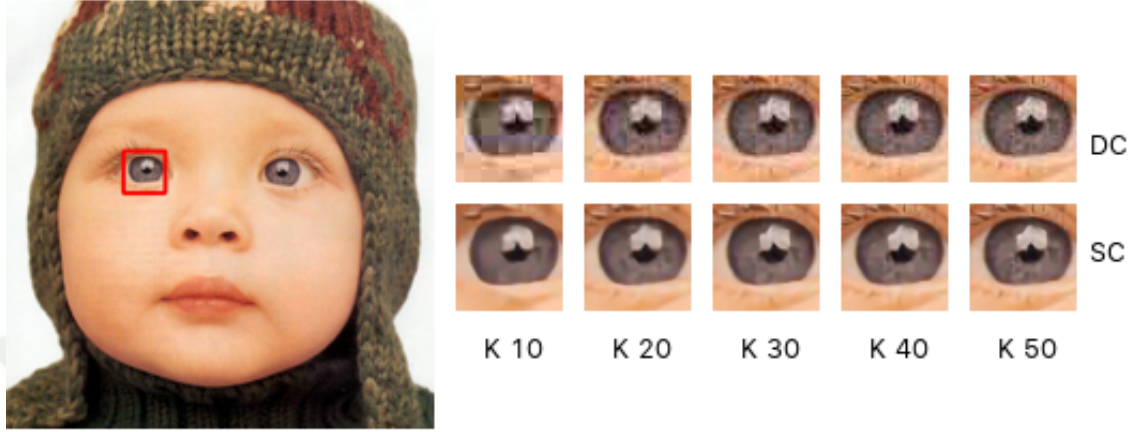


**Şekil 4.17 :** Farklı K değerinde VDSR SSIM metrik sonuçları.


Test aşamasında, farklı kalite değerleri için eğitilmiş modeller, farklı bir kalite değeri ile sıkıştırılmış görüntülerle test edilmiştir. Ancak bu durumda performans dramatik

bir şekilde düşmüştür. Bu nedenle VDSR modeli, SRCNN modeli gibi kalite değerine duyarlıdır.


Şekil 4.18, 4.19, 4.20, 4.21 ve 4.22'de Set5 ve BSDS100 veri kümelerinden alınan örneklerin model üzerindeki performansı görülmektedir.




Şekil 4.18 : Set5 veri kümesi bebek görüntüsü VDSR çıktısı.



Şekil 4.19 : Set5 veri kümesi çocuk görüntüsü VDSR çıktısı.



**Şekil 4.20 :** Set5 veri kümesi kelebek görüntüsü VDSR çıktısı.



**Şekil 4.21 :** BSDS100 veri kümesi bina görüntüsü VDSR çıktısı.

Genel olarak, VDSR modeli tüm kalite değerlerinde başarılı sonuçlar üretmiş ve görüntülerde gözle görülür derecede iyileşme sağlamıştır. SRCNN modeli ile karşılaştırıldığında, görüntülerde daha fazla iyileşme elde edilmiştir. Model eğitimi için döngü (epoch) sayısı 200 olarak belirlenmiş ve belirli bir noktadan sonra daha fazla iyileşme görülmediği için bu sayı daha da artırılmamıştır.




**Şekil 4.22 :** BSDS100 veri kümesi zebra görüntüsü VDSR çıktısı.

#### 4.5 SRDenseNet Eğitim Sonuçları

Diğer modellerde olduğu gibi SRDenseNet modelinin de hiper-parametre değerleri orijinal çalışmada bulunan değerlere sadık kalınarak seçilmiştir. Eğitim aşamasında tüm K değerleri için kullanılan hiper-parametre değerleri şu şekildedir: Görüntü boyutu 100 x 100'dür, yığın (batch) boyutu 32'dir ve toplam döngü sayısı (epoch) 30 olarak belirlenmiştir. SRCNN ve VDSR modellerinin aksine, optimizasyon algoritması olarak Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation, ADAM) kullanılmıştır. Eğitim adımı (learning rate) 0.001 olarak seçilmiş ve eğitim süresince sabit olarak kabul edilmiştir. L2 regülasyon parametresi (weight decay) 0 olarak ayarlanmış, bu nedenle herhangi bir regülasyon işlemi uygulanmamıştır. Kayıp fonksiyonu olarak MSE kullanılmıştır. Denklem 4.2'de MSE fonksiyonu verilmiştir.


SRCNN, VDSR ve SRDenseNet modelleri karşılaştırıldığında, öğrenilebilir parametre sayısı en fazla SRDenseNet modelinde bulunmaktadır. SRDenseNet modeli, içerisinde barındırdığı yoğun (dense) bloklar sayesinde çok karmaşık bir yapıya sahiptir. Bu nedenle eğitim süreleri karşılaştırıldığında, en uzun süren model SRDenseNet'tir. Modelin yineleme (iterasyon) bazında kayıp fonksiyonunun değeri Şekil 4.23'de gösterilmiştir.

Modelin performansı PSNR ve SSIM metrikleri kullanılarak değerlendirilmiştir. Şekil 4.24 ve 4.25'te, PSNR ve SSIM metriklerinin her bir döngü (epoch) için hesaplanan değerleri sunulmuştur. Grafikler, 5 farklı K (Kalite Değeri) için elde edilen sonuçları göstermektedir. Her bir kalite değeri için ayrı bir model eğitilmiş ve her bir modelde sadece ilgili kalite değeri ile sıkıştırılmış görüntüler kullanılmıştır.




**Şekil 4.23 :** Farklı K değerinde SRDenseNet kayıp fonksiyon sonuçları.

Test aşamasında, farklı kalite değerleri için eğitilmiş modeller, farklı bir kalite değeri ile sıkıştırılmış görüntülerle test edilmiştir. Ancak bu durumda performansı dramatik bir şekilde düşmüştür. Bu nedenle SRDenseNet modeli, SRCNN ve VDSR modellerinde olduğu gibi kalite değerine duyarlıdır.




**Şekil 4.24 :** Farklı K değerinde SRDenseNet PSNR metrik sonuçları.


Şekil 4.26, 4.27, 4.28, 4.29 ve 4.30'de Set5 ve BSDS100 veri kümelerinden alınan örneklerin model üzerindeki performansı görülmektedir.




Şekil 4.25 : Farklı K değerinde SRDenseNet SSIM metrik sonuçları.



Şekil 4.26 : Set5 veri kümesi bebek görüntüsü SRDenseNet çıktısı.



**Şekil 4.27 :** Set5 veri kümesi çocuk görüntüsü SRDenseNet çıktısı.



**Şekil 4.28 :** Set5 veri kümesi kelebek görüntüsü SRDenseNet çıktısı.

SRDenseNet modeli tüm kalite değerlerinde elde edilen performansı SRCNN ve VDSR'a göre daha başarılıdır. Modeli eğitmek düşük bir döngü (epoch) değeri seçilmesine karşın öğrenilebilir parametre sayısının fazlalığından dolayı eğitim ve test süreleri diğer modellere göre daha fazladır ve model daha yavaş çalışmaktadır.



Şekil 4.29 : BSDS100 veri kümesi bina görüntüsü SRDenseNet çıktısı.



Şekil 4.30 : BSDS100 veri kümesi zebra görüntüsü SRDenseNet çıktısı.

#### 4.6 Sonuçların Karşılaştırılması

Modeller, eğitilirken aynı kalite değerinde sıkıştırılmış veriler kullanılmıştır. Örneğin kalite değeri 10 olan sıkıştırılmış verilerle eğitilen model, test aşamasında yalnızca 10 kalite değerine sahip test verileriyle test edilmiştir. Farklı kalite değerleriyle yapılan testlerde, model performanslarının düşük olduğunu tespit edilmiştir. Çizelge 4.1, 4.2, 4.3, 4.4 ve 4.5'te sırasıyla Kalite değeri 10, 20, 30, 40 ve 50 için sonuçlar sunulmuştur.

Her bir veri kümesi, verilen kalite değeriyle sıkıştırılmış ve çizelgelerde "SO (Sıkıştırma Oranı)" sütununda belirtilmiştir. "JPEG (SR Yok)" sütunlarındaki değerler, süper çözünürlük yöntemi kullanılmadan sıkıştırılmış ve geri elde edilen görüntülerin karşılaştırılması sonuçlarını içermektedir. Bu sütun değerleri, süper çözünürlük modellerinin performanslarını karşılaştırmak için kullanılmıştır. Her bir veri kümesi için PSNR/SSIM metrikleri sonuçları hesaplanmıştır.

Çizelgelerden görüleceği üzere, kalite değeri düştükçe sıkıştırma oranının arttığı gözlemlenmektedir. Ancak aynı oranda görüntü kalitesi de düşmektedir.

SRCNN modeli, eğitim süresi ve test cevap süresi açısından diğer modellere göre daha avantajlıdır. Bu sayede test aşamasında daha hızlı sonuçlar üretebilmektedir. Bu nedenle kaynak kullanımı açısından en iyi model SRCNN modeli olarak değerlendirilebilir.

VDSR modeli, çok derin bir ağ modeline sahiptir ve performans açısından SRCNN modelinin önündedir. PSNR ve SSIM metriklerine göre genellikle SRCNN ve SRDenseNet modelleri arasında bir konumdadır. Modelin eğitim süresi uzun olmasına rağmen test görüntülerini hızlı bir şekilde süper çözünürlük görüntülerine dönüştürebilmektedir.

SRDenseNet modeli, Şekil 4.26, 4.27, 4.28, 4.29 ve 4.30'e bakıldığında gözle görülür bir şekilde başarılı sonuçlar üretmektedir. Bütün kalite değerlerinde en başarı PSNR ve SSIM metrik sonuçları SRDenseNet modeline aittir. Model yoğun katmanlardan oluşmakta ve bu durum eğitim ve test sürelerini uzatmaktadır.

Eğitim ve test süreleri göz önüne alındığında, SRCNN modeli kaynak kullanımı açısından verimli bir seçenekken, performans açısından SRDenseNet modeli en etkili model olarak öne çıkmaktadır.

Görüntülerdeki yapaylıkların giderilmesi gereken durumlarda, SRCNN modeli hem eğitim süreleri hem de kaynak tüketimi açısından en uygun seçenek olarak öne çıkmaktadır. Yapaylıkların yanı sıra bulanıklıkların giderilmesi ve daha net bir görüntü elde etme isteği durumunda, VDSR ve SRDenseNet modelleri önerilmektedir. VDSR ve SRDenseNet modellerinin kendi içinde kıyaslaması yapıldığında, SRDenseNet modeli daha başarılı sonuçlar elde etmektedir. Ancak SRDenseNet modelinin yoğun

ađ yapısından kaynaklı eđitim ve test ařamasında verdiđi tepki sũresi ok uzundur. Bu durum kaynak tũketimini de arttırmaktadır. Kaynak sorunu olmayan ve daha berrak bir gũrũntũ istendiđi durumda SRDenseNet modelinin kullanılması ȃnerilmektedir.



**Çizelge 4.1** : K = 10, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO).

Veri	SO (%)	JPEG (SR Yok)	SRCNN	VDSR	SR DenseNet
SET5	96.70	29.87/0.82	30.36/0.85	31.71/0.88	32.00/0.89
SET14	96.89	28.44/0.78	28.57/0.80	29.97/0.83	30.22/0.85
BSDS100	97.10	27.87/0.76	27.93/0.77	28.92/0.79	29.16/0.80
BSDS200	97.04	28.38/0.78	28.45/0.79	29.52/0.82	29.82/0.83
General100	98.44	29.84/0.83	30.08/0.85	31.60/0.88	32.10/0.89

**Çizelge 4.2** : K = 20, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO).

Veri	SO (%)	JPEG (SR Yok)	SRCNN	VDSR	SR DenseNet
SET5	95.56	32.37/0.88	32.79/0.90	34.00/0.92	34.34/0.92
SET14	95.28	30.69/0.85	30.85/0.87	32.22/0.88	32.30/0.88
BSDS100	95.48	29.89/0.84	30.00/0.85	31.08/0.86	31.28/0.87
BSDS200	95.47	30.51/0.85	30.65/0.86	31.79/0.88	32.03/0.89
General100	97.67	32.40/0.89	32.67/0.90	34.17/0.92	34.63/0.93

**Çizelge 4.3** : K = 30, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO).

Veri	SO (%)	JPEG (SR Yok)	SRCNN	VDSR	SR DenseNet
SET5	94.35	33.82/0.90	34.16/0.92	35.27/0.93	35.69/0.93
SET14	93.94	31.92/0.88	32.03/0.89	33.52/0.91	33.50/0.91
BSDS100	94.16	31.07/0.87	31.10/0.88	32.37/0.89	32.55/0.90
BSDS200	94.19	31.72/0.89	31.80/0.90	33.13/0.91	33.34/0.91
General100	97.04	33.82/0.91	34.02/0.92	35.59/0.94	36.03/0.94

**Çizelge 4.4** : K = 40, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO).

Veri	SO (%)	JPEG (SR Yok)	SRCNN	VDSR	SR DenseNet
SET5	93.41	34.74/0.92	34.98/0.93	36.01/0.94	36.52/0.94
SET14	92.84	32.78/0.90	32.72/0.91	34.40/0.92	34.31/0.92
BSDS100	93.04	31.91/0.89	31.74/0.90	33.30/0.91	33.43/0.92
BSDS200	93.11	32.57/0.90	32.47/0.91	34.07/0.92	34.21/0.93
General100	96.52	34.80/0.93	34.86/0.94	36.55/0.95	36.93/0.95

**Çizelge 4.5** : K = 50, test sonuçları (PSNR/SSIM) ve sıkıştırma oranı (SO).

Veri	SO (%)	JPEG (SR Yok)	SRCNN	VDSR	SR DenseNet
SET5	92.21	35.55/0.93	35.86/0.94	36.82/0.95	37.29/0.95
SET14	91.78	33.53/0.91	33.18/0.92	35.17/0.93	34.94/0.93
BSDS100	91.97	32.61/0.91	32.15/0.91	34.13/0.93	34.11/0.93
BSDS200	92.07	33.27/0.91	32.90/0.92	34.90/0.94	34.85/0.94
General100	96.03	35.58/0.94	35.44/0.94	37.33/0.96	37.54/0.96

## 5. SONUÇLAR VE GELECEK ÇALIŞMALAR

### 5.1 Özet ve Katkılar

Bu çalışma, bant genişliğinin etkin kullanımına odaklanarak, sıkıştırma yöntemlerine ve bu yöntemler sırasında oluşacak kayıpların geri kazanılmasına yönelik bir araştırmayı ele almıştır. Literatürdeki çeşitli yöntemler üzerinde detaylı bir inceleme yapılmış ve derin öğrenme yaklaşımlarına odaklanılmıştır. Büyük verilerin iletimi, haberleşme kanalının kapasitesini önemli ölçüde meşgul etmektedir. Bu durum veri iletiminde gecikmelere ve kayıplara yol açabilmektedir. Bu nedenle, bant genişliğinin etkin kullanımı büyük öneme sahiptir. Bant genişliği, haberleşme kanalı kullanılarak bu kanal üzerinde bir saniyede iletilen maksimum veri miktarını temsil etmektedir. Bant genişliğinin verimli kullanılması adına bu verilen sıkıştırılması ihtiyacı ortaya çıkmıştır. Verilerin kullanım alanlarına göre tercih edilen iki farklı sıkıştırma yöntemleri bulunmaktadır: kayıplı ve kayıpsız sıkıştırma. Kayıplı sıkıştırma, kullanıcının tercihine göre sıkıştırma oranının özelleştirilebileceği bir veri sıkıştırma tekniğidir. Bu teknik, veri boyutunu azaltmak için önemsiz, tekrarlı ve insan algısına etkisi düşük olan belirli veri parçalarının atılması ya da kodlanması yoluyla sıkıştırma yapar. Kayıplı sıkıştırma algoritmaları kullanıldığında, bazı veri parçaları kalıcı olarak kaybolur ve geri getirilemez. Kayıpsız sıkıştırma ise kullanıcının tercihine bırakılmayan, özelleştirilemeyen bir sıkıştırma tekniğidir. Bu teknik, veri boyutunu azaltmak için tekrarlı olan verileri azaltıp kodlama yöntemiyle sıkıştırma yapmasıyla sağlanır. Bu yöntemde herhangi bir veri kaybolmaz. Verinin kaybolacağı noktada sıkıştırma devam etmez ve orijinal veri geri elde edilmeye çalışıldığında herhangi bir kayıp söz konusu olmaz. Çalışma kapsamında özellikle web teknolojilerinde sıkça kullanılan JPEG algoritması derinlemesine incelenmiştir. Bu yöntem, web sayfalarında ve diğer dijital platformlarda görüntüleri daha düşük boyutlarda ve daha hızlı yükleyebilme avantajı sağlar. Bu nedenle, yüksek görüntü sıkıştırma oranları

tercih edilir. Ancak, JPEG algoritması kayıplı bir sıkıştırma tekniği olduğundan dolayı görüntülerde geri getirilemez hasarlar meydana getirmektedir.

Son yıllarda, süper çözünürlük alanında derin öğrenme tabanlı birçok çalışma yapılmış ve birçok model ortaya atılmıştır. Bu modeller, kalite veri kümelerinde yüksek başarılar elde etmişlerdir. Yapılan çalışmalar, interpolasyon tabanlı düşük çözünürlüklü görüntüler üzerinde iyileştirme sağlamayı konu almaktadır. Ancak, sıkıştırılmış ve kayıp yaşanmış düşük çözünürlüklü görüntüler üzerinde herhangi bir etkisi incelenmemiştir. Süper çözünürlük, bilgisayar biliminde düşük çözünürlüklü bir görüntüyü yüksek çözünürlüklü bir görüntüye dönüştürmeyi hedefler. Bu yöntem, görüntüdeki çeşitli nedenlerle kaybedilen ayrıntıları geri kazanarak daha yüksek kalitede görüntüler elde etmeyi amaçlar. Günümüzde, uydu görüntüleri, uzaktan algılama, tıbbi görüntüleme gibi birçok alanda yüksek çözünürlüklü görüntüler elde etmek için kullanılır. Bu çalışma kapsamında 3 farklı süper çözünürlük modeli incelenmiştir. SRCNN adı verilen ilk model, süper çözünürlük problemini derin öğrenme teknikleriyle inceleyen ilk çalışma olarak kabul edilir. Basit bir yapıya sahip olan bu modelin sıkıştırma kaybına verdiği tepki incelenmiştir. Modelin performansı beklenildiği gibi çok yüksek çıkmamıştır, ancak model, basit bir yapıya sahip olmasına rağmen tüm veri kümelerinde iyileşme göstermiştir. SRCNN modelinden sonra derin ağ mimarisine sahip VDSR modeli önerilmiştir. Bu model üzerinde gerekli eğitim işlemleri gerçekleştirilmiş ve başarılı sonuçlar elde edilmiştir. Ancak bu modelin eğitim süreleri ve test görüntülerine verdiği tepki hızı, kullanılması ve eğitilmesi SRCNN modeline göre çok daha zordur. Ancak performansı SRCNN modeline göre daha başarılıdır. Daha kompleks olan ve içerisinde çok fazla matematiksel işlem barındıran SRDenseNet modeli de bu çalışma kapsamında incelenmiştir ve bu model ile son derece başarılı sonuçlar elde edilmiştir. Modellerin basitliği ve kolay eğitilebilir olması göz önünde bulundurulduğunda SRCNN modeli en avantajlı model olarak seçilebilmektedir. Ancak performans göz önünde bulundurulduğunda SRDenseNet modeli hem sayısal hem de gözle görülür sonuçlarda açık ara en avantajlı model olarak karşımıza çıkmaktadır.

Literatürde süper çözünürlük modelleriyle yapılan çalışmalarda kullanılan görüntüler, kübik interpolasyon yöntemiyle aşağıya indirgenmiş ve kayıp yaşanmış görüntüler

kullanılmıştır. Bu nedenle bu çalışmalarda, bu modellerin sıkıştırma kayıplarına nasıl tepki vereceği incelenmemiştir. Yapılan bu çalışma, süper çözünürlük modellerinin yalnızca kübik interpolasyon yöntemiyle değil, aynı zamanda JPEG sıkıştırma kaybını da geri kazanabileceğini göstermektedir. Bu çalışma, gelecekte yapılacak birçok çalışmaya öncülük edecektir. Bu nedenle bu çalışmanın literatüre önemli bir katkısı bulunmaktadır.

## 5.2 Gelecekteki Çalışmalar

Çalışma sonucunda elde edilen sonuçlara bakıldığında, ileriye dönük bir çok farklı yeni çalışma yapılabileceği ortaya çıkmıştır.

JPEG sıkıştırma adımlarında ayırık kosinüs dönüşümü ile elde edilen frekans katsayıları,  $8 \times 8$ 'lik örneklem matrislerine bölünmektedir. Bu bölme işlemi nedeniyle elde edilen görüntülerde kare şeklinde yapaylıklar oluşmaktadır. Süper çözünürlük yöntemleri bu yapaylıkları azaltmada yardımcı olsa da dikkatli bakıldığında hala gözle görülür yapaylıklar fark edilmektedir. Bu yapaylıkların giderilmesi için dikkat mekanizmasına sahip bir modül, modellerin bu yapaylıkları azaltma konusunda yönlendirilmesini sağlayarak eklenebilir. Ayrıca elde edilen görüntüler üzerinde bazı görüntü işleme teknikleriyle bu yapaylıklar azaltılabilir.

Modeller eğitilirken birbirleriyle ilişkisi olmayan görüntülerden oluşan ImageNet veri kümesi kullanılmıştır. Örneğin, uydu görüntüleme, tıbbi cihaz görüntüleme gibi belirli alanlara özgü verilerle eğitilmiş modellerin performansı gözlemlenebilir. Bu çalışma, sıkıştırma konusunu ele almış ve daha önceki modellerin performansı incelendiğinden ImageNet veri kümesi kullanılmıştır. Bu nedenle gelecekte, farklı alanlara özgü veri kümeleriyle modeller eğitilebilir ve sonuçlar gözlemlenebilir.

Her bir kalite değeri için ayrı bir model eğitilerek baştan oluşturulmuştur. Herhangi bir transfer öğrenme yöntemi veya ince ayar işlemi uygulanmamıştır. Test aşamasında farklı kalite değerleriyle testler yapılmış olsa da, başarı oranı dramatik bir şekilde düşmüştür. Gelecekte yapılacak bir çalışmayla kalite değeri bağımsız modeller oluşturulabilir ve model eğitimleriyle kaybedilen süreler azaltılabilir.

Çalışma kapsamında kullanılan modellerden SRCNN, çok ilkel bir modeldir. Diğer modellerden VDSR ve SRDenseNet ise artık öğrenme yöntemi kullanmaktadır. Süper çözünürlük probleminde kullanılacak diğer öğrenme paradigmaları gelecekte kullanılabilir ve daha kapsamlı bir analizin temelini oluşturabilir.



## KAYNAKLAR

- [1] **Bolat, M., Çalık, N. ve Ata, L.D.** (2023). Recovering JPEG Compression Loss via Deep Learning-Based Super Resolution Techniques, *2023 31st Signal Processing and Communications Applications Conference (SIU)*, s.1–4.
- [2] **Routray, S., Mishra, P., Sarkar, S., Javali, A. ve Ramnath, S.** (2019). Communication Bandwidth for Emerging Networks: Trends and Prospects.
- [3] **Sayood, K.** (2006). In *The Morgan Kaufmann Series in Multimedia Information and Systems, Introduction to Data Compression (Third Edition)*, s.163–194.
- [4] **Sayood, K.** (2006). In *The Morgan Kaufmann Series in Multimedia Information and Systems, Introduction to Data Compression (Third Edition)*, s.1–11.
- [5] **Andrews, J.G., Buzzi, S., Choi, W., Hanly, S.V., Lozano, A., Soong, A.C.K. ve Zhang, J.C.** (2014). What Will 5G Be?, *IEEE Journal on Selected Areas in Communications*, 32(6), 1065–1082.
- [6] **Wikström, G., Peisa, J., Rugeland, P., Johansson, N., Parkvall, S., Girnyk, M., Mildh, G. ve Da Silva, I.L.** (2020). Challenges and Technologies for 6G, *2020 2nd 6G Wireless Summit (6G SUMMIT)*, s.1–5.
- [7] **C. Dong, C. C. Loy, K.H. ve Tang, X.** (2015). Image Super-Resolution Using Deep Convolutional Networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, NY, USA.
- [8] **Jiwon Kim, J.K.L. ve Lee, K.M.** (2016). Accurate Image Super-Resolution Using Very Deep Convolutional Networks, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA.
- [9] **T. Tong, G. Li, X.L. ve Gao, Q.** (2017). Image Super-Resolution Using Dense Skip Connections, *IEEE International Conference on Computer Vision (ICCV)*, Venice, Italy.
- [10] **Nuno-Maganda, M. ve Arias-Estrada, M.** (2005). Real-time FPGA-based architecture for bicubic interpolation: an application for digital image scaling, *2005 International Conference on Reconfigurable Computing and FPGAs (ReConFig'05)*, s.8 pp.–1.
- [11] **M. Iwahashi, T. M. Aye, T.Y. ve Kiya, H.** (2016). Subset noise bias compensation for tone-mapping and up-scaling of JPEG images, *IEEE International Symposium on Circuits and Systems (ISCAS)*, Montreal, QC, Canada.

- [12] **Chen, H., He, X., Ren, C., Qing, L. ve Teng, Q.** (2017). CISRDCNN: Super-resolution of compressed images using deep convolutional neural networks, *CoRR, abs/1709.06229*, <http://arxiv.org/abs/1709.06229>, 1709.06229.
- [13] **He, X., Chen, H., Chen, J. ve Qing, L.** (2017). Soft decoding of JPEG 2000 compressed images using bit-rate-driven deep convolutional neural networks, *2017 IEEE International Conference on Information and Automation (ICIA)*, s.843–847.
- [14] **Skodras, A., Christopoulos, C. ve Ebrahimi, T.** (2001). The JPEG 2000 still image compression standard, *IEEE Signal Processing Magazine*, 18(5), 36–58.
- [15] **Horé, A. ve Ziou, D.** (2010). Image Quality Metrics: PSNR vs. SSIM, *2010 20th International Conference on Pattern Recognition*, s.2366–2369.
- [16] **Kara, O., Uçurmak, , Karaca, A.C. ve Güllü, M.K.** (2020). Reduction of JPEG2000 Compression Artifacts using Very Deep Super Resolution Approach for Multitemporal Multispectral Images, *2020 28th Signal Processing and Communications Applications Conference (SIU)*, s.1–4.
- [17] **Can Karaca, A., Uçurmak, ve Kemal Güllü, M.** (2021). Efficient Resolution Enhancement of JPEG2000 Compressed Multispectral Images Using Deep Super-resolution Methods, *2021 International Conference on Innovations in Intelligent Systems and Applications (INISTA)*, s.1–6.
- [18] **Dufaux, F., Sullivan, G. ve Ebrahimi, T.** (2009). The JPEG XR image coding standard [Standards in a Nutshell], *Signal Processing Magazine, IEEE*, 26, 195–199, 204.
- [19] **Öztürk, E., Mesut, A. ve Carus, A.** (2016). Performance comparison of JPEG, JPEG2000 JPEG XR image compression standards, *2016 24th Signal Processing and Communication Application Conference (SIU)*, s.201–204.
- [20] **Min, T. ve Aramvith, S.** (2022). Performance Analysis of JPEG XR with Deep Learning-Based Image Super-Resolution, *Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*, Jeju Island, Korea (South).
- [21] **Chen, H., He, X., Qing, L., Xiong, S. ve Nguyen, T.Q.** (2018). DPW-SDNet: Dual Pixel-Wavelet Domain Deep CNNs for Soft Decoding of JPEG-Compressed Images, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, s.824–82409.
- [22] **S. Chang, J.K. ve h. Hahm, C.** (2020). Lightweight Super-resolution for Compressed Image, *IEEE International Conference on Consumer Electronics - Asia (ICCE-Asia)*, Seoul, Korea (South).

- [23] **Y. Tan, J. Cai, S.Z.W.Z. ve Ye, L.** (2016). Image Compression Algorithms Based on Super-Resolution Reconstruction Technology, *IEEE 4th International Conference on Image, Vision and Computing (ICIVC)*, Xiamen, China.
- [24] **Albalawi, U., Mohanty, S.P. ve Kougianos, E.** (2015). A Hardware Architecture for Better Portable Graphics (BPG) Compression Encoder, *2015 IEEE International Symposium on Nanoelectronic and Information Systems*, s.291–296.
- [25] **Hamis, S., Zaharia, T. ve Rousseau, O.** (2019). Image Compression at Very Low Bitrate Based on Deep Learned Super-Resolution, *2019 IEEE 23rd International Symposium on Consumer Technologies (ISCT)*, s.128–133.
- [26] **Park, S.C., Park, M.K. ve Kang, M.G.** (2003). Super-resolution image reconstruction: a technical overview, *IEEE Signal Processing Magazine*, 20(3), 21–36.
- [27] **Kawulok, M., Benecki, P., Piechaczek, S., Hrynczenko, K., Kostrzewa, D. ve Nalepa, J.** (2020). Deep Learning for Multiple-Image Super-Resolution, *IEEE Geoscience and Remote Sensing Letters*, 17(6), 1062–1066.
- [28] **Tan, H.H. ve Lim, K.H.** (2019). Vanishing Gradient Mitigation with Deep Learning Neural Network Optimization, *2019 7th International Conference on Smart Computing Communications (ICSCC)*, s.1–4.
- [29] **Hu, Z., Zhang, J. ve Ge, Y.** (2021). Handling Vanishing Gradient Problem Using Artificial Derivative, *IEEE Access*, 9, 22371–22377.
- [30] **Kim, J., Lee, J.K. ve Lee, K.M.** (2016). Deeply-Recursive Convolutional Network for Image Super-Resolution, 1511.04491.
- [31] **Tai, Y., Yang, J. ve Liu, X.** (2017). Image Super-Resolution via Deep Recursive Residual Network, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- [32] **Qiu, Y., Wang, R., Tao, D. ve Cheng, J.** (2019). Embedded Block Residual Network: A Recursive Restoration Model for Single-Image Super-Resolution, *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, s.4179–4188.
- [33] **He, K., Zhang, X., Ren, S. ve Sun, J.** (2016). Deep Residual Learning for Image Recognition, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, s.770–778.
- [34] **Larsson, G., Maire, M. ve Shakhnarovich, G.** (2017). *FractalNet: Ultra-Deep Neural Networks without Residuals*, 1605.07648.
- [35] **Huang, G., Liu, Z., van der Maaten, L. ve Weinberger, K.Q.** (2018). *Densely Connected Convolutional Networks*, 1608.06993.

- [36] **Lim, B., Son, S., Kim, H., Nah, S. ve Lee, K.M.** (2017). Enhanced Deep Residual Networks for Single Image Super-Resolution, *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, s.1132–1140.
- [37] **Yin, C., Rosendahl, L. ve Luo, Z.** (2003). Methods to improve prediction performance of ANN models, *Simulation Modelling Practice and Theory*, *11*, 211–222.
- [38] **Pan, S.J. ve Yang, Q.** (2010). A Survey on Transfer Learning, *IEEE Transactions on Knowledge and Data Engineering*, *22*(10), 1345–1359.
- [39] **Elizar, E., Zulkifley, M.A., Muharar, R., Mohd Zaman, M.H. ve Mustaza, S.** (2022). A Review on Multiscale-Deep-Learning Applications, *Sensors*, *22*, 7384.
- [40] **Li, J., Fang, F., Mei, K. ve Zhang, G.** (2018). Multi-scale Residual Network for Image Super-Resolution, *V. Ferrari, M. Hebert, C. Sminchisescu ve Y. Weiss, (düzenleyenler), Computer Vision – ECCV 2018*, Springer International Publishing, Cham, s.527–542.
- [41] **Qin, J., Huang, Y. ve Wen, W.** (2020). Multi-scale feature fusion residual network for Single Image Super-Resolution, *Neurocomputing*, *379*, 334–342, <https://www.sciencedirect.com/science/article/pii/S0925231219315140>.
- [42] **Zhang, X., Zeng, H., Guo, S. ve Zhang, L.** (2022). Efficient Long-Range Attention Network for Image Super-resolution, *2203.06697*.
- [43] **Wu, H., Zou, Z., Gui, J., Zeng, W.J., Ye, J., Zhang, J., Liu, H. ve Wei, Z.** (2021). Multi-Grained Attention Networks for Single Image Super-Resolution, *IEEE Transactions on Circuits and Systems for Video Technology*, *31*(2), 512–522.
- [44] **Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B. ve Fu, Y.** (2018). *Image Super-Resolution Using Very Deep Residual Channel Attention Networks*, *1807.02758*.
- [45] **Niu, B., Wen, W., Ren, W., Zhang, X., Yang, L., Wang, S., Zhang, K., Cao, X. ve Shen, H.** (2020). *Single Image Super-Resolution via a Holistic Attention Network*, *2008.08767*.
- [46] **Dai, T., Cai, J., Zhang, Y., Xia, S.T. ve Zhang, L.** (2019). Second-Order Attention Network for Single Image Super-Resolution, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, s.11057–11066.
- [47] **Haris, M., Shakhnarovich, G. ve Ukita, N.** (2018). Deep Back-Projection Networks for Super-Resolution, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, s.1664–1673.

- [48] **Li, Z., Yang, J., Liu, Z., Yang, X., Jeon, G. ve Wu, W.** (2019). Feedback Network for Image Super-Resolution, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, s.3862–3871.
- [49] **Xie, W., Song, D., Xu, C., Xu, C., Zhang, H. ve Wang, Y.** (2021). Learning Frequency-aware Dynamic Network for Efficient Super-Resolution, *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, s.4288–4297.
- [50] **Magid, S.A., Zhang, Y., Wei, D., Jang, W.D., Lin, Z., Fu, Y. ve Pfister, H.** (2021). Dynamic High-Pass Filtering and Multi-Spectral Attention for Image Super-Resolution, *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, s.4268–4277.
- [51] **Lin, T. ve Hao, P.** (2005). Compound image compression for real-time computer screen image transmission, *IEEE Transactions on Image Processing*, *14*(8), 993–1005.
- [52] **Hu, J., Song, S. ve Gong, Y.** (2017). Comparative performance analysis of web image compression, *2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, s.1–5.
- [53] **Öztürk, E. ve Mesut, A.** (2021). Performance Evaluation of JPEG Standards, WebP and PNG in Terms of Compression Ratio and Time for Lossless Encoding, *2021 6th International Conference on Computer Science and Engineering (UBMK)*, s.15–20.
- [54] **Awang, S. ve Aizuddin Nik Azmi, N.M.** (2021). Performance Evaluation between RGB and YCrCb in TC-SF-CNNLS for Vehicle Type Recognition System, *2021 IEEE 8th International Conference on Industrial Engineering and Applications (ICIEA)*, s.550–555.
- [55] *YcRcb Calculation*, <https://en.wikipedia.org/wiki/YCbCr>, accessed: 25th November 2023.
- [56] **Lin, C.Y. ve Chang, S.F.** (2001). A robust image authentication method distinguishing JPEG compression from malicious manipulation, *IEEE Transactions on Circuits and Systems for Video Technology*, *11*(2), 153–168.
- [57] **Ahmed, N., Natarajan, T. ve Rao, K.** (1974). Discrete Cosine Transform, *IEEE Transactions on Computers*, *C-23*(1), 90–93.
- [58] **Yang, E.h. ve Wang, L.** (2007). Joint Optimization of Run-Length Coding, Huffman Coding and Quantization Table with Complete Baseline JPEG Compatibility, *2007 IEEE International Conference on Image Processing*, cilt 3, s.III – 181–III – 184.
- [59] **Huffman, D.A.** (1952). A Method for the Construction of Minimum-Redundancy Codes, *Proceedings of the IRE*, *40*(9), 1098–1101.

- [60] **Deng, J., Dong, W., Socher, R., Li, L.J., Li, K. ve Fei-Fei, L.** (2009). ImageNet: A large-scale hierarchical image database, *2009 IEEE Conference on Computer Vision and Pattern Recognition*, s.248–255.
- [61] *BSDS100: Berkeley Segmentation Dataset 100*, <http://www.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/>, accessed: 13th April 2023.
- [62] **Dong, C., Loy, C.C. ve Tang, X.** (2016). *Accelerating the Super-Resolution Convolutional Neural Network*, 1608.00367.



## ÖZGEÇMİŞ

**Adı SOYADI:** Muhammet Bolat

### ÖĞRENİM DURUMU:

- **Lisans:** 2016, Yıldız Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü
- **Yüksek Lisans:** 2024, İstanbul Teknik Üniversitesi, Bilişim Uygulamaları, Bilgi ve Haberleşme Mühendisliği Bölümü

### MESLEKİ DENEYİMLER VE ÖDÜLLER:

- (2016 - 2020) Turkcell, Yazılım Mühendisi
- (2020 - 2021) Turkcell, Kıdemli Yazılım Mühendisi
- (2021 - 2024) Siemens, Kıdemli Yazılım Mühendisi

### YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **M. Bolat**, N. Çalık and L. D. Ata, "Recovering JPEG Compression Loss via Deep Learning-Based Super Resolution Techniques," 2023 31st Signal Processing and Communications Applications Conference (SIU), Istanbul, Turkiye, 2023, pp. 1-4, doi: 10.1109/SIU59756.2023.10223843.

## **DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:**

- **M. Bolat** (2020). Bölgesel Erişim Kontrol Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2020/06511
- **M. Bolat** (2020). Sorun Yaşayan Aboneleri Tespit Eden Bir Sistem ve Yöntem (Türk Patent ve Marka Kurumu). Patent numarası: 2020/08862
- **M. Bolat**, H. Eker (2020). Veri Trafikinin Yönlendirilmesini Sağlayan Bir Sistem (Türk Patent ve Marka Kurumu). Patent numarası: 2020/09745
- **M. Bolat** (2020). Bir Ücretlendirme Yönetim Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2020/11491
- E. K. Kartepe, K. Ecir, **M. Bolat**, F.M. Yılmaz (2020). Bir Anten Önerme Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2020/11639
- H.Eker, **M. Bolat** (2020). Global Ağlara Çıkış Yapmayan Kişilerin Global Ağlarla Bağlantı Kurmasını Sağlayan Bir Sistem (Türk Patent ve Marka Kurumu). Patent numarası: 2020/14330
- **M. Bolat** (2020). Bir Paket Ücretlendirme Sistemi ve Yöntemi (Türk Patent ve Marka Kurumu). Patent numarası: 2020/15079
- **M. Bolat** (2020). Bir Bağlantı Engelleme Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2020/16049
- **M. Bolat** (2020). 4G Aramalarının Yönetilmesini Sağlayan Bir Sistem (Türk Patent ve Marka Kurumu). Patent numarası: 2020/16092
- H. Öztunç Tütüncü, B. Köseren, Ö.B. Uçar, A. Ç. Akça, F. M. Yılmaz, **M. Bolat** (2020). Bir Kira Tahminleme Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2020/17954
- **M. Bolat** (2020). Bir. Ücretlendirme İzleme ve Yönetim Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2020/18513
- H. Öztunç Tütüncü, **M. Bolat**, H. Avcıoğlu (2020). İletişim Kaynaklarının Önceliklendirilmesini Sağlayan Bir Sistem (Türk Patent ve Marka Kurumu). Patent numarası: 2020/18957
- H. Eker, **M. Bolat** (2021). SGSN Trafik Dengeleme Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2021/006847
- **M. Bolat** (2021). Bir Veri Yönlendirme Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2021/017157
- **M. Bolat** (2021). Bir Çalıntı Mobil Cihaz Konum Tespit Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2021/017161
- **M. Bolat** (2021). 3G Şebekesinde Bireysel ve Kurumsal APN Service Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2021/017202

- **M. Bolat** (2021). Yurtdışında Bulunan Aboneler için Tarife Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2021/017204
- **M. Bolat** (2021). Veri Trafikinin Yönlendirilmesini Sağlayan Bir Sistem (Türk Patent ve Marka Kurumu). Patent numarası: 2021/017809
- **M. Bolat, H. Öztunç Tütüncü, Haluk Avcıoğlu** (2020/18957). Bir Sanal Özel Ağ Kontrol Sistemi (Türk Patent ve Marka Kurumu). Patent numarası: 2021/020064

