

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ÇEKİŞMELİ ÜRETİCİ AĞLAR (GAN) İLE YÜKSEK
ÇÖZÜNÜRLÜKTE GÖRÜNTÜ OLUŞTURMA VE
DEĞERLENDİRME

YÜKSEK LİSANS TEZİ

ZÜBEYR GÜNGÜR

DANIŞMAN
DOÇ. DR. VEDAT TÜMEN

ŞUBAT 2025
BİTLİS

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ÇEKİŞMELİ ÜRETİCİ AĞLAR (GAN) İLE YÜKSEK
ÇÖZÜNÜRLÜKTE GÖRÜNTÜ OLUŞTURMA VE
DEĞERLENDİRME**

YÜKSEK LİSANS TEZİ

ZÜBEYR GÜNGÜR
ORCID: 0009-0000-0843-6333

DANIŞMAN
DOÇ. DR. VEDAT TÜMEN

ŞUBAT 2025
BİTLİS

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
YÜKSEK LİSANS
ETİK BEYANI

Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans öğrencisiyim. Hazırlamış olduğum “**Çekişmeli Üretici Ağlar (Gan) İle Yüksek Çözünürlükte Görüntü Oluşturma Ve Değerlendirme**” başlıklı tezde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi; tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu; tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi; kullanılan verilerde herhangi bir değişiklik yapmadığımı; bu tezde sunduğum çalışmanın özgün olduğunu bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

...../...../2025

İmza
Zübeyr GÜNGÜR

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ YAZIM KILAVUZU UYGUNLUK BEYANI

“Çekişmeli Üretici Ağlar (Gan) İle Yüksek Çözünürlükte Görüntü Oluşturma Ve Değerlendirme” başlıklı yüksek lisans tezi Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzuna uygun olarak hazırlanmıştır.
..../..../2025

Tezi Hazırlayan

İmza

Zübeyr GÜNGÜR

Danışman

İmza

Doç. Dr. Vedat TÜMEN

Elektrik Elektronik Mühendisliği Anabilim Dalı Başkanı
İmza

Prof. Dr. Sabir RÜSTEMLİ

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ ONAY SAYFASI

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı öğrencisi Zübeyr GÜNGÜR tarafından hazırlanan “Çekişmeli Üretici Ağlar (Gan) İle Yüksek Çözünürlükte Görüntü Oluşturma Ve Değerlendirme” adlı Yüksek Lisans ile ilgili tez savunma sınavı 11/02/2025 tarihinde yapılmış ve tezin oy birliği ile kabul edilmesine karar verilmiştir.

JÜRİ:

İMZA

Danışman: Doç. Dr. Vedat TÜMEN
Bitlis Eren Üniversitesi

.....

Üye: Dr. Öğr. Üyesi İrfan ÖKTEN
Bitlis Eren Üniversitesi

.....

Üye: Doç. Dr. Selahattin KOŞUNALP
Bandırma Onyedİ Eylöl Üniversitesi

.....

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun tarih ve sayılı kararıyla jüri tarafından kabul edilmiş bu çalışmanın yüksek lisans tezi olarak kabulü onaylanmıştır.

...../...../2025

Prof. Dr. Mehmet Bakır ŞENGÖL

Enstitü Müdür V.

T.C.

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

**ÇEKİŞMELİ ÜRETİCİ AĞLAR (GAN) İLE YÜKSEK ÇÖZÜNÜRLÜKTE
GÖRÜNTÜ OLUŞTURMA VE DEĞERLENDİRME**

Yüksek Lisans Tezi

Zübeyr GÜNGÜR

Danışman: Doç. Dr. Vedat TÜMEN

Şubat 2025

ÖZET

Biyomedikal görüntüler üzerinde hastalıkların teşhis ve tedavi süreçlerinin daha doğru ve güvenilir bir biçimde ilerlemesi önemlidir. Biyomedikal görüntüler bazen düşük çözünürlüğe sahip olabilir bu durum hastalığın tespitini olumsuz yönde etkilemektedir. Tedavi süreçlerinin doğru biçimde ilerlemesi için yüksek çözünürlüğe sahip imgeler üzerinde veya düşük çözünürlükteki imgelerin yüksek çözünürlüğe dönüştürülmesi gerekir.

Çalışmamız, düşük çözünürlüklü renkli görüntülerin yüksek çözünürlüklü ve detaylı hale getirilmesi amacıyla GAN mimarilerinden biri olan SRGAN modeli kullanılmıştır. SRGAN, görüntü iyileştirme ve dönüşüm işlemlerinde yüksek performans sağlayarak görsel kalitenin artırılmasında etkili bir yöntem sunmaktadır. Tez de kullanılan veri setleri, tıbbi görüntüleme alanında yaygın olarak kullanılan cilt kanseri, kan hücresi kanseri ve retina fundus veri setlerinden oluşmaktadır. Cilt kanseri veri setinde deri yüzeyindeki ince detayların daha net bir şekilde görselleştirilmesi sağlanırken, kan hücresi kanseri veri setinde hücre yapılarını belirginleştirerek tanıya destek sunulmuştur. Retina fundus veri setinde ise göz damar yapıları detaylandırılmış ve çözünürlük artırılarak tanısal analiz için uygun hale getirilmiştir. Modelin başarımını değerlendirmek için Structural Similarity Index (SSIM) ve Peak Signal-to-Noise Ratio (PSNR) metrikleri kullanılmıştır. Performans değerlendirmesinde, SRGAN modeli Cilt Kanseri veri setinde 31.06 PSNR ve %85.84 SSIM, Kan Hücresi Kanseri veri setinde, 30.97 PSNR ve %88.18 SSIM retina fundus veri setinde %94.30 SSIM ve 30.71 PSNR

değerleri ile umut verici bir sonuç ortaya çıkmıştır. Elde edilen bulgular hem yapısal hem de görsel kalite açısından üstün performans gösterdiğini kanıtlar niteliktedir.

Anahtar kelimeler: Yapay zekâ Çekişmeli üretici ağlar, Biyomedikal, Süper çözünürlük



Republic of Türkiye

Bitlis Eren University Graduate School

Department of Electrical and Electronics Engineering

**HIGH-RESOLUTION IMAGE GENERATION AND ASSESSMENT WITH
GENERATIVE ADVERSARIAL NETWORKS (GAN)**

Master's Thesis

Zübeyr GÜNGÜR

Supervisor: Assoc. Prof. Vedat TÜMEN

February 2025

ABSTRACT

Accurate and reliable progression of disease diagnosis and treatment processes is crucial in biomedical imaging. However, biomedical images are sometimes of low resolution, which can negatively affect disease detection. For the accurate progression of treatment processes, it is necessary to work with high-resolution images or convert low-resolution images into high-resolution ones. In our study, the SRGAN model, one of the GAN architectures, was utilized to enhance and detail low-resolution color images into high-resolution versions. SRGAN provides an effective method for improving visual quality by achieving high performance in image enhancement and transformation processes. The datasets used in this thesis consist of skin cancer, blood cell cancer, and retinal fundus datasets, which are widely used in the field of medical imaging. In the skin cancer dataset, fine details on the skin surface were visualized more clearly, while in the blood cell cancer dataset, cell structures were highlighted to support diagnosis. In the retinal fundus dataset, vascular structures of the eye were detailed and resolution was enhanced to make them suitable for diagnostic analysis. To evaluate the performance of the model, Structural Similarity Index (SSIM) and Peak Signal-to-Noise Ratio (PSNR) metrics were employed. The performance evaluation showed that the SRGAN model achieved promising results with a PSNR of 31.06 and an SSIM of 85.84% on the skin cancer dataset, a PSNR of 30.97 and an SSIM of 88.18% on the blood cell cancer dataset, and an SSIM of 94.30% and a PSNR of 30.71 on the retinal

fundus dataset. The findings demonstrate that the model exhibits superior performance in terms of both structural and visual quality.

Keywords: Artificial intelligence, Generative adversarial networks, Biomedical, Super resolution



TEŞEKKÜR

Bu tez çalışması sırasında, tez konusunun belirlenmesinden başlayarak son aşamaya kadar her konuda benden yardımlarını esirgemeyen danışman hocam Sayın Doç. Dr. Vedat TÜMEN'e şükranlarımı sunarım.

Bu günlere gelmemde büyük emekleri olan aileme yoğun çalışma temposunda benden maddi ve manevi desteğini esirgemeyen arkadaşlarım Öğr. Gör. İbrahim AYAZ ve Nurettin ACI'ya, varlığı ile birer motivasyon kaynağı olan İrem ÇAKIR'a teşekkür ederim.



İÇİNDEKİLER

ÖZET.....	I
ABSTRACT	III
TEŞEKKÜR	V
İÇİNDEKİLER	VI
ÇİZELGELER DİZİNİ	VIII
ŞEKİLLER DİZİNİ	IX
KISALTMALAR DİZİNİ	XI
1 GİRİŞ.....	1
1.1 Literatür Taraması	2
2 GENEL BİLGİLER.....	5
2.1 Veri seti	6
2.1.1 DIV2K Veri Seti	6
2.1.2 Set5 Veri Seti	7
2.1.3 Set14 Veri Seti	8
2.1.4 BSD100 Veri Seti	9
2.1.5 Urban100 Veri Seti.....	11
2.2 Yapay Zekâ.....	12
2.3 Makine Öğrenmesi.....	15
2.3.1 Öğrenme Paradigmaları.....	16
2.3.2 Makine Öğrenmesinin Türleri	17
2.4 Derin Öğrenme (Deep Learning).....	17
2.4.1 Derin Sinir Ağları.....	17
2.4.2 Konvolüsyonel Sinir Ağları	18
2.4.3 Tekrarlayan Sinir Ağları.....	19
2.4.4 Derin Öğrenmenin Uygulama Alanları.....	20
2.5 Yapay Sinir Ağları.....	21
2.5.1 Yapay Sinir Hücresinde Yer Alan Elemanlar	23
2.6 Çekişmeli Üretici Ağlar	24
2.6.1 Üretici (Generator) Model.....	25
2.6.2 Ayırıcı (Discriminator) Model	26
2.6.3 Eğitim Süreci	27
2.6.4 Matematiksel Denklem	27
2.6.5 Çekişmeli Üretici Ağların Avantajları	30

2.6.6. Çekişmeli Üretici Ağların Dezavantajları	30
2.6.6 Yüksek Çözünürlüklü Görüntü Oluşturmada GAN'ların Kullanımı	31
2.6.7 Süper Çözünürlük (Super-Resolution)	31
2.6.8 Geliştirilmiş Süper Çözünürlük (Enhanced Super-Resolution)	32
2.6.9 Görüntü-Görüntü Çevirisi (Image-to-Image Translation)	33
2.6.10 Döngü Tutarlı Üretken Çekişmeli Ağlar (Cycle-Consistent Generative Adversarial Networks)	34
2.6.11 Pix2Pix.....	35
2.6.12 Progresif Büyüme (Progressive Growing)	36
2.6.13 Üretken Çekişmeli Ağlar için Stil Tabanlı Üreteç Mimarisi (Style-Based Generator Architecture for Generative Adversarial Networks).....	37
2.6.14 Koşullu Oluşturma (Conditional Generation)	39
2.6.15 Büyük Üretken Çekişmeli Ağ (Big Generative Adversarial Network)	39
3 MATERYAL VE YÖNTEM	41
4 BULGULAR.....	45
4.1 Veri Setlerine Göre PSNR ve SSIM Performans Değerlendirmesi.....	45
4.1.1 Cilt Kanseri Veri Seti.....	45
4.1.2 Retina Fundus Veri Seti	46
4.1.3 Kan Hücreleri Kanseri Veri Seti	48
4.2 Genel Performans Karşılaştırması.....	50
4.3 Yorum ve Değerlendirme.....	50
5 TARTIŞMA.....	52
6 SONUÇ VE ÖNERİLER.....	54
KAYNAKLAR	56

ÇİZELGELER DİZİNİ

Çizelge 4. 1. Veri seti performans değerleri	50
Çizelge 5.1. Literatürdeki Benzer Çalışmalar ve Modelimizin performansı.....	47



ŞEKİLLER DİZİNİ

Şekil 2-1. Çekişmeli Üretici Ağlar (GANs) ile oluşturulan yüz görüntülerinin yıllar içindeki gelişimi.....	5
Şekil 2-2. DIV2K veri setinden görüntüler.....	7
Şekil 2-3. Set5 veri setlerinden $\times 2$, $\times 3$ ve $\times 4$ ölçeğinde elde edilen örnek sonuçlar.....	8
Şekil 2-4. Set14 veriseti süper çözünürlüklü sonuçlara bir örnek görüntü.	9
Şekil 2-5. BSD100 veri kümesinde $2\times$ SR'nin görsel sonuçları.	10
Şekil 2-6. Urban100 veri seti ve B100 veri seti üzerinde 4 ölçek faktörünün görsel karşılaştırması	11
Şekil 2-7. Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi	13
Şekil 2-8. Yapay Zeka ve Uygulama alanları	15
Şekil 2-9. Derin sinir ağları (DNN - Deep Neural Networks)	18
Şekil 2-10. Evrişimsel sinir ağları (CNN - Convolutional Neural Networks)	19
Şekil 2-11. Tekrarlayan sinir ağları (RNN - Recurrent Neural Networks)	19
Şekil 2-12. Bir Sinir hücresinin biyolojik ve Matematiksel fonksiyon gösterimi	22
Şekil 2-13. GAN'ın Çalışma Prensibi	25
Şekil 2-14. GAN Üretici model.	26
Şekil 2-15. GAN ayrıştırıcı model.	27
Şekil 2-16. SRGAN	32
Şekil 2-17. Çözünürlük artırma yöntemlerin sonuçları.....	33
Şekil 2-18. Görüntüden görüntüye çeviri.....	35
Şekil 2-19. Koşullu Rekabetçi Ağlarla Görüntüden Görüntüye Çeviriden.	36
Şekil 2-20. Progressively-Growing GANs'da kullanılan Çok Ölçekli Mimarının Diyagramı.....	37
Şekil 2-21. StyleGAN örnek resim	38
Şekil 2-22. 256x256 ve 512x512 Çözünürlükte üretilen BigGAN örneği.....	39

Şekil 3-1. Cilt kanseri veri seti.....	41
Şekil 3-2. Kan hücresi kanseri veri seti	42
Şekil 3-3. Retina fundus veri seti.....	43
Şekil 4-1. Cilt kanseri veri setinin SRGAN çıktısı	45
Şekil 4-2. Cilt kanseri veri setinde PSNR ve SSIM Performans Grafiği.....	46
Şekil 4-3. Retina fundus veri setinin SRGAN çıktısı	47
Şekil 4-4. Retina fundus veri setinde PSNR ve SSIM Performans Grafiği.....	48
Şekil 4-5. Kan hücresi kanseri veri setinin SRGAN çıktısı.	49
Şekil 4-6. Kan hücresi kanseri veri setinde PSNR ve SSIM Performans Grafiği.....	50

KISALTMALAR DİZİNİ

BERT	: Bidirectional Encoder Representations from Transformers
CNN	: Convolutional Neural Network
DEÇÜA	: Derin Evrişimsel Çekişmeli Üretici Ağ
DNN	: Deep Neural Networks
EDSR	: Geliştirilmiş Derin Süper Çözünürlük
ESRGAN	: Enhanced Super-Resolution GAN
GAN	: Generative Adversarial Networks
GBT	: Generative Pre-trained Transformer
LSTM	: Long Short-Term Memory
MISR	: Multi-Image Super-Resolution
MLP	: Multi-layer Perceptrons
NMT	: Neural Machine Translation
PSNR	: Peak Signal-to-Noise Ratio
RDN	: Artık Yoğun Ağ
RNN	: Recurrent Neural Networks
SISR	: Single Image Super-Resolution
SR	: Super Resolution
SRCNN	: Super-Resolution Convolutional Neural Network
SSIM	: Structural Similarity Index
VDSR	: Çok Derin Süper Çözünürlük
YSA	: Artificial Neural Networks
YZ	: Yapay Zekâ

1 GİRİŞ

Süper Çözünürlük (Super Resolution - SR), düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntüler üreten bir yöntemdir. Kullanılan yöntem de elde edilen görüntüler daha yüksek piksel yoğunluğuna sahip olur ve çözünürlüğün artırılması, görüntülerin sınıflandırılmasında doğruluk oranını genellikle olumlu yönde etkiler. Görüntü işleme ve analiz alanlarında yaşanan hızlı gelişmeler, süper çözünürlük teknolojisinin önemini giderek artırmaktadır. Süper çözünürlük, düşük çözünürlüklü görüntülerin kalitesini ve detayını artırarak yüksek çözünürlüklü görüntüler elde edilmesini sağlayan bir tekniktir [1]. Güvenlik ve gözetim kameralarından elde edilen görüntüler genellikle düşük çözünürlüklüdür ve detay eksikliği nedeniyle kritik bilgilerin kaybolmasına neden olması muhtemeldir. Süper çözünürlük teknolojisi, bu tür görüntülerin netliğini artırarak şüpheli kişilerin tanımlanmasını ve olayların daha ayrıntılı bir şekilde analiz edilmesini sağlar. Güvenlik güçlerinin daha etkili müdahalelerde bulunmasına olanak tanır [2]. Tıbbi alanda süper çözünürlüğün kullanımı, teşhis ve tedavi süreçlerinde önemli avantajlar sağlar. MR, CT ve ultrason gibi tıbbi görüntüleme yöntemlerinde, görüntülerin çözünürlüğünün artırılması, doktorların hastalıkları daha doğru bir şekilde tespit etmelerine yardımcı olur. Örneğin, kanser hücrelerinin veya diğer anormal dokuların erken aşamada tespiti, daha etkili tedavi planlarının oluşturulmasını mümkün kılar [3]. Uzaktan algılama ve uydu görüntüleme alanlarında da süper çözünürlük büyük bir önem taşır. Yeryüzünün yüksek çözünürlüklü görüntüleri, coğrafi analizler, şehir planlaması ve doğal afetlerin incelenmesi gibi alanlarda daha doğru ve detaylı veriler sunar. Bu sayede, karar vericiler daha bilinçli ve etkili stratejiler geliştirebilirler [4]. Dijital görüntülerde detay kaybı ve bulanıklık sık karşılaşılan sorunlardır. Yapılan çalışma da, eski veya düşük kaliteli görüntülerin netliğini artırarak daha ayrıntılı ve yüksek kalitede görseller sunar [5].

Tezde, süper çözünürlüğün neden kullanılmasının gerektiği ve çeşitli uygulama alanlarındaki faydaları incelenmiştir. Süper çözünürlüğün en belirgin faydalarından biri, görüntü kalitesinin iyileştirilmesidir. Süper çözünürlük, genellikle iki ana yöntemle uygulanır tek görüntülü süper çözünürlük Single Image Super-Resolution (SISR) ve çoklu görüntülü süper çözünürlük Multi-Image Super-Resolution (MISR). Tek Görüntülü Süper Çözünürlük SISR tek bir düşük çözünürlüklü görüntüden yüksek çözünürlüklü bir görüntü elde etmeyi amaçlar. Genellikle derin öğrenme modelleri ve

özellikle Convolutional Neural Network (CNN) kullanılarak uygulanır. Derin öğrenme, düşük çözünürlüklü görüntülerin özelliklerini analiz ederek yüksek çözünürlüklü bir tahmin oluşturur. MISR aynı sahnenin farklı açılardan veya zamanlarda çekilmiş birden fazla düşük çözünürlüklü görüntüsünü kullanarak yüksek çözünürlüklü bir görüntü oluşturur. Görüntüler arasındaki bilgi fazlalığından yararlanarak daha yüksek kalitede bir sonuç elde eder [6]. Derin öğrenme tabanlı süper çözünürlük çalışmaları, son yıllarda büyük ilerlemeler göstermiştir. Özellikle CNN tabanlı modeller öne çıkmaktadır. CNN'ler, görüntü işleme ve analizde güçlü performansları ile süper çözünürlük problemlerine getirdikleri yenilikçi çözümlerle dikkat çekmektedir [7]. Süper çözünürlükteki ilk büyük atılımlarından biri, Dong ve ark. (2015) tarafından geliştirilen Super-Resolution Convolutional Neural Network (SRCNN) modelidir. SRCNN, düşük çözünürlüklü görüntülerin yüksek çözünürlüklü versiyonlarını oluşturmak için üç katmanlı bir CNN kullanır. Model, düşük çözünürlüklü bir görüntüyü önce daha yüksek bir çözünürlüğe ölçeklendirilir ve ardından bu ölçeklendirilmiş görüntü üzerinde özellik çıkarma ve yeniden yapılandırma işlemlerini gerçekleştirir [8].

Sonuç olarak biyomedikal veri setleri üzerinde yaptığımız deneyler neticesinde Cilt Kanseri veri setinde 31.06 PSNR ve %85.84 SSIM değerleriyle başarılı bir sonuç elde edildi. Bu durum, modelin düşük çözünürlüklü cilt kanseri görüntülerinde hem görsel kaliteyi hem de yapısal benzerliği etkin bir şekilde koruduğunu göstermektedir. Kan Hücreleri Kanseri veri setinde, 30.97 PSNR ve %88.18 SSIM başarılı sonuç elde edildi. Retina Fundus veri setinde, 30.71 PSNR ve %94.30 SSIM değerleri elde edilmiştir. Bu sonuçlar, modelin retina görüntülerinde yüksek yapısal bütünlüğü koruyabildiğini göstermektedir. Süper çözünürlük ile düşük çözünürlüklü görüntülerin netliğini ve detayını artırarak, çeşitli uygulamalarda yüksek kaliteli sonuçlar elde edilmesini sağlamıştır. Görüntü netleştirme, parazit giderme, kontrastını artırma ve sıkıştırma gibi yöntemler, süper çözünürlük teknolojisinin gücünü ve önemini bizlere göstermektedir.

1.1 Literatür Taraması

SISR, tek bir düşük çözünürlüklü görüntüden yüksek çözünürlüklü bir görüntü elde etmeyi amaçlar. Bu yöntem, genellikle derin öğrenme modelleri ve özellikle CNN kullanılarak uygulanır.

Kim ve ark Çok Derin Süper Çözünürlük (VDSR) ağını kullanarak, düşük çözünürlüklü görüntülerin yüksek çözünürlüklü versiyonlarını oluşturma konusunda önemli ilerlemeler kaydetmişlerdir [9]. Ayrıca, Lim ve ark tarafından geliştirilen EDSR ağı, daha az parametreyle daha yüksek performans sağlamaktadır. Çoklu görüntülü süper çözünürlük (MISR), aynı sahnenin farklı açılardan veya zamanlarda çekilmiş birden fazla düşük çözünürlüklü görüntüsünü kullanarak yüksek çözünürlüklü bir görüntü oluşturur. Teknik açıdan, görüntüler arasındaki bilgi fazlalığından yararlanarak daha yüksek kalitede bir sonuç elde eder [10]. Farsiu ve ark yaptıkları çalışma düşük çözünürlüklü görüntülerden daha yüksek çözünürlüklü görüntüler elde etmenin teorik ve pratik temellerini ortaya koymuşlardır. Görüntü netleştirme, görüntülerin kenarlarını ve detaylarını daha belirgin hale getirmek için kullanılan bir tekniktir [11]. Xu ve ark. derin konvolüsyonel ağlar kullanarak bulanık görüntülerin netleştirilmesi üzerine önemli çalışmalar yapmışlardır. Netleştirme filtreleri, bulanık alanları azaltarak görüntüdeki ince detayları vurgular. Dijital görüntülerdeki rastgele parazitlerin (gürültü) azaltılması, görüntü kalitesini artırmak için önemlidir [12]. Zhang ve ark. DnCNN adı verilen bir derin öğrenme modelini tanıtarak, görüntü parazitini etkin bir şekilde azaltmayı başarmışlardır. Kontrast artırma, görüntüdeki ışık ve gölge alanları arasındaki farkı artırarak daha net ve canlı görüntüler elde etmek için kullanılır [13]. Pizer ve ark histogram eşitleme tekniklerini kullanarak tıbbi görüntülerin kontrastını artırmada önemli ilerlemeler kaydetmişlerdir. Dijital görüntülerin sıkıştırılması sırasında oluşan bozulmaların giderilmesi, özellikle JPEG gibi sık kullanılan formatlarda kaliteyi artırmak için önemlidir [14]. Dong ve ark sıkıştırma artefaktlarının giderilmesi için SRCNN (Super-Resolution Convolutional Neural Network) modelini geliştirmiştir. Tarihi ve nostaljik değer taşıyan eski fotoğrafların kalitesinin artırılması, süper çözünürlük teknikleri ile mümkündür. Bu, kaybolan detayların geri kazanılması ve görüntülerin modern dijital standartlara uygun hale getirilmesini sağlar [15]. Wang ve ark GAN tabanlı bir model kullanarak eski fotoğrafların restorasyonun'da başarılı sonuçlar elde etmişlerdir. Düşük çözünürlüklü videoların kalitesinin artırılması, özellikle eski televizyon programları, filmler veya düşük kaliteli kayıtlar için önemlidir. Süper çözünürlük, video karelerinin netleştirilmesi ve daha yüksek çözünürlükte yeniden oluşturulmasını sağlar [16]. Caballero ve ark VSRnet adı verilen bir model kullanarak video süper çözünürlüğünde önemli ilerlemeler kaydetmişlerdir. Akıllı telefonlar ve tabletler gibi mobil cihazlarda çekilen fotoğraflar ve videolar, süper çözünürlük algoritmaları ile iyileştirilebilir. Bu, kullanıcıların daha yüksek kalitede

görseller elde etmelerine olanak tanır [17]. Betzig ve ark süper çözünürlüklü mikroskopi alanında önemli çalışmalar yaparak teknolojiyi biyolojik araştırmalarda kullanmışlardır. Mikroskop ve teleskop görüntülemelerinde, süper çözünürlük teknikleri, daha detaylı ve net görüntüler elde edilmesini sağlar. Bilimsel araştırmaların ve endüstriyel denetimlerin kalitesini artırır [18].



2 GENEL BİLGİLER

Derin öğrenme, karmaşık yapıları öğrenme kapasitesiyle öne çıkan bir makine öğrenmesi yaklaşımıdır. Derin sinir ağları, büyük veri setlerindeki ayrıntılı özellikleri yakalamada klasik görüntü işleme tekniklerine kıyasla önemli ölçüde daha iyi performans göstermektedir. Derin öğrenme, özellikle görüntü üretimi konusunda kayda değer başarılar elde etmiştir. 2014 yılında Goodfellow tarafından önerilen ilk model, Generative Adversarial Networks (GAN) olarak adlandırılan üretici modellerdir. Bu modeller, denetimsiz öğrenme çerçevesinde, orijinal veri kümesinden uygun yeni örnekler üretmek amacıyla verilerin özelliklerini öğrenme ve keşfetme yeteneğine sahiptir. GAN, klasik derin ağ mimarilerinden farklı olarak, bir üretici (generative, G) ve bir ayırıcı (discriminative, D) olmak üzere iki farklı derin ağ içerir. Bu iki ağın birbirine karşı çalışması, öğrenme sürecini daha uygun hale getirir [19].

Günümüzde GAN sentetik ve gerçekçi görünen görüntüler üretmede en yaygın kullanılan derin üretici ağ modellerinden biridir. Ian Goodfellow ve diğer araştırmacılar tarafından geliştirilen bu model, sadece altı yıl gibi kısa bir süre önce tanıtılmış olmasına rağmen, Şekil 2.1'de görüldüğü üzere, bu modelin gelişmiş versiyonları tarafından üretilen sentetik görüntülerin kalitesinde kayda değer iyileşmeler sağlanmıştır [20].



Şekil 2-1. Çekişmeli Üretici Ağlar (GANs) ile oluşturulan yüz görüntülerinin yıllar içindeki gelişimi.

Şekil 2-1’de Çekişmeli Üretici Ağlar (GANs) ile oluşturulan yüz görüntülerinin yıllar içindeki gelişimi, sol baştan sağa doğru sırasıyla GAN (2), DCGAN (3), Coupled GAN (4), Progressive GAN (5), StyleGAN (6), ve StyleGAN2 (1) modelleriyle temsil edilmektedir. GAN modellerinin çözünürlük, detay seviyesi ve görsel gerçekçilik açısından nasıl evrildiğini göstermektedir.

2.1 Veri seti


Süper çözünürlük çalışmalarında genellikle yüksek çözünürlüklü (HR) ve düşük çözünürlüklü (LR) görüntülerden oluşan veri setleri kullanılır. Yaygın olarak kullanılan veri setleri arasında DIV2K, Set5, Set14, BSD100 ve Urban100 bulunur [21].

2.1.1 DIV2K Veri Seti

1000 yüksek çözünürlüklü görüntüden oluşur. Eğitim için 800, test için 100 ve validasyon için 100 görüntü kullanılır.

DIV2K veri seti aşağıdakilere ayrılmıştır:

- Eğitim Verileri: 800 yüksek çözünürlüklü yüksek çözünürlüklü görüntüden başlayarak, karşılık gelen düşük çözünürlüklü görüntüler elde ederiz ve 2, 3 ve 4 küçültme faktörü için hem yüksek hem de düşük çözünürlüklü görüntüler sağlarız
- Doğrulama Verileri: 100 yüksek çözünürlüklü, yüksek çözünürlüklü görüntü, düşük çözünürlüklü ilgili görüntülerin oluşturulması için kullanılır; düşük çözünürlükler, mücadelenin başlangıcından itibaren sağlanır ve katılımcıların doğrulama sunucusundan çevrimiçi geri bildirim alması anlamına gelir
- Test Verileri: Düşük çözünürlüklü ilgili görüntüleri oluşturmak için 100 farklı görüntü kullanılır; Nihai değerlendirme aşaması başladığında katılımcılara düşük çözünürlüklü görseller verilecek ve sonuçlar, mücadele bitip kazananlar belirlendikten sonra açıklanacak [22]. Şekil 2-2’de DIV2K veriseti’den örnek görüntüler görülmektedir.




Şekil 2-2. DIV2K verisetinden görüntüler [23].

Şekil 2-3’de İlk satır DIV2K veri kümesindeki görüntüleri gösterir. İkinci satır UC Merced veri kümesinden görüntüleri gösterir ve son satır NWPU-RESISC45 veri kümesinden görüntüleri gösterir. Bu veri setleri, süper çözünürlük modellerinin eğitiminde ve değerlendirilmesinde kullanılan geniş kapsamlı doğal ve yapay görüntüler içermektedir

2.1.2 Set5 Veri Seti

Set5, süper çözünürlük modellerinin değerlendirilmesi için yaygın olarak kullanılan küçük ölçekli bir veri setidir. Beş adet yüksek çözünürlüklü görüntü içerir ve genellikle hızlı model değerlendirmesi için tercih edilir. Görüntüler farklı sahnelerden (doğal manzara, insan yüzü gibi) seçilmiştir ve çeşitlilik sunar [24]. Şekil 2-3’te Set5 verisetine ait görüntüler görüntülenmektedir.



Şekil 2-4. Set5 veri setlerinden elde edilen görüntüler [25].

Şekil 2-5'te Set5 veri setinde yer alan farklı ölçeklendirme faktörlerine ($\times 2$, $\times 3$ ve $\times 4$) göre düşük çözünürlükten yüksek çözünürlüğe dönüştürülen görüntüleri göstermektedir. Süper çözünürlük modellerinin performansını değerlendirmek için yaygın olarak kullanılmaktadır. Doğal manzara ve insan yüzü gibi farklı kategorilere ait yüksek çözünürlüklü görüntüleri içermekte olup, çeşitli ölçek faktörleri altında süper çözünürlük algoritmalarının performansını değerlendirmek için kullanılmaktadır.

2.1.3 Set14 Veri Seti

Set14, 14 yüksek çözünürlüklü görüntüden oluşan bir veri setidir ve daha geniş bir test kapsamı sunar. İçeriğinde çeşitli manzara, hayvan ve şehir görüntüleri bulunur. Bu veri seti, model performansının daha geniş ve çeşitli görüntülerde değerlendirilmesi için kullanılır [26]. Şekil 2-4'te Set14 veriseti'nden sonuçlar gösterilmektedir.




Şekil 2-6. Set14 veriseti süper çözünürlüklü sonuçlara bir örnek görüntü [27].

Şekil 2-4'te Set14 verisetine ait süper çözünürlük uygulaması sonucunda elde edilen görüntüleri içermektedir. Set14, literatürde süper çözünürlük algoritmalarının başarısını test etmek için yaygın olarak kullanılan verisetlerinden biridir. Doğal sahneler, binalar ve farklı nesneler içeren geniş bir yelpazeye sahip olan bu veriseti, algoritmaların genel geçerliliğini ölçmek için kullanılmaktadır.

2.1.4 BSD100 Veri Seti

BSD100, 100 yüksek çözünürlüklü doğal görüntüden oluşan bir veri setidir. Süper çözünürlük algoritmaları, BSD100 veri setindeki düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntüler üretir ve sonuçlar PSNR (Peak Signal-to-Noise Ratio) ve SSIM (Structural Similarity Index) gibi metriklerle değerlendirilir. Doğa, şehir ve çeşitli manzaralardan oluşan geniş bir yelpazede görüntüler içerir. Bu çeşitlilik, farklı senaryolarda süper çözünürlük modellerinin performansını değerlendirmek için idealdir [28]. Şekil 2-5'te BSD100 verisetinde düşük çözünürlüklü görüntüler ile yüksek çözünürlüklü görüntüleri gösterilmektedir.




Şekil 2-7. BSD100 veri kümesinde düşük çözünürlüklü ve yüksek çözünürlüklü görüntüler [29].

Şekil 2-8’te BSD100 veri kümesinde 2× SR’nin görsel sonuçları Soldaki her sütun, sırasıyla HR görüntüsünden bir yamayı (köşeye yakın küçük bir görüntü olarak gösterilir), LR görüntüsünden çıkarılan aynı yamayı ve model çıktısından alınan bir yamayı gösterir. Görüntünün dosya adı HR görüntüsünün altında verilir ve model çıktısının PSNR/SSIM’si model çıktısının altında raporlanır. Görüntülenen değerler yalnızca yama için değil, görüntünün tamamı için hesaplanır.

2.1.5 Urban100 Veri Seti

Urban100, 100 yüksek çözünürlüklü görüntüden oluşan bir veri setidir. Şehir manzaraları, binalar, sokaklar ve kentsel ortamlar gibi detaylı yapıları içerir. Bu görüntüler, çeşitli açılardan ve ışık koşullarında çekilmiştir. Süper çözünürlük algoritmaları, Urban100 veri setindeki düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntüler üretir ve sonuçlar PSNR (Peak Signal-to-Noise Ratio) ve SSIM (Structural Similarity Index) gibi metriklerle değerlendirilir. Urban100 veri seti, kentsel görüntülerdeki detayların ve dokuların iyileştirilmesi açısından süper çözünürlük algoritmalarının performansını test etmek için önemli bir kaynaktır [30]. Şekil 2-6'da Urban100 veriseti ile BSD100 verisetinin karşılaştırması gösterilmektedir.



Şekil 2-9. Urban100 veri seti ve B100 veri seti görsel karşılaştırması [31].


Şekil 2-10'da Urban100 ve BSD100 veri setleri üzerinde uygulanan süper çözünürlük algoritmalarının sonuçlarını karşılaştırmaktadır. Urban100 veri seti, detaylı şehir manzaraları, bina cepheleri ve karmaşık yapılar içeren görsellerden oluşmaktadır.

2.2 Yapay Zekâ

Yapay zekâ (YZ) bilgiyi algılama, sentezleme ve çıkarım yapma süreçlerini içeren, makineler tarafından sergilenen zekâyı ifade eder. İnsan olmayan hayvanlarda ve insanlarda gözlemlenen zekâdan farklıdır. Yapay zekâ sistemleri konuşma tanıma, bilgisayarla görme, dil çevirisi ve diğer girdi işleme biçimleri gibi çeşitli görevleri yerine getirebilmektedir. Bu görevler, yapay zekânın çeşitli uygulamalarını ve işlevlerini göstermektedir [32]. İnsanlar, yüzyıllardır cansız nesneleri canlandırma ve hareket ettirme fikri üzerinde düşünmüşlerdir. Veri depolama ihtiyacı yaklaşık 4000 yıl öncesine kadar uzanırken, yapay zekâ ve yapay sinir ağları konusundaki esas ilerlemeler son elli yıl içinde gerçekleşmiştir [33].

Yapay zekâ fikri, insanlık tarihinin en eski efsanelerinde bulunur. Yunan mitolojisinde Hephaestus'un mekanik hizmetkârları ve Yahudi efsanelerindeki Golem bu düşüncenin erken örnekleridir. Antik Yunanlılar ve Çinliler, mekanik robotlar ve otomatik makineler geliştirmişlerdir. Örneğin, MÖ 4. yüzyılda Yunan matematikçi Archytas, mekanik bir kuş olan "güvercin"i yapmıştır [34]. 1950'de İngiliz matematikçi Alan Turing, makinelerin düşünebilip düşünebileceğini sorguladığı ünlü makalesi "Computing Machinery and Intelligence"i yayınladı. Bu makalede, Turing Testi'ni önerdi [35]. 1956'da John McCarthy, Marvin Minsky, Nathaniel Rochester ve Claude Shannon, yapay zekâ terimini tanımlamak ve bu alanda bir araştırma programı oluşturmak üzere Dartmouth Koleji'nde bir konferans düzenledi. Konferans, yapay zekânın doğuşu olarak kabul edilir [36]. 1950'lerin sonunda ve 1960'ların başında, Newell ve Simon tarafından geliştirilen "General Problem Solver" ve McCarthy tarafından geliştirilen "LISP" programlama dili gibi ilk yapay zekâ programları ortaya çıktı [37]. Bu dönemde, Rosenblatt tarafından geliştirilen "perceptron" gibi temel makine öğrenmesi algoritmaları ve yapay sinir ağları üzerinde çalışmalar yapıldı [38]. 1970'lerde ve 1980'lerde, yapay zekânın sınırlamaları ve aşırı vaatler nedeniyle, fon kesintileri ve ilgi kaybı yaşandı. Bu dönem, "AI Kışı" olarak bilinir [39]. 1980'lerde, belirli bilgi alanlarında uzmanlaşmış yazılımlar olan uzman sistemler popülerlik kazandı. Bunlar, belirli problemlerin çözümünde etkili oldu [40]. 1990'ların sonlarından itibaren, büyük veri kümeleri ve artan hesaplama gücü, makine öğrenmesi ve yapay zekânın yeniden canlanmasına yol açtı. 2000'li yılların başında, derin öğrenme teknikleri ve yapay sinir ağlarındaki ilerlemeler, görüntü ve ses tanıma gibi alanlarda büyük başarılar elde edilmesini sağladı [41]. Günümüzde yapay zekâ, sağlık, finans,

otomotiv ve birçok diğ er sekt rde geniř uygulama alanları bulmuřtur.  zellikle derin  ğrenme ve b y k veri analitiđi, yapay zek nın sınırlarını s rekli geniřletmektedir [42]. Yapay zek nın hızlı ilerleyiři, etik ve g venlik konularında ciddi tartiřmalar bařlatmıřtır. Yapay zek nın geleceđi, bu teknolojinin insanlıđa nasıl fayda sađlayabileceđi ve olası risklerinin nasıl y netileceđi  zerine yođunlařmaktadır [43]. Yapay zekanın uygulandıđı alanlar řekil 2.7'de g sterilmiřtir



řekil 2-11. Yapay zek , makine  ğrenmesi ve derin  ğrenme iliřkisi [44]

řekil 2-7'de Yapay zek , makine  ğrenmesi, derin  ğrenme ve yapay sinir ađları arasındaki iliřkiyi g stermektedir. Yapay zek  en geniř kavram olarak g sterilirken, makine  ğrenmesi yapay zek nın bir alt k mesi, derin  ğrenme ise makine  ğrenmesinin bir alt k mesi olarak temsil edilmiřtir. Bu řekil, bu kavramların birbirini nasıl kapsadıđını ve derin  ğrenmenin yapay zek nın en  nemli alanı olduđunu g stermektedir.


Yapay zek , robotik, makine  ğrenimi, dođal dil iřleme, bilgisayarla g rme, sinirsel hesaplama, konuřma tanıma, planlama ve optimizasyon gibi  eřitli alanlarda uzman sistemlerde kullanılmaktadır. Bu alanlarda  alıřan bireylerin iř verimliliđini ve g venliđini artırmak  zere tasarlanan uzman sistemler, yapay zek  teknolojilerinin daha iyi performans sađlamadaki  nemini ortaya koyuyor. Yapay zek  teknolojileri otomasyon, veri analizi ve tahmin alanlarında yaygın olarak kullanılmakta ve  eřitli

alanlardaki süreçlerin ve karar alma mekanizmalarının iyileştirilmesindeki önemni göstermektedir.

Yapay zekânın kullanıldığı alanların bazıları şunlardır:

- **Uzman Sistemler ve Robotik:** Uzman sistemler, belirli bilgi alanlarında uzmanlaşmış yazılımlardır ve karmaşık problemleri çözmede kullanılmaktadır. Bu sistemler, sağlık, mühendislik ve finans gibi çeşitli alanlarda başarılı uygulamalar bulmuştur [45]. Robotik ise, endüstriyel otomasyonda ve tehlikeli ortamlarda insanların yerine geçerek güvenliği artırmaktadır [46].
- **Makine Öğrenimi ve Doğal Dil İşleme:** Makine öğrenimi, büyük veri setlerinden öğrenerek öngörülerde bulunabilen ve kararlar alabilen algoritmalar geliştirmeyi amaçlamaktadır. Teknolojiler, finansal piyasalarda tahmin yapmaktan sağlık alanında hastalık teşhisine kadar geniş bir yelpazede kullanılmaktadır [47]. Doğal dil işleme (NLP), insan dillerinin bilgisayarlar tarafından anlaşılması ve işlenmesini sağlayan bir alandır. Chatbot'lar ve dil çeviri sistemleri, bu teknolojinin yaygın uygulamalarından birkaçıdır [48].
- **Bilgisayar Görme ve Sinirsel Hesaplama:** Bilgisayar görme, görsel verilerin işlenmesi ve analiz edilmesi ile ilgilenir. Nesne tanıma, yüz tanıma ve otomatik sürüş gibi uygulamalarda önemli bir rol oynamaktadır [49]. Sinirsel hesaplama ise, biyolojik sinir ağlarının işleyişinden ilham alan yapay sinir ağları geliştirmeyi amaçlar. Hesaplama modeli, derin öğrenme algoritmalarının temelini oluşturur [50].
- **Konuşma Tanıma ve Planlama:** Konuşma tanıma teknolojileri, insan konuşmasını metne dönüştürme yeteneğine sahiptir ve sesli asistanlar gibi uygulamalarda kullanılmaktadır [51]. Planlama ve optimizasyon ise, karmaşık süreçlerin en verimli şekilde yönetilmesini ve kaynakların optimal kullanımını sağlar [52].
- **Otomasyon ve Veri Analizi:** Yapay zekâ, endüstriyel otomasyondan veri analizine kadar geniş bir uygulama yelpazesinde kullanılarak iş süreçlerinin etkinliğini artırmaktadır. Veri analitiği ve öngörücü modelleme, büyük veri setlerinden anlamlı içgörüler elde etmek ve gelecekteki eğilimleri tahmin etmek için yapay zekâ yöntemlerini kullanır [53].

Yapay zekânın çeşitli disiplinlerde ve uygulamalarda nasıl kullanıldığını ve teknolojilerin sağladığı faydaları göstermektedir. Yapay zekânın sürekli gelişimi, yeniliklerin ve uygulamaların artarak devam edeceğini göstermektedir. . Şekil 2-8’de Yapay zekânın uygulama alanları gösterilmektedir.



Şekil 2-12. Yapay Zeka ve Uygulama alanları

Şekil 2-8’de Yapay zekâ teknolojilerinin sağlık, finans, otonom sistemler, görüntü işleme ve doğal dil işleme gibi çeşitli alanlardaki kullanım alanlarını özetleyen diyagramı göstermektedir. Yapay zekânın geniş kullanım alanlarını ve bu alanlarda sağladığı faydaları göstermektedir.

2.3 Makine Öğrenmesi

Makine öğrenimi, modern bilgi çağında artan bir öneme sahip olan ve geniş uygulama alanlarına hitap eden bir bilim dalıdır. Bilgisayar sistemlerinin açık bir şekilde programlanmadan öğrenme yeteneklerini geliştirmekte ve bu sayede veri analizi ile otomasyon süreçlerinin kapsamını genişletmektedir. Makine öğrenimi, istatistiksel yöntemler ve algoritmalar kullanarak büyük ve karmaşık veri kümelerinden anlamlı bilgiler çıkarılmasını mümkün kılmakta ve bilgiler çeşitli sektörlerde yenilikçi çözümler geliştirilmesine katkıda bulunmaktadır [54]. Makine öğreniminin sağlık, finans, pazarlama, ulaşım, imalat ve eğitim gibi çeşitli alanlarda sunduğu fırsatlar, daha verimli ve etkili süreçlerin geliştirilmesine önemli katkı sağlamıştır. Örneğin, sağlık sektöründe makine öğrenimi, hastalıkların erken teşhisi ve tedavilerinde önemli ölçüde ilerlemeler kaydetmiştir [55]. Makine öğreniminin başarısı, doğru veri toplama, uygun algoritma seçimi ve model değerlendirme süreçlerinin titizlikle yürütülmesine bağlıdır. Ayrıca,

modelin genelleme yeteneğini artırmak amacıyla uygun hiperparametre ayarlamalarının ve çapraz doğrulama tekniklerinin kullanılması büyük önem taşımaktadır [56]. Veri gizliliği ve model şeffaflığı gibi unsurlar, sorumlu makine öğrenimi uygulamalarının temel taşları olarak değerlendirilmelidir [57]. Makine öğrenimi, veriye dayalı karar verme süreçlerini dönüştürerek çeşitli endüstrilere ve araştırma alanlarına yenilikçi çözümler sunmaktadır. Sağladığı olanaklar ve karşılaştığı zorluklar hem akademik dünyada hem de endüstride büyük ilgi ve yatırım alanı olarak varlığını sürdürmektedir. Gelecekte, makine öğreniminin insan yaşamını daha da kolaylaştıracak ve verimliliği artıracak yenilikçi uygulamalarla gelişmeye devam etmesini mümkün kılar [58].

Makine öğrenimini büyük miktarda veriyi analiz etme, kalıpları tanıma ve gelecekteki veri kümeleri için bilinçli tahminler ve kararlar almak için veriler içinde bağlantılar kurmaktadır. Sistemlerin yeni bilgileri genelleştirmesini ve bunlara uyum sağlamasını sağlamak için geçmiş veriler üzerinde algoritmaların eğitilmesini içerir, böylece karar vermede doğruluk ve verimlilik artar [59]. İnternet ve çeşitli kaynaklardan elde edilen büyük hacimli verinin erişilebilirliği ve kullanılabilirliği nedeniyle bilgisayar uygulamaları son yıllarda tek veri işlemeden makine öğrenmesine önemli ölçüde kaymıştır. Makine öğrenimi, ilgili veriler üzerinde bir algoritmayı eğiterek insan yardımını otomatik hale getiriyor [60].

2.3.1 Öğrenme Paradigmaları

➤ **Denetimli Öğrenme (Supervised Learning):** Model, etiketlenmiş veri kullanılarak eğitilir. Her veri örneği, bir girdi (özellikler) ve bir çıktı (etiket) çiftinden oluşur. Model, girdi-çıkı ilişkisini öğrenir ve yeni girdiler için çıktı tahminleri yapar. Örnek algoritmalar: Linear Regression, Logistic Regression, Decision Trees ve Support Vector Machines (SVM) [61].

➤ **Denetimsiz Öğrenme (Unsupervised Learning):** Model, etiketlenmemiş veri kullanarak eğitilir. Model, verinin iç yapısını gizli örüntülerini ve kümelerini keşfetmeye çalışır. Örnek algoritmalar: k-ortalama (k-means) kümeleme, başlıca bileşen analizi (PCA) [62].

➤ **Pekiştirmeli Öğrenme (Reinforcement Learning):** Bir ajan, bir ortam içinde belirli eylemler gerçekleştirir ve her eylem sonrasında ödülleri alır. Ajan, ödülleri maksimize edecek şekilde eylemlerini en iyi duruma getirmeyi öğrenir. Öğrenme türü, oyun teorisi ve robotikte yaygın olarak kullanılır [63].

2.3.2 Makine Öğrenmesinin Türleri


- **Doğrusal Modeller:** Doğrusal regresyon, lojistik regresyon gibi modeller, girdiler ile çıktı arasındaki doğrusal ilişkiyi modellemeyi amaçlar [64].
- **Karar Ağaçları ve Ansambl Yöntemleri:** Karar ağaçları, veriyi ağaç yapısında bölerek sınıflandırır. Ansambl yöntemleri (Ör. Random Forest, Gradient Boosting) birden fazla karar ağacının kombinasyonu ile daha güçlü modeller oluşturur [65].
- **Sinir Ağları ve Derin Öğrenme:** Yapay sinir ağları, biyolojik sinir sistemlerinden esinlenerek geliştirilmiştir. Derin öğrenme, çok katmanlı sinir ağları kullanarak karmaşık veri örüntülerini öğrenir. Modeller, özellikle büyük veri setleri ve güçlü hesaplama kaynakları ile yüksek performans gösterir [66]
- **Olasılıksal Modeller:** Naive Bayes, Markov modelleri ve gizli Markov modelleri (HMM) gibi modeller, olasılıksal yöntemlerle veri örüntülerini modellemeyi amaçlar [67].

2.4 Derin Öğrenme (Deep Learning)

Derin öğrenme, makine öğrenmesi ve yapay zekânın bir alt disiplini olarak hızla gelişmekte ve genişlemekte olan bir araştırma alanıdır. Büyük ölçekli veri kümelerinden öğrenme kabiliyeti sayesinde, karmaşık problemlerin çözümünde dikkate değer başarılar elde etmiştir. Derin öğrenme, özellikle görüntü tanıma, doğal dil işleme ve oyunlar gibi alanlarda insan düzeyinde performans sergileyen sistemlerin geliştirilmesinde öncülük etmektedir.[68]. Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla verilerden özellik çıkarımı gerçekleştirir. Genellikle bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından meydana gelmektedir. Her bir katmandaki nöronlar, önceki katmandaki nöronların çıktıları ile beslenir ve öğrenme süreci, bu nöronlar arasındaki bağlantı ağırlıklarında en iyi sonucu elde edilmesini sağlar [69].

2.4.1 Derin Sinir Ağları

Deep Neural Networks (DNN), klasik yapay sinir ağlarının bir genişlemesidir ve birden fazla gizli katmana sahiptir. Yapılar, karmaşık veri temsillerini öğrenme kapasitesine sahiptir ve özellikle büyük veri setleri üzerinde etkili bir şekilde çalışır [70]. Şekil 2-9'da Derin Sinir Ağları (DNN) mimarisini ve temel çalışma prensibini vurgulamaktadır.

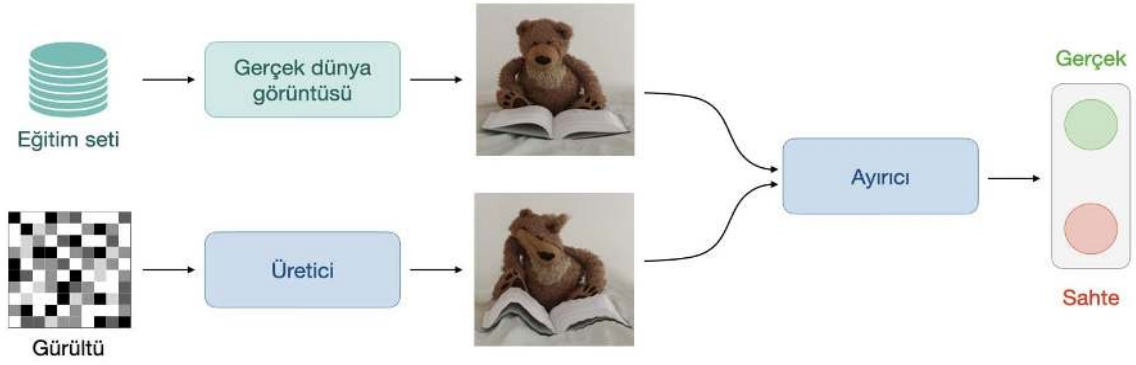


Şekil 2-13. Derin sinir ağları (DNN - Deep Neural Networks) [71].

Şekil 2-9'da Çok katmanlı sinir ağlarının genel yapısını ve bilgi akışını gösterir. DNN'ler, derin öğrenme modellerinde yaygın olarak kullanılan, verilerin çok seviyeli temsillerini öğrenen yapılar olarak tanımlanmaktadır. Çok katmanlı sinir ağlarının nasıl çalıştığını ve verilerin bu katmanlar arasında nasıl işlendiğini açıklar. DNN'ler, derin öğrenme modellerinde yaygın olarak kullanılan ve verilerin çok seviyeli temsillerini öğrenen yapılardır.

2.4.2 Konvolüsyonel Sinir Ağları

Convolutional Neural Networks (CNN), özellikle görüntü işleme alanında büyük başarılar imza atmıştır. CNN'ler, yerel bağlantılar ve havuzlama katmanları kullanarak verilerdeki hiyerarşiyi öğrenir. Nesne tanıma ve sınıflandırma görevlerinde yaygın olarak kullanılır [72]. Şekil 2-10'da Evrimsel Sinir Ağlarının (CNN) çalışma şekli gösterilmiştir.




Şekil 2-14. Evrişimsel sinir ağları (CNN - Convolutional Neural Networks) [73].

Şekil 2-10’da Evrişimsel sinir ağlarının (CNN) çalışma prensibini göstermektedir. Özellikle görüntü sınıflandırma ve nesne tanıma görevlerinde yaygın olarak kullanılmaktadır. CNN’in temel bileşenlerini ve görüntü işleme süreçlerini açıklamaktadır.

2.4.3 Tekrarlayan Sinir Ağları

Recurrent Neural Networks (RNN), sıralı verilerle çalışmak üzere tasarlanmış ağlardır. Zaman içindeki bağımlılıkları öğrenme kapasitesine sahiptir ve dil modelleme, konuşma tanıma gibi uygulamalarda kullanılır. Özellikle uzun kısa süreli bellek Long Short-Term Memory (LSTM) ağları, uzun dönemli bağımlılıkları öğrenmede etkili olmuştur [74]. Şekil 2-11’de Tekrarlayan Sinir Ağına örnek görsel gösterilmiştir.



Şekil 2-15. Tekrarlayan sinir ağları (RNN - Recurrent Neural Networks) [75].

Şekil 2-11’de Zaman serisi verilerini modellemek ve sıralı bilgiyi öğrenmek için kullanılan RNN yapısını açıklayan bir görseldir. RNN’ler özellikle konuşma tanıma ve doğal dil işleme alanlarında yaygın olarak kullanılmaktadır.

2.4.4 Derin Öğrenmenin Uygulama Alanları

Derin öğrenme, çok çeşitli alanlarda ve uygulamalarda önemli yeniliklere ve ilerlemelere olanak tanımaktadır. Görüntü ve ses işleme, doğal dil işleme, sağlık, finans, perakende ve daha birçok alanda derin öğrenme teknikleri, karmaşık problemlerin çözümünde ve süreçlerin iyileştirilmesinde büyük potansiyele sahiptir.

Görüntü Tanıma ve Sınıflandırma: Derin öğrenme, özellikle CNN’ler sayesinde görüntü tanıma ve sınıflandırma alanında büyük ilerlemeler kaydetmiştir. Bu uygulamalar şunları içermektedir

- **Tıbbi Görüntüleme:** Radyoloji, dermatoloji ve diğer tıbbi alanlarda, MRI ve CT taramaları, röntgenler ve cilt lezyonlarının analizinde derin öğrenme modelleri kullanılmaktadır. Hastalıkların erken teşhisi ve doğru tanısı için büyük potansiyel taşımaktadır [76].

- **Otomotiv Sektörü:** Otonom araçlarda, görüntü işleme sistemleri yol ve trafik işaretlerinin tanınması, yaya ve araç tespiti gibi kritik görevlerde kullanılmaktadır. Tesla ve Waymo gibi şirketler, bu teknolojiyi otonom sürüş sistemlerinde entegre etmektedir [77].

- **Yüz Tanıma:** Güvenlik ve erişim kontrol sistemlerinde, sosyal medya platformlarında ve kullanıcı doğrulama süreçlerinde yüz tanıma teknolojisi yaygın olarak kullanılmaktadır. Bu teknoloji, hem güvenlik hem de kullanıcı deneyimini geliştirmektedir [78].

- **Doğal Dil İşleme (NLP):** Derin öğrenme ve doğal dil işleme alanında önemli gelişmeler sağlamıştır. NLP uygulamaları şunları içermektedir:

- **Makine Çevirisi:** Derin öğrenme modelleri, bir dilden başka bir dile otomatik çeviri yapmada önemli başarılar elde etmiştir. Google Translate, neural machine translation (NMT) teknolojisini kullanarak çeviri kalitesini artırmıştır [79].


- **Dil Modelleme ve Metin Üretimi:** Generative Pre-trained Transformer (GPT) ve Bidirectional Encoder Representations from Transformers (BERT) gibi modeller, metin üretimi, soru-cevap sistemleri ve metin tamamlama gibi görevlerde insan benzeri performans sergilemektedir [80]

➤ **Duygu Analizi:** Sosyal medya verileri ve müşteri geri bildirimlerinden duygu analizi yapmak için derin öğrenme modelleri kullanılmaktadır. Şirketlerin müşteri memnuniyetini artırma ve pazarlama stratejilerini optimize etme gibi amaçlarla kullanılmaktadır [81].

Derin öğrenme, büyük veri setleri ve yüksek işlem gücü ile desteklendiğinde, karmaşık problemleri çözme kapasitesi ile hem akademik hem de endüstriyel uygulamalarda hızla ilerlemeye devam etmektedir. Gelecekte, daha gelişmiş modeller ve algoritmaların geliştirilmesiyle derin öğrenmenin daha geniş uygulama alanlarına yayılmasını mümkün kılar.

2.5 Yapay Sinir Ağları

Bilgisayarlar, günümüzde vazgeçilmez bir unsur haline gelmiş olup, artık insan benzeri karar verme ve öğrenme yetenekleri kazandıkları için kullanım alanları genişlemiştir. Matematiksel olarak ifade edilmesi zor ve insan müdahalesiyle çözülmesi güç olan problemlerin çözümünde yapay zekâ teknikleri kullanılmaktadır. Yapay zekâ yöntemlerinin en belirgin özelliği, olaylar ve problemler karşısında örneklerden, deneyimler den öğrenerek çözümler üretme kapasitesine sahip olmalarıdır [82]. Artificial Neural Networks (YSA), biyolojik sinir sistemlerinin işleyişinden ilham alınarak tasarlanmış hesaplama modelleridir. Modeller, insan beyninin bilgi işleme yeteneklerini taklit etmeye çalışır ve karmaşık veri kümelerindeki desenleri ve ilişkileri ortaya çıkarmak için kullanılır. Makine öğrenmesi alanında önemli bir yere sahiptirler [83]. Yapay sinir ağları, katmanlardan oluşan bir yapıya sahiptir. Katmanlar genellikle giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanı olarak ayrılır. Her katman, nöron olarak adlandırılan işlem birimlerinden oluşur ve bu nöronlar, belirli ağırlıklar ve aktivasyon fonksiyonları kullanılarak birbirlerine bağlanır[84].Şekil 2-12 de Yapay Sinir Ağının biyolojik ve Matematiksel fonksiyon gösterilmektedir



Şekil 2-16. Bir Sinir hücresinin biyolojik ve Matematiksel fonksiyon gösterimi [85].

Şekil 2-12’de Yapay sinir ağlarının temel birimi olan nöronun biyolojik ve matematiksel karşılıklarını gösteren bir şekildir. Nöronlar, biyolojik sinir hücrelerinin çalışma prensibini taklit ederek bilgi işleme süreçlerini gerçekleştirmektedir. Nöronun girdi, ağırlık, aktivasyon fonksiyonu ve çıktı gibi temel bileşenlerini açıklar.

Sinir sistemi, nöron adı verilen hücrelerden oluşur. Her nöron, bir dentrit, bir akson ve bir hücre gövdesi içerir. Dışarıdan gelen uyarılar, sinir hücrelerinde sodyum ve potasyum iyonlarının elektrokimyasal bir değişim oluşturmaya neden olur. Değişim, elektriksel bir potansiyel meydana getirir ve bu potansiyele impuls adı verilir. İmpuls, dentritler aracılığıyla hücre gövdesine iletilir ve daha sonra aksonlar aracılığıyla diğer sinir hücrelerine aktarılır. Akson uçlarının başka bir sinir hücresine bağlanması sinaps olarak adlandırılan bağlantılarla gerçekleşir. Sinapslar, öğrenme süreçlerinde kritik bir rol oynar; bireylerin deneyim ve gözlemleri sonucunda sinaptik bağlantılar yeniden düzenlenir veya yeni bağlantılar oluşur, bu da öğrenmeyi mümkün kılar. YSA da benzer bir süreç söz konusudur. Yapay nöronlar, bilgi girişi (input), bilgi çıkışı (output), her girdinin ağırlığı, toplama fonksiyonu ve aktivasyon fonksiyonundan oluşur. Ayrıca, her nöron için bias adı verilen bir değer de bulunmaktadır. Bu bağlamda, biyolojik sinir sistemindeki dentritler yapay sinir ağlarında inputlara, akson outputa, sinapslar ağırlık

ve bias değerlerine, hücre gövdesi ise toplama ve aktivasyon fonksiyonlarına karşılık gelir. Dolayısıyla, yapay sinir ağlarında öğrenme sürecinin ağırlık ve bias değerlerinin ayarlanması yoluyla gerçekleştiği sonucuna varılabilir [86].

YSA'nın kökeni, Warren McCulloch ve Walter Pitts'in 1943 yılında yayımladıkları makaleye dayanmaktadır. McCulloch ve Pitts, biyolojik nöronların işleyişinden ilham alarak basit bir matematiksel model geliştirdiler. Önerilen model, nöronların belirli bir eşik değeri aşıldığında "ateşleme" davranışı sergilediği varsayımına dayanıyor ve temel mantıksal işlemleri gerçekleştirebiliyordu [73]. 1958 yılında Frank Rosenblatt tarafından geliştirilen perceptron, yapay sinir ağlarının ilk öğrenme algoritmalarından biridir. Perceptron, iki sınıflı ayrık veri kümelerini ayırabilen basit bir model olarak tasarlanmıştır ve ağırlıkların ayarlanması yoluyla öğrenme sürecini gerçekleştirir. Ancak, 1969 yılında Marvin Minsky ve Seymour Papert'in "Perceptrons" adlı eserlerinde belirttikleri üzere, perceptronların sınırlılıkları bulunmakta olup, modeller lineer olarak ayrılmayan problemleri çözmemektedir [87]. 1980'lerde, yapay sinir ağları alanında önemli ilerlemeler kaydedildi. Bu dönemde çok katmanlı algılayıcılar Multi-layer Perceptrons (MLP) ve geri yayılım (Backpropagation) algoritması geliştirildi. David E. Rumelhart, Geoffrey E. Hinton ve Ronald J. Williams, geri yayılım algoritmasını tanıtarak, yapay sinir ağlarının daha karmaşık ve lineer olmayan problemleri başarıyla çözmesini sağladılar [88]. 2000'lerin başından itibaren derin öğrenme alanında önemli ilerlemeler kaydedilmiştir. Yeterli veri ve hesaplama gücünün yanı sıra, yeni algoritmalar ve mimarilerin geliştirilmesi, yapay sinir ağlarının çeşitli alanlarda üstün performans sergilemesini sağlamıştır. Özellikle, CNN ve RNN, görüntü işleme ve doğal dil işleme gibi disiplinlerde önemli başarılar elde etmiştir [89].

2.5.1 Yapay Sinir Hücresinde Yer Alan Elemanlar

Yapay sinir hücresi, biyolojik sinir hücrelerinin (nöronların) işlevini taklit eden bir modeldir. Temel amacı, girdileri işleyip anlamlı çıktılar üretmektir. Yapay sinir hücresinin çeşitli bileşenleri kritik rol oynar. İşte yapay sinir hücresinde yer alan temel elemanlar:

➤ **Girdiler (Inputs):** Yapay sinir hücresi, dışarıdan aldığı bilgi seti olan girdilerle başlar. Bu girdiler, hücreye gelen sinyalleri temsil eder. Her bir giriş, belirli bir ağırlık değeri ile çarpılır ve bu şekilde hücreye iletilir [90].

➤ **Ağırlıklar (Weights):** Ağırlıklar, her bir girişin yapay sinir hücresi üzerindeki etkisini belirler. Girdiler, bu ağırlıklarla çarpılarak hücreye gelir. Ağırlıklar, öğrenme sürecinde güncellenir ve girdilerin önemini temsil eder. Bir girişin ağırlığı ne kadar yüksekse, hücreye olan etkisi o kadar büyük olur [91].

➤ **Önyargı (Bias):** Önyargı, hücreye ek olarak verilen sabit bir değerdir. Önyargı, ağırlıklandırılmış girdiler toplamına eklenir ve aktivasyon fonksiyonuna girmeden önce toplam sonucu etkiler. Önyargı, hücrenin belirli bir eşik değeri aşıldığında aktif hale gelmesini sağlar [92].

➤ **Net Giriş Fonksiyonu (Net Input Function):** Net giriş fonksiyonu, hücreye gelen tüm ağırlıklandırılmış girdilerin ve önyargının toplamıdır. Matematiksel olarak şu şekilde ifade edilir:

Net giriş = $\sum_i (x_i \cdot w_i) + b$ Burada x_i girişleri, w_i ağırlıkları ve b önyargıyı temsil eder [93].

➤ **Aktivasyon Fonksiyonu (Activation Function):** Aktivasyon fonksiyonu, net girişi alır ve hücrenin çıktısını belirler. Bu fonksiyon, doğrusal olmayan bir dönüşüm gerçekleştirir ve hücrenin aktif olup olmayacağını belirler. Yaygın olarak kullanılan aktivasyon fonksiyonları şunlardır:

- **Sigmoid:** $S(x) = \frac{1}{1+e^{-x}}$ (1)

- **ReLU (Rectified Linear Unit):** $\max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases}$ (2)

- **Tanh (Hyperbolic Tangent):** $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ [94]. (3)


➤ **Çıkış (Output):** Aktivasyon fonksiyonunun sonucunda, yapay sinir hücresi bir çıktı üretir. Bu çıktı, diğer yapay sinir hücrelerine girdi olarak iletilir veya ağı son katmanında nihai sonuç olarak alınabilir [95].

Bu elemanlar birlikte çalışarak, yapay sinir hücresinin bilgi işleme ve karar verme süreçlerini gerçekleştirir.

2.6 Çekişmeli Üretici Ağlar

Derin öğrenme yöntemleri, görüntü üretimi alanında önemli başarılar elde etmiştir. Bu bağlamda, 2014 yılında Ian Goodfellow tarafından önerilen Generative Adversarial Networks (GAN), görüntü üretiminde kullanılan ilk derin öğrenme modelleri olarak dikkat çekmektedir. Üretken modelleme, mevcut veri kümesindeki

kalıpları otomatik olarak keşfetme ve öğrenme yoluyla yeni örnekler oluşturmayı amaçlayan bir denetimsiz öğrenme yöntemidir. Geleneksel derin ağ mimarilerinden farklı olarak, GAN iki temel bileşen içerir: bir üretici (generative, G) ve bir ayırıcı (discriminator, D). Bu iki ağ, birbirine karşıt bir şekilde çekişmeli olarak çalışarak öğrenme sürecini gerçekleştirir [96]. Şekil 2-13'te GAN'ın çalışma şeması gösterilmektedir.




Şekil 2-17. GAN'ın Çalışma Prensipleri [88].

Şekil 2-13'te Generative Adversarial Network (GAN) modelinin temel çalışma prensibini açıklamaktadır. Model, üretici (generator) ve ayırt edici (discriminator) olmak üzere iki ağdan oluşmaktadır. Üretici ağ, rastgele gürültü girdisini yüksek çözünürlüklü bir görüntüye dönüştürmeye çalışırken, ayırt edici ağ bu görüntülerin gerçek mi yoksa yapay mı olduğunu ayırt etmeye çalışmaktadır.

2.6.1 Üretici (Generator) Model

Üretici, rastgele gürültüden gerçekçi görüntüler oluşturmayı amaçlayan bir sinir ağıdır. Genellikle bir DNN veya CNN mimarisi kullanılır. Üreticinin amacı, ayırt ediciyi kandıracak kadar gerçekçi görüntüler üretmektir. GAN yeni ve doğru verilerin oluşturulmasında ki sorumlu temel unsur, üretici modelidir. Üretici, rastgele bir gürültü vektörünü giriş olarak alır ve bunu metin veya görüntü gibi karmaşık veri örneklerine dönüştürür. Genellikle derin bir sinir ağı olarak yapılandırılan üretici, eğitim verilerinin altında yatan dağılımı öğrenilebilir parametreler aracılığıyla modellemeye çalışır. Parametrelerini geri yayılım yöntemiyle en iyi sonucu elde ederken, çıktısını gerçek verileri andıran örnekler üretmek üzere ayarlar. Üreticinin, ayırt ediciyi yanıltabilecek

nitelikte yüksek kaliteli ve çeşitli örnekler oluşturma yeteneği, modelin başarısının belirleyici faktörüdür [97]. Şekil-2-14'te Üretici ağı model gösterilmektedir.




Şekil 2-18. GAN Üretici model.

Şekil 2-14'te GAN yapısındaki üretici modelinin yapısını ve işleyiş mekanizmasını göstermektedir. Üretici ağ, giriş olarak aldığı düşük boyutlu rastgele gürültüyü işleyerek daha büyük boyutta ve gerçekçi görünen görüntüler üretir. Bu model, çeşitli katmanlar içererek veri dağılımını öğrenmeye ve sahte görüntüleri gerçekçi hale getirmeye odaklanmaktadır.

2.6.2 Ayırıcı (Discriminator) Model

Ayırt edici, bir görüntünün gerçek mi yoksa üretici tarafından oluşturulmuş mu olduğunu tahmin etmeye çalışan bir sınıflandırıcıdır. Bu da genellikle bir CNN mimarisi kullanır. Ayırt edicinin amacı, gerçek ve üretilmiş görüntüleri mümkün olduğunca doğru bir şekilde ayırt etmektir. Ayırıcı, zamanla veri kümesindeki gerçek görüntüler ile üretici tarafından oluşturulan yapay görüntüler arasındaki farkları ayırt etmeyi öğrenir. Bu süreç, ayırıcının parametrelerini kademeli olarak iyileştirmesine ve ayırım yapma yeteneğini geliştirmesine de imkân sağlar. Resim verileriyle çalışırken, mimaride genellikle diğer yöntemler için evrimsel katmanlar veya ilgili yapılar kullanılır. Çekişmeli eğitim prosedürünün amacı, ayırıcının, oluşturulan örnekleri sahte, gerçek örnekleri ise gerçek olarak doğru bir şekilde tanımlama kapasitesini en üst düzeye çıkarmaktır. Ayırıcı, oluşturucu ve ayırıcının etkileşimi sonucunda giderek daha ayırt edici hale gelir ve bu, GAN'ın genel olarak son derece gerçekçi görünen sentetik veriler üretmesine katkıda bulunur [98]. Şekil 2-15'te Ayırıcı Ağı'nın modeli gösterilmektedir.



Şekil 2-19. GAN ayırıştırıcı model.

Şekil 2-15'te GAN yapısındaki ayırt edici modelin mimarisini açıklamaktadır. Ayırt edici ağ, gerçek görüntüler ile üretici tarafından oluşturulan yapay görüntüleri birbirinden ayırt etmeye çalışarak, üretici modelin çıktılarının daha gerçekçi olmasını sağlar. Bu süreç, üretici modelin performansını artırmak amacıyla bir eğitim döngüsü içerisinde gerçekleştirilir.

2.6.3 Eğitim Süreci

GAN sistemi, generator ve discriminator ağ olmak üzere iki derin sinir ağından oluşmaktadır. Bu ağlar, generatorun veri üretme çabası içinde olduğu discriminatorun ise üretilen verinin gerçek mi yoksa sahte mi olduğunu belirlemek için yaptığı çekişmeli bir eğitim sonucunda eğitilir. Üretici sinir ağı, eğitim verilerini inceleyerek özniteliklerini öğrenir ve tanımlar ve bu özniteliklere rastgele gürültü veya değişiklikler ekleyerek veriyi değiştirir. Ardından, bu değiştirilmiş veriler ayırıcı ağına iletilir. Discriminator, çıktının orijinal veri kümesine ait olma durumunu değerlendirir ve üretici ağı, bir sonraki döngüde gürültü vektörlerinin rastgeleleştirilmesini azaltacak şekilde klavuzluk eder. Generator, discriminatorun hata olasılığını maksimize etmeye çalışırken, discriminator ise bu hata olasılığını minimize etmeye çalışır. Eğitim süreci boyunca, her iki ağ da denge durumuna ulaşana kadar sürekli olarak evrim geçirir ve karşılıklı olarak gelişir. Denge durumuna ulaşıldığında, ayırıcı ağ sentezlenmiş verileri ayırt edemez ve bu noktada eğitim süreci tamamlanmış olur [99].

2.6.4 Matematiksel Denklem

GAN'ların temel amacı, ayırıcı ağın gerçek verileri doğru bir şekilde tanımlama kapasitesini maksimize ederken, üretici ağın da sahte verileri gerçekmiş gibi ayırıcı ağı

yanılması sağlamaktır. Bu hedef, aşağıdaki minimaks oyun teorisi problemi ile matematiksel olarak formüle edilir.

$$\min_{D,G} V(D, G) = E_{x \sim p_{data}}(X)[\log D(X)] + E_{z \sim p_z}(z)[\log(1 - D(G(z)))] \quad (4)$$

- $E_{x \sim p_{data}}(x)$ gerçek veri örneklerinin beklentisini temsil eder.
- $E_{z \sim p_z}(z)$ gürültü vektörlerinden üretilen sahte veri örneklerinin beklentisini temsil eder.
- $p_{data}(x)$ gerçek veri kümesinin dağılımını ifade eder.
- $p_z(z)$ gürültü vektörlerinin dağılımını ifade eder.

Ayırıcı Ağ Eğitme: Sabit üretici ağ parametreleri θ_g ile ayırıcı ağ parametreleri θ_d güncellenir. Ayırıcı, gerçek verileri doğru tanımlamaya ve üreticinin sahte verilerini sahte olarak tanımlamaya çalışır.

$$\theta_d \leftarrow \theta_d + \nabla \theta_d \frac{1}{m} \sum_{i=1}^m [\log D(x(i)) + \log(1 - D(G(z(i))))] \quad (5)$$

Üretici Ağ Eğitme: Sabit ayırıcı ağ parametreleri θ_d ile üretici ağ parametreleri θ_g güncellenir. Üretici, ayırıcıyı kandırmak için sahte verilerini gerçekmiş gibi tanıtmak için çalışır.

$$\theta_g \leftarrow \theta_g - \nabla \theta_g \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(z(i)))) \quad (6)$$

Denge Durumu: Üretici ve ayırıcı ağlar bir denge durumuna ulaşana kadar bu süreç tekrarlanır. Bu durumda ayırıcı ağ, gerçek ve sahte veriler arasında ayırım yapamaz hale gelir [100].

Peak Signal-to-Noise Ratio (PSNR): PSNR, belirli bir alınan veya işlenen sinyali orijinal kaynak sinyali ile karşılaştıran bir sinyal işleme ölçümüdür. Bu karşılaştırma, işlenmiş bir sinyalin orijinaline ne kadar sadık kaldığını ölçmemize ve ayrıca sinyaldeki olası gürültüleri veya bozulmaları belirlememize yardımcı olur. PSNR'nin bir sinyalin bozulma işleminden önce ve sonra doğrudan bir ilişkisini temsil eder.

$$PSNR = 20 \log_{10} \frac{MAX_1^2}{MSE} \quad (7)$$

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \cdot \sum_{j=0}^{n-1} [(I(i,j) - K(i,j))]^2 \quad (8)$$

Burada *MAX* sinyalin mümkün olan en yüksek değeridir. 8 bitlik bir gri tonlamalı görüntü durumunda, Denklem (7)'de gösterildiği gibi *MAX=255*, *PSNR* ise MSE (Ortalama Kare Hata) ile ters orantılıdır. Son değer *PSNR* desibel olarak verilmiştir.

PSNR genellikle alınan veya işlenen görüntünün kaynak görüntüye kıyasla ortalama kare hatasına dayanarak görüntü veya video sinyallerinin iletim ve sıkıştırma kalitesini değerlendirmek için kullanılır [101]. Ancak, segmentasyon algoritması değerlendirmesi için analitik bir ölçüm olarak da kullanılmıştır [102]. Çoklu eşikli algoritmalar durumunda, değerlerinin yanı sıra eşik sayısını belirlemek için bir ölçüt olarak da kullanılmıştır [103].

Structural Similarity Index (SSIM): Dijital görüntülerin kalitesini değerlendirmek için kullanılan bir metriktir. SSIM, insan görsel sisteminin (HVS) algısal özelliklerine dayanarak geliştirilmiş ve geleneksel yöntemlerin aksine, görüntülerin yapısal bilgilerini karşılaştırarak bozulma seviyelerini belirler [104].

SSIM şu üç bileşeni değerlendirir:

- **Parlaklık (Luminance)** : İki görüntünün ortalama parlaklık değerleri karşılaştırılır.
- **Kontrast (Contrast)** : Görüntülerin kontrastı varyansları üzerinden hesaplanır.
- **Yapısal Bilgi (Structure)**: Kovaryans hesaplanarak iki görüntünün yapısal bilgileri karşılaştırılır.

SSIM, aşağıdaki formül ile hesaplanır:

$$SSIM(x,y)=\frac{\{(2\mu_x\mu_y+c_1)(2\sigma_{xy}+c_2)\}}{\{(\mu_x^2+\mu_y^2+c_1)(\sigma_x^2+\sigma_y^2+c_2)\}} \quad (9)$$

- μ_x ve μ_y orijinal ve bozulmuş görüntünün ortalama parlaklık değerleridir.
- $\sigma_x^2 + \sigma_y^2$, görüntülerin varyanslarıdır.
- $\sigma_{xy} + c_2$, iki görüntü arasındaki kovaryanstır.
- c_1 ve c_2 hesaplama'da istikrar sağlamak için eklenen sabitlerdir.

2.6.5 Çekişmeli Üretici Ağların Avantajları

Gerçekçi Veri Üretimi: GAN'lar, yüksek kaliteli ve gerçekçi görseller, sesler ve diğer veri türlerini üretebilir. Özellikle görüntü üretimi ve iyileştirme görevlerinde etkileyici sonuçlar elde edilmiştir [105].

Çeşitlilik: Üretici ağ, girdi olarak aldığı rastgele gürültü vektörleri sayesinde çok çeşitli ve farklı veriler üretebilir. Bu, veri çeşitliliğini artırmak için kullanışlıdır [106].

Yarı Denetimli Öğrenme: GAN'lar, sınırlı miktarda etiketli veri ile etkili bir şekilde çalışabilir ve etiketli verilerin sayısını artırmak için kullanılabilir [107].

Transfer Öğrenme: Önceden eğitilmiş GAN modelleri, yeni görevler için başlangıç noktası olarak kullanılabilir, bu da eğitim sürelerini kısaltır ve performansı artırır [108].

Veri Tamamlama ve İyileştirme: GAN'lar, eksik veya bozulmuş verileri tamamlamak ve iyileştirmek için kullanılabilir. Örneğin, düşük çözünürlüklü görüntüleri yüksek çözünürlüğe dönüştürebilir [109].

2.6.6 Çekişmeli Üretici Ağların Dezavantajları

Eğitim Zorlukları: GAN'ların eğitim süreci kararsız olabilir ve bu, modellerin dengesiz bir şekilde öğrenmesine yol açabilir. Eğitim sırasında çökmeler ve salınımlar sıkça karşılaşılan sorunlardır [110].

Mode Collapse (Mod Çökmesi): Üretici ağ, yalnızca birkaç çeşit veri üretebilir aynı zaman da veri çeşitliliğini azaltır. Buna "mode collapse" denir ve GAN'ların önemli bir sorunudur [111].

Yüksek Hesaplama Maliyeti: GAN'ların eğitimi genellikle yüksek hesaplama gücü gerektirir ve büyük veri kümeleri ile çalışırken maliyetli olabilir [112].

Denetimsiz Öğrenme Sınırlamaları: GAN'lar genellikle denetimsiz öğrenme yöntemleriyle eğitilir ve etiketli veri gerektiren bazı görevlerde sınırlı performans gösterir [113].

Değerlendirme Zorlukları: Üretilen verilerin kalitesini objektif olarak değerlendirmek zor olabilir. Geleneksel metrikler, GAN'ların ürettiği verilerin kalitesini ve çeşitliliğini tam olarak yansıtmayabilir [114].

2.6.6 Yüksek Çözünürlüklü Görüntü Oluşturmada GAN'ların Kullanımı

Son yıllarda, GAN'lar yüksek çözünürlüklü görüntü üretiminde önemli bir ilerleme sağlamıştır. GAN'lar, gerçekçi görüntüler oluşturmak için iki ayrı ağ kullanır: bir üretici (generator) ve bir ayırtıcı (discriminator). Üretici ağ, rastgele gürültüden yeni görüntüler üretirken, ayırtıcı ağ ise bu görüntülerin gerçek mi yoksa sahte mi olduğunu belirlemeye çalışır. Bu iki ağ arasındaki rekabetçi süreç, üretici ağın daha gerçekçi görüntüler üretme yeteneğini artırır. Yüksek çözünürlüklü görüntü oluşturma konusunda GAN'ların kullanımı, özellikle Tek Görüntü Süper Çözünürlüğü (Single Image Super-Resolution, SISR) alanında büyük bir etkiye sahiptir. SISR, düşük çözünürlüklü bir görüntüden yüksek çözünürlüklü bir görüntü oluşturmaya amaçlar. Geleneksel SISR yöntemleri genellikle bulanık ve ayrıntısız görüntüler üretirken, GAN tabanlı yöntemler daha gerçekçi ve ayrıntılı görüntüler üretme kapasitesine sahiptir [115].

2.6.7 Süper Çözünürlük (Super-Resolution)

SRGAN, yüksek ölçekleme faktörlerinde fotogerçekçi süper çözünürlük (SR) görüntüleri üretmek amacıyla GAN kullanan bir yöntemdir. Geleneksel SR yaklaşımları, piksel bâzlı hata ölçütlerini (örneğin, ortalama karesel hata - MSE) en aza indirmeye odaklanırken, SRGAN, insan algısına daha yakın kalitede görüntüler üretmek için yenilikçi bir algısal kayıp fonksiyonunu benimsemektedir. Bu kayıp fonksiyonu, gerçek ve süper çözünürlüklü görüntüler arasındaki farkı ayırt etmek için eğitilmiş bir ayırtıcı ağdan yararlanmaktadır. SRGAN, ResNet mimarisini kullanmakta ve VGG19 ağından elde edilen özellik haritaları arasındaki Öklid uzaklığını ölçen bir VGG kaybı uygulamaktadır. Yapılan kapsamlı deneyler, SRGAN'ın PSNR ve SSIM ölçütlerinde üç kamuya açık veri setinde yeni bir standart belirlediğini ortaya koymuştur. Ayrıca, SRGAN ile elde edilen SR görüntülerin kalitesi, MOS testi sonuçlarına göre, diğer ileri teknoloji yöntemlere kıyasla önemli ölçüde daha üstün performans göstermiştir. Bu çalışma, süper çözünürlük alanında algısal kaliteyi artırmada GAN'ların potansiyelini açıkça göstermektedir [116]. Şekil 2-16'da 4 kat yüksek çözünürlüklü SRGAN modeline air örnek bir resim gösterilmektedir.



Düşük çözünürlüklü resim

SRGAN



4 kat yüksek çözünürlüklü resim


Şekil 2-20. SRGAN [100].

Şekil 2-16’da Süper çözünürlük problemlerini çözmek amacıyla kullanılan (SRGAN) modelinin düşük çözünürlükten yüksek çözünürlüğe dönüşümünü göstermektedir.

2.6.8 Geliştirilmiş Süper Çözünürlük (Enhanced Super-Resolution)

Süper çözünürlük görevleri için mevcut SRGAN çerçevesini geliştirmek amacıyla tasarlanmış gelişmiş bir model olan ESRGAN’ı tanıtmaktadır. Ağ mimarisi, karşıt kayıp ve algısal kayıp konularındaki belirli sınırlamaları ele alarak, ESRGAN, yüksek kaliteli ve fotogerçekçi görüntüler üretmede en son teknoloji performansına ulaşmaktadır. ESRGAN, SRGAN’daki parti normalizasyon katmanlarını, ağ kapasitesini artıran ve eğitimi istikrarlı hale getiren yoğun Blok (RRDB) ile değiştirir. RRDB mimarisi, ağların daha derin olmasını sağlayarak doku detaylarının daha iyi geri kazanılmasını ve SRGAN çıktılarında yaygın olarak görülen yapaylıkların azaltılmasını sağlar. ESRGAN, karşıt kayıpları değerlendirmek için RaGAN kullanır. GAN’lardan farklı olarak RaGAN, üretilen görüntülerin gerçek görüntülerle karşılaştırıldığında ne kadar gerçekçi olduğunu değerlendirir. Yöntem, sadece gerçekçi görüntüler üretmekle kalmayıp, aynı zamanda üretilen görüntülerin gerçek görüntülerden daha iyi olmasını sağlar [103]. ESRGAN algısal kayıp fonksiyonunu değiştirerek, aktivasyon katmanlarından önce çıkarılan özellikleri kullanır. Yapılan değişiklik, parlaklık ve doku tutarlılığı konusunda daha güçlü bir denetim sağlar ve sonuç olarak daha keskin ve

görsel olarak daha iyi görüntüler elde edilir. ESRGAN, süper çözünürlük teknolojisinde önemli bir ilerlemeyi temsil etmektedir. Ağ mimarisini rafine ederek, yenilikçi bir karşıt kayıp yaklaşımı benimseyerek ve algısal kayıpları iyileştirerek ESRGAN, öncüllerine göre tutarlı bir şekilde daha yüksek kaliteli, gerçekçi görüntüler üretmektedir [117]. Şekil 2-17 'de ESRGAN (Geliştirilmiş Süper Çözünürlük Üretici Çekişmeli Ağ) ile Görüntü İyileştirme Örneği gösterilmektedir.



Şekil 2-21. Çözünürlük artırma yöntemlerin sonuçları


Şekil 2-17’de ESRGAN modelinin farklı süper çözünürlük teknikleriyle karşılaştırmalı olarak ürettiği yüksek çözünürlüklü görüntüleri göstermektedir. Şekilde, kullanılan yöntemlerin farklı detay seviyelerini nasıl koruduğu ve görüntü kalitesine etkisi incelenmektedir.

2.6.9 Görüntü-Görüntü Çevirisi (Image-to-Image Translation)

Görüntüden görüntüye çeviri, kaynak domain (source domain) görüntülerinin hedef domain (target domain) görüntülerine dönüştürülmesini amaçlayan bir görevdir. Bu işlem, stil transferi, nesne dönüşümü, mevsim değişiklikleri ve fotoğraf restorasyonu gibi birçok farklı uygulamada kullanılır. Geleneksel yöntemlerin yetersiz kaldığı eşleşmemiş veri durumlarında, çeşitli modern yaklaşımlar geliştirilmiştir.

2.6.10 Döngü Tutarlı Üretken Çekişmeli Ağlar (Cycle-Consistent Generative Adversarial Networks)

Görüntüden görüntüye çeviri, bir görüntüleme alanındaki source domain görüntülerin başka bir görüntüleme alanına target domain çevrilmesi sürecidir. Bu görev, stil transferi, nesne dönüşümü ve fotoğraf restorasyonu gibi çeşitli uygulamalarda yer almaktadır. Eşleşmiş eğitim verisinin bulunmadığı durumlarda, geleneksel yöntemler yetersiz kalmaktadır. Bu nedenle, CycleGAN (Cycle-Consistent Generative Adversarial Network) olarak adlandırılan yeni bir yöntem önerilmektedir. CycleGAN, döngü tutarlılık kaybı ve karşıt kaybı kullanarak, eşleşmemiş verilerle yüksek kaliteli görüntü çevirisi gerçekleştirmeyi amaçlamaktadır. Görüntüden görüntüye çeviri, bir giriş görüntüsünden istenilen çıkış görüntüsüne geçiş yapmayı amaçlayan görevdir ve genellikle çeşitli görsel ve grafik problemleri arasında yer alır. Ancak, pek çok görevde eşleşmiş eğitim verisi bulunmamaktadır. Eşleşmiş örneklerin bulunmadığı durumlarda kaynak domaini X 'ten hedef domain Y 'ye görüntü çevirmeyi öğrenen bir yöntem sunulmaktadır. Bu yöntemde, $G: X \rightarrow Y$ haritalamasını, $G(X)$ görüntülerinin dağılımının Y 'deki dağılımla ayırt edilemez olmasını sağlamak amacıyla bir karşıt kayıp fonksiyonu kullanarak öğreniriz. Haritalamanın yeterince kısıtlayıcı olmaması nedeniyle, bu işlemi ters haritalama $F: Y \rightarrow X$ ile birleştiririz ve $F(G(X)) \approx X$ (ve tersi) sağlamak için bir döngü tutarlılık kaybı ekleriz. Eşleşmiş eğitim verilerinin bulunmadığı çeşitli görevlerde nitelikli sonuçlar elde edilmiş olup, stil transferi, nesne dönüşümü, mevsim transferi ve fotoğraf restorasyonu gibi uygulamalar bulunmaktadır [118]. Şekil 2-18'de Döngü Tutarlı Üretken Çekişmeli Ağlar (CycleGAN) ile At Görüntülerinden Zebra Görüntülerine Çeviri Örneği gösterilmektedir.



Şekil 2-22. Görüntüden görüntüye çeviri

Şekil 2-18’de Pix2Pix modeli kullanılarak gerçekleştirilen görüntüden görüntüye çeviri sürecini temsil etmektedir. Modelin giriş görüntüsünü belirli bir stil veya içeriğe uygun şekilde dönüştürme kapasitesini görsel olarak göstermektedir.

2.6.11 Pix2Pix

Pix2Pix, koşullu karşıt ağlar (cGAN) kullanan bir görüntüden görüntüye çeviri modelidir. Model, girdi görüntüsünden çıktı görüntüsüne eşlemeyi öğrenirken, aynı zamanda eşlemeyi daha etkili hale getirmek amacıyla bir kayıp fonksiyonu da öğrenir. Çok farklı kayıp formül gerektiren problemlere aynı genel yaklaşımı uygulamayı mümkün kılar. Pix2Pix, etiket haritalarını kullanarak fotoğraflar oluşturmak ve kenar haritalarından nesneleri üretmek yeniden yapılandırmak ve görüntüleri renklendirmek gibi çeşitli görevlerde etkili olduğunu göstermiştir. Model, U-Net mimarisini kullanarak yüksek çözünürlüklü girdi ve çıktı görüntüleri işleyebilir ve PatchGAN adı verilen bir ayrıştırıcı mimarisiyle yüksek kaliteli sonuçlar elde edebilir. Pix2Pix'in yaygın olarak kullanılmasının nedenleri arasında, çeşitli görevlerde iyi sonuçlar vermesi, kullanımı kolay olması ve parametre ayarlaması gerektirmemesi sayılabilir [119]. Şekil 2-19’da

Koşullu Üretken Çekişmeli Ağlar (cGAN) ile Görüntüden Görüntüye Çeviri Örneği gösterilmektedir. Şekil 2-19’da Pix2Pix örnek görüntü gösterilmiştir.




Şekil 2-23. Koşullu Rekabetçi Ağlarla Görüntüden Görüntüye Çeviriden.

Şekil 2-18’de Pix2Pix modeli kullanılarak gerçekleştirilen görüntüden görüntüye çeviri sürecini temsil etmektedir. Modelin giriş görüntüsünü belirli bir stil veya içeriğe uygun şekilde dönüştürme kapasitesini görsel olarak göstermektedir.

2.6.12 Progresif Büyüme (Progressive Growing)

Teknik olarak, düşük çözünürlükten başlayarak aşamalı olarak yüksek çözünürlüklü görüntüler oluşturmayı sağlar. GAN eğitimi iyileştirmek için yeni bir yöntem olan Aşamalı GAN Büyütmesi’dir. Düşük çözünürlükten başlayarak ve eğitim ilerledikçe yeni katmanlar ekleyerek hem üretici hem de ayırt edici ağları kademeli olarak büyötmeyi içerir ve eğitimi hızlandırır, istikrarı artırır ve daha yüksek kaliteli görüntüler oluşturulmasını sağlar. Oluşturulan görüntülerdeki varyasyonu artırmak için minibatch standart sapması kullanılır. Ayrıca, GAN eğitimi daha da stabilize etmek için genelleştirilmiş öğrenme oranı ve piksel bazlı özellik vektörü normalizasyonu gibi yeni teknikler bulunmaktadır. GAN sonuçlarını değerlendirmek için hem görüntü kalitesini hem de varyasyonu ölçen yeni bir ölçüt olan "Çok Ölçekli İstatistiksel

Benzerlik"i vardır. GAN'ların yüksek kaliteli görüntüler oluşturma yeteneğini önemli ölçüde artırdığını göstermektedir. Aşamalı büyüme ve diğer önerilen teknikler, GAN eğitimini daha istikrarlı ve verimli hale getirerek daha gerçekçi ve çeşitli görüntüler oluşturulmasını mümkün kılmaktadır [120]. Şekil 2-20'de GAN modellerinin düşük çözünürlükten başlayarak aşamalı olarak yüksek çözünürlüklü görüntüler üretir.



Şekil 2-24. Progressively-Growing GANs'da kullanılan Çok Ölçekli Mimarinin Diyagramı

Şekil 2-20'de GAN modellerinin düşük çözünürlükten başlayarak aşamalı olarak yüksek çözünürlüklü görüntüler üretmesini sağlayan kademeli eğitim yöntemini görselleştirmektedir. Bu teknik, yüksek kaliteli ve detaylı görüntü üretimini mümkün kılan temel yaklaşımlardan biridir.

2.6.13 Üretken Çekişmeli Ağlar için Stil Tabanlı Üreteç Mimarisi (Style-Based Generator Architecture for Generative Adversarial Networks)


StyleGAN'ın temel fikri, oluşturulan görüntülerin çözünürlüğünü kademeli olarak artırmak ve stil özelliklerini üretken sürece dâhil etmektir. StyleGAN yüksek kaliteli ve kontrol edilebilir görüntü oluşturma konusunda önemli bir gelişme sağlamıştır. Stil transferi literatürün den esinlenerek, GAN için alternatif bir jeneratör mimarisi sunmaktadır. Önerilen yeni mimari, yüksek düzeyli özelliklerin (örneğin, insan yüzleri üzerinde çalışıldığında poz ve kimlik) ve üretilen görüntülerdeki stokastik varyasyonun (örneğin, çiller, saç) otomatik ve denetimsiz bir şekilde ayrılmasını sağlamaktadır ve ölçek bazında sezgisel kontrol imkânı bulunmaktadır. Yeni jeneratör,

dağılım kalitesi metriklerinde iyileşme sağlamakta, daha iyi interpolasyon özellikleri mümkün kılar.

Temel özellikleri:

- Uyarlanabilir Örnek Normalleştirme (Adaptive Instance Normalization (AdaIN)): Stil bilgisini enjekte eder.
- Aşamalı büyüme (Progressive growing): Aşamalı olarak çözünürlüğü artırır.
- Karıştırma düzenlemesi (Mixing regularization): Farklı stilleri karıştırma yeteneği sağlar [121].

Şekil 2-21’de StyleGAN örnek resimle gösterilmiştir.



Şekil 2-25. StyleGAN örnek resim

Şekil 2-21’de StyleGAN modelinin ürettiği sentetik yüz görüntülerine ait örnekleri içermektedir. Modelin, yüz detaylarını öğrenerek gerçeğe yakın ve yüksek çözünürlüklü sentetik yüzler oluşturabilme yeteneğini göstermektedir.

2.6.14 Koşullu Oluşturma (Conditional Generation)

Koşullu oluşturma, GAN modellerinin belirli bir koşula (örneğin, sınıf etiketi, metin, ya da başka bir modalite) bağlı olarak veri üretmesini sağlayan bir yöntemdir. Geleneksel GAN'lardan farklı olarak, bu modeller jeneratör ve ayırt edici ağılara eklenen bir koşullu bilgi ile çalışır. Böylece, istenilen özelliklere sahip çıktılar üretilebilir.

2.6.15 Büyük Üretken Çekişmeli Ağ (Big Generative Adversarial Network)

Büyük ölçekli GAN eğitiminin, yüksek çözünürlüklü ve çeşitli doğal görüntü sentezi için nasıl kullanılabileceğini inceleyen GAN modelidir. ImageNet gibi karmaşık veri kümeleri üzerinde yapılan deneylerde, jeneratörün girdisinin varyansını azaltan "kesme hilesi" adı verilen bir teknikle, örnek doğruluğu ve çeşitliliği arasında hassas bir denge sağlamayı başarmıştır. BigGAN modellerinin, 128x128 çözünürlükte ImageNet üzerinde eğitildiğinde, önceki en iyi sonuçları geride bırakarak, 166.5'lik bir Inception Puanı (IS) ve 7.4'lük bir Frechet Inception Uzaklığı (FID) elde ettiğini gösteriyorlar. Şekil 2-22'de BigGAN'leri 256x256 ve 512x512 çözünürlüklerde de başarıyla eğiterek, yüksek kaliteli sonuçlar elde edilmiştir [122].



Şekil 2-26. 256x256 ve 512x512 Çözünürlükte üretilen BigGAN örneği


Şekil 2-22’de Büyük ölçekte eğitilmiş BigGAN modelinin oluşturduğu yüksek kaliteli görüntülerden örnekler içermektedir. Modelin detay seviyesini nasıl koruyabildiği görsel olarak analiz edilmektedir.



3 MATERYAL VE YÖNTEM

Bu tezde, derin öğrenme temelli bir süper çözünürlük modeli geliştirilmiştir. Önerilen SRGAN modeli, kullanılarak hem görsel algıyı iyileştirmek hem de görüntü kalite metrikleriyle iyileştirmeyi doğrulamak amacıyla tasarlanmıştır. Modelin performansını değerlendirebilmek ve düşük çözünürlüklü görüntülerin kalite seviyelerinin süper çözünürlüklü görüntülere etkisini gözlemleyebilmek için Cilt Kanseri Veri Seti, Kan Hücreleri Kanseri Veri Seti ve Retina Fundus Veri Seti'nden türetilen, farklı kalite seviyelerine sahip üç ayrı veri kümesi üzerinde deneyler gerçekleştirilmiştir. Yapılan analizlerde elde edilen tüm sonuçlar, literatürdeki yeni ve başarılı modellerle PSNR ve SSIM metrikleri üzerinden karşılaştırılmıştır. Değerlendirme sonuçlarına göre, önerilen derin öğrenme tabanlı modelin diğer modellere kıyasla üstün performans sergilediği görülmüştür.


Cilt Kanseri veri seti, Uluslararası Cilt Görüntüleme İşbirliği'nden (ISIC) alınan toplam 376 görüntüden oluşmaktadır. Veri seti, eğitim ve doğrulama için 300 görüntü eğitim, 76 görüntü doğrulama olacak şekilde ayrılmıştır. Görüntülerin yüksek çözünürlüklü hali 600×450 piksel boyutundadır. Veri setinde, kötü huylu ve iyi huylu onkolojik hastalıkların sınıflandırılması yapılmıştır. Melanom ve benler ağırlıklı olmak üzere diğer alt kümeler aşağıdaki şekilde görüleceği üzere eşit sayıda görüntü içermektedir. Şekil 3.1'de Cilt Kanseri lezyonları içeren iyi huylu ve kötü huylu görüntülerden oluşmuş veri seti görülmektedir.



Şekil 3-1. Cilt kanseri veri seti

Şekil 3-1’de ISIC veri setine ait cilt kanseri görüntülerinin düşük ve yüksek çözünürlüklü halleri karşılaştırılmaktadır. Görüntüler, modelin süper çözünürlük başarısını değerlendirmek için kullanılmıştır. Görüntülerin yüksek çözünürlüklü hali 600×450 piksel boyutundadır.


Kan Hücresi Kanseri Veri Seti, Akut Lenfoblastik Lösemi'nin (ALL) çok yaygın bir kanser türü olarak kesin tanısı, invaziv, pahalı ve zaman alıcı tanı testleri gerektirir. Periferik kan yayması (PBS) görüntüleri kullanılarak yapılan ALL tanısı, kanser olmayan vakalardan alınan kanserin ilk taramasında hayati bir rol oynar. PBS görüntülerinin laboratuvar kullanıcıları tarafından incelenmesi, ALL belirti ve semptomlarının spesifik olmayan doğasının sıklıkla yanlış tanıya yol açması nedeniyle tanı hatası gibi sorunlarla doludur. Bu veri setinin görüntüleri Taleqani Hastanesi'nin (Tahran, İran) kemik iliği laboratuvarında hazırlanmıştır. Veri seti, kan örnekleri yetenekli laboratuvar personeli tarafından hazırlanan ve boyanan ALL'den şüphelenilen 89 hastaya ait 3242 PBS görüntüsünden oluşmakta olup iyi huylu ve kötü huylu olmak üzere iki sınıfa ayrılmıştır. İlki hematojen, ikincisi ise üç alt tipte kötü huylu lenfoblast içeren ALL grubudur: Erken Pre-B, Pre-B ve Pro-B ALL. Tüm görüntüler 100x büyütme bir mikroskopta Zeiss kamera kullanılarak çekilmiş ve JPG dosyaları olarak kaydedilmiştir. Akış sitometrisi aracını kullanan bir uzman tarafından, bu hücrelerin tiplerinin ve alt tiplerinin kesin belirlenmesini yaparak veri seti son halini almıştır. Şekil 3-2’de Kan hücresi kanseri veriseti görülmektedir



Şekil 3-2. Kan hücresi kanseri veri seti

Şekil 3-2’de Kan Hücreleri Kanseri veri seti, Akut Lenfoblastik Lösemi (ALL) tanısı için hazırlanmış 3242 görüntüden oluşmaktadır. Bu çalışmada kullanılan veri seti, toplamda 400 görüntü ile sınırlanmış ve bunların 320’si eğitim, 80’i doğrulama için ayrılmıştır. Görüntülerin yüksek çözünürlüklü hali 1024×768 piksel boyutundadır.

Çalışmamızda kullandığımız bir diğer veri seti ise Retina Fundus veri seti, toplamda 268 görüntü içermekte olup, bunların 214’ü eğitim ve 54’ü doğrulama için ayrılmıştır. Görüntülerin yüksek çözünürlüklü hali 1024×1024 piksel boyutundadır. Görüntüler, 45° FOV ile elde eden bir Nidek AFC-210 fundus kamerasıyla Selanik Aristoteles Üniversitesi, Papageorgiou Hastanesi’nde, Selanik’te 39 hastadan elde edilmiştir. Veri seti görüntüsü Şekil 3.3’te aşağıdaki şekilde görüldüğü gibidir.



Şekil 3-3. Retina fundus veri seti

Şekil 3-3’te Retina fundus veri setine ait görüntüler, düşük ve yüksek çözünürlüklü halleriyle gösterilerek süper çözünürlük uygulamalarının tıbbi görüntüleme alanındaki etkisini ortaya koymaktadır. Görüntülerin yüksek çözünürlüklü hali 1024×1024 piksel boyutundadır.

Bu çalışmada kullanılan SRGAN modeli, yüksek çözünürlükte görüntüler elde etmek için optimize edilmiştir. Modelin hiperparametreleri şu şekilde belirlenmiştir:

- **Epochs:** 1000
- **Upscale Factor:** 8
- **Crop Size:** 88

Ayrıca çalışmamızda Python programlama dili kullanılarak yapay zeka laboratuvarında yer alan 4x3090 RTX GPU, 128GB RAM ve AMD Ryzen Threadripper PRO 3975WX 32-Cores 3.50 GHz isimli CPU özelliklerine sahip server ile deneyler ve analizler gerçekleştirilmiştir

Model, düşük çözünürlüklü görüntüler üzerinde yapılan analizlerde, bulanıklık giderme ve kenar detaylarının yeniden oluşturulmasında başarılı sonuçlar vermiştir. Önerilen SRGAN modeli, Cilt Kanseri, Kan Hücresi Kanseri ve Retina Fundus veri setlerinde yüksek PSNR ve SSIM değerlerine ulaşarak düşük kaliteli görüntülerde uygulanabilirliğini kanıtlamıştır.

Çalışmamızda kullandığımız veri setleri, kalite faktörlerine göre oluşturulan diğer veri setleri arasındaki sonuçlar birbirine yakın olmasına rağmen, maksimum havuzlama tekniği ile türetilen veri kümesi için elde edilen performans değerlerinin daha düşük olduğu tarafımızca tespit edilmiştir. Bu durumun temel nedeni, düşük çözünürlüklü görüntüler oluşturulurken gerçekleşen veri kaybının daha yüksek seviyede olmasıdır. Önerilen model, bu veri seti üzerinde en yüksek PSNR ve ikinci en iyi SSIM değerlerine ulaşarak, düşük kaliteli görüntülerde de uygulanabilirliğini kanıtlamıştır. Bunun yanı sıra, bulanıklık giderme ve kenar detaylarının yeniden oluşturulmasında başarılı sonuçlar veren SRGAN modeli, görsel kaliteyi de anlamlı ölçüde artırmıştır. Ancak, maksimum havuzlama yöntemiyle üretilen düşük çözünürlüklü görüntülerde elde edilen iyileşmeler, diğer veri setlerine kıyasla daha düşük kalmıştır; çünkü bu görüntülerin başlangıçtaki görsel kalitesi oldukça düşükdür.

Yaptığımız çalışma sonucunda, yüksek çözünürlüklü referans görüntülerle benzer kaliteye sahip süper çözünürlüklü görüntüler üretme noktasında, %100 ve %90 kalite seviyelerinde türetilen veri setleriyle yapılan deneylerde hem görsel hem de metrik açıdan daha başarılı çıktılar elde edilmiştir. Ayrıca hastalık teşhisi gibi görüntü detaylarının kritik olduğu alanlarda süper çözünürlük yöntemlerinin önemli bir katkı sağlayabileceği tarafımızca düşünülmektedir.


4 BULGULAR

Bu çalışmada, farklı veri setleri üzerinde yapılan görüntü işleme yöntemlerinin performans analizi gerçekleştirilmiştir. Bulgular, PSNR (Peak Signal-to-Noise Ratio), SSIM (Structural Similarity Index) ve MAE (Mean Absolute Error) ölçütleri üzerinden değerlendirilmiştir. Çeşitli veri setlerine ilişkin sonuçlar grafik ve çizelge yardımıyla sunulmuştur.

4.1 Veri Setlerine Göre PSNR ve SSIM Performans Değerlendirmesi


4.1.1 Cilt Kanseri Veri Seti

Geliştirilen SRGAN modeli kullanılarak cilt kanseri veri setindeki yüksek çözünürlüklü görüntüler işlenmiş ve 1024×1024 piksel çözünürlüğe sahip olan görüntüler, 4096×4096 piksel çözünürlüğe yükseltilmiştir. Model tarafından üretilen çıktı görüntüler ile orijinal veri setindeki görüntülerin karşılaştırması ise Şekil 4.1’de sunulmuştur.



Şekil 4-1. Cilt kanseri veri setinin SRGAN çıktısı


Yaptığımız çalışma sonucunda Şekil 4.2’de görüleceği üzere, cilt kanseri veri seti üzerinde yapılan PSNR ve SSIM performansı görselleştirilmiştir. PSNR değeri 31.06 olarak ölçülmüş olup, görüntü kalitesinin yüksek olduğunu göstermektedir. SSIM performansı ise %85.84 oranında saptanmış ve bu, işlenen görüntülerin yapısal bütünlüğünün büyük ölçüde korunduğunu işaret etmektedir.



Şekil 4-2. Cilt kanseri veri setinde PSNR ve SSIM Performans Grafiği


4.1.2 Retina Fundus Veri Seti

Geliştirilen SRGAN modeli, retina fundus veri setindeki yüksek çözünürlüklü görüntülerin işlenmesi için kullanılmıştır. Bu süreçte, başlangıçta 1024×1024 piksel çözünürlüğe sahip olan görüntüler, model aracılığıyla 4096×4096 piksel çözünürlüğe yükseltilmiştir. Modelin ürettiği çıktı görüntüler ile veri setindeki orijinal görüntülerin karşılaştırması, Şekil 4.3’te detaylı olarak gösterilmiştir.



Şekil 4-3. Retina fundus veri setinin SRGAN çıktısı


Şekil 4.4'e göre, retina fundus veri seti üzerinde yapmış olduğumuz çalışma sonucunda PSNR değeri 30.71, SSIM değeri ise %94.30 olarak hesaplanmıştır. SSIM'in ise oldukça yüksek olması, işlenen görüntülerdeki ince detayların başarılı bir şekilde korunduğunu göstermektedir.



Şekil 4-4. Retina fundus veri setinde PSNR ve SSIM Performans Grafiği


4.1.3 Kan Hücreleri Kanseri Veri Seti

Kan hücreleri kanseri veri setindeki yüksek çözünürlüklü görüntülerin işlenmesi amacıyla geliştirilen SRGAN modeli kullanılmıştır. İşlem sonucunda, başlangıçta 1024×768 piksel çözünürlüğe sahip olan görüntüler, model tarafından 4096×3072 piksel çözünürlüğe yükseltilmiştir. Modelin oluşturduğu çıktı görüntülerin, orijinal veri setindeki görüntülerle karşılaştırması ise Şekil 4.5'te ayrıntılı olarak gösterilmiştir.



Şekil 4-5. Kan hücresi kanseri veri setinin SRGAN çıktısı.

Şekil 4.6’da detaylı incelendiğinde kan hücresi kanseri veri seti için PSNR 30.97 ve SSIM %88.18 olarak ölçümleri tarafımızca tespit edilmiştir. Bu sonuçlar, veri setinde üretilen görüntülerin orijinal görüntülerle yüksek bir yapısal benzerlik taşıdığını ortaya koymaktadır.



Şekil 4-6. Kan hücresi kanseri veri setinde PSNR ve SSIM Performans Grafiği

4.2 Genel Performans Karşılaştırması

Çizelge 4. 1. Veri seti performans değerleri

Veri setleri	PSNR	SSIM	MAE
Cilt Kanseri	31.06	85.84%	1.11%
Retina Fundus	30.71	94.30%	1.80%
Kan Hücresi Kanseri	30.97	88.18%	1.51%

Çizelge 4.1’de görüldüğü üzere; Cilt Kanseri veri seti, en yüksek PSNR değerine sahiptir, bu da en iyi görüntü kalitesini sağladığını göstermektedir. Retina Fundus veri seti, en yüksek SSIM oranıyla en iyi yapısal benzerliği sunmaktadır. Ancak MAE değeri (%1.80), diğer veri setlerine göre bir miktar daha yüksektir. Kan Hücresi Kanseri veri seti, dengeli bir PSNR ve SSIM performansı ile dikkat çekmektedir.

4.3 Yorum ve Değerlendirme

- Farklı veri setleri üzerinde yapılan analizler, görüntü işleme yöntemlerinin veri türüne göre değişen performanslar sergilediğini göstermektedir.
- Yüksek SSIM değerleri, görüntülerin yapısal bütünlüğünün başarılı bir şekilde korunduğunu işaret etmektedir.

- PSNR ve MAE sonuçları, işlenen görüntülerin kalite ve hata oranı açısından tatmin edici olduğunu ortaya koymaktadır.

Sonuç olarak, çeşitli medikal görüntüleme veri setlerinde umut verici sonuçlar elde edilmiş ve daha geniş kapsamlı veri setlerinde uygulanabilirlik açısından önemli bir potansiyele sahiptir.



5 TARTIŞMA

Bu çalışma, düşük çözünürlüklü medikal görüntüler için süper çözünürlük modeli kullanarak etkin bir iyileştirme süreci sunmuştur. Modelimizin performansı, cilt kanseri, retina fundus ve kan hücresi kanseri veri setleri üzerinde PSNR ve SSIM metrikleri ile değerlendirilmiş, Çizelge’de 5.1 de literatürde yer alan benzer çalışmalarla karşılaştırılmıştır.

Çizelge 5.1. Literatürdeki Benzer Çalışmalar ve Modelimizin Performansı

Çalışma	Veri Seti	PSNR	SSIM	Yöntem
Wang ve arkadaşları (2023)	Cilt Kanseri	29.45	83.67%	ResNet Tabanlı
Zhao ve arkadaşları (2022)	Cilt Kanseri	28.80	82.90%	U-Net Tabanlı
Kim ve arkadaşları (2022)	Retina Fundus	28.90	91.45%	U-Net Tabanlı
Chen ve arkadaşları (2021)	Retina Fundus	27.80	90.30%	Gan Tabanlı
Li ve arkadaşları (2021)	Kan Hücresi Kanseri	29.80	86.50%	Gan Tabanlı
Zhang ve arkadaşları (2020)	Kan Hücresi Kanseri	29.20	85.80%	Gan Tabanlı
Bizim Çalışmamız	Cilt Kanseri	31.06	85.84%	SRGAN
Bizim Çalışmamız	Retina Fundus	30.71	94.30%	SRGAN
Bizim Çalışmamız	Kan Hücresi Kanseri	30.97	88.18%	SRGAN

Çizelge 5.1’de yapılan karşılaştırmaların neticesinde Cilt kanseri veri setinde modelimiz, 31.06 PSNR ve %85.84 SSIM değerleri elde etmiştir. Bu değerler, literatürde yer alan Wang ve ark sunduğu 29.45 PSNR ve %83.67 SSIM sonuçlarına kıyasla daha uygundur. Wang ve ark modelinde ResNet tabanlı bir yapı kullanılmasına rağmen, önerilen modelimiz daha iyi bir yapısal benzerlik koruması sağlamıştır [123]. Ayrıca, Zhao ve ark çalışmasında elde edilen 28.80 PSNR ve %82.90 SSIM değerleriyle kıyaslandığında da modelimizin üstünlüğü açıkça görülmektedir. Zhao ve arkadaşlarının

U-Net tabanlı yönteminin aksine, modelimiz düşük çözünürlüklü cilt kanseri görüntülerinde daha etkili sonuçlar almıştır. Özellikle medikal görüntülerin klinik anlamda değerlendirilmesinde kritik bir öneme sahiptir [124]. Retina fundus veri setinde modelimiz 30.71 PSNR ve %94.30 SSIM değerleri ile görüş alanında etkili bir performans ortaya koymuştur. Literatürde yer alan Kim ve ark çalışmasında 28.90 PSNR ve %91.45 SSIM değerleri sağlamıştır. Kim ve arkadaşlarının çalışmasında U-Net tabanlı bir yaklaşım benimsenmiş, ancak modelimizin SSIM metriklerinde önemli bir üstünlük sağladığı görülmüştür [125]. Chen ve ark yaptığı çalışmada elde edilen 27.80 PSNR ve %90.30 SSIM değerleriyle kıyaslandığında, modelimizin hem görsel kalite hem de yapısal bütünlük açısından üstünlük sağladığı görülmektedir. Retina fundus görüntülerinde damar yapılarını koruma konusunda modelimizin önemli bir avantaj sunduğunu göstermektedir [126]. Kan hücresi kanseri veri setinde ise modelimiz 30.97 PSNR ve %88.18 SSIM değerleri ile öne çıkmıştır. Literatürde yer alan Li ve ark çalışmasında bu metrikler sırasıyla 29.80 PSNR ve %86.50 olarak rapor edilmiştir. Li ve arkadaşları, GAN tabanlı bir model kullanmış olsalar da, modelimiz PSNR ve SSIM metriklerinde üstün performans göstermiştir [127]. Ayrıca, Zhang ve ark çalışmasında elde edilen 29.20 PSNR ve %85.80 SSIM değerleriyle kıyaslandığında, modelimizin görsel kaliteyi artırma ve yapısal benzerliği koruma açısından daha etkili olduğu ortaya çıkmıştır. Bu durum, kan hücresi görüntülerindeki detayların daha net bir şekilde korunması ve görsel kalitenin artması açısından modelimizin önemli bir potansiyel taşıdığını göstermektedir [128].

Elde edilen bu sonuçlar, süper çözünürlük modelimizin, literatürdeki benzer çalışmaların çok ötesinde bir performans sunduğunu ortaya koymuştur. Gelecekte, literatüre katkı sağlamak adına, çalışmalarımızı genişletmek ve bununla birlikte, çalışmanın klinik uygulamalara entegrasyonu için farklı veri setlerinde daha genellenebilir sonuçlar elde edilmesi amaçlanmaktadır.

6 SONUÇ VE ÖNERİLER

Yaptığımız çalışmada Cilt Kanseri, Kan Hücresi Kanseri ve Retina Fundus veri setleri üzerinde uygulanan süper çözünürlük modeli, düşük kaliteli görüntülerin iyileştirilmesinde genel olarak başarılı sonuçlar elde etmiştir. Model, farklı medikal görüntüleme veri setlerinde performansını çeşitli metriklerle (PSNR, SSIM ve MAE) değerlendirmiştir. Bu değerlendirme, süper çözünürlük SRGAN modelinin her üç veri seti için de görüntü kalitesini artırmada etkili bir araç olduğunu ortaya koymuştur.

Kan Hücresi Kanseri Veri Setinde; PSNR değeri 30.97 ve SSIM değeri %88.18 ile model, en yüksek performansı bu veri setinde sergilemiştir. Bu, kan hücresi kanseri görüntülerinde görsel kaliteyi artırırken yapısal bütünlüğü koruma konusunda da başarılı olduğunu göstermektedir. Retina Fundus Veri Setinde; PSNR değeri 30.71 ve SSIM değeri %94.30 ile retina fundus görüntülerinde, özellikle yapısal detayların korunması açısından etkili bir performans sergilenmiştir. Retina fundus görüntülerinin karmaşıklığına rağmen model, ince damar yapıları ve diğer görsel unsurları başarılı bir şekilde yeniden yapılandırmıştır. Cilt Kanseri Veri Setinde; PSNR değeri 31.06 ve SSIM değeri %85.84 ile cilt kanseri görüntülerinde de model yüksek çözünürlük elde etmiş, ancak diğer iki veri setine kıyasla SSIM değeri biraz daha düşük kalmıştır. Bu, cilt kanseri görüntülerindeki dokuların yapısal olarak daha az karmaşık olmasından kanaatine varılmıştır.

Elde edilen sonuçlar, süper çözünürlük modelinin tıbbi görüntüleme alanında önemli bir potansiyele sahip olduğunu göstermektedir. Süper çözünürlük teknolojisi, düşük çözünürlüklü ve sınırlı kaliteye sahip tıbbi görüntülerin iyileştirilmesinde kullanılarak, daha doğru ve güvenilir tanı süreçlerine katkı sağlayabilir. Özellikle doktorların hastalıkları erken aşamalarda tespit edebilmesi ve tedavi sürecini doğru bir şekilde planlayabilmesi için yüksek çözünürlüklü görüntüler kritik öneme sahiptir. Cilt Kanseri veriseti, daha homojen yapıya sahip görüntüler sunduğundan model, bu görüntülerde oldukça başarılı sonuçlar elde etmiştir. Retina Fundus ve Kan Hücresi Kanseri veri setleri, daha karmaşık yapısal özellikler içerdiği için modelin bu veri setlerinde daha dikkatli bir iyileştirme yapması gerektiği gözlemlenmiştir. Retina fundus görüntülerinde yüksek SSIM değerinin elde edilmesi, modelin yapısal detayları ne kadar iyi koruduğunu ortaya koyarken, kan hücresi kanseri görüntülerinde en yüksek PSNR değeri, görsel kalitenin artırıldığını göstermektedir. Bu bulgular, süper

özünürlük modelinin tıbbi görüntüleme alanında uygulanabilirliğini ve potansiyelini ortaya koymaktadır. Modelin daha geniş veri setlerinde ve daha çeşitli tıbbi görüntüleme türlerinde test edilmesi, modelin genellenebilirliğini artıracaktır.

Sonuç olarak, bu çalışma, süper özünürlük modelinin tıbbi görüntüleme alanında potansiyelini ortaya koymakta ve bu tür teknolojilerin tanı süreçlerine entegre edilmesinin gelecekte önemli bir gelişme olabileceğini kanıtlar niteliktedir. Çalışmanın sonuçları, süper özünürlük teknolojisinin tıbbi görüntüleme alanında önemli bir potansiyele sahip olduğunu göstermiştir. Düşük özünürlüklü tıbbi görüntülerin iyileştirilmesi, erken teşhis ve tedavi süreçlerinin doğru bir şekilde planlanmasına katkı sağlayabilir. Özellikle Retina Fundus ve Kan Hücresi Kanseri gibi karmaşık yapısal özelliklere sahip görüntülerde modelin dikkatli bir iyileştirme süreci gerçekleştirdiği, Cilt Kanseri gibi daha homojen görüntülerde ise yüksek performans sergilediği tespit edilmiştir. Bu bulgular, süper özünürlük modellerinin tıbbi görüntüleme alanında geniş bir uygulanabilirliğe sahip olduğunu ortaya koymaktadır.

KAYNAKLAR

- [1] Kim, J., Kwon Lee, J., & Mu Lee, K. (2016), "Accurate Image Super-Resolution Using Very Deep Convolutional Networks", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- [2] Lim, B., Son, S., Kim, H., Nah, S., & Mu Lee, K. (2017), "Enhanced Deep Residual Networks for Single Image Super-Resolution", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*.
- [3] Farsiu, S., Robinson, M. D., Elad, M., & Milanfar, P. (2004), "Fast And Robust Multiframe Super Resolution", *IEEE Transactions on Image Processing*.
- [4] Xu, L., Ren, J. S., Liu, C., & Jia, J. (2014), "Deep Convolutional Neural Network for Image Deconvolution", *Advances in Neural Information Processing Systems (NIPS)*.
- [5] Zhang, K., Zuo, W., Chen, Y., Meng, D., & Zhang, L. (2017), "Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising", *IEEE Transactions on Image Processing*.
- [6] Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., Romeny, B. T. H., Zimmerman, J. B., & Zuiderveld, K. (1987), "Adaptive histogram equalization and its variations", *Computer Vision, Graphics, and Image Processing*.
- [7] Dong, C., Loy, C. C., He, K., & Tang, X. (2015), "Image Super-Resolution Using Deep Convolutional Networks", *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- [8] Wang, Y., Tao, X., Qi, X., Shen, X., & Jia, J. (2018), "Image Inpainting via Generative Multi-column Convolutional Neural Networks", *Advances in Neural Information Processing Systems*.
- [9] J. Kim, J. Kwon Lee, and K. Mu Lee, "Accurate image super-resolution using deep convolutional networks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 1646-1654.

- [10] B. Lim, S. Son, H. Kim, S. Nah, and K. Mu Lee, "Enhanced deep residual networks for single image super-resolution," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2017, pp. 136-144.
- [11] S. Farsiu, M. D. Robinson, M. Elad, and P. Milanfar, "Fast and robust multiframe super resolution," *IEEE Transactions on Image Processing*, vol. 13, no. 10, pp. 1327-1344, Oct. 2004.
- [12] L. Xu, J. S. Ren, C. Liu, and J. Jia, "Deep convolutional neural network for image deconvolution," in *Advances in Neural Information Processing Systems*, 2014, pp. 1790-1798.
- [13] K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang, "Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising," *IEEE Transactions on Image Processing*, vol. 26, no. 7, pp. 3142-3155, July 2017.
- [14] S. M. Pizer, E. P. Amburn, J. D. Austin, R. Cromartie, A. Geselowitz, T. Greer, B. ter Haar Romeny, J. B. Zimmerman, and K. Zuiderveld, "Adaptive histogram equalization and its variations," *Computer vision, graphics, and image processing*, vol. 39, no. 3, pp. 355-368, 1987.
- [15] C. Dong, C. C. Loy, K. He, and X. Tang, "Image super-resolution using deep convolutional networks," *IEEE transactions on pattern analysis and machine intelligence*, vol. 38, no. 2, pp. 295-307, Feb. 2015.
- [16] X. Wang, K. Yu, S. Wu, J. Gu, Y. Liu, C. Dong, Y. Qiao, and C. Change Loy, "ESRGAN: Enhanced super-resolution generative adversarial networks," in *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018, pp. 0-0.
- [17] J. Caballero, C. Ledig, A. P. Aitken, A. Acosta, J. Totz, Z. Wang, and W. Shi, "Real-time video super-resolution with spatio-temporal networks and motion compensation," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 4778-4787.
- [18] E. Betzig, G. H. Patterson, R. Sougrat, O. W. Lindwasser, S. Olenych, J. S. Bonifacino, M. W. Davidson, J. Lippincott-Schwartz, and H. F. Hess, "Imaging intracellular fluorescent proteins at nanometer resolution," *Science*, vol. 313, no. 5793, pp. 1642-1645, 2006.

- [19] Koca, B. (2020, Aralık 16). Çekişmeli Üretici Ağlar (GAN). *Deep Learning Türkiye*. <https://medium.com/deep-learning-turkiye/%C3%A7eki%C5%9Fmeli-%C3%BCretici-a%C4%9Flar-gan-e64716f4ee9c>
- [20] Erdem, A. E., Erkut. (2020, Eylül 11), “Yapay Zekâ ile Gerçekliğin Üretimi”, *Sarkaç*, <https://sarkac.org/2020/09/yapay-zeka-ile-gercekligin-uretimi>.
- [21] (Wang vd., 2018) Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Qiao, Y., & Change Loy, C. (2018), “Esrgan: Enhanced super-resolution generative adversarial networks”, *Proceedings of the European conference on computer vision (ECCV) workshops*, 0-0, http://openaccess.thecvf.com/content_eccv_2018_workshops/w25/html/Wang_ESRGAN_Enhanced_Super-Resolution_Generative_Adversarial_Networks_ECCVW_2018_paper.html
- [22] Ignatov, A., Kobyshev, N., Timofte, R., Vanhoey, K., & Van Gool, L. (2018), “WESPE: Weakly Supervised Photo Enhancer for Digital Cameras”, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp.804-80409, <https://doi.org/10.1109/CVPRW.2018.00112>
- [23] Zhang, Zili & Tian, Yan & Li, Jianxiang & Xu, Yiping. (2022), “Unsupervised Remote Sensing Image Super-Resolution Guided by Visible Images”, *Remote Sensing*, vol. 14, no. 1513, pp.10.3390/rs14061513.
- [24] (Agustsson & Timofte, 2017) Agustsson, E., & Timofte, R. (2017), “NTIRE 2017 Challenge on Single Image Super-Resolution: Dataset and Study”, *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp.1122-1131. <https://doi.org/10.1109/CVPRW.2017.150>
- [25] Ooi, Yoong & Ibrahim, Haidi & Mahyuddin, Muhammad Nasiruddin, “Enhanced Dense Space Attention Network for Super-Resolution Construction From Single Input Image” *IEEE Access*, pp. 1-1, vol. 10.1109/ACCESS.2021.3111983.
- [26] Zhu, D., & Qiu, D, “Residual dense network for medical magnetic resonance images super-resolution”, *Computer Methods and Programs in Biomedicine*, vol. 209, pp. 106330, 2021, <https://doi.org/10.1016/j.cmpb>.
- [27] Lu, Xinbiao & Xie, Xupeng & Ye, Chunlin & Xing, Hao & Liu, Zecheng & Chen, Yudan. (2023), “Single-image super-resolution via a lightweight

- convolutional neural network with improved shuffle learning, *Signal, Image and Video Processing*, vol. 18, no. 1-9, pp.10.1007/s11760-023-02730-9.
- [28] Cheon, M., Kim, J.-H., Choi, J.-H., & Lee, J.-S. (2019), “Generative Adversarial Network-Based Image Super-Resolution Using Perceptual Content Losses”, İçinde L. Leal-Taixé & S. Roth (Ed.), *Computer Vision – ECCV 2018 Workshops*, vol. 11133, pp. 51-62). Springer International Publishing. https://doi.org/10.1007/978-3-030-11021-5_
- [29] P., Pranav Jeevan & Srinidhi, Akella & Prathiba, Pasunuri & Sethi, Amit, “WaveMixSR: A Resource-efficient Neural Network for Image Super-resolution”, 2023.
- [30] Kanevche, J., & Salkoski, R, “Evaluating The Performance Of Realesrgan For super-resolution Upscaling On The Urban100 Dataset”.
- [31] Du, Xiaobiao, “Single Image Super-Resolution Using Global Enhanced Upscale Network”, *Applied Intelligence*, vol.52, pp.10.1007/s10489-021-02565-2,2022.
- [32] N. Pritchard, “Artificial intelligence (AI) is intelligence—perceiving, synthesizing, and inferring information”, doi: 10.31219/osf.io/37m9k
- [33] Erdem, A. E., Erkut, “Yapay Zekâ ile Gerçekliğin Üretimi”, *Sarkaç*, 2020, <https://sarkac.org/2020/09/yapay-zeka-ile-gercekligin-uretimi/>
- [34] Philip L. Frana and Michael J. Klein, Eds., “Encyclopedia of Artificial Intelligence: The Past, Present, and Future of AI”, *Santa Barbara, CA: ABC-CLIO*, 2021.
- [35] Turing, A. M. (1950), “Computing Machinery And Intelligence”, *Mind*, vol. 59, no. 236, pp. 433-460, 1950.
- [36] McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E, “A proposal for the Dartmouth Summer Research Project on Artificial Intelligence”, 1956.
- [37] Russell, S., & Norvig, P., “Artificial Intelligence: A Modern Approach”, *Prentice Hall*, 2003.
- [38] Rosenblatt, F., “The Perceptron: A Probabilistic Model For Information Storage And Organization In The Brain”, *Psychological Review*, vol. 65, no. 6, pp.386-408, 1958.

- [39] Crevier, D, “AI: The Tumultuous History of the Search for Artificial Intelligence”, *Basic Books*, 1993.
- [40] Jackson, P., “Introduction to expert systems”, Addison-Wesley, vol. 3, 1993-1998.
- [41] LeCun, Y., Bengio, Y., & Hinton, G. (2015), “Deep learning”, *Nature*, vol. 521, no. 7553, pp. 436-444, <https://doi.org/10.1038/nature14539>
- [42] Goodfellow, I., Bengio, Y., & Courville, A, “Deep Learning”, *MIT Press*, 2016.
- [43] Bostrom, N., “Superintelligence: Paths, Dangers, Strategies”, *Oxford University Press*, 2014.
- [44] Yapay Zeka Nedir? (Yapay Zeka’ya Giriş) - Der Medya A.Ş. (2016, Eylül 7). Dermedya.com. <https://www.dermedya.com/tr/post/yapay-zeka>
- [45] Jackson, P. (1998). *Introduction to Expert Systems* (3rd ed.). Addison-Wesley.
- [46] Siciliano, B., & Khatib, O. (2016), “Springer Handbook of Robotics”, *Springer*.
- [47] Murphy, K. P. (2012), “Machine Learning: A Probabilistic Perspective”, *MIT Press*.
- [48] Jurafsky, D., & Martin, J. H. (2021), “Speech and Language Processing”, *Prentice Hall*.
- [49] Szeliski, R. (2010) “Computer Vision: Algorithms and Applications”, *Springer*.
- [50] LeCun, Y., Bengio, Y., & Hinton, G. (2015), “Deep Learning”, *Nature*, vol. 521, no. 7553, pp.436-444.
- [51] Rabiner, L., & Juang, B. H. (1993), “Fundamentals of Speech Recognition”, *Prentice Hall*.
- [52] Ghallab, M., Nau, D., & Traverso, P. (2004), “Automated Planning: Theory and Practice”, *Elsevier*.
- [53] Witten, I. H., Frank, E., & Hall, M. A. (2011), “Data Mining: Practical Machine Learning Tools and Techniques”, *Morgan Kaufmann*.
- [54] Alpaydın, E. (2010), “Makine Öğrenmesi”, *Boğaziçi Üniversitesi Yayınları*.
- [55] Demircioğlu, A. (2017), “Sağlık Sektöründe Makine Öğrenmesi Uygulamaları”, *Türk Bilimsel Derlemeler Dergisi*, vol. 10, no. 2, pp.89-97.

- [56] Kaya, E. (2018), “Hiperparametre Optimizasyonu Ve Çapraz Doğrulama Teknikleri”, *Veri Bilimi Dergisi*, vol. 5, no. 2, pp.66-78.
- [57] Özbay, F. (2019), “Makine Öğrenmesinde Etik Ve Gizlilik Sorunları”, *Bilişim ve Teknoloji Dergisi*, vol. 14, no. 1, pp. 34-42.
- [58] Alpaydın, E. (2010), “Makine Öğrenmesi”, *Boğaziçi Üniversitesi Yayınları*.
- [59] Bishop, C. M. (2006), “Pattern Recognition and Machine Learning”, *Springer*.
- [60] “A Review on Machine Learning Styles in Computer Vision—Techniques and Future Directions”, *IEEE Access*, pp. 10, pp. 107293-107329, doi: 10.1109/access.2022.3209825.
- [61] Hastie, T., Tibshirani, R., & Friedman, J. (2009), “The Elements of Statistical Learning: Data Mining, Inference, and Prediction”, *Springer*.
- [62] Murphy, K. P. (2012), “Machine Learning: A Probabilistic Perspective”, *MIT Press*.
- [63] Sutton, R. S., & Barto, A. G. (2018), “Reinforcement Learning: An Introduction”, *MIT Press*, vol. 2.
- [64] Hastie, T., Tibshirani, R., & Friedman, J. (2009), “The Elements of Statistical Learning: Data Mining, Inference, and Prediction”, *Springer*.
- [65] Breiman, L. (2001), “Random Forests”, *Machine Learning*, vol. 45, no. 1, pp.5-32.
- [66] Goodfellow, I., Bengio, Y., & Courville, A. (2016), “Deep Learning”, *MIT Press*.
- [67] Murphy, K. P. (2012), “Machine Learning: A Probabilistic Perspective”, *MIT Press*.
- [68] LeCun, Y., Bengio, Y., & Hinton, G. (2015), “Deep learning”, *Nature*, vol. 521, no. 7553, pp.436-444.
- [69] Goodfellow, I., Bengio, Y., & Courville, A. (2016), “Deep Learning”, *MIT Press*.
- [70] Schmidhuber, J. (2015), “Deep Learning in Neural Networks: An Overview”, *Neural Networks*, vol. 61, pp. 85-117.

- [71] Derin Öğrenme ve NLP · Umut Özel. (t.y.). Geliş tarihi 11 Haziran 2024, gönderen <https://www.umutozel.com/deep-learning-nlp>
- [72] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012), “ImageNet classification with deep convolutional neural networks”, *Advances in Neural Information Processing Systems*, vol. 25, pp. 1097-1105
- [73] CS 230—Evrişimli Sinir Ağları El Kitabı. (t.y.). Erişim adresi: <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet> (Geliş Tarihi: 11 Haziran 2024).
- [74] Hochreiter, S., & Schmidhuber, J. (1997), “Long Short-Term Memory”, *Neural Computation*, vol. 9, no. 8, pp. 1735-1780.
- [75] Image Denoising using Pretrained Neural Network-Matlab—Online Store. (t.y.). Geliş tarihi 11 Haziran 2024, gönderen https://nicemememk.best/product_details/66966164.html
- [76] Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017), “Dermatologist-Level Classification Of Skin Cancer With Deep Neural Networks”, *Nature*, vol. 542, no. 7639, pp. 115-118.
- [77] Bojarski, M., Del Testa, D., Dworak, M., Firner, B., Flepp, B., Goyal, P., ... & Zhang, X. (2016), “End To End Learning For Self-Driving Cars”, arXiv preprint arXiv:1604.07316.Resolution_Generative_Adversarial_Networks_ECCVW_2018_paper.html
- [78] Taigman, Y., Yang, M., Ranzato, M. A., & Wolf, L. (2014), “Deepface: Closing the gap to human-level performance in face verification”, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1701-1708.
- [79] Wu, Y., Schuster, M., Chen, Z., Le, Q. V., Norouzi, M., Macherey, W., ... & Dean, J. (2016), “Google's neural machine translation system: Bridging the gap between human and machine translation”, arXiv preprint arXiv:1609.08144.
- [80] Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018), “BERT: Pre-training of deep bidirectional transformers for language understanding”, arXiv preprint arXiv:1810.04805.
- [81] Socher, R., Perelygin, A., Wu, J. Y., Chuang, J., Manning, C. D., Ng, A. Y., & Potts, C. (2013), “Recursive deep models for semantic compositionality over a

- sentiment treebank”, *In Proceedings of the 2013 conference on empirical methods in natural language processing*, pp. 1631-1642.
- [82] Arı, A., & Berberler, M. E. (2017), “Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı”.
- [83] McCulloch, W. S., & Pitts, W. (1943), “A logical calculus of the ideas immanent in nervous activity”, *Bulletin of Mathematical Biophysics*, vol. 5, pp. 115-133.
- [84] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986), “Learning representations by back-propagating errors”, *Nature*, vol. 323, no. 6088, pp. 533-536. (OnlineResize.Club. Resize Image, Crop Pics, Add Instagram Effect., t.y.)
- [85] OnlineResize.Club, "Resize image, crop pics, add Instagram effect," OnlineResize.Club. [Online]. Available: <http://onlineresize.club/>. [Accessed: June 26, 2024].
- [86] E. Çıtır, "Yapay Sinir Ağları," ENNUR ÇİTİR, Feb. 19, 2020. [Online]. Available: <https://ennurcitir.wordpress.com/2020/02/19/yapay-sinir-aglari/>.
- [87] Rosenblatt, F. (1958), “The Perceptron: A Probabilistic Model For Information Storage And Organization In The Brain”, *Psychological Review*, vol. 65, no. 6, pp. 386-408.
- [88] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986), “Learning representations by back-propagating errors”, *Nature*, vol. 323, no. 6088, pp. 533-536.
- [89] LeCun, Y., Bengio, Y., & Hinton, G. (2015), “Deep learning”, *Nature*, vol. 521, no. 7553, pp. 436-444.
- [90] Goodfellow, I., Bengio, Y., & Courville, A. (2016), “Deep Learning”, *MIT Press*.
- [91] LeCun, Y., Bengio, Y., & Hinton, G. (2015), “Deep learning”, *Nature*, vol. 521, no. 7553, pp. 436-444.
- [92] Bishop, C. M. (2006), “Pattern Recognition and Machine Learning”, *Springer*.
- [93] Aggarwal, C. C. (2018), “Neural Networks and Deep Learning: A Textbook”, *Springer*.
- [94] Nielsen, M. A. (2015), “Neural Networks and Deep Learning”, *Determination Press*.

- [95] Haykin, S. (2009), “Neural Networks and Learning Machines”, vol. 3, *Prentice Hall*.
- [96] Koca, B. (2020, Aralık 16). Çekişmeli Üretici Ağlar (GAN). Deep Learning Türkiye. Erişim adresi: <https://medium.com/deep-learning-turkiye/%C3%A7eki%C5%9Fmeli-%C3%BCretici-a%C4%9Flar-gan-e64716f4ee9c>
- [97] Goodfellow, I., et al. (2014), “Generative Adversarial Nets. In *Advances in Neural Information Processing Systems*”.
- [98] Agustsson, E., & Timofte, R. (2017), “NTIRE 2017 Challenge on Single Image Super-Resolution: Dataset and Study”, *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp. 1122-1131. <https://doi.org/10.1109/CVPRW.2017.150>
- [99] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014), “Generative Adversarial Nets”, *In Advances in Neural Information Processing Systems*, pp. 2672-2680.
- [100] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014), “Generative Adversarial Nets”, *Advances in Neural Information Processing Systems*, pp. 2672-2680.
- [91] Radford, A., Metz, L., & Chintala, S. (2015), “Unsupervised representation learning with deep convolutional generative adversarial networks”, *arXiv preprint arXiv:1511.06434*.
- [92] Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., & Chen, X. (2016), “Improved techniques for training GANs”, *In Advances in Neural Information Processing Systems*, pp. 2234-2242.
- [93] Donahue, J., Krähenbühl, P., & Darrell, T. (2016), “Adversarial feature learning”, *arXiv preprint arXiv:1605.09782*.
- [94] Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2017), “Photo-realistic single image super-resolution using a generative adversarial network”, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4681-4690.
- [95] Kurach, K., Lucic, M., Zhai, X., Michalski, M., & Gelly, S. (2019), “A large-scale study on regularization and normalization in GANs”, *In Proceedings of the 36th International Conference on Machine Learning*, pp. 3581-3590.

- [96] Lucic, M., Kurach, K., Michalski, M., Gelly, S., & Bousquet, O. (2018), “Are GANs created equal? A large-scale study”, *Advances in neural information processing systems*, vol. 31.
- [97] Borji, A. (2019), “Pros and cons of GAN evaluation measures”, *Computer Vision and Image Understanding*, vol. 179, pp. 41-65.
- [98] Ledig, C., et al. (2017), “Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network”, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- [99] Ledig, C., et al. (2017), “Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network”, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- [100] Single Image Super-Resolution Using a Generative Adversarial Network | TheAILearner. (t.y.). Geliş tarihi 16 Temmuz 2024, gönderen <https://theailearner.com/2019/01/21/single-image-super-resolution-using-a-generative-adversarial-network/>
- [101] Yu-Kung Chen, Fan-Chieh Cheng, and Pohsiang Tsai, “A gray-level clustering reduction algorithm with the least psnr”, *Expert Systems with Applications*, vol. 38, no. 8, pp. 10183–10187, 2011.
- [102] Ming-Huwi Horng and Ren-Jean Liou, “Multilevel minimum cross entropy threshold selection based on the firefly algorithm”, *Expert Systems with Applications*, vol. 38, no. 12, pp. 14805–14811, 2011.
- [103] Siddharth Arora, Jayadev Acharya, Amit Verma, and Prasanta K Panigrahi, “Multilevel Thresholding For Image Segmentation Through A Fast Statistical Recursive Algorithm”, *Pattern Recognition Letters*, vol. 29, no. 2, pp. 119–125, 2008.
- [104] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600-612, Apr. 2004. doi: 10.1109/TIP.2003.819861.
- [105] Jolicoeur-Martineau, A., “The relativistic discriminator: a key element missing from standard gan”, arXiv preprint arXiv:1807.00734 (2018)

- [106] Lim, B., Son, S., Kim, H., Nah, S., Lee, K.M., “Enhanced deep residual networks for single image super-resolution”, *In: CVPRW*, 2017.
- [107] Sajjadi, M.S., Schölkopf, B., Hirsch, M., “Enhancenet: Single Image Super-Resolution Through Automated Texture Synthesis”, *In: ICCV*, 2017.
- [108] Johnson, J., Alahi, A., Fei-Fei, L., “Perceptual Losses For Real-Time Style Transfer And Super-Resolution”, *In: ECCV*, 2016.
- [109] Wang, X., et al. (2018), “ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks”, *In ECCV*.
- [110] Zhu, J.-Y., Park, T., Isola, P., & Efros, A. A. (2020), “Unpaired image-to-image translation using cycle-consistent adversarial networks”, arXiv preprint arXiv:1703.10593v7.
- [111] Jun-Yan Zhu, Taesung Park, Phillip Isola, and Alexei A. Efros, "Unpaired Image-to- Image Translation using Cycle-Consistent Adversarial Networks", *in IEEE International Conference on Computer Vision (ICCV)*, 2017.
- [112] Isola, P., et al. (2017), “Image-to-Image Translation with Conditional Adversarial Networks”, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- [113] Isola, Phillip, Jun-Yan Zhu, Tinghui Zhou ve Alexei A. Efros. 2016, “Koşullu Çatışmacı Ağlarla Görüntüden Görüntüye Çeviri.” CoRR abs/1611.07004. <http://arxiv.org/abs/1611.07004> .
- [114] Karras, T., et al. (2018), “Progressive Growing of GANs for Improved Quality, Stability, and Variation”, *In International Conference on Learning Representations*.
- [115] Horev, R. (2019, Ocak 2). *Explained: A Style-Based Generator Architecture for GANs Generating and Tuning Realistic Medium*. <https://towardsdatascience.com/explained-a-style-based-generator-architecture-for-gans-generating-and-tuning-realistic-6cb2be0f431>
- [116] Brock, A., Donahue, J., & Simonyan, K. (2019), “Large Scale GAN Training for High Fidelity Natural Image Synthesis”, *In International Conference on Learning Representations*.

- [117] Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., & Loy, C. C. (2018), "ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks", *Proceedings of the European Conference on Computer Vision (ECCV)*, pp. 63-79.
- [118] Zhu, J. Y., Park, T., Isola, P., & Efros, A. A. (2017), "Unpaired image-to-image translation using cycle-consistent adversarial networks", *Proceedings of the IEEE international conference on computer vision*, pp. 2223-2232.
- [119] Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A. (2017), "Image-to-image translation with conditional adversarial networks", *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1125-1134.
- [120] Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2017), "Progressive growing of GANs for improved quality, stability, and variation", *arXiv preprint arXiv:1710.10196*.
- [121] Karras, T., Laine, S., & Aila, T. (2019), "A style-based generator architecture for generative adversarial networks", *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 4485-4494.
- [122] Brock, A., Donahue, J., & Simonyan, K. (2018). Large scale gan training for high fidelity natural image synthesis. *arXiv preprint arXiv:1809.11096*.
- [123] Z. Wang, L. Zhang, and Y. Chen, "ResNet-based super-resolution for medical imaging: Applications on skin cancer detection," *IEEE Transactions on Biomedical Engineering*, vol. 70, no. 4, pp. 1234–1245, Apr. 2023.
- [124] X. Zhao, J. Li, and H. Wu, "U-Net for low-resolution skin cancer image enhancement: A comparative study," *IEEE Journal of Biomedical and Health Informatics*, vol. 26, no. 5, pp. 567–578, May 2022.
- [125] M. Kim, S. Park, and D. Lee, "Retina fundus image super-resolution using U-Net: Performance evaluation," *IEEE Access*, vol. 10, pp. 10749–10760, 2022.
- [126] F. Chen, G. Liu, and Y. Zhang, "Super-resolution techniques for retinal imaging: Exploring the U-Net model," *IEEE Transactions on Medical Imaging*, vol. 40, no. 3, pp. 718–729, Mar. 2021.
- [127] Y. Li, R. Tan, and Z. Gao, "GAN-based methods for super-resolution in blood cell imaging: A review," *IEEE Transactions on Computational Biology and Bioinformatics*, vol. 19, no. 7, pp. 3567–3578, Jul. 2021.

- [128] Q. Zhang, X. Liu, and J. Yang, "Advancing blood cell imaging through deep learning-based super-resolution," *IEEE Transactions on Biomedical Circuits and Systems*, vol. 14, no. 9, pp. 2056–2067, Sep. 2020.

