

**T.C.  
İNÖNÜ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ÇEKİŞMELİ ÜRETKEN AĞLARLA MEDİKAL GÖRÜNTÜLERİN ÜRETİMİ  
ve ANALİZİ**

**DOKTORA TEZİ**

**Sara ALTUN GÜVEN**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Prof. Dr. Muhammed Fatih TALU**

**HAZİRAN 2022**

**T.C.  
İNÖNÜ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ÇEKİŞMELİ ÜRETKEN AĞLARLA MEDİKAL GÖRÜNTÜLERİN ÜRETİMİ  
ve ANALİZİ**

**DOKTORA TEZİ**

**Sara ALTUN GÜVEN  
36173619004**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Prof. Dr. Muhammed Fatih TALU**

**HAZİRAN 2022**

## TEŐEKKÜR VE ÖN SÖZ

Bu tez alıőmasının her aőamasında yardım, öneri, bilgi, tecrübe ve desteklerini esirgmeden beni her konuda yönlendiren danışman hocam Sayın Prof. Dr. Muhammed Fatih TALU'ya,

Tez alıőmam süresince deęerli görüşleriyle tezime katkı sağlayan Bilgisayar Mühendislięi Bölümünde görev yapan tüm dięer deęerli hocalarıma,

Manevi desteklerinden ötürü Yazılım Mühendislięi bölüm başkanı Prof. Dr. Ali KARCI'ya ve Arő. Grv. Elif Aslı OYMAK'a,

Tüm hayatım boyunca olduęu gibi bu alıőmalarım süresince de desteklerini esirgemeyen aileme,

Bu süreçte beni sabırla bekleyen ve desteęini esirgemeyen eőime,

Tezin uygulama aőamasında "FDK-2021-2675" nolu proje numarasıyla vermiő oldukları maddi ve manevi destekten dolayı, İnönü Üniversitesi BAP birimine

teőekkür ederim.

## ONUR SÖZÜ

Doktora veya yüksek lisans tezi olarak sunduđum “Çekiřmeli Üretken Ağlarla Medikal Görüntülerin Üretimi ve Analizi” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığına ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla dođrularım.

Sara ALTUN GÜVEN



## İÇİNDEKİLER

TEŞEKKÜR VE ÖN SÖZ .....	iv
ONUR SÖZÜ .....	v
İÇİNDEKİLER.....	vi
ÇİZELGELER DİZİNİ.....	viii
ŞEKİLLER DİZİNİ.....	ix
SEMBOLLER VE KISALTMALAR .....	xi
ÖZET.....	xiv
ABSTRACT .....	xvi
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1. Çekişmeli Üretken Ağların Genel Yapısı.....	2
1.2. Çekişmeli Üretken Ağlarda Görüntü Sentezleme .....	2
1.3. Tezin Amaç ve Hedefleri .....	4
1.4. Tezin Organizasyonu ve Yapılan Bilimsel Katkılar .....	4
<b>2. ÇEKİŞMELİ ÜRETKEN AĞLARLA PAPSMEAR HÜCRE ÇEKİRDEĞİ ÜRETİMİ.....</b>	<b>7</b>
2.1. Çekişmeli Üretici Ağ Mimarileri .....	7
2.1.1. Pix2Pix .....	7
2.1.2. CycleGAN.....	9
2.2. Veri Kümesi .....	11
2.3. Kullanılan Ölçüm Metrikleri.....	12
2.3.1. Dice indeksi.....	12
2.3.2. Jacard indeksi .....	12
2.4. Deneysel Çalışmalar ve Sonuçları.....	12
2.4.1. Sonuç.....	15
<b>3. MATEMATİKSEL MODEL İLE PAPSMEAR VERİ KÜMESİ OLUŞTURULMASI.....</b>	<b>16</b>
3.1. PAPSMEAR Görüntüsünde Nesnelerin Oluşturulması .....	16
3.1.1. Hücre çekirdeği ve sitoplazma .....	16
3.1.2. Beyaz kan hücreleri (lökositler), basiller ve diğer yapılar .....	18
3.2. Deneysel Çalışmalar ve Sonuçlar.....	19
3.2.1. Modelleme yaklaşımı ile veri kümesi oluşturulması.....	19
<b>4. ÇEKİŞMELİ ÜRETKEN AĞLARLA PAPSMEAR GÖRÜNTÜSÜ OLUŞTURMADA YENİ YAKLAŞIMLAR.....</b>	<b>22</b>
4.1. Sentetik Papsmear Görüntüsü Üretmede Çekişmeli Üretken Ağların Kullanılması .....	22
4.1.1. Görüntü sentezleme mimarileri.....	23
4.1.1.1. DiscoGAN .....	23
4.1.1.2. AttentionGAN .....	24
4.1.1.3. Pix2PixSSIM (Önerilen) .....	24
4.1.2. Kullanılan ölçüm metrikleri .....	25
4.1.2.1. Ortalama karesel hata (MSE) .....	25
4.1.2.2. Yapısal benzerlik metriği (SSIM).....	26
4.1.2.3. Pik Sinyal Gürültü Oranı (PSNR) .....	26
4.1.3. Deneysel çalışmalar ve sonuçları .....	27
4.1.3.1. Çalışma 1: Metodların performans incelemesi.....	27
4.1.3.2. Çalışma 2: Önerilen yöntemin analizi .....	28

4.2.	Algısal Benzerlik Maliyeti Tabanlı Çekişmeli Üretici Ağ Mimarisi ile Görüntü Üretimi .....	30
4.2.1.	Evrişimsel Sinir Ağı tabanlı görüntü kıyaslama kriterleri .....	32
4.2.1.1.	LIPS .....	32
4.2.1.2.	DISTS .....	32
4.2.1.3.	CONTENT .....	33
4.2.1.4.	Ölçütlerin <b>L1</b> ile kullanımı .....	34
4.2.2.	Görüntü karşılaştırma metrikleri .....	35
4.2.2.1.	Klasik görüntü karşılaştırma metrikleri .....	35
4.2.2.2.	Güncel görüntü kıyaslama metrikleri .....	35
4.2.3.	Deneysel çalışmalar ve sonuçları .....	36
<b>5.</b>	<b>KONTRASTLI ÖĞRENME TABANLI ÇEKİŞMELİ ÜRETKEN AĞLAR İLE PAPSMEAR GÖRÜNTÜ BÖLÜTLEME .....</b>	<b>38</b>
5.1.	Görüntü Sentezleme Mimarileri .....	38
5.1.1.	CUT ve FastCUT .....	39
5.1.2.	DCLGAN ve SimDCL .....	40
5.2.	Eğitim Detayları .....	42
5.3.	Veri Kümesi .....	43
5.4.	Deneysel Çalışmalar ve Sonuçları .....	43
<b>6.</b>	<b>KONTRASTLI ÖĞRENME TABANLI ÇEKİŞMELİ ÜRETKEN AĞLAR İLE BEYİN MRI BÖLÜTLEMEDE YENİ YAKLAŞIM .....</b>	<b>47</b>
6.1.	Görüntü Sentezleme Mimarileri .....	51
6.1.1.	Önerilen Yöntem (SSimDCL) .....	51
6.2.	Eğitim Detayları .....	53
6.3.	Veri kümesi .....	54
6.4.	İyileştirilmiş Veri Kümesi .....	55
6.5.	Kullanılan Ölçüm Metrikleri .....	56
6.6.	Deneysel Çalışmalar ve Sonuçları .....	57
6.6.1.	Çalışma 1: Farklı metodlarla karşılaştırma .....	57
6.6.2.	Çalışma 2: Önerilen yöntemle göre yüksek kaliteli görüntü oluşturulması ....	59
6.6.3.	Çalışma 3: Yeni oluşturulan veri kümesinin verimliliğinin ölçülmesi .....	61
6.6.4.	Çalışma 4: VolBrain sonuçları ile karşılaştırılması .....	63
<b>7.</b>	<b>KONTRASTLI ÖĞRENME TABANLI ÇEKİŞMELİ ÜRETKEN AĞLAR İLE MEDİKAL GÖRÜNTÜ BÖLÜTLEMEDE YENİ YAKLAŞIM .....</b>	<b>66</b>
7.1.	Veri kümeleri .....	68
7.2.	Deneysel Çalışmalar ve Sonuçları .....	69
7.2.1.	Veri kümelerine göre görsel sonuçlar .....	69
7.3.	Sonuç .....	74
<b>8.</b>	<b>ÖNERİLEN KONTRASTLI ÖĞRENME TABANLI ÇEKİŞMELİ ÜRETKEN AĞ İLE BEYİN TÜMÖRÜ ALGILAMA .....</b>	<b>75</b>
8.1.	Kullanılan Yöntemler .....	78
8.1.1.	nnU-Net .....	78
8.2.	Eğitim Detayları .....	79
8.3.	Veri Kümesi .....	80
8.4.	Deneysel Çalışmalar ve Sonuçları .....	82
8.5.	Sonuç .....	87
<b>Teşekkür . . . . .</b>		<b>87</b>
<b>KAYNAKLAR .....</b>		<b>88</b>
<b>ÖZGEÇMİŞ .....</b>		<b>97</b>

## ÇİZELGELER DİZİNİ

<b>Çizelge 2.1:</b>	CycleGAN ve Pix2Pix Benzerlik Sonuçları .....	13
<b>Çizelge 2.2:</b>	CycleGAN ve Pix2Pix Eğitim Sonuçları .....	14
<b>Çizelge 3.1:</b>	Görüntü üretmede sabit değerler .....	19
<b>Çizelge 3.2:</b>	PAPSMEAR görüntü üretmede model parametreleri .....	20
<b>Çizelge 4.1:</b>	ÇÜA Yöntemlerinin MSE, SSIM ve PSNR'ye göre sonuçları .....	28
<b>Çizelge 4.2:</b>	Pix2Pix ve Pix2PixSSIM yöntemlerinin benzerlik metriği sonuçları .....	30
<b>Çizelge 4.3:</b>	Görüntü sentezleme doğrulukları .....	36
<b>Çizelge 5.1:</b>	Yöntemlerin metriksel benzerlik sonuçları .....	45
<b>Çizelge 6.1:</b>	Yöntemlerin metriksel benzerlik sonuçları .....	58
<b>Çizelge 6.2:</b>	Yeni Beyin MRI veri kümeleri üzerinde önerilen yöntemin kıyaslanması .	62
<b>Çizelge 6.3:</b>	İyileştirilmiş veri kümesine göre yöntemlerin metriksel benzerlik kıyaslaması .....	64
<b>Çizelge 7.1:</b>	PAPSMEAR veri kümesinin metriksel benzerlik kıyaslaması .....	70
<b>Çizelge 7.2:</b>	CHASEDB veri kümesinin metriksel benzerlik kıyaslaması .....	72
<b>Çizelge 7.3:</b>	XRAY veri kümesinin metriksel benzerlik kıyaslaması .....	73
<b>Çizelge 8.1:</b>	Önerilen yöntem ve nnU-Net yönteminin metriksel kıyaslanması .....	86

## ŞEKİLLER DİZİNİ

Şekil 1.1:	Genel Görüntüden Görüntüye Dönüşüm Yapan Çekişmeli Üretken Ağlar... 3
Şekil 1.2:	Çekişmeli Üretken Ağ türlerinin genel yapısı (a) Denetimli (b) Denetimsiz .....4
Şekil 2.1:	PAPSMEAR hücre çekirdeği sentezlemede Pix2Pix mimarisi ..... 9
Şekil 2.2:	Özdeşlik kaybı ..... 10
Şekil 2.3:	CycleGAN mimarisi ..... 11
Şekil 2.4:	PAPSMEAR hücre çekirdeği örneği (a) Hücre çekirdeği (b) Maskesi ..... 11
Şekil 2.5:	Bir iterasyon eğitim çıktıları (a) CycleGAN (b) Pix2Pix ..... 13
Şekil 3.1:	Desen yayma algoritması (Patch-based texture generation) ..... 18
Şekil 3.2:	PAPSMEAR Hücre Görüntüsünde Bulunan Nesnelere ..... 19
Şekil 3.3:	Modelleme yaklaşımıyla üretilen görüntüler (a) PAPSMEAR, (b) Maske . 20
Şekil 3.4:	Modelleme yaklaşımıyla üretilen görüntüler PAPSMEAR, Maske ..... 21
Şekil 4.1:	PAPSMEAR görüntüsü oluşturulurken genel aşama ..... 23
Şekil 4.2:	Sentezleme yaklaşımlarının PAPSMEAR görseli üretme sonuçları ..... 27
Şekil 4.3:	PAPSMEAR veri kümesi çıktıları. (Sütunsal sırasıyla GT, GT (zoom), Pix2Pix (zoom), Önerilen Yöntem (zoom) )..... 29
Şekil 4.4:	Algısal Benzerlik Maliyeti Tabanlı ÇÜA ile Görüntü Üretiminin Şematik Gösterimi ..... 31
Şekil 4.5:	LPIPS Fonksiyonu Şematik Gösterim. (Zhang vd., 2018). ..... 32
Şekil 4.6:	DISTD fonksiyonu (Ding vd., 2020) ..... 33
Şekil 4.7:	CONTENT yöntemi örneği (Gatys vd., 2015)..... 34
Şekil 4.8:	PAPSMEAR veri kümesi çıktıları. Satırlar: Girdi, Çıktı, L1, LPIPS, L1- LPIPS, DISTD, L1-DISTD, CONTENT, L1-CONTENT ..... 37
Şekil 5.1:	CUT yönteminin genel mimarisi ..... 39
Şekil 5.2:	DCLGAN ve SimDCL mimarisi ..... 41
Şekil 5.3:	Ayrıştırıcı ağ mimarisi ..... 42
Şekil 5.4:	Özellik çıkaran gömülü ağ mimarisi..... 42
Şekil 5.5:	Üretici ağ mimarisi (a) Ağın iç yapısı (b) Ağın iç yapısındaki ağ katmanlarının gösterimi ..... 43
Şekil 5.6:	Yöntemlerin görsel olarak görüntü bölütleme sonuçları ..... 44
Şekil 5.7:	PAPSMEAR görüntü bölütleme çıktıları. (a) Orijinal boyutlu ve (b) Yakınlaştırılmış görüntüler ..... 44
Şekil 6.1:	Beyin MRI görüntü bölütlemesinde yeni yaklaşım şematik gösterimi..... 51
Şekil 6.2:	Beyin MRI bölütleme için önerilen yöntemin mimarisi ..... 53
Şekil 6.3:	Önerilen yöntemdeki ağların iç yapıları ..... 54
Şekil 6.4:	2 boyutlu beyin MRI veri kümeleri (a) Orijinal (b) Maske görüntü..... 55
Şekil 6.5:	Beyin MRI veri kümeleri (a) Orijinal (b) Çözünürlüğü artırılmış ..... 56
Şekil 6.6:	Yöntem çıktılarının görsel kıyaslanması. .... 57
Şekil 6.7:	Beyin MRI veri kümesi üzerinde görsel çıktılar (a) Orijinal (b) Yakınlaştırılmış..... 58
Şekil 6.8:	Gerçek görüntüler ve özdeşlik maliyetine göre görsel sonuçlar. .... 59
Şekil 6.9:	Beyin MRI görüntüleri (a) Gerçek (b) Önerilen yöntemle çözünürlüğü arttırılmış..... 60
Şekil 6.10:	Beyin MRI maske görüntüleri (a) Gerçek (b) Önerilen yöntemle çözünürlüğü arttırılmış..... 60
Şekil 6.11:	Gerçek ve çözünürlüğü arttırılmış görüntüler (a) Orijinal görüntü (b) Çözünürlüğü artırılmış (c) Orijinal maske (d) Çözünürlüğü artırılmış maske ..... 61
Şekil 6.12:	Önerilen yöntemler oluşturulan veri kümelerinin görsel çıktıları..... 62



<b>Şekil 6.13:</b>	Beyin MRI bölütmede VolBrain ve önerilen yöntemin görsel çıktıları .....	64
<b>Şekil 7.1:</b>	Veri kümeleri (a) PAPSMEAR (b) XRAY (c) CHASEDB (d) Beyin MRI	68
<b>Şekil 7.2:</b>	PAPSMEAR veri kümesi üzerinde görsel çıktılar (a) Orijinal (b) Yakınlaştırılmış.....	69
<b>Şekil 7.3:</b>	PAPSMEAR veri kümesine göre yöntemlerin görsel çıktıları .....	70
<b>Şekil 7.4:</b>	CHASEDB veri kümesi görsel çıktılar (a) Orijinal (b) Yakınlaştırılmış.....	71
<b>Şekil 7.5:</b>	CHASEDB veri kümesine göre yöntemlerin görsel çıktıları.....	71
<b>Şekil 7.6:</b>	XRAY veri kümesi görsel çıktılar (a) Orijinal (b) Yakınlaştırılmış .....	72
<b>Şekil 7.7:</b>	XRAY veri kümesine göre yöntemlerin görsel çıktıları .....	73
<b>Şekil 8.1:</b>	nnU-Net mimarisi (Isense vd., 2021).....	79
<b>Şekil 8.2:</b>	Orijinal Veri Kümesi (a) Tüm beyin (b) a'dan elde edilen beyin tümörü....	80
<b>Şekil 8.3:</b>	Fazlalıkları Elimine Edilmiş Veri Kümesi (a) Tüm beyin (b) a'dan elde edilmiş beyin tümörü .....	81
<b>Şekil 8.4:</b>	İyileştirilmiş Veri Kümesi (a) Tüm beyin (b) a'dan elde edilen beyin tümörü .....	81
<b>Şekil 8.5:</b>	Veri Kümeleri (a) Orjinal (b) Fazlalıkları elimine edilmiş (c) İyileştirilmiş	82
<b>Şekil 8.6:</b>	Orjinal veri kümesine göre nnU-Net ve önerilen yöntemin görsel kıyaslanması.....	83
<b>Şekil 8.7:</b>	Fazlalıkları elimine edilmiş veri kümesine göre nnU-Net ve önerilen yöntemin kıyaslanması.....	84
<b>Şekil 8.8:</b>	İyileştirilen veri kümesine göre nnN-Unet ve önerilen yöntemin görsel kıyaslanması.....	85

## SEMBOLLER VE KISALTMALAR

<b>ÇÜA</b>	: Çekişmeli üretken ağlar
<b>ESA</b>	: Evrişimsel sinir ağları
<b>DECODE</b>	: Kod çözücü
<b>ENCODE</b>	: Kodlayıcı
<b>CONCAT</b>	: Görüntüyü birleştirme
<b>RESNET BLOCK</b>	: Fazla bloklar (Residual Block)
<b>SSIM</b>	: Yapısal benzerlik metriği
<b>FID</b>	: Fréchet başlangıç mesafesi
<b>KID</b>	: Kernel başlangıç mesafesi
<b>FSIM</b>	: Özellik tabanlı benzerlik indeksi
<b>HaarPSI</b>	: Haar dalgacık tabanlı algısal benzerlik indeksi
<b>MS-SSIM</b>	: Çok ölçekli yapısal benzerlik metriği
<b>PSNR</b>	: Pik Sinyal Gürültü Oranı
<b>VIF</b>	: Görsel bilgi doğruluğu
<b>VSI</b>	: Görsel belirginliğe bağlı indeks
<b>DISTS</b>	: Derin görüntü yapısı ve doku benzerliği
<b>LPIPS</b>	: Öğrenilmiş algısal görüntü yama benzerliği
<b>CONTENT</b>	: İçerik ağı
<b>CNN</b>	: Konvolusyonel Sinir Ağları
<b>ReLU</b>	: Doğrultulmuş lineer birim (Rectified linear unit)
<b>PatchNCE</b>	: Görüntü parçalarının eşleştirilmesine dayalı bir mimari
<b>MSE</b>	: Ortalama karesel hata
<b>MathModel</b>	: Oluşturulmuş matematiksel model
<b>CUT</b>	: Zıt eşlenmemiş dönüşüm (Contrastive Unpaired Translation)
<b>FASTCUT</b>	: Hızlı zıt eşlenmemiş dönüşüm (Contrastive Unpaired Translation)
<b>CYCLEGAN</b>	: Eşlenmemiş görüntüden görüntüye dönüşüm
<b>Pix2PixSSIM</b>	: Önerilen Çekişmeli Üretken Ağ mimarisi
<b>BT</b>	: Bilgisayarlı tomografi
<b>MRI</b>	: Manyetik rezonans görüntüleme
<b>FCN</b>	: Tam bağlantılı ağ (Fully Connected Network)
<b>SSimDCL</b>	: Önerilen Çekişmeli Üretken Ağ mimarisi
<b>YSA</b>	: Yapay Sinir Ağları
<b>SVM</b>	: Destek vektör makineleri
<b>k-NN</b>	: k en yakın komşu yöntemi

<b>GT</b>	: Gerçek doğru (Ground True)
<b><math>X, Y</math></b>	: Görüntü Domaini
<b><math>x</math></b>	: $X$ görüntü domainine ait görüntü
<b><math>y</math></b>	: $Y$ görüntü domainine ait görüntü
<b><math>G, F</math></b>	: Üretici ağlar
<b><math>D, D_y, D_x</math></b>	: Ayırıştırıcı ağlar
<b><math>H</math></b>	: Özellik çıkartıcı ağ
<b><math>\mathcal{L}_{cyc}</math></b>	: Döğü tutarlılık kaybı
<b><math>\mathcal{L}_{adv}</math></b>	: Tartışmalı kayıp
<b><math>\mathcal{L}_{identity}</math></b>	: Özdeşlik kaybı
<b><math>\mathcal{L}_{GAN}^G</math></b>	: $G$ üretici ağının kaybı
<b><math>\mathcal{L}_{GAN}^F</math></b>	: $F$ üretici ağının kaybı
<b><math>\mathcal{L}_{cGAN}</math></b>	: Koşullu Çekişmeli Üretken Ağların temel maliyet fonksiyonu
<b><math>L_1</math></b>	: Ortalama mutlak hata ile uzaklık ölçme metriği
<b><math>L_2</math></b>	: Ortalama karesel hata ile uzaklık ölçme metriği
<b>MAE</b>	: Ortalama mutlak hata
<b><math>\mathcal{L}_{similarity_x}</math></b>	: $X$ görüntü alanı için benzerlik maliyeti
<b><math>\hat{X}</math></b>	: $X$ 'den üretilen yeni görüntü domaini
<b><math>\hat{Y}</math></b>	: $Y$ 'den üretilen yeni görüntü domaini,
<b>TP</b>	: Gerçek pozitif (True Positive)
<b>FP</b>	: Yanlış pozitif (False Positive)
<b>TN</b>	: Gerçek negatif (True Negative)
<b>FN</b>	: Yanlış negatif (False Negative)
<b><math>L_{CONST_x}</math></b>	: $X$ görüntü domaininde yeniden oluşturma kaybı
<b><math>L_{CONST_y}</math></b>	: $Y$ görüntü domaininde yeniden oluşturma kaybı
<b><math>L_D</math></b>	: Genel ayırıştırıcı ağ kaybı
<b><math>\mathcal{L}_{DiscoGAN}</math></b>	: DiscoGAN genel kaybı
<b><math>L_G</math></b>	: Genel üretici ağ kaybı
<b><math>A_X, A_Y</math></b>	: $X$ ve $Y$ görüntü domainindeki dikkat ağları
<b><math>\mathcal{L}_{L\_SSIM}(x, y)</math></b>	: SSIM'e dayalı düzgünleştirme terimi
<b><math>\mu</math></b>	: Ortalama
<b><math>\sigma</math></b>	: Standart sapma
<b><math>\mathcal{L}_{PatchNCE}</math></b>	: Parça tabanlı maliyet
<b><math>\lambda</math></b>	: Maliyeti düzenlemeye yardımcı katsayı

**$\mathcal{L}_{sim}$**  : Benzerlik kaybı  
**GB** : Gygabyte  
**GPU** : Ekran kartı (Graphics Processing Unit)



# ÖZET

Doktora Tezi

## MEDİKAL GÖRÜNTÜ SENTEZLEME VE BÖLÜTLEMEDE ÇEKİŞMELİ ÜRETİCİ AĞLARIN KULLANILMASI

Sara ALTUN GÜVEN

İnönü Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

98+XVII sayfa

2022

Danışman: Prof. Dr. Muhammed Fatih TALU

Çekişmeli Üretken Ağlar (ÇÜA), son yıllarda popüler derin öğrenme mimarilerinden biridir. Görüntü sentezlemesi yapılırken gerçek görsellere çok yakın görseller elde etmiştir. ÇÜA, sinyalden görüntüye dönüşümde, görüntü sentezleme ve bölütlemesinde, çözünürlük artırma ve eksik parçaların tamamlanması gibi alanlarda birçok araştırmacının dikkatini çekmiştir. Bilgisayar görmesi alanındaki çoğu yöntemi geride bıraktığı gözlenmiştir.

Bu tez çalışmasında, medikal veri kümesi oluşturma ve medikal veriler üzerinden görüntü sentezleme, bölütleme ve çözünürlük artırma gibi alanlardaki en güncel yaklaşımlar incelenmiş ve ÇÜA temelli yeni mimariler geliştirilerek literatüre katkılar sunulmuştur.

Yapılan ilk deneysel çalışmada, klasik ÇÜA mimarilerinden CycleGAN ve Pix2Pix yöntemlerinin PAPSMEAR hücre çekirdeği üretmedeki etkisi incelenmiştir. Mimarilerin performansları kıyaslanırken Jaccard ve Dice benzerliklerinden yararlanılmıştır. Görüntü sentezleme performansları ayrı ayrı incelenerek sonuçlar çizelgeler ve görsel şekilde sunulmuştur.

Tez kapsamında yapılan ikinci deneysel çalışma, sentetik PAPSMEAR veri kümesi oluşturmada matematiksel modelleme tabanlı yöntemin kullanılmasıdır. Oluşturulan yöntem MathModel olarak adlandırılmıştır.

Tez kapsamında yapılan üçüncü deneysel çalışmanın birinci kısmında, PAPSMEAR veri kümesi üzerinde klasik ÇÜA mimarileri (CycleGAN, Pix2Pix, DiscoGAN ve AttentionGAN) kullanılarak yeni görüntüler sentezlenmiştir. Oluşturulan görüntüler MSE, SSIM ve PSNR'ye göre kıyaslanmıştır. Bu çıktılar dikkate alınarak Pix2PixSSIM olarak adlandırılan yeni bir ÇÜA mimarisi önerilmiştir. Elde edilen sonuçlar çizelgelerle ve görsellerle sunulmuştur. İkinci kısmında ise PAPSMEAR veri kümesi üzerinde klasik ve güncel karşılaştırma metriklerinin ÇÜA mimarileri maliyetinin değişmesindeki etkisi incelenmektedir. Bu çalışmadaki amaç gelecekte ÇÜA mimarilerinde genel kullanmaya elverişli maliyet fonksiyonu keşfetmektir. Sonuçlar görsel ve çizelgesel olarak sunulmaktadır.

Tez kapsamında yapılan dördüncü deneysel çalışmada, PAPSMEAR veri kümesi üzerinde görüntü bölütlemesi yaparken klasik ÇÜA mimarileri (CycleGAN, CUT, FastCUT, DCLGAN, SimDCL) kullanılmıştır. Yöntem sonuçları kıyaslanırken hem görsel hem de

çizelgesel sonuçlara yer verilmiştir. Çıktılar kıyaslanırken LPIPS, PSNR, FID ve KID benzerlik metrikleri kullanılmıştır.

Tez kapsamında yapılan beşinci deneysel çalışmada, 2 boyutlu beyin MRI veri kümesi üzerinde görüntü bölütlemesi yaparken klasik ÇÜA mimarileri (CycleGAN, CUT, FastCUT, DCLGAN, SimDCL) kullanılmıştır ve SSIMDCL olarak adlandırılan yeni ÇÜA mimarisi önerilmiştir. Önerilen yöntemin hem görüntü çözünürlüğü arttırmada hem de bölütlemeye başarılı sonuçlar verdiği gözlemlenmiştir. Oluşturulan görüntüler kıyaslanırken LPIPS, PSNR, FID ve KID yöntemleri kullanılmıştır. Çalışmanın son aşamasında ise günümüzde dokusal olarak Beyin MRI konusunda iyi bölütleme yapabilen VolBrain sonuçları ile görsel ve metriksel olarak kıyaslama yapılmıştır.

Tez kapsamında yapılan altıncı deneysel çalışma, beşinci deneysel çalışmanın devamı şeklindedir. 2 boyutlu Beyin MRI, PAPSMEAR, CHASEDB ve XRAY veri kümelerinde görüntü bölütlemesi yaparken klasik ÇÜA mimarileri (CycleGAN, CUT, FastCUT, DCLGAN, SimDCL) ile SSIMDCL yöntemi kullanılmıştır. Amaç, diğer medikal görüntüler üzerinde bölütleme yapılırken önerilen yöntemin verimliliği incelenmektedir. Çıktılar görsel ve çizelgesel olarak sunulmaktadır.

Tez kapsamında yapılan yedinci deneysel çalışma, beyin tümörü bölütlemeye ÇÜA mimarilerinden SSIMDCL (önerilen) ile derin öğrenme mimarilerinden nnU-Net yöntemi kıyaslanmıştır. Beyin tümörü veri kümesi olarak BraTs kullanılmıştır. Bu çalışmada veri kümeleri iyileştirilmiş ve bu veri kümeleri üzerinden tekrar sonuçlar elde edilmiştir. Çıktılar hem görsel hem de çizelgesel olarak sunulmuştur. dördüncü deneysel çalışmanın devamı şeklindedir. Benzerlik metriği olarak LPIPS ve PSNR yöntemleri kullanılmıştır. Çıktılar görsel ve çizelgesel olarak sunulmaktadır.

Yapılan deneyler ve incelemeler sonucunda, ÇÜA temelli yaklaşımların birçok problem çözümüne olumlu katkılar sağladığı gözlemlenmiştir.

**Anahtar Kelimeler:** Derin Öğrenme, Çekişmeli Üretken Ağlar, Sentetik Görüntü Üretimi, Görüntü İyileştirme, Görüntü Bölütleme, Mathmodel, Pix2PixSSIM, SSIMDCL, Medikal Görüntü Sentezleme

# ABSTRACT

Phd. Thesis

## USE OF GENERATIVE ADVERSARIAL NETWORKS IN MEDICAL IMAGE SYNTHESIS AND SEGMENTATION

Sara ALTUN GÜVEN

Inonu University  
Graduate School of Natural and Applied Sciences  
Department of Computer Science

98+XVII page

2021

Supervisor: Prof. Dr. Muhammed Fatih TALU

Generative Adversarial Networks (GANs) are one of the popular deep learning architectures in recent years. While performing image synthesis, images very close to real images were obtained. GANs have attracted the attention of many researchers in areas such as signal-to-image conversion, image synthesis and segmentation, resolution enhancement and completion of missing parts. It has been observed that it surpasses most methods in the field of computer vision.

In this thesis, the most up-to-date approaches in areas such as creating medical datasets and image synthesis, segmentation and resolution enhancement on medical data were examined, and new GAN-based architectures were developed and contributions were made to the literature.

In the first experimental study, the effect of classical GAN architectures CycleGAN and Pix2Pix methods on PAPSMEAR cell nuclei production was investigated. While comparing the performances of the architectures, Jaccard and Dice similarities were used. Image synthesis performances were examined separately and the results were presented in charts and visual forms.

The second experimental study within the scope of the thesis is the use of mathematical modeling-based method to create synthetic PAPSMEAR dataset. The created method is named MathModel.

In the first part of the third experimental study conducted within the scope of the thesis, new images were synthesized on the PAPSMEAR dataset by using classical MPA architectures (CycleGAN, Pix2Pix, DiscoGAN and AttentionGAN). The created images were compared according to MSE, SSIM and PSNR. Considering these outputs, a new GAN architecture called Pix2PixSSIM has been proposed. Obtained results are presented with charts and visuals. In the second part, the effect of classical and current comparison metrics on the PAPSMEAR dataset on the cost of GAN architectures is examined. The aim of this study is to discover a cost function suitable for general use in future GAN architectures. Results are presented visually and tabularly.

In the fourth experimental study conducted within the scope of the thesis, classical GAN architectures (CycleGAN, CUT, FastCUT, DCLGAN, SimDCL) were used while performing image segmentation on the PAPSMEAR dataset. While comparing the method

results, both visual and tabular results are included. LPIPS, PSNR, FID and KID similarity metrics were used when comparing the outputs.

In the fifth experimental study within the scope of the thesis, classical GAN architectures (CycleGAN, CUT, FastCUT, DCLGAN, SimDCL) were used while performing image segmentation on the 2D brain MRI dataset, and a new GAN architecture called SSimDCL was proposed. It has been observed that the proposed method gives successful results both in increasing image resolution and in segmentation. LPIPS, PSNR, FID and KID methods were used when comparing the created images. In the last stage of the study, a visual and metric comparison was made with VolBrain results, which can now make good segmentation in brain MRI texturally.

The sixth experimental study conducted within the scope of the thesis is the continuation of the fifth experimental study. Classical GAN architectures (CycleGAN, CUT, FastCUT, DCLGAN, SimDCL) and SSimDCL method were used while performing image segmentation on 2D Brain MRI, PAPSMEAR, CHASEDB and XRAY datasets. The aim is to examine the efficiency of the proposed method when segmentation on other medical images. Outputs are presented in a visual and tabular form.

In the seventh experimental study conducted within the scope of the thesis, SSimDCL (recommended) from GAN architectures and nnU-Net method from deep learning architectures were compared in brain tumor segmentation. BraTs was used as the brain tumor dataset. In this study, datasets were improved and results were obtained over these datasets. Outputs are presented both visually and schematically. It is a continuation of the fourth experimental study. LPIPS and PSNR methods were used as similarity metrics. Outputs are presented visually and in tabular form.

As a result of experiments and investigations, it has been observed that GAN-based approaches make positive contributions to many problem solutions.

**Keywords:** Deep Learning, Generative Adversarial Networks, Synthetic Image Generation, Image Enhancement, Image Segmentation, MathModel, Pix2PixSSIM, SSimDCL, Medical Image Synthesis



## 1. GİRİŞ

Görüntü sentezleme; görüntü işleme, bilgisayar görmesi ve bilgisayar grafikleri gibi görsel yapı kullanan alanlarda problem çözümünde sıklıkla kullanılmaktadır. Görüntü sentezleme işlemi yapılırken alınan giriş görüntüsünün başka bir çıkış görüntüsü ile eşlemeyi öğrenmesi gerekmektedir.

Derin öğrenme algoritmaların giderek artan popülerliği bilgisayar görmesi alanında yapılan dijital görüntüleri inceleme ve anlama işlemlerinde ilgi odağı olmuştur (Hanbay K., 2020). Çekişmeli Üretken Ağlar (ÇÜA) derin öğrenme algoritmalarındandır. ÇÜA, 2014 yılında Ian Goodfellow tarafından önerilmiştir (Goodfellow I., 2014). Günümüzde ÇÜA'lar görüntü sentezleme, bölütleme ve oyun tasarımı gibi görselliğe dayanan yapılarda sıklıkla kullanılmaktadır.

Sentezleme ve bölütleme yapabilen ÇÜA'lar, hem denetimli hem de denetimsiz olarak sınıflandırılmaktadır. ÇÜA'lar denetimli dönüşüm yaparken iki farklı alandaki görüntüleri de barındırmaktadır. Her bir giriş görüntüsü ile buna karşılık gelen çıkış görüntüsüne dönüşüm yapmaktadır. Bu dönüşümü yaparken olasılıksal dağılımı öğrenmektedir. Denetimli dönüşüm, yönlü ve çift yönlü olarak ikiye ayrılır. Yönlü denetimli dönüşüm, Pix2Pix (Isola vd., 2017) koşullu üretken çekişmeli ağa dayanan denetimli görüntü sentezleme yaklaşımıdır. Sonrasında Pix2PixHD (Wang vd., 2018), StarGAN (Choi vd., 2018) ve SB-GAN (Azadi vd., 2019) yöntemleri geliştirilmiştir. Çift yönlü denetimli dönüşüm, eşleştirilmiş görüntü gerektiren birden fazla model içeren alanlar arası dönüşüm yöntemidir. BiCycleGAN (Zhu vd., 2017) ve CEGAN (Xiong vd., 2019 ) modelleri çift yönlü dönüşüme örnektir. Denetimsiz dönüşüm, iki veya daha fazla etki alanı arasında eşleme yaparken eşleştirilmiş görüntüye ihtiyaç duymamaktadır. Denetimsiz dönüşüm; döngüsel tutarlılık tabanlı, otomatik kodlayıcı tabanlı ve çözülmüş gösterim olmak üzere üçe ayrılmaktadır. Döngüsel tutarlılık tabanlı denetimsiz dönüşüm, iki maliyet fonksiyonu kullanılır. Yani ters maliyetler ve döngüsel tutarlılık maliyetleri kullanılarak aynı anda eğitilmektedir. Otomatik kodlayıcı tabanlı denetimsiz dönüşüm hem bir kodlayıcıdan hem de giriş görüntülerini gizli gösterime dönüştüren bir kod çözücünden oluşmaktadır. Çözülmüş gösterim ile denetimsiz dönüşüm, bir içerik kodlayıcı ve bir stil kodlayıcı ile veri varyasyonlarının faktörlerini modelleyen çözülmüş gösterimi öğrenmektedir. Döngüsel tutarlılık tabanlı denetimsiz dönüşüme CycleGAN (Zhu vd., 2017), DiscoGAN (Kim vd., 2017) ve AttentionGAN (Mejjati vd., 2018); otoenkoder tabanlı denetimsiz dönüşüme

UNIT (Liu vd., 2017) ve BranchGAN (Zhou vd., 2019); çözülmüş temsil ile denetimsiz dönüşüme ise MUNIT (Huang vd., 2018) ve DosGAN (Lin vd., 2019) yöntemleri örnek verilebilir.

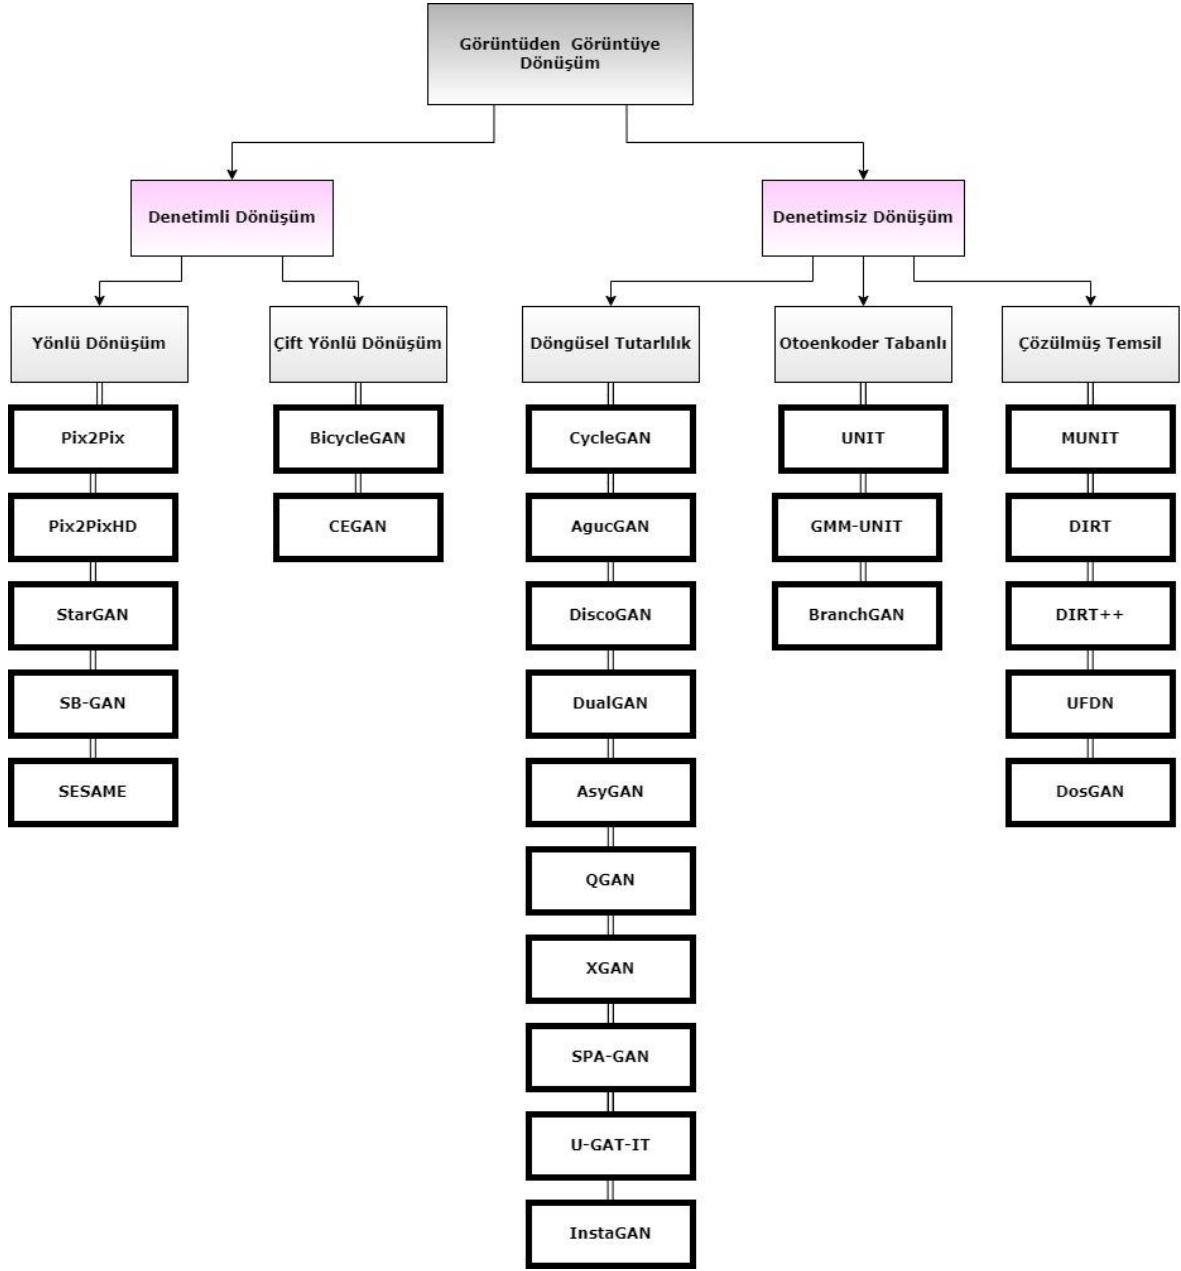
Medikal görüntü sentezleme yapılırken derin sinir ağları, konvolüsyonel sinir ağları ve ÇÜA'lar ilgi odağı şeklinde günümüz araştırmacıları tarafından yüksek oranda tercih edilmektedir (Yurt vd., 2021; Beers vd., 2018; Kaya vd., 2016; Kasım vd., 2015; Shakuntala, 2016). Kaya vd. 2016 yılında, kornea görüntülerinin bölütlenme ve benzetim süreçlerini otomatize eden Keratokonus hastalığının teşhis ve tedavisine destek sağlayan uygulama geliştirmiştir (Kaya vd., 2016). Kasım ve diğerleri 2015 yılında, görüntünün MRA ile modellenerek analizini yapabilme özelliğine sahip tam otomatik olarak tasarlanmış görüntü işleme uygulaması önermişlerdir (Kasım vd., 2015).

### **1.1. Çekişmeli Üretken Ağların Genel Yapısı**

Çekişmeli üretken ağlar ilk olarak Ian Goodfellow ve arkadaşları tarafından 2014 yılında önerilmiştir. Çekişmeli üretken ağlar rekabetçi iki ağdan meydana gelmektedir. Bu iki ağ gerçek verilerden ayırt edilmeyen sentetik verileri en iyi şekilde oluşturmayı amaçlayan makine öğrenimi tekniğidir (Örneğin el yazısı ile oluşturulmuş görüntülerin üretimi). ÇÜA'lar Üretici ve Ayırıştırıcı olmak üzere iki ağa sahiptir. Üretici ağ, herhangi bir gürültü, sinyal veya görüntüyü giriş olarak alıp gerçeğine benzeyen sahte görüntüler üretmeyi öğrenir. Ayırıştırıcı ağın amacı ise üretici ağdan çıkan sonucun gerçeğe ne kadar benzediğini bulmaktır.

### **1.2. Çekişmeli Üretken Ağlarda Görüntü Sentezleme**

Son yıllarda derin öğrenme algoritmalarının giderek artan popülerliği sayesinde birçok bilgisayar görmesi uygulamalarında dijital görüntüleri inceleme ve anlamada ilgi odağı olmuştur. Bu tez çalışması çekişmeli üretken ağ algoritmalarını ve türevlerini kullanarak görüntü sentezlemeye ve bölütlemeye kapsamlı bakış açısı sunmaktadır. Çekişmeli Üretken Ağlara genel giriş yapılmaktadır. Giriş yapılırken ÇÜA değişkenleri, mimarileri ve amaçları gösterilir. Görüntü sentezleme yaklaşımları, en son teknolojiye sahip algoritmalar, uygulamalar ve teoriler avantaj ve dezavantajları ile birlikte ayrıntılı olarak tartışılmaktadır. Görüntüden yeni bir görüntü üretebilen ÇÜA'lar denetimli ve denetimsiz olarak sınıflandırılmaktadır. Denetimli ve denetimsiz görüntüden görüntüye dönüşüm yapabilen ÇÜA'lar Şekil 1.1'de ayrıntılı olarak sunulmuştur.




**Şekil 1.1:** Genel Görüntüden Görüntüye Dönüşüm Yapan Çekişmeli Üretken Ağlar

Denetimli görüntüden görüntüye dönüşüm yönteminde bazı şartlarda iyi kalitede görüntü sentezleyebilmek için koşullandırılmış etki alanını ya da sınıf etiketlerini kullanır. Denetimli dönüşüm yönteminde iki alanda kullanılacak görüntüler belirlidir. Yani  $(X, Y)$  iki alanı temsil etmektedir ve  $(x, y)$  ise bu iki alana ait görüntülerdir. Denetimli dönüşüm yapılırken  $x \in X$  görüntüsü ve başka alandaki  $y \in Y'$  ye karşılık gelen karşılık gelen bir görüntü için  $G: X \rightarrow Y$  alanına dönüşümü yapılırken olasılıksal dağılımı öğrenir. Yönlü ve

çift yönlü dönüşüm olmak üzere ikiye ayrılmaktadır. Denetimli dönüşümün ilerleyiş biçimi Şekil 1.2(a)'da gösterilmektedir.

Denetimsiz dönüşümde bir alandaki görüntü verilirken diğer alandaki görüntü bilinmemektedir. Bu nedenle iki alanda farklı üretici ağa ve ayrıştırıcı ağa sahiptir. Denetimsiz dönüşüm yöntemi Şekil 1.2(b) de gösterildiği gibi  $G: X \rightarrow Y$ ,  $F: Y \rightarrow X$  üretici ağlarına ve  $D_y, D_x$  olan simetrik yapıda ayrıştırıcı ağa sahiptir.



Şekil 1.2 Çekişmeli Üretken Ağ türlerinin genel yapısı (a) Denetimli (b) Denetimsiz

### 1.3. Tezin Amaç ve Hedefleri

Bu tez çalışmasının amacı, medikal ve farklı çalışma alanlarında görüntülerde klasik yöntemlere kıyasla performans artışı sağlayan özgün ÇÜA mimarilerinin geliştirilmesidir. Bunun için ilk aşamada bahsedilen alanlardaki mevcut yaklaşımlar detaylıca incelenmekte, daha sonra performans artışı sağlayan özgün mimariler geliştirilerek literatüre katkılar sunulmaktadır.

ÇÜA'lar son yıllarda görüntüden görüntü dönüşüm yaparken bilgisayar görmesi alanında büyük başarılar elde etmiştir. Bu tez çalışmasında görüntüden görüntüye dönüşüm ile ilgili ÇÜA yöntemlerine ve uygulamalarına kapsamlı şekilde yer verilmiştir.

### 1.4. Tezin Organizasyonu ve Yapılan Bilimsel Katkılar

Tez çalışmasının ikinci bölümünde, farklı ÇÜA mimarilerinin görüntü sentezlemede kullanımını ayrıntılı bir şekilde incelenmekte ve gelecek çalışmalara ışık tutmaktadır. Yapılan bilimsel çalışma, "Görüntüden Görüntüye Dönüşüm ve Görüntü Sentezleme Yapan Üretici Çekişmeli Ağların İncelenmesi" başlığı altında derleme bir makaleye dönüştürülerek Avrupa Bilim ve Teknoloji Dergisi dergisinde yayınlanmıştır (Sara ve Fatih, 2021a).

Üçüncü bölümünde, sentetik PAPSMEAR veri kümesi oluşturulurken kullanılan matematiksel modelin ayrıntılarına ve veri kümesinin oluşturulma aşamalarına yer verilmiştir.

Dördüncü bölümünde, PAPSMEAR görüntü üretimi hakkında ÇÜA temelli özgün bir çalışma önerilmiştir. Dördüncü bölümün ilk kısmında klasik ÇÜA mimarileri eğitim aşamasında  $L_1$  maliyet fonksiyonu olarak MAE yöntemini kullanırken, önerilen mimari maliyet fonksiyonu olarak görüntü çiftlerinin benzerlik skorunu elde etmek için ortalama ( $\mu$ ) ve standart sapma ( $\sigma$ ) gibi birkaç basit istatistiksel moment bilgisi kullanılmaktadır. Görsel üretim performansının önerilen mimariyle %5-8 oranında arttığı görülmüştür. Bu bölümde yapılan çalışma “Çekişmeli üretken ağlarla PAPSMEAR görüntüsü oluşturmada yeni bir yaklaşım” başlığı ile Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi’nde yayınlanmıştır (Sara ve Fatih, 2022a). Dördüncü bölümün ikinci kısmında ise güncel ve klasik metriklerin çekişmeli üretici ağlarının maliyet fonksiyonu olarak kullanılmıştır. Böylece çekişmeli üretken ağların maliyet fonksiyonu olarak yeni bir bakış açısı getirmiştir. Bu bölümde yapılan çalışma “Çekişmeli Üretken Ağların Evrimsel Sinir Ağı Tabanlı Algısal Benzerlik Metrikleri ile Görüntü Sentezlemesi” başlığı ile Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi’nde değerlendirme aşamasındadır (Sara ve Fatih, 2022b).

Beşinci bölümünde PAPSMEAR görüntüleri üzerinde görüntü bölütleme yapılmıştır. PAPSMEAR görüntü bölütlemesi yapılırken mevcut kontrastlı öğrenme tabanlı çekişmeli üretken ağlar kullanılmıştır. Kullanılan yöntemler CUT, FastCUT, CycleGAN, DCLGAN, SimDCL yöntemleridir. Bu bölümde PAPSMEAR ile ilgili yapılan çalışma “Kontrastlı Öğrenme Tabanlı Çekişmeli Üretken Ağlar İle PAPSMEAR Görüntü Bölütleme” başlığı ile Bilgisayar Bilimleri Dergisi’nde yayınlanmıştır (Sara ve Fatih, 2022c).

Altıncı bölümde 2 Boyutlu beyin MRI görüntüleri üzerinde görüntü bölütleme yapılmıştır. 2 boyutlu beyin MRI görüntüleri bölütlenirken mevcut yöntemlere göre daha iyi sonuç veren SSIMDCL Yöntemi önerilmiştir. Bu bölümde Beyin MRI bölütlemeye yeni fikir sunan çalışma “Brain Mri High Resolution Image Creation And Segmentation With The New Gan Method” başlığı ile Biomedical Signal Processing and Control dergisinde değerlendirme aşamasındadır (Sara ve Fatih, 2022b).

Yedinci bölümde, medikal veri kümeleri kullanılarak önerilen ÇÜA mimarisi üzerinde görüntü bölütleme başarımlarının incelenmesi yapılmıştır. Görüntü bölütlemesi yapılırken mevcut kontrastlı öğrenme tabanlı çekişmeli üretken ağlar CUT, FastCUT, CycleGAN, DCLGAN, SimDCL yöntemleri ve SSIMDCL (önerilen) yöntemleridir.

Sekizinci bölümde, 2 Boyutlu beyin tümörü görüntüleri üzerinde görüntü bölütleme yapılmıştır. Beyin tümörü algılanırken ve bölütlenirken SSIMDCL ve nnU-Net yöntemleri kullanılmıştır. Aynı zamanda veri kümelerinin iyileştirilmesinin SSIMDCL yöntemi üzerindeki etkileri incelenmiştir.

Tez çalışmasından türetilen diğer birinci yayın, “Görüntüden Görüntüye Dönüşüm ve Görüntü Sentezleme Yapan Üretici Çekişmeli Ağların İncelenmesi” başlığı altında derleme bir makale Avrupa Bilim ve Teknoloji Dergisi dergisinde yayımlanmıştır (Sara ve Fatih, 2021b). Yapılan çalışma farklı GAN mimarilerinin görüntü sentezlemede kullanımını ayrıntılı bir şekilde incelemek ve gelecek çalışmalara ışık tutmaktadır.

Tez çalışmasından türetilen diğer ikinci bilimsel çalışma, “Investigation of Hyperparametry Methods and Kits for Deep Neural Networks” başlığı adı altında Dicle University Journal of Engineering Dergisi’nde inceleme makalesi olarak yayımlanmıştır (Sara ve Fatih, 2021b). Bu çalışmada derin öğrenmede kullanılan hiperparametreler ve araçlar ayrıntılı şekilde incelenmektedir.

Tez çalışmasından türetilen diğer üçüncü bilimsel çalışma “Aynı Şartlar Altında Farklı Üretici Çekişmeli Ağların Karşılaştırılması” başlığı altında “2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)” sempozyumunda sunulup IEEE Xplore’de yayımlanmıştır (Sara ve Fatih, 2019). Bu çalışmada, bir gürültü sinyalinden görüntü üretebilen farklı GAN mimarileri incelenmektedir. Mimarilerin performans karşılaştırmaları MNIST (Deng, 2012) veri kümesi üzerinde gerçekleştirilmektedir.

## 2. ÇEKİŞMELİ ÜRETKEN AĞLARLA PAPSMEAR HÜCRE ÇEKİRDEĞİ ÜRETİMİ

Hertzmann ve arkadaşları tarafından önerilen Görüntü Anatolojileri en az bir görüntü çifti üzerinde parametrik olmayan doku modelini kullanmaktadır. Bu da görüntüden görüntüye dönüştürme fikrinin başlangıcıdır (Hertzmann et al.,2001).

Güncel üretken yaklaşımlar, evrimsel sinir ağlarını (ESA) kullanarak parametrik dönüştürme işlevini öğrenmede girdi-çıkı örneklerinden oluşan veri kümesi kullanmaktadır (Örn. Long vd., 2015).

Bu bölümde aynı veri kümesi üzerinde güncel çekişmeli üretken ağlardan olan Zhu ve diğerleri tarafından 2017 yılında önerilen CycleGAN (Zhu vd., 2017) ve Isola ve diğerleri tarafından 2017 yılında önerilen Pix2Pix yöntemlerinin sentetik görüntü üretmedeki etkileri incelenmiştir. CycleGAN yöntemi, Isola ve arkadaşlarının önerdiği “Pix2Pix” çerçevesine dayalıdır (Isola vd., 2017). Bahsi geçen yöntemler girdi görüntülerinden çıktı görüntülerini oluşturmak için çekişmeli üretken ağ kullanmaktadır (Goodfellow vd., 2014). Eski çalışmalardan farklı olarak CycleGAN eşleştirilmiş eğitim örnekleri olmadan eşleşmeyi yani denetimsiz şekilde çalışmayı öğrenmektedir.

Hem Pix2Pix hem de CycleGAN için aynı başlangıç durumları belirlenmiştir. Bu koşullar göz önünde bulundurularak üretici ve ayrıştırıcı ağ maliyetleri deneysel sonuçlarla görsel ve tablosal olarak karşılaştırılmıştır.

Tezin bu bölümündeki çalışma CycleGAN ve Pix2Pix yöntemleri ile yapılacak araştırma ve uygulamalar için ön bilgi niteliğindedir. Bölüm düzeni şu şekildedir: Birinci kısımda kullanılan ÇÜA mimarileri ile ilgili genel bilgiler verilmektedir. İkinci kısımda uygulamada kullanılan veri kümesine, üçüncü kısımda sentetik görüntü oluşturulduktan sonra kıyaslamada kullanılan ölçüm metriklerine ve dördüncü kısımda deneysel çalışmalar ve sonuçlarına yer verilmiştir.

### 2.1. Çekişmeli Üretici Ağ Mimarileri

#### 2.1.1. Pix2Pix

Pix2Pix (Isola vd., 2017), görüntü sentezleme alanında yaygın olarak kullanılan bir ÇÜA mimarisidir. DCGAN'ın geliştirilmiş bir sürümüdür. Pix2Pix yöntemi bir üretici ağ ve

bir ayrıştırıcı ağdan oluşur. Üretici ağ, giriş görüntüsünden yeni bir görüntü üretirken ayrıştırıcı ağ bu üretilen görüntünün gerçek mi yoksa sahte mi olduğunu sınıflandırmaktadır. Kısacası iki ağ, düşmanca bir ilişkiye sahiptir. Üretici ağ, DCGAN'daki gibi bir vektör almak yerine bir görüntüyü giriş olarak almaktadır ve genellikle U-Net mimari yapısına sahiptir. U-Net, yaygın olarak kullanılan bir evrimsel sinir ağıdır (ESA) ve kodlayıcı-kod çözücü kısımları bulunmaktadır. Pix2Pix ayrıştırıcı ağının girişi tek bir görüntü yerine hem üretici ağdan gelen hem de gerçek veri kümesinden gelen görüntüler olmak üzere çift görüntüdür. Ayrıştırıcı ağda PatchGAN mimarisi kullanılmaktadır (Wang et al., 2018). Bu mimari düşük boyutlu görselleri yüksek çözünürlüklere dönüştürmek için kullanılır. Pix2Pix yönteminin üretici ve ayrıştırıcı maliyet fonksiyonları Denklem 2.1 ve Denklem 2.3 arasında ifade edilmektedir.

$$L_D = \|D(X, Y) - 1\|_2 + \|D(X, G(X))\|_2 \quad (2.1)$$

$$L_G = \|D(X, G(X)) - 1\|_2 \quad (2.2)$$

$$\mathcal{L}_{GAN}(G, D, X, Y) = L_G + L_D \quad (2.3)$$

Yapılan çalışmalar neticesinde Pix2Pix ile üretilen görsellerde bulanıklık seviyesinin yüksek olduğu gözlemlenmiştir. Bulanıklığı bir derece giderebilmek için Isola ve diğerleri (Isola vd., 2017), üretici mimarinin maliyet fonksiyonuna ek bir  $L_1$  regülarizasyon terimi eklemiştir.

$$G^* = \underset{G}{\operatorname{argmin}} \underset{D}{\operatorname{max}} \mathcal{L}(G, D, X, Y) = \mathcal{L}_{GAN}(G, D, X, Y) + \lambda \mathcal{L}_{\text{Reg}} \quad (2.4)$$

$$\mathcal{L}_{\text{Reg}} = \|Y - G(X)\|_1 \quad (2.5)$$

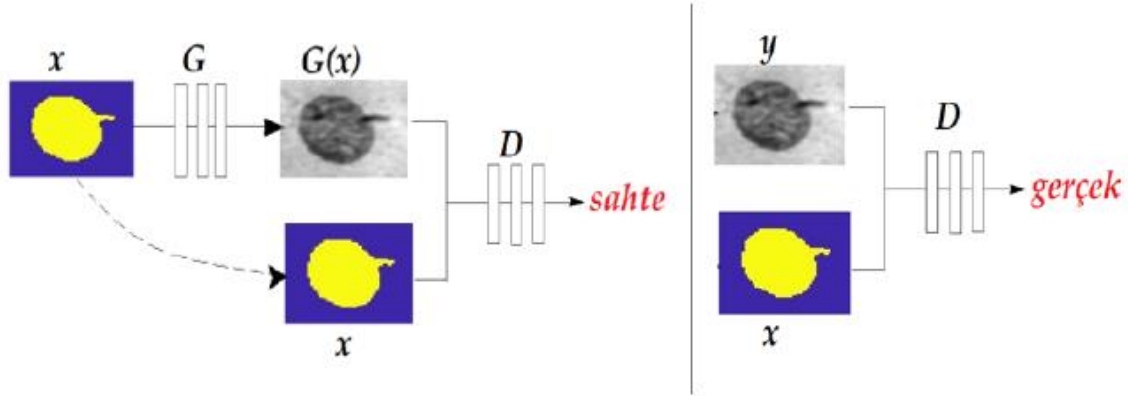
Pix2Pix, giriş ve çıkış görüntüleri arasında eğitim yapabildiği için sentetik görüntü üretmede kullanılabilir. Şekil 2.1'de üretici ağın sentetik bir görüntü ürettiğini ve ayrıştırıcı ağın ise iki görüntüyü gerçek veya sahte olarak sınıflandırdığı görülmektedir.

Bu çalışmada, hücre çekirdeği maskesi giriş olarak üretici ağa (Generator- G) verilmektedir. Üretici ağdan sentetik görüntü elde edilirken ağın iç kısmında konvolusyon, havuzlama gibi ara işlemlerden geçirilir. Ayrıştırıcı ağ (Discriminator - D), gerçek ve üretici ağdan gelen sentetik görüntü arasındaki farkı ayırt etmeye çalışır. Durma kriteri, ayrıştırıcı ağın ayırt edebilme olasılığı azaldığında sonlanır. Denklem 2.4'te Pix2Pix'in amaç



fonksiyonuna ve Denklem 2.5'te ise amaç fonksiyonunda kullanılan  $\mathcal{L}_{Reg}$  maliyetine yer verilmiştir. Burada  $\lambda$ , iki hedefin göreceli önemini kontrol etmektedir.

PAPSMEAR hücre çekirdeği oluşturulurken kullanılan Pix2Pix mimarisine Şekil 2.1'de yer verilmiştir.



Şekil 2.1: PAPSMEAR hücre çekirdeği sentezlemede Pix2Pix mimarisini

### 2.1.2. CycleGAN

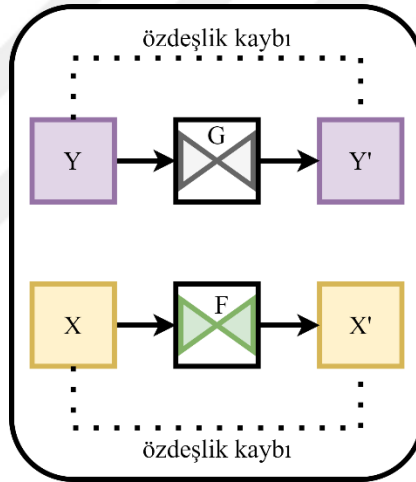
CycleGAN (Zhu vd., 2017), çift taraflı dönüşüm kullanan bir ÇÜA mimarisidir. CycleGAN,  $X$  alanındaki bir giriş görüntüsünü,  $Y$  alanındaki bir çıkış görüntüsüne dönüştürürken  $G: X \rightarrow Y$  ve  $F: Y \rightarrow X$  şeklinde iki farklı üretken ağı kullanmaktadır (Zhu vd., 2017). Bu mimari eğitilirken toplu normalleştirme yerine örnek (instance) normalleştirme kullanılmakta ve üretici ağın iç yapısında ResNET blokları yer almaktadır. Şekil 2.3'te CycleGAN mimarisinin genel yapısına yer verilmiştir. Buna göre CycleGAN mimarisinin kayıp fonksiyonu iki farklı terim içermektedir: 1) dögüsel tutarlılık kaybı; 2) özdeşlik kaybı.

Dögüsel tutarlılık kaybı: Dögüsel kayıp hesaplanırken  $X \rightarrow G(X) \rightarrow Y' \rightarrow F(Y') \rightarrow \hat{X}$  ve  $Y \rightarrow F(Y) \rightarrow X' \rightarrow G(X') \rightarrow \hat{Y}$  dönüşümleri yapılmakta ve  $X - \hat{X}$  ile  $Y - \hat{Y}$  fark değerlerinin toplamı minimize edilmeye çalışılmaktadır. Buna göre dögüsel kayıp Denklem 2.6'daki gibi hesaplanır:

$$\mathcal{L}_{cyc} = |X - \hat{X}| + |Y - \hat{Y}| \quad (2.6)$$

**Özdeşlik Kaybı (identity loss):**  $X \rightarrow \hat{X}$  ve  $Y \rightarrow \hat{Y}$  dönüşümler gerçekleştirilirken  $X \rightarrow Y'$  ve  $Y \rightarrow X'$  ara çıktılar üretilmektedir. Bu ara çıktıların orijinal görsellere benzetilmesi hedeflenmektedir. Normal görüntü üretimi yapılırken  $G$  üretici ağı  $X$  alanındaki görüntülerin  $Y$  alanındaki görüntülere dönüşümü için,  $F$  üretici ağı ise  $Y$  alanındaki görüntülerin  $X$  alanına dönüşümü için kullanılmaktadır. Eğer  $G$  üretici ağına  $Y$  alanından görüntü verilirse tekrardan  $Y$  alanından yeni bir  $Y'$  görüntüsü elde edilir. Aynı şekilde  $F$  üretici ağına  $X$  alanından görüntü verilirse  $X$  alanından yeni bir  $X'$  görüntüsü elde edilir. Şekil 2.2'de özdeşlik kaybı gösterilmektedir. Buna göre özdeşlik kaybı Denklem 2.7'deki gibi formülize edilir:

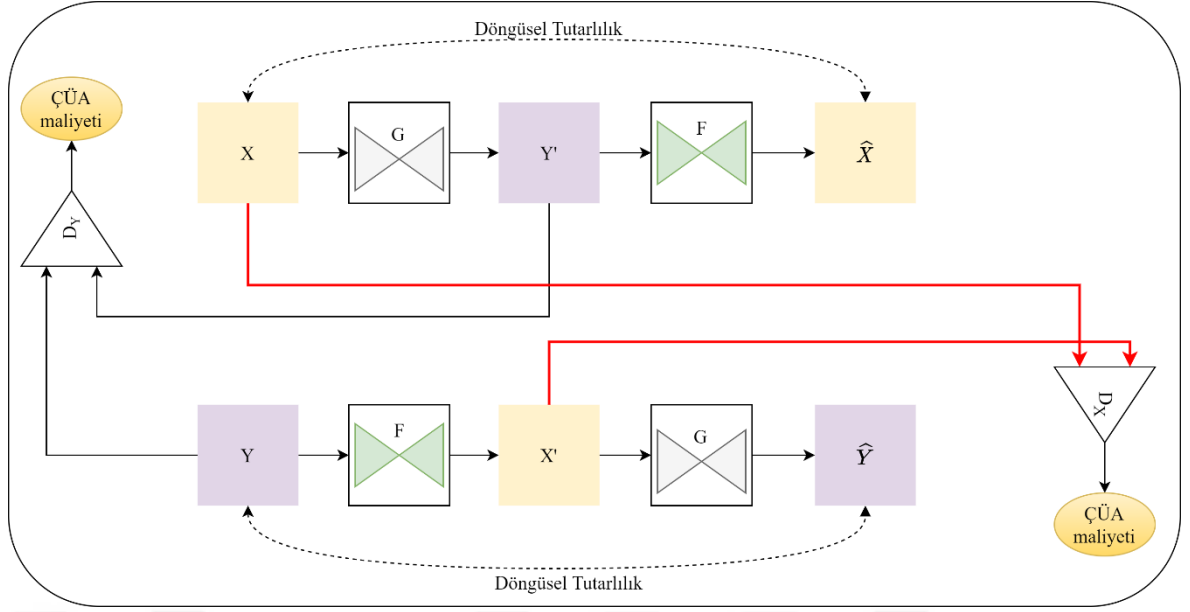
$$\mathcal{L}_{identity} = L_1(G(Y) - Y) + L_1(F(X) - X) \quad (2.7)$$



Şekil 2.2: Özdeşlik kaybı

Bu kayıt terimlerinin yanında üretken ağlardaki ayırıcı mimarilerin hatalarında ( $\mathcal{L}_{GAN}^G$  ve  $\mathcal{L}_{GAN}^F$ ) hesaplanmaktadır. Böylelikle Denklem 2.8'deki amaç terim ortaya çıkmaktadır (Zhu vd., 2017).


$$\begin{aligned} G^*, F^* &= \underset{G, F}{\operatorname{argmin}} \underset{D_X, D_Y}{\max} \mathcal{L}(G, F, D_X, D_Y) \\ &= \mathcal{L}_{GAN}^G(G, D_Y, X, Y) + \mathcal{L}_{GAN}^F(F, D_X, Y, X) \\ &\quad + \lambda \left( \mathcal{L}_{cyc}(G, F, X, Y) + \mathcal{L}_{identity}(G, F, X, Y) \right) \end{aligned} \quad (2.8)$$



Şekil 2.3: CycleGAN mimarisi

## 2.2. Veri Kümesi

PAPSMEAR hücre çekirdeği üretilirken eğitim aşamasında 100 adet, test aşamasında 50 adet hücre çekirdeği kullanılmıştır. Hücre çekirdekleri ardışıl görüntü (dip\_image) olarak depolanmıştır. Sonrasında bu depolanmış görüntüler tek bir görüntü haline getirilmiştir. Veri kümesi orijinal hücre çekirdekleri ve bu hücre çekirdeklerinin maskelerini içermektedir. Hücre çekirdeği maskeleri gerçek görüntüde hücre çekirdeğinin bulunmadığı kısımlara 0, bulunduğu kısımlara ise 1 değeri verilerek elde edilen siyah-beyaz görüntülerdir. Şekil 2.4'te PAPSMEAR hücre çekirdeği ve maskesinden bir örnek görülmektedir.



Şekil 2.4: PAPSMEAR hücre çekirdeği örneği (a) Hücre çekirdeği (b) Maskesi

Veri kümesi düzenlenirken Matlab 2019b ortamı kullanılmıştır. ÇÜA mimarilerindeki üretici ağı uygun olması için görüntüler 256x256 boyutuna getirilmiştir. Eğitim aşaması 200 iterasyon olarak belirlenmiştir.

## 2.3. Kullanılan Ölçüm Metrikleri

Üretilen hücre çekirdeğinin gerçek hücre çekirdeğine benzerliğini ölçmede Dice indeksi ve Jacard indeksi kullanılmıştır.

### 2.3.1. Dice indeksi

Dice indeksi Jaccard indeksi ile Denklem 2.9'da gösterilen ilişkiye sahiptir.

$$dice(A, B) = 2 * jaccard(A, B) / (1 + jaccard(A, B)) \quad (2.9)$$

Jaccard  $jaccard(A, B)$ 'nin formül ve açıklamasına Bölüm 2.3.2'de yer verilmiştir.

### 2.3.2. Jacard indeksi

A ve B iki kümenin Jaccard benzerlik katsayısı (IoU üzerinden kesişme veya birleşme olarak da bilinir) Denklem 2.10'daki gibi ifade edilir.


$$jaccard(A, B) = | kesişim(A, B) | / | birleşim(A, B) | \quad (2.10)$$

Burada  $|A|$ , A kümesinin nicelliğini temsil eder. Jaccard indeksi yanlış pozitif (FP), yanlış negatif (FN) ve gerçek pozitif (TP) olarak da Denklem 2.11'deki gibi ifade edilmektedir.

$$jaccard(A, B) = TP / (TP + FP + FN) \quad (2.11)$$

## 2.4. Deneysel Çalışmalar ve Sonuçları

Pix2Pix yöntemi tek yönlü eğitim işlemi gerçekleştirilirken, CycleGAN yöntemi çift taraflı eğitim yapmaktadır. Şekil 2.5'de CycleGAN ve Pix2Pix yöntemlerinin bir iterasyon eğitim sonucundaki çıktılarına yer verilmiştir.



Şekil 2.5: Bir iterasyon eğitim çıktıları (a) CycleGAN (b) Pix2Pix

Zaman açısından incelendiğinde bir iterasyon sonunda geçen süre Pix2Pix için  $t \sim 38.3607s$ ; CycleGAN için  $t \sim 98.5609s$ 'dir.

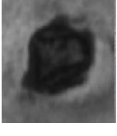





Çizelge 2.1'de Pix2Pix ve CycleGAN yöntemlerinin Dice ve Jaccard benzerlik metriklerine göre sonuçlarına yer verilmiştir.

Çizelge 2.1: CycleGAN ve Pix2Pix Benzerlik Sonuçları

ÇÜA MİMARİLERİ	ÖLÇÜM METRİKLERİ	
	Jaccard İndeksi	Dice İndeksi
CycleGAN	0.2954874	0.4561795
Pix2Pix	<b>0.3011773</b>	<b>0.4629305</b>

Çizelge 2.2'de Pix2Pix ve CycleGAN yöntemlerinin belirli iterasyon aralığındaki eğitildikten sonraki oluşan hücre çekirdeği görüntülerine yer verilmiştir.

**Çizelge 2.2:** CycleGAN ve Pix2Pix Eğitim Sonuçları

İterasyon Sayısı	Orijinal Hücre Çekirdeği	CycleGAN	Pix2Pix
5			
25			
50			
75			
100			
125			
150			
175			
200			

Bu kısımda gerçek görüntülerden sahte görüntüler üretme yeteneğine sahip olan ÇÜA yöntemlerinden Pix2Pix ve CycleGAN yöntemlerinin hücre çekirdeği üretmedeki etkisi kıyaslanmaktadır. Yapılan kıyaslama performans, görsel sonuç ve nicel benzerlik üzerinedir.

Yöntemler performans olarak kıyaslandığında Pix2Pix yönteminin  $t \sim 38.3607s$  ile daha verimli olduğu gözlemlenmiştir.

Çizelge 2.1'deki Jaccard ve Dice benzerlik metriklerine göre Pix2Pix yönteminin gerçek görüntüye benzerlik oranının daha yüksek olduğu gözlemlenmiştir.

Şekil 2.1'deki görsel sonuçlar incelendiğinde Pix2Pix yöntemi 25. iterasyon sonrasında gerçeğe daha benzer görüntüler üretmeye başlarken, CycleGAN yöntemi 75. iterasyondan sonra gerçeğe benzer görüntüler üretmeye başlamıştır.

#### **2.4.1 Sonuç**

Tezin bu bölümünde çıkarım olarak Pix2Pix ve CycleGAN yöntemleri görüntüden görüntüye dönüşüm yapabilme yeteneğine sahip olduğundan sentetik medikal görüntü üretiminde kullanılabilirliği gözlemlenmiştir. Kıyaslama sonuçları incelendiğinde Pix2Pix yönteminin CycleGAN yöntemine göre avantajlarından ötürü tercih edilebilme oranı yüksektir. Hücre çekirdeği üretirken Pix2Pix ve CycleGAN yöntemlerinin dezavantajları, gerçek bir bölütleme yapılırken ya da görüntü oluşturulurken net oluşturulamayan pikseller oluşturması bakımından hata ile karşılaşılmaktadır.

### 3. MATEMATİKSEL MODEL İLE PAPSMEAR VERİ KÜMESİ OLUŞTURULMASI

Malm ve diğerleri 2015 yılında (sıkça bahsedileceği için MathModel olarak isimlendirilir) modelleme yaklaşımıyla sentetik PAPSMEAR görüntülerinin üretildiği görülmektedir (Malm vd.,2015). Bilindiği gibi PAPSMEAR görüntüleri çekirdek, sitoplazma, basil, beyaz kan hücreleri gibi nesnelere oluşmaktadır. Bu çalışmada her bir nesne görseli matematiksel olarak modellenmeye çalışılmıştır. Önerilen modelleme yaklaşımı genel olarak üç aşamalı bir yapıya sahiptir. Bu yaklaşımın ilk aşamasında nesnelere şekil ve desen modelleri üretilmekte ve yeni oluşturulacak sentetik görüntüye aktarılmaktadır. Ayrıca, nesnelere önde veya arkada oluşlarını temsil etmek için derinlik değeri atanmaktadır. İkinci aşamada, nesne parlaklık ayarlaması yapılmakta, son aşamada ise nesne görseli üzerine eklenecek gürültü miktarı modellenmektedir.

Çalışmanın kalan organizasyonu şu şekilde ilerlemektedir: Bölüm 3.1’de PAPSMEAR görüntüsünün içerdiği nesnelere oluşturulmasına, Bölüm 3.2’de deneysel çalışmalar ve sonuçlarına yer verilmiştir.

#### 3.1. PAPSMEAR Görüntüsünde Nesnelere Oluşturulması

PAPSMEAR; hücre çekirdeği, sitoplazma, beyaz kan hücreleri, basiller ve diğer yapılardan oluşmaktadır.

##### 3.1.1 Hücre çekirdeği ve sitoplazma

Hücre çekirdeği, koyu mavi renkli, katı ve eliptik bir yapıya sahipken, sitoplazma çekirdeği sarmalayan transparan bir yapıdadır. Bu nesnelere geometrik şekillerini üretebilmek için gerçek PAPSMEAR görüntülerinden çekirdek ve sitoplazmayı içeren 100 adet hücre görüntüsü kullanılmaktadır. Bu görüntülerdeki çekirdek ve sitoplazma bölümlerini birbirinden ayırmak ve maske görsellerini elde etmek için Watershed ve interaktif bölütleme araçları kullanılmaktadır. Maskede yer alan geometrik şeklin modellenebilmesi için ilk olarak şekil görüntü ortasına taşınır ve sınır hatları üzerinden eşit açılı dairesel bir örnekleme yapılarak  $K$  adet nokta koordinatı  $(x(1), y(1)), (x(2), y(2)), \dots, (x(K - 1), y(K - 1))$  elde edilir. Her bir nokta koordinatı Denklem 3.1’de gösterildiği gibi karmaşık bir sayı şeklinde yazılır ve Denklem 3.2’de gösterilen ayrık Fourier dönüşümüyle frekans uzayına taşınır.



$$z(k) = x(k) + iy(k) \quad (3.1)$$

$$u = \frac{1}{K} \sum_{k=0}^{K-1} z(k) e^{-i2\pi k/K} \quad (3.2)$$

Geometrik şekillerin boyutları arasındaki farklılığı ortadan kaldırmak için frekans alanında normalizasyon işlemi gerçekleştirilmektedir.  $u_0$ , pozisyona bağlı DC bileşen olduğu için göz ardı edilir ve  $u_1$  şeklin alanını temsil etmektedir (Denklem 3.3).

$$\hat{u} = \left[ \frac{u_0}{|u_1|}, \frac{u_1}{|u_1|}, \dots, \frac{u_{K-1}}{|u_1|} \right]^T \quad (3.3)$$


Frekans alanındaki  $N$  adet ( $N = 100$  seçilmiştir) normalize edilmiş maske vektöründen yeni maskeler üretebilmek için Denklem 3.4-3.6'da gösterilen işlemler gerçekleştirilir.

$$\mu_{\hat{u}} = \text{mean}(\hat{u}_1, \dots, \hat{u}_N) \quad (3.4)$$

$$\sigma_{\hat{u}} = \text{std}(\hat{u}_1, \dots, \hat{u}_N) \quad (3.5)$$

$$\hat{u}_{new} = \mu_{\hat{u}} + \sigma_{\hat{u}} * \mathcal{N}(0,1) \quad (3.6)$$

Elde edilen örnek hücre çekirdeği ve sitoplazma görselleri Şekil 3.1'de gösterilmektedir.

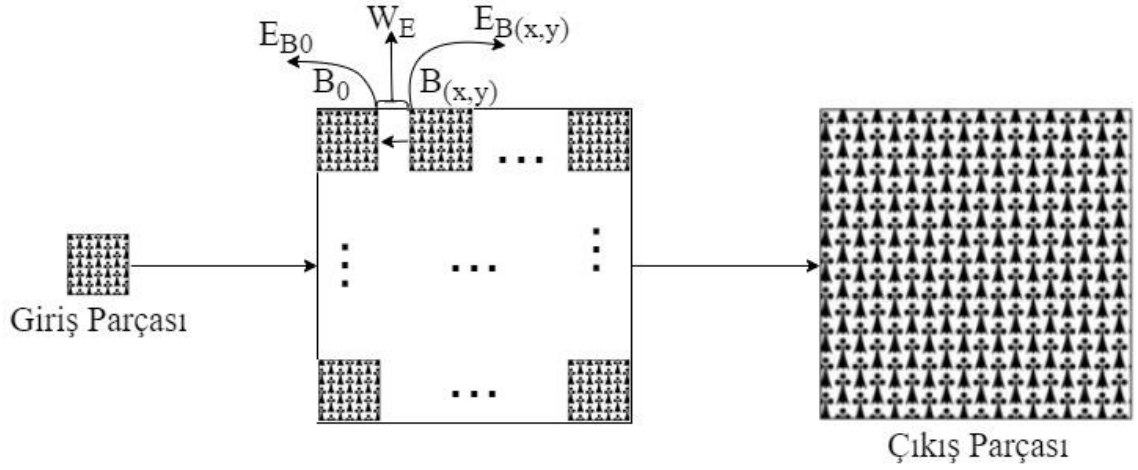


**Şekil 3.1.** Üretilen hücre çekirdeği ve sitoplazma örnekleri

Geometrik şekil üretimi tamamlandıktan sonra üzerine desen giydirme aşamasına geçilir. Bunun için ilk olarak orijinal görsellerde parlaklık normalizasyonu gerçekleştirilir (Denklem 3.7).

$$\widehat{nuclei}_k = \frac{(nuclei_k - \mu_{nuclei_k})}{\sigma_{nuclei_k}} * \sigma_{nuclei_{all}} + \mu_{nuclei_{all}} \quad (3.7)$$

Normalize edilmiş görüntü bir parça olarak düşünülür ve bu küçük parçanın geometrik şekil üzerine yayılabilmesi için “Desen Yayma” algoritması kullanılır. Bu algoritmayla küçük boyutlu desen görüntüleri genişletilerek daha büyük boyutlu görüntüler elde edebilir (bkz. Şekil 3.1). Desen görüntülerinin geometrik şekillere giydirilebilmesi için noktasal çarpım işlemi kullanılır.



Şekil 3.1: Desen yayma algoritması (Patch-based texture generation)

Sitoplazma desenini oluşturabilmek için “desen yayma algoritması” kullanılmıştır.

### 3.1.2 Beyaz kan hücreleri (lökositler), basiller ve diğer yapılar

Beyaz kan hücre (lökosit) şekillerinin üretilmesi için Denklem 3.8’de ifade edilen model kullanılmaktadır:


$$\begin{aligned} x_i(\theta_i) &= s[\mathcal{N}(0, \theta_i) U(-\alpha, \alpha) + \cos(\theta_i + U(-\beta, \beta))] \\ y_i(\theta_i) &= s[U(-\alpha, \alpha) + \sin(\theta_i + U(-\beta, \beta))] \end{aligned} \quad (3.8)$$

Burada  $\alpha$  ve  $\beta$  değer aralığını;  $s$ , ölçek parametresini;  $U$ , koordinatların tanım aralığını göstermektedir. Sonraki aşamada, kümeli bir şekilde beyaz kan hücrelerinin dağılımı gerçekleştirilir. Doğal bir küme dağılımı elde edebilmek için ağırlıklı dağıtım

yöntemleri ve rastgele oluşturulmuş ağırlık haritaları birlikte kullanılır. Son olarak, Perlin gürültüsü eklenerek doğal bir görünüm kazandırılır.

Basil nesneleri, doğrusal bir eğri modeliyle üretilir ve beyaz kan hücreleri gibi kümelenir. Benekler, tek bir piksel olarak oluşturulur.

Mikroskopta hücre görüntüleri elde edilirken sinyal iletimi yapılmaktadır. Bu sinyal iletiminde; arka plan aydınlatması, absorban, sinyal algılama ve dijitalleştirme yapılmıştır. Şekil 3.2’de PAPSMEAR hücre maskesinde yer alan nesnelere yer verilir.



Şekil 3.2: PAPSMEAR Hücre Görüntüsünde Bulunan Nesnelere Yer Verilir

## 3.2. Deneysel Çalışmalar ve Sonuçlar

### 3.2.1. Modelleme yaklaşımı ile veri kümesi oluşturulması

Bu bölümde, PAPSMEAR görüntülerinin üretilmesinde literatürdeki sentezleme yaklaşımlarının performansları incelenmektedir. Sentezleme yaklaşımlarının kullanılabilmesi için giriş ve maske görüntü çiftlerine ihtiyaç duyulmaktadır. PAPSMEAR görüntü çiftleri, modelleme yaklaşımıyla Matlab 2020a kullanılarak üretilmiştir. Buna göre Çizelge 3.1’de belirtilen özelliklere sahip 500 adet PAPSMEAR görüntüsü üretilmiştir.

Çizelge 3.1: Görüntü üretmede sabit değerler


ÖZELLİK	DEĞER
Görüntü boyutu	256x256
Çözünürlük	0.25
Dolgu	200
Görüntü derinliği	0.4
Yoğunluk	255
Hücre sayısı	3

PAPSMEAR görüntüleri sitoplazma, çekirdek, beyaz kan hücresi, basil ve benek nesnelere oluşmaktadır. Her bir nesnenin kendine özgü modelleme parametreleri bulunmaktadır. Çizelge 3.2’de veri kümesindeki görseller üretilirken kullanılan parametreler verilmektedir. Böylece üretilen görüntülerde belirli bir standardizasyon sağlanmıştır.


Çizelge 3.2: PAPSMEAR görüntü üretmede model parametreleri

Nesneler	Küme Sayısı	Örnek Sayısı	Küme Dağılımı	Derecelendirme	Transparanlık	Üst Üste Gelme
Sitoplazma	3	1	-	0,6-0,9	0.06	0.6
Çekirdek	3	1	-	1-1.1	0.21	0.3
Lökositler	5	3-5	50	-	0.15	-
Basil	2	5-10	30	-	0.7	-
Benek	100	1	-	-	0.25	-

Nesnelerin geometrik şekilleri kullanılarak maske görselleri elde edilmektedir. Daha sonra nesne maskeleri birleştirilerek genel görüntü maskesi üretilmektedir. Sonuç olarak, modelleme yaklaşımıyla üretilen örnek bir [PAPSMEAR-Maske] görüntü çifti Şekil 3.3 ve Şekil 3.4’te gösterilmektedir.



Şekil 3.3: Modelleme yaklaşımıyla üretilen görüntüler (a) PAPSMEAR, (b) Maske



Şekil 3.4: Modelleme yaklaşımıyla üretilen görüntüler PAPSMEAR, Maske



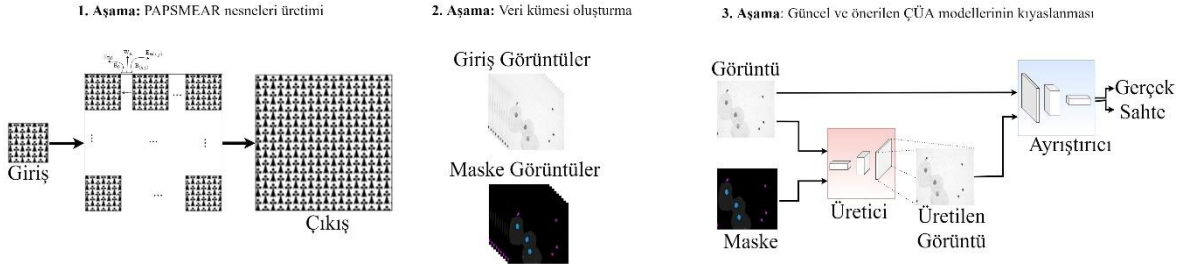
## 4. ÇEKİŞMELİ ÜRETKEN AĞLARLA PAPSMEAR GÖRÜNTÜSÜ OLUŞTURMADA YENİ YAKLAŞIMLAR

### 4.1. Sentetik Papsmea Görüntüsü Üretmede Çekişmeli Üretken Ağların Kullanılması

Otomatik bir şekilde PAPSMEAR görsellerinin tanısı ve tespiti için bilgisayar temelli yazılımlar rahim ağzı kanserinin varlığının teşhisi aktif bir çalışma alanıdır. Bunun nedeni görsellerinin kompleks bir yapıya sahip olmasıdır. PAPSMEAR görüntülerinin kompleks olmasının nedeni barındırdığı nesnelerin üst üste gelerek ya da çakışarak birbirlerinin boyutunu, geometrik yapısını ve yoğunluklarını değiştirmesinden kaynaklanır. Bu görüntüler hücre çekirdeği, sitoplazma, beyaz kan hücresi, bacil ve benek nesnelerini içermektedir. Aynı zamanda nesnelerin çok ve karmaşık olması büyük veri kümesi oluşturmadaki güçlük ve maliyetin fazla olması bu alanda ortak veri kümesinin meydana gelmesini engellemiştir. Değinen zorluklar, var olan sınıflandırma çalışmalarındaki sonuçları olumsuz etkilemektedir. Bu zorluklar yeni yaklaşım ve yöntemlere olan ihtiyacı tetiklemektedir.

Tezin bu bölümünde, PAPSMEAR sentetik veri kümesi oluşturulurken ÇÜA yöntemleri kullanılmıştır ve yeni bir ÇÜA mimarisi önerilmiştir. PAPSMEAR veri kümesi oluşturmak için üç aşamalı bir çalışma yapılmıştır. İlk aşamada PAPSMEAR görsellerinin içerdiği nesnelerin desen modelleri ve geometrik şekilleri oluşturulmaktadır. İkinci aşamada tekli şekilde oluşturulan nesnelere birleştirilerek istenilen sayıda ve dağılımda nesneyi içeren PAPSMEAR görselleri (Ground True) meydana getirilmektedir. Üçüncü aşamada ise literatürde bulunan ÇÜA'ların (Pix2Pix, CycleGAN, DiscoGAN ve AttentionGAN) sentetik PAPSMEAR görselleri oluşturma performansları değerlendirilmektedir. Son olarak çözüm odaklı yeni güncel bir ÇÜA mimarisi (Pix2PixSSIM) önerilmektedir. Önerilen yöntem kıyaslanan ÇÜA yöntemlerinin en iyi performansa sahip olan Pix2Pix yönteminin geliştirilmiş halidir. Yapılan deneysel çalışmalar, önerilen ÇÜA mimarisiyle hem kısa zamanda hem de daha iyi görsellerle büyük PAPSMEAR veri kümesinin üretilebildiğini ortaya koymaktadır. Bu sayede yüksek sınıflandırma başarısına sahip derin ağların eğitilebileceği görülmektedir.

Şekil 4.1'de tezin bu bölümünde sentetik PAPSMEAR görüntüsü üretmede çekişmeli üretken ağların kullanılırken genel aşamaları gösterilmiştir.



Şekil 4.1: PAPSMEAR görüntüsü oluşturulurken genel aşama

Tezin bu kısımdaki organizasyonu şu şekilde ilerlemektedir: Bölüm 4.1.1’de görüntü sentezleme mimarilerine (DiscoGAN, AttentionGAN ve Pix2PixSSIM (önerilen)); Bölüm 4.1.2’de kıyaslama yapılırken kullanılan ölçüm metriklerine (MSE, SSIM, PSNR); Bölüm 4.1.3’te deneysel çalışmalar ve sonuçlara yer verilmiştir.

#### 4.1.1. Görüntü sentezleme mimarileri

Bu kısımda, PAPSMEAR görüntülerinin sentezlenmesinde (sentetik olarak üretilmesinde) literatürdeki mevcut yaklaşımlardan Pix2Pix, CycleGAN, DiscoGAN ve AttentionGAN mimarileri kullanılmıştır. Pix2Pix yöntemine Bölüm 2.1.1.’de ve CycleGAN yöntemine ise Bölüm 2.1.2.’de yer verilmiştir. DiscoGAN ve AttentionGAN yöntemleri bu bölümde açıklanmıştır.

##### 4.1.1.1. DiscoGAN

CycleGAN mimarisine benzer olarak burada da iki farklı ÇÜA mimarisi ( $G_{XY}$  ve  $G_{YX}$ ) kullanılmaktadır.  $G_{XY}$  mimarisiyle,  $X$  giriş görüntüsünden  $Y$  çıkış görüntüsü elde edilirken,  $G_{YX}$  mimarisinde tersi işlem gerçekleşmektedir (Kim vd., 2017). Burada farklı olarak iki dögüsel tutarlılık maliyeti kullanılmaktadır ( $L_{CONST_X}, L_{CONST_Y}$ ).

CycleGAN’daki gibi  $X \rightarrow \hat{Y} \rightarrow \hat{X}$  ve  $Y \rightarrow \hat{X} \rightarrow \hat{Y}$  dönüşümleri yapılmakta ve iki dögüsel kayıp  $L_{CONST_X} = X - \hat{X}$  ve  $L_{CONST_Y} = Y - \hat{Y}$  minimize edilmektedir. Bu kayıplara, üretici ve ayrıştırıcı kayıpları da ilave edilmektedir (Denklem 4.1-4.3).

$$L_G = L_{G_{X \rightarrow Y}} + L_{G_{Y \rightarrow X}} = \underbrace{L_{GAN_Y} + L_{CONST_X}}_{L_{G_{X \rightarrow Y}}} + \underbrace{L_{GAN_X} + L_{CONST_Y}}_{L_{G_{Y \rightarrow X}}} \quad (4.1)$$

$$L_D = L_{D_X} + L_{D_Y} \quad (4.2)$$

$$\mathcal{L}_{DiscoGAN} = L_G + L_D \quad (4.3)$$

#### 4.1.1.2. AttentionGAN

CycleGAN ve DiscoGAN dan farkı, dikkat ağlarında ( $A_X, A_Y$ ) kullanmasıdır. Dikkat ağları renkli giriş görüntüsünü alıp iki seviyeli maske görüntülerini üretirler ve görüntü içerisinde odaklanması gereken bölgenin ön plana çıkmasını sağlarlar. Bu GAN mimarisinin toplam maliyet fonksiyonu Denklem 4.4'de gösterilmektedir (Mejjati vd., 2018):

$$\mathcal{L}(G_{X \rightarrow Y}, G_{Y \rightarrow X}, A_X, A_Y, D_X, D_Y) = \mathcal{L}_{GAN}^x + \mathcal{L}_{GAN}^y + \lambda_{cyc}(\mathcal{L}_{cyc}^x + \mathcal{L}_{cyc}^y) \quad (4.4)$$

$\mathcal{L}_{cyc}^x, \mathcal{L}_{cyc}^y$  döngüsel tutarlılık maliyetleridir.  $\lambda_{cyc} = 10$  genelde olarak kullanılır.  $\mathcal{L}$ 'nin optimal parametreleri, minimax optimizasyon problemi çözülerek elde edilir (bknz. Denklem 4.5) :

$$\begin{aligned} & G_{X \rightarrow Y}^*, G_{Y \rightarrow X}^*, A_X^*, A_Y^*, D_X^*, D_Y^* \\ &= \underset{G_{X \rightarrow Y}, G_{Y \rightarrow X}, A_X, A_Y}{\operatorname{argmin}} \left( \underset{D_X, D_Y}{\operatorname{argmax}} \mathcal{L}(G_{X \rightarrow Y}, G_{Y \rightarrow X}, A_X, A_Y, D_X, D_Y) \right) \end{aligned} \quad (4.5)$$

#### 4.1.1.3. Pix2PixSSIM (Önerilen)

Bu çalışmada yukarıda anlatılmış olan PAPSMEAR görüntü sentezlemede yeni bir yaklaşım önerilmiştir. Önerilen yaklaşım ÇÜA mimarilerinden ile performans ve sonuç analizi yapıp kıyaslanmıştır. Modelleme yaklaşımı (Malm vd., 2015) ile PAPSMEAR veri kümesi oluşturulmuş ve sonrasında günümüz güncel çalışma alanından Pix2Pix (Isola vd., 2017), CycleGAN (Zhu vd., 2017), DiscoGAN (Kim vd., 2017) ve AttentionGAN (Mejjati vd., 2018) ÇÜA mimarileri geliştirilerek hem zamansal hem de görsel olarak daha iyi sonuçlar sergileyen Pix2PixSSIM yöntemi önerilmiştir. Pix2PixSSIM yöntemi görüntü sentezlerken ayrıntıları daha net bir şekilde oluşturduğu deneysel olarak gözlemlenmiştir.

Önerilen yöntem, Pix2Pix mimarisinin güncellenmiş bir versiyonudur. Klasik Pix2Pix mimarisinin üretici maliyet fonksiyonunda düzgünleştirme terimi olarak  $L_1$



normalizasyon kullanılmaktadır. Bu durum, tahmin görseliyle Ground true görselindeki nesnelerin konumsal farklılıklarında yumuşatma etkisini arttırmaktadır. Böylece sitoplazma gibi şeffaf nesnelerin sınır hatlarında bulanıklaşmalar, kaybolmalar meydana gelmektedir. Bunun yerine uzaysal konum farklılığını göz ardı ederek, görüntü çiftleri arasındaki benzerliğin hesaplanmasında ortalama ve standart sapma gibi parametreler kullanan SSIM metriğinin kullanımı önerilmektedir. SSIM'e dayalı düzgünleştirme terimi Denklem 4.6'da ifade edilmektedir.

$$\mathcal{L}_{L\_SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (4.6)$$

Önerilen yöntemin üretici maliyet fonksiyonu Denklem 4.7'deki gibi güncellenerek PAPSMEAR görsel üretimi gerçekleştirilmiştir.

$$G^* = \underset{G}{\operatorname{argmin}} \underset{D}{\operatorname{max}} \mathcal{L}_{GAN}(G, D, X, Y) + \lambda \mathcal{L}_{L\_SSIM}(Y, G(X)) \quad (4.7)$$

## 4.1.2. Kullanılan ölçüm metrikleri

### 4.1.2.1. Ortalama karesel hata (MSE)

Mihelich ve diğerleri tarafından 2020 yılında önerdiği karşılaştırma metriğidir. Karşılaştırma yaparken giriş verisi ile çıkış verisi arasındaki benzerliği hesaplamak için noktasal farkın karesel ortalamasını almaktadır. Denklem 4.8'de MSE yönteminin genel formülüne yer verilmiştir.

$$L_2 = MSE(x, \hat{x}) = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (4.8)$$

Denklem de gerçek görüntü  $x$  ve  $x$  görüntüne benzeyen yapay  $\hat{x}$  görüntüsünün denk gelen her bir piksel farkının karesi alınıp toplanır ve sonuç görüntülerde bulunan toplam piksel sayısına ( $n$ ) bölünür. MSE sonucunun düşük olması iki görüntü arasındaki benzerliğin yüksek olduğunu göstermektedir.

#### 4.1.2.2. Yapısal benzerlik metriği (SSIM)

Nilsson ve Akenine tarafından 2020 yılında önerilen karşılaştırma metriğidir. Yapısal benzerlik metriği (SSIM), iki görüntü arasındaki benzerliği hesaplarken pikseller arasındaki konum farklılığı yerine ortalama ( $\mu$ ) ve standart sapma ( $\sigma$ ) kullanarak hesaplama yapan bir ölçümdür (Nilsson ve Akenine, 2020). Sadece maskeleye, parlaklık ve kontrast gibi algısal özellikleri değil aynı zamanda görüntüde algılanan değişikliği de analiz etmektedir. Gerçek görüntü  $x$  ve sahte görüntü  $\hat{x}$  arasındaki SSIM benzerlik hesaplanması Denklem 4.9'da verilmiştir.

$$SSIM(x, \hat{x}) = \frac{(2\mu_x\mu_{\hat{x}} + c_1)(2\sigma_{x\hat{x}} + c_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + c_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + c_2)} \quad (4.9)$$

Burada,  $\mu_x$  ve  $\mu_{\hat{x}}$  sırasıyla gerçek ve sahte görüntünün piksel ortalamasını;  $\sigma_x^2$  ve  $\sigma_{\hat{x}}^2$  görüntüler arasındaki varyansı belirtir.  $\sigma_{x\hat{x}}$  iki görüntü arasındaki kovaryansı belirtmektedir.  $c_1 = (k_1L)^2$  ve  $c_2 = (k_2L)^2$  değerleri sabitlerdir ve piksel aralığını belirten  $L$  değeri 255 alınarak hesaplanmaktadır.

#### 4.1.2.3. Pik Sinyal Gürültü Oranı (PSNR)


Fardo ve diğerleri tarafından 2016 yılında önerilen görüntü çiftleri arasındaki benzerliği logaritmik olarak hesaplayan metriktir. Sinyal veri ya da gerçek görüntü olarak kabul edilmektedir. Gürültü ise verideki bozulmadan ya da sıkıştırılmadan kaynaklanan hatadır. İki görüntü veya iki sinyal arasındaki PSNR oranı desibel olarak hesaplanır. Denklem 4.10'da PSNR yönteminin genel formülüne yer verilmiştir.

$$PSNR(x, \hat{x}) = 10 * \log_{10} \left( \frac{MAX_x^2}{MSE(x, \hat{x})} \right) \quad (4.10)$$

Buradaki  $x$  gerçek ve  $\hat{x}$  yapay görüntüsü arasındaki ölçüm için  $MSE$  değeri kullanılmaktadır. Aynı zamanda  $MAX_x^2$  gerçek görüntüdeki en büyük piksel değeri de hesaplama dahilidir. PSNR metriği sonucunun yüksek çıkması sinyal kalitesinin iyi olduğu anlamına gelmektedir. Diğer bir deyişle yapay ve gerçek veri arasındaki maliyet düşük olduğu anlamını taşımaktadır.

### 4.1.3. Deneysel çalışmalar ve sonuçları

#### 4.1.3.1. Çalışma 1: Metodların performans incelemesi



Şekil 4.2: Sentezleme yaklaşımlarının PAPSMEAR görseli üretme sonuçları

İlk deneysel çalışmada; Pix2Pix, CycleGAN, DiscoGAN ve AttentionGAN yaklaşımlarının veri kümesindeki Maske görsellerinden PAPSMEAR görsellerini (MathModel-GroundTruth) üretme başarımları incelenmektedir. Bunun için veri kümesindeki 450 adet görüntü çifti eğitim faaliyetlerinde kullanılırken, test için 50 çift ayrılmıştır. Her bir mimari 150 iterasyon boyunca eğilmiştir. Mimari eğitimleri tamamlandıktan sonra farklı test maskeleri kullanılarak görüntü üretimi gerçekleştirilmiştir. Şekil 4.2’de altı farklı maske görseline karşılık mimariler tarafından üretilen sentetik PAPSMEAR görüntüleri gösterilmektedir.

Sentezleme yaklaşımlarıyla üretilen görsellerin Ground-True (GT)'ya hangi oranda benzediğini belirleyebilmek için üç farklı değerlendirme metriği (MSE, SSIM ve PSNR) kullanılmıştır. Çizelge 4.1'de her bir yöntemin 50 adet test görseli üzerindeki ortalama benzerlik değerleri gösterilmektedir. Ayrıca çizelgenin son sütununda, yöntemlerin bir adet görseli üretmek için harcadıkları ortalama süre verilmektedir.

**Çizelge 4.1:** ÇÜA Yöntemlerinin MSE, SSIM ve PSNR'ye göre sonuçları

Yöntemler	Benzerlik			Zaman (sn)
	MSE↓	SSIM↑	PSNR↑	Bir görüntü için
Pix2Pix (Isola vd., 2017)	<b>30.750</b>	<b>0.902</b>	<b>37.222</b>	<b>0.022</b>
CycleGAN (Zhu vd., 2017)	106.464	0.852	29.526	0.024
DiscoGAN (Kim vd., 2017)	544.066	0.850	34.005	0.848
AttentionGAN (Mejjati vd., 2018)	634.137	0.865	31.498	0.865
MathModel (Malm vd., 2015)	0	1		107.486

Çizelge 4.1'deki sonuçlar incelendiğinde, denetimli model olan Pix2Pix yönteminin, denetimsiz yöntemlere (CycleGAN, DiscoGAN, AttentionGAN) göre daha kaliteli görseller ürettiği görülmektedir. PAPSMEAR görüntülerindeki bağımsız nesne sayısının fazla olması ve sitoplazma gibi kısımların üst üste gelmesi gibi olumsuzluklar denetimsiz yöntemlerin başarımını düşürmüştür.


Üretim süresi olarak bakıldığında, MathModel'in oldukça yavaş çalıştığı görülmektedir. Bunun nedeni, görüntüdeki her bir nesnenin geometrik şekli, yüzey deseni ve üzerindeki gürültü değerleri sırayla matematiksel olarak üretilmekte ve daha sonra nesnel derinliklerine göre birleştirilmektedir. DiscoGAN ve AttentionGAN yöntemlerinin Pix2Pix ve CycleGAN'a göre yaklaşık 40 kat yavaş çalıştığı görülmektedir. Bunun nedeni, bu yöntemlerde çift yönlü iki farklı ÇÜA mimarisinin eğitilmesidir. Hiperparametre sayısının iki katına çıktığı bu durumda eğitim zamanının eksponansiyel bir şekilde arttığı görülmüştür.

#### 4.1.3.2. Çalışma 2: Önerilen yöntemin analizi

Bir sonraki deneysel çalışmada, ilk deneyde en iyi sonucu üreten Pix2Pix mimarisine odaklanılmakta ve ince ayarlama işlemleri yapılarak Pix2PixSSIM yöntemiyle karşılaştırılmaktadır. Buna göre, GT ve tahmini üretilen görseller içerisindeki nesnelere

(hücre, sitoplazma, ... ) uzaysal konumları farklılaştıkça maliyet değerinin yükselmesi söz konusudur.

Pix2PixSSIM yönteminde Pix2Pix üzerinden yapılan maliyet fonksiyonunda yapılan güncelleştirmenin etkisi Şekil 4.3’de net bir şekilde gösterilmektedir.



**Şekil 4.3:** PAPSMEAR veri kümesi çıktıları. (Sütunsal sırasıyla GT, GT (zoom), Pix2Pix (zoom), Önerilen Yöntem (zoom) )

Pix2Pix sonucuyla kıyaslandığında önerilen yöntemin nesne kenarlarındaki sınır hatlarını daha belirgin ve düzgün tespit edebildiği görülmektedir. Çizelge 4.2’de önerilen yöntemle ve Pix2Pix sonuçlarının GT’ye benzerliği ve çalışma zamanı sonuçları gösterilmektedir. Önerilen yaklaşımın ek bir maliyet getirmeden benzerlik metriklerinde iyileşme sağladığı açık bir şekilde görülmektedir. Bunun nedeni SSIM benzerlik metriğinin nesne konumlarını önemsemeyişi ve konumsal bağımsızlık sağlaması olarak değerlendirilmektedir. Ayrıca görüntü parlaklık değerlerinden sadece iki parametre ( $\mu$ ,  $\sigma$ ) üretildiği için oldukça hızlı çalıştığı görülmektedir. Zaman karşılaştırması yapıldığında iz miktarda fark olduğu gözükmemektedir.

**Çizelge 4.2:** Pix2Pix ve Pix2PixSSIM yöntemlerinin benzerlik metriği sonuçları

Yöntemler	Benzerlik			Zaman (sn.)
	MSE↓	SSIM↑	PSNR↑	Bir görüntü için
Pix2Pix (Isola vd., 2017)	30.750	0.902	37.222	0.022
Pix2PixSSIM	<b>23.649</b>	<b>0.952</b>	<b>37.476</b>	0.021

PAPSMEAR görsellerinde bulunan hücre çekirdeği ve sitoplazma gibi yapıların üst üste gelmesiyle geometrik yapılarda oluşan farklılaşmalar nesnelerin algılanmasını zorlaştırmaktadır. Ayrıca etiketlenmiş büyük veri kümesinin olmaması, ESA tabanlı yapay öğrenme mimarilerinin gelişmesini engellemiştir.

Bu çalışmada, histopatolojik PAPSMEAR görsellerini otomatik sentezleyen Çekişmeli Üretici Ağ tabanlı bir yaklaşım önerilmiştir. Önerilen yaklaşım ile görsellerdeki her bir nesnenin şekil ve desen bilgilerini görüntü işleme teknikleriyle modellemekte, üretilen modeller kullanılarak büyük bir PAPSMEAR veri kümesi oluşturmakta ve son olarak önerilen yeni bir Çekişmeli Ağ mimarisiyle (Pix2PixSSIM) veri kümesindeki görsellere benzer görüntüler üretilmektedir.

Önerilen ÇÜA mimarisinin gerçek PAPSMEAR görsellerine benzer görüntüleri üretme performansının mevcut yaklaşımlarla kıyaslandığında (MathModel ve klasik görüntü sentezleme yöntemleri) başarılı sonuçlar verdiği (MSI=23.649; PSNR=37.476) görülmektedir. Ayrıca bu başarıyı sağlarken eğitim sürecinde zaman olarak bir artışın söz konusu olmadığı görülmüştür.

#### **4.2. Algısal Benzerlik Maliyeti Tabanlı Çekişmeli Üretici Ağ Mimarisi ile Görüntü Üretimi**

Görüntü sentezleme farklı özellikteki görseller arasındaki dönüşüm işlemidir. Günümüzde ÇÜA mimarileri ve Evrişimsel Sinir Ağları (ESA (Lecun vd., 1998)) görüntü sentezleme işlemi yapılırken yaygın bir şekilde kullanılmaktadır.

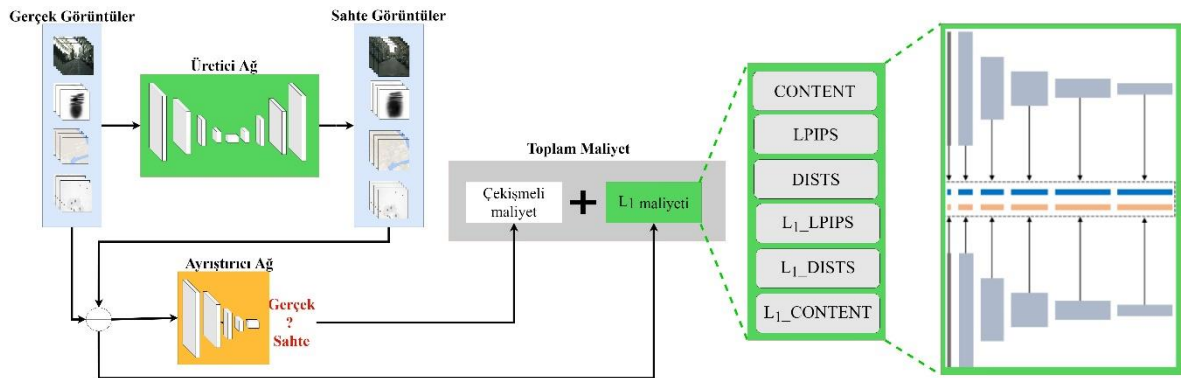
Tezin bu kısmında sentezlenen görüntülerin iyileştirilmesi ve genel ÇÜA mimarilerinde kullanabilmek üzere en uygun maliyet fonksiyonunun bulunması

amaçlanmıştır. Uygun maliyet fonksiyonu bulunması için sabit bir ÇÜA mimarisi tercih edilmiştir. Kullanılan ÇÜA mimarisi Pix2Pix'dir. Maliyet fonksiyonu olarak Pix2Pix yöntemi maliyet fonksiyonu olarak ortalama mutlak hata (MAE) yani  $L_1$  metriğini kullanmaktadır.

Bu bölümde ESA tabanlı CONTENT (Gatys vd., 2015), LPIPS (Zhang vd., 2018) ve DISTSTS (Ding vd., 2020) maliyet fonksiyonları kullanılmıştır. ESA tabanlı yöntemlere ek olarak  $L_1$  maliyeti birleştirilmiş ve yeni maliyet fonksiyonları elde edilmiştir. Oluşturulan yeni maliyet fonksiyonları L1\_CONTENT, L1\_LPIPS ve L1\_DISTSTS şeklinde isimlendirilmiştir. İfade edilen maliyet fonksiyonlarının görsel ve metrik sonuçlarına yer verilmiştir.

Veri kümesi olarak PAPSMEAR görselleri kullanılmıştır. Sonuçlar analiz edilirken güncel ve klasik ölçüm metriklerinden yararlanılmıştır. FID (Heusel vd., 2017) ve KID (Bińkowski vd., 2018) kullanılan güncel ölçüm metrikleridir. (FSIM (Zhang vd., 2011), HaarPSI (Reisenhofer vd., 2018), MS\_SSIM (Wang vd., 2003), PSNR, SSIM, VIFp (Sheikh ve Boyik, 2006) ve VSI (Zhang vd., 2014) ise klasik ölçüm metrikleridir.

Şekil 4.4'te algısal benzerlik maliyeti tabanlı çüa ile görüntü üretiminin şematik gösterimine yer verilmiştir.



**Şekil 4.4:** Algısal Benzerlik Maliyeti Tabanlı ÇÜA ile Görüntü Üretiminin Şematik Gösterimi

Tezin bu kısımdaki organizasyonu şu şekilde ilerlemektedir: Bölüm 4.2.1'de ESA tabanlı görüntü kıyaslama kriterlerine (LPIPS, DISTSTS, CONTENT ve  $L_1$  ile kullanımları);

Bölüm 4.2.2’de kıyaslama yapılırken kullanılan görüntü karşılaştırma metriklerine; Bölüm 4.2.3’te ise deneysel çalışmalar ve sonuçlara yer verilmiştir.


#### 4.2.1. Evrişimsel Sinir Ağı tabanlı görüntü kıyaslama kriterleri

Literatürde ESA mimari yapısını kullanan ve iki görüntü arasındaki benzerlik değeri bulunurken eğitim yapan LPIPS, DISTS ve CONTENT yapıları mevcuttur.

LPIPS ve DISTS yöntemleri birbirlerine benzemektedir. Ancak yorumlanabilirliğin eksik olması yüksek hesaplama modellerine uyarlanabilirliğini düşürebilmektedir (Ding vd., 2021).

##### 4.2.1.1. LPIPS

LPIPS yöntemi, 2018 yılında iki görüntü arasındaki benzerliği hesaplamak için Zhang ve diğerleri tarafından önerilen güncel metriklerdendir (Zhang vd., 2018). Şekil 4.5’te LPIPS fonksiyonunun görsel olarak hesaplanma şekline yer verilmiştir.



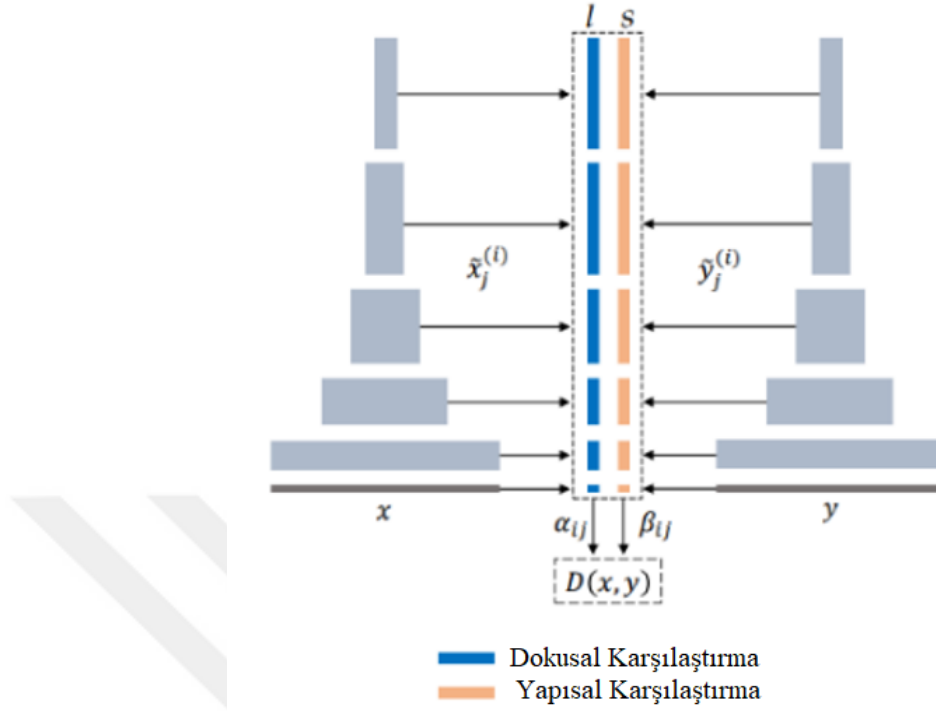
Şekil 4.5: LPIPS Fonksiyonu Şematik Gösterim. (Zhang vd., 2018).

Şekil 4.5(Sol) İki görüntü parçası arasındaki uzaklık, Şekil 4.5 (Sağ) İki uzaklık değerlerden  $h$  algısal kararını tahmin etmek için yapılan küçük bir ağı eğitimi Burada,  $x$  gerçek görüntü,  $x_0$  ise  $x$  gerçek görüntüsünden oluşturmuş sahte görüntüdür.  $x$  ve  $x_0$  görüntüsü VGG’ye dayanan ve  $F$  olarak adlandırılan ESA ağı ile eğitilir.  $F$  ağındaki aynı dereceye sahip olan katman sonuçları (aktivasyonlar) nomalleştirilir (görüntüdeki ‘Normalize’) ve birbirinden çıkarılarak (görüntüdeki ‘Subtract’) yeni bir çıktı elde edilir. Çıktılar derecelendirilten sonra tek bir vektörel biçime ( $w$ ) çevrilip vektör normu ( $L_2$  norm) hesaplanır. Sonuç olarak  $d$  uzaklığı elde edilir (Zhang vd., 2018).

##### 4.2.1.2. DISTS

DISTS yöntemi, 2020 yılında iki görüntünün benzerliğini hesaplamada kullanılmak üzere Ding ve diğerleri tarafından önerilmiştir (Ding vd., 2020). Şekil 4.6’te görüntüler arasındaki benzerliğin DISTS yöntemi ile hesaplanmasına yer verilmiştir.





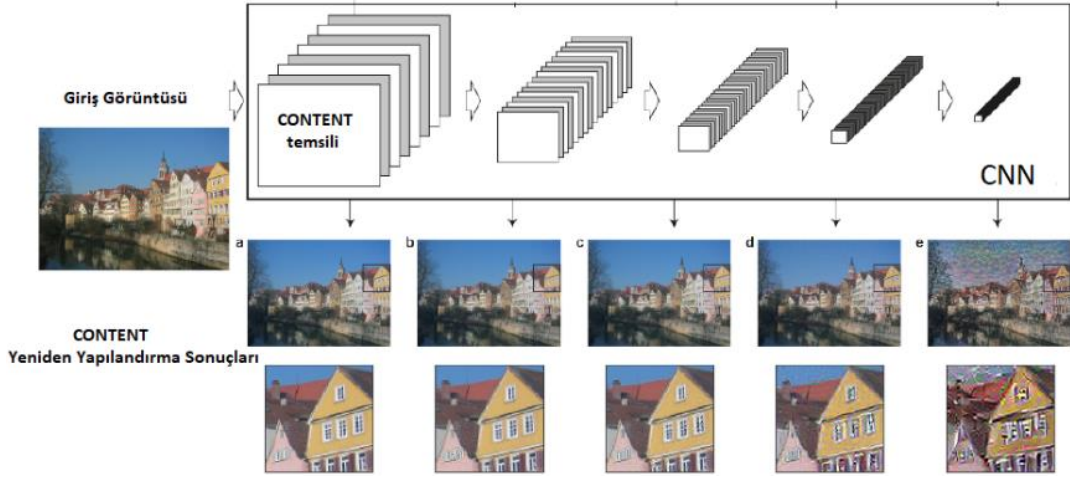
Şekil 4.6: DISTS fonksiyonu (Ding vd., 2020)

Burada  $x$  gerçek görüntü,  $y$  sahte görüntüdür. DISTS fonksiyonu dokusal ve yapısal benzerliği birleştirmektedir. Dokusal görsellerde performansının iyi olduğu gözlenmiştir. Geometrik bozulmalara karşı dirençli olduğu nadirdir.

#### 4.2.1.3. CONTENT

CONTENT yöntemi, 2015 yılında Gatys ve diğerleri tarafından önerilmiştir. Bu yöntem, VGG ağındaki evrişimli katmanların herbirinden gerçek görüntüyü geçirir ve çıktı olarak sentetik görüntü oluşturur (Gatys vd., 2015). CONTENT yöntemi, ESA'ya dayanan diğer yöntemlerden görüntünün stilini ve içeriğini birbirinden ayırt etmede kullanılma yönünden farklılık oluşturmaktadır.

Şekil 4.7'de CONTENT yönteminin çalışmasına dair bir örnek gösterilmiştir.



Şekil 4.7: CONTENT yöntemi örneği (Gatys vd., 2015).

#### 4.2.1.4. Ölçütlerin $L_1$ ile kullanımı

Bu bölümde Pix2Pix yöntemindeki  $L_1$  maliyetine güncel yöntemlerden olan  $\{LPIPS, DISTS, CONTENT\}$  yöntemleri eklenerek yeni maliyet fonksiyonu oluşturmak istenmiştir. Yeni maliyet fonksiyonu oluşturulurken %50 oranda  $\{LPIPS, DISTS, CONTENT\}$  ve %50 oranda  $L_1$  kullanılmıştır.

Şekil 4.1’de Pix2Pix yöntemindeki maliyet fonksiyonu üzerinden yapılan değişiklik gösterilmektedir.

$$\mathcal{L}_{G,D} = \arg \min_G \max_D \mathcal{L}_{CGAN}(G, D) + \lambda * \mathcal{L}_{\{LPIPS, DISTS, CONTENT\}}(x, \hat{x}) \quad (4.1)$$

Burada, Pix2Pix formülünde genel olarak kullanılan  $L_1$  maliyetinden farklı olarak  $\mathcal{L}_{\{LPIPS, DISTS, CONTENT\}}(x, \hat{x})$  maliyeti eklenmiştir.

Denklem 4.2’de oluşturulan genel amaç fonksiyonuna yer verilmiştir.

$$\mathcal{L}_{G,D} = \arg \min_G \max_D \mathcal{L}_{CGAN}(G, D) + \lambda * \{0.5 * L_1(x, \hat{x}) + 0.5 * \mathcal{L}_{\{LPIPS, DISTS, CONTENT\}}(x, \hat{x})\} \quad (4.2)$$

Burada, maliyet olarak  $L_1$  maliyeti ile ESA yöntemlerinin (LPIPS, DISTS, CONTENT) ortak kullanımına yer verilmiştir.

## 4.2.2. Görüntü karşılaştırma metrikleri

Görüntüler karşılaştırılırken klasik ve güncel görüntü karşılaştırma metrikleri kullanılmıştır.

### 4.2.2.1. Klasik görüntü karşılaştırma metrikleri

Klasik görüntü karşılaştırma metriği olarak Özellik Tabanlı Benzerlik İndeksi Ölçümü (FSIM), Haar dalgacık tabanlı algısal benzerlik indeksi (HaarPSI), Yapısal benzerlik ölçütü (SSIM), Çok Ölçekli SSIM (MSSIM), Pik Sinyal Gürültü Oranı (PSNR), Görsel bilgi doğruluğu (VIF), Görsel Belirginliğe Bağlı İndeks (VSI) yöntemleri kullanılmıştır.

FSIM, iki görüntü arasındaki faz benzerliğini ve gradyan büyüklüğünü kıyaslamaktadır (Zhang vd., 2011). HaarPSI, görüntülerin parçalarından elde edilen yerel dalgacık kat sayılarını kullanarak görüntüler arasında kıyaslama işlemi yapmaktadır. SSIM, görüntüler arasındaki benzerliği hesaplamada ortalamayı ( $\mu$ ) ve standart sapma ( $\sigma$ ) kullanarak istatistiksel hesaplama yapmaktadır (Nilsson ve Akenine, 2006). MSSIM, SSIM yönteminden elde edilen çıktıları farklı çözünürlük seviyesinde alarak birleştirmektedir (Wang vd., 2003). PSNR, Görüntü kalitesini ölçen ve sıklıkla kullanılan ölçüm metriklerindedir. VIF, bozulma (kanal) modeli ile gerçekçi istatistiksel modelleri (NSS) birlikte kullanarak görüntülerdeki benzerliği ölçmektedir (Sheikh ve Bovik, 2006). VSI, görüntüdeki yerel bozulmaları ağırlıklandırırken yerel bir belirginlik haritası kullanmaktadır (Zhang vd., 2014).

### 4.2.2.2. Güncel görüntü kıyaslama metrikleri

Güncel görüntü kıyaslama metrikleri olarak Fréchet başlangıç mesafesi (FID) ve Kernel başlangıç mesafesi (KID) kullanılmıştır.

FID yöntemi gerçek girdi görüntü ile çekişmeli üretken ağlar sonucu çıkan sentetik görüntülerin benzerliklerini ölçmede kullanılan metriktir. Gerçek görüntü ile sentetik görüntü arasında benzerlik kıyaslaması yaparken olasılıksal dağılımlardan faydalanmaktadır (Heusel vd., 2017). KID yöntemi, FID yöntemi gibi çekişmeli üretken ağlarda benzerlik ölçmede sıklıkla kullanılmaktadır. Benzerlik kıyaslaması yaparken karesel Maksimum Ortalama Tutarsızlık kullanılmaktadır. FID metriğine göre yapısında ReLU aktivasyon fonksiyonu içerdiğinden avantajlıdır (Bińkowski vd., 2018).

### 4.2.3. Deneysel çalışmalar ve sonuçları

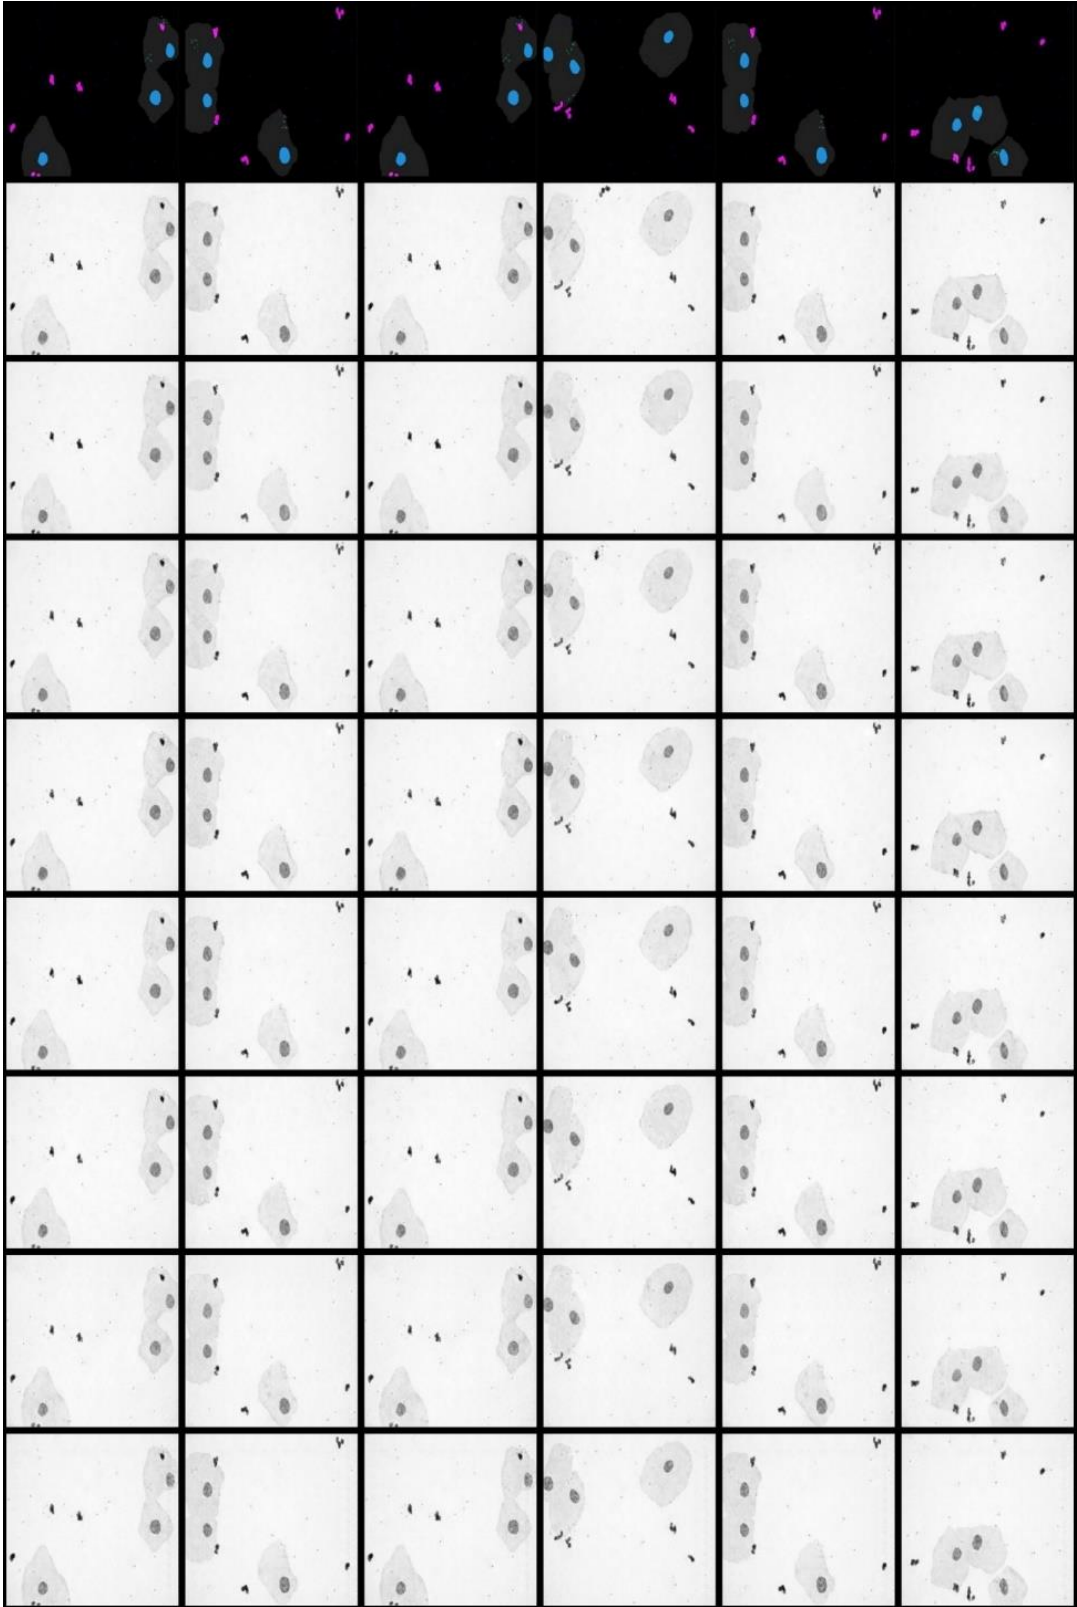
Maliyet fonksiyonlarının etkisini anlamak için ÇÜA temelli Pix2Pix yöntemi üzerinde PAPSMEAR veri kümesi üzerinde çalışılmıştır. PAPSMEAR veri kümesi medikal görüntüleri barındırmaktadır. PAPSMEAR veri kümesindeki görüntülerde bulunan nesnelerin (çekirdek, sitoplazma vb.) birbirine bağlı şekilde bölümlenmesinden dolayı çoğu veri kümesinden farklılaşmaktadır. PAPSMEAR veri kümesinin detaylı bilgilerine Bölüm 3'te yer verilmiştir. Önerilen görüntü sentezleme yöntemleri değerlendirilmektedir. Uygulanan farklı maliyetlerin Pix2Pix üzerindeki ve çekişmeli üretken ağılardaki etkisini görmek için Şekil 4.8'de medikal PAPSMEAR veri kümesi üzerindeki etkisi gözlemlenmiştir. Çizelge 4.5'te ise klasik (FSIM, MS\_SSIM, SSIM, VIFp, HaarPSI, PSNR) ve güncel benzerlik metrikleri (FID, KID) sonuçlarına bakılarak nicel bir karşılaştırma yapılmıştır.

Sonuç olarak medikal PAPSMEAR veri kümesi için CONTENT, L1-LPIPS ve LPIPS fonksiyonlarının diğer ölçütlere kıyasen tatmin edici düzeyde doğruluk sağladığı görülmüştür. Maliyet ölçümü olarak CONTENT, L1-LPIPS ve LPIPS fonksiyonlarının ÇÜA mimarilerinde kullanılabileceği gözlemlenmiştir.

PAPSMEAR gibi karmaşıklık düzeyi daha az olan LPIPS fonksiyonunun diğer yöntemlerle kıyaslandığında daha iyi sonuçlar verdiği görülmektedir. Bu fonksiyonlarının görüntü sentezleme mimarilerinde kullanılmasının sentezleme doğruluğunu pozitif yönde etkilediği söylenebilir.

Çizelge 4.3: Görüntü sentezleme doğrulukları

		Benzerlik Ölçütleri								
		Klasik							Güncel	
	FONKSİYONLAR	FSIM↑	HaarPSI↑	MS_SSIM↑	PSNR↑	SSIM↑	VIFp↑	VSI↑	FID↓	KID↓
PAPSMEAR	L <sub>1</sub>	0.832	0.581	0.917	20.851	0.874	0.121	0.886	72.362	0.036
	LPIPS	<u>0.841</u>	0.576	<u>0.922</u>	20.826	<u>0.877</u>	<u>0.144</u>	0.886	<b>39.471</b>	<b>0.002</b>
	L <sub>1</sub> -LPIPS	<b>0.840</b>	<u>0.592</u>	<b>0.924</b>	20.855	<b>0.879</b>	<b>0.148</b>	0.887	47.919	0.013
	DISTS	0.832	0.589	0.913	20.835	0.869	0.110	0.886	<u>45.807</u>	0.009
	L <sub>1</sub> -DISTS	0.831	<b>0.601</b>	0.912	20.851	0.868	0.110	<u>0.888</u>	46.578	<u>0.003</u>
	CONTENT	0.824	0.568	0.910	<b>20.907</b>	0.863	0.107	<b>0.891</b>	75.947	0.041
	L <sub>1</sub> -CONTENT	0.818	0.581	0.911	<u>20.880</u>	0.858	0.102	0.886	82.476	0.049



Şekil 4.8: PAPSMEAR veri kümesi çıktıları. Satırlar: Girdi, Çıktı, L1, LPIPS, L1-LPIPS, DISTS, L1-DISTS, CONTENT, L1-CONTENT

## 5. KONTRASTLI ÖĞRENME TABANLI ÇEKİŞMELİ ÜRETKEN AĞLAR İLE PAPSMEAR GÖRÜNTÜ BÖLÜTLEME

Tezin bu bölümünde, PAPSMEAR görüntü bölütlemeye güncel ÇÜA mimarileri ve karşılaştırmalı öğrenme yöntemleri kıyaslanmıştır.

CUT (Contrastive Unpaired Translation) yöntemi Park ve diğerleri tarafından 2020 yılında parçacık tabanlı öğrenme olarak önerildi. Bu yöntem, denetimsiz görüntüden görüntüye dönüşüm için karşılaştırmalı öğrenmeyi kullanmayı daha faydalı hale getirerek, yeni karşılaştırmalı öğrenme tekniğidir. DCLGAN (Dual Contrastive Learning for Unsupervised Image-to-Image Translation) yöntemi, CUT yöntemindeki mod çökmesini verimli şekilde gidermektedir. Bu yöntemde hem denetimsiz hem de denetimli yöntemler arasındaki boşluğun verimli bir şekilde kapatılabileceği gösterilmiştir. DCLGAN, denetimsiz dönüşüm yapan CycleGAN yöntemi ile CUT yönteminin birleştirilmesiyle oluşturulan yeni bir yaklaşımdır.

ÇÜA mimarilerinden CycleGAN (Zhu vd., 2017), DCLGAN (Han vd., 2021) ve SimDCL (Han vd., 2021) yöntemleri uygulanıp incelenmiştir. Karşılaştırmalı öğrenme yöntemlerinden ise görüntülerin parçalarını karşılaştırarak sonuca giden parça tabanlı karşılaştırma (CUT) yöntemi (Park vd., 2020) ile CUT yönteminin daha hızlı çalışmasını sağlayan FastCUT yöntemi ile çalışılmıştır. Yapılan metrikse karşılaştırmalar sonucu en son çıkan DCLGAN yöntemi bölütleme yapılırken diğer yöntemlere göre daha üstün sonuçlar elde ettiği gözlemlenmiştir.

Tezin bu bölümdeki organizasyonu şu şekilde ilerlemektedir: Bölüm 5.1’de görüntü sentezleme mimarilerine (CUT, FastCUT, DCLGAN ve SimDCL); Bölüm 5.2’de eğitim detaylarına; Bölüm 5.3’te kullanılan veri kümesi hakkında kapsamlı bilgiye ve Bölüm 5.4’te ise deneysel çalışmalar ve sonuçlarına yer verilmiştir.

### 5.1. Görüntü Sentezleme Mimarileri

Bu çalışmada bölütleme mimarileri olarak CycleGAN (Zhu vd., 2017), CUT (Park vd., 2020) ve FastCUT (Park vd., 2020), DCLGAN (Han vd., 2021), SimDCL (Han vd., 2021) ve yeni mimari kullanılmıştır ve geniş bir şekilde açıklanmıştır. CycleGAN yöntemine 2.1.2.’de yer verilmiştir.

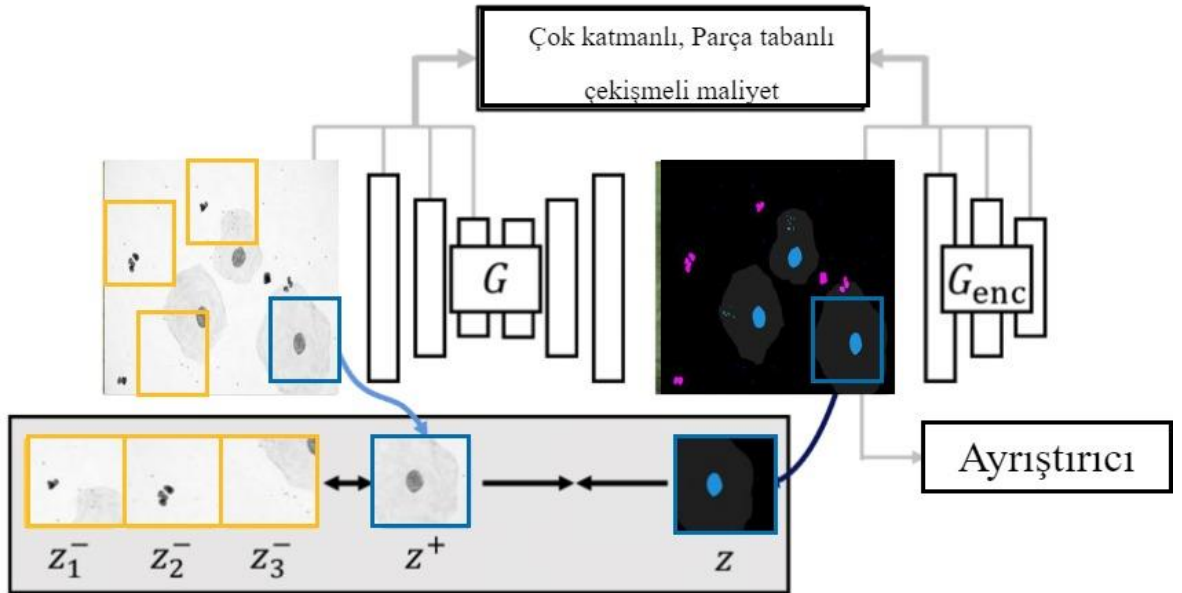
### 5.1.1. CUT ve FastCUT

Bu yaklaşım giriş ve çıkış görsellerindeki görüntü parçalarının eşleştirilmesine dayalı bir mimari (PatchNCE) eğitimi içermektedir. Şekil 3'te kullanılan mimari ve yapılan bu eşleştirme işlemi gösterilmektedir. Buna göre, giriş görüntüsünden  $N$  adet parça alınmakta ve  $G_{enc}$  yardımıyla özniteliklerine dönüştürülmektedir. Bu alınan parçalardan sadece 1 tanesiyle aynı konumda çıkış görüntüsünden parça alınmakta ve benzer şekilde vektörleştirilmektedir. Daha sonra vektörler arasındaki benzerlik değerlerine göre sınıflandırma yapılmaktadır.

Parça tabanlı maliyet  $\mathcal{L}_{PatchNCE}(G, H, X)$  olarak gösterilmektedir.  $G$  üretken ağ,  $H$  özellik vektörünün gömüldüğü kısım,  $X$  ise alanı ifade etmektedir. Buna göre CUT yönteminin amaç fonksiyonu Denklem 5.1'deki gibi oluşmaktadır:

$$\begin{aligned} G^*, H^* &= \underset{G, H, D}{\operatorname{argminmax}} \mathcal{L}(G, H, D, X, Y) \\ &= \mathcal{L}_{GAN}(G, D, X, Y) + \lambda_X \mathcal{L}_{PatchNCE}(G, H, X) + \lambda_Y \mathcal{L}_{PatchNCE}(G, H, Y) \end{aligned} \quad (5.1)$$

Şekil 5.1'de, CUT yönteminin mimarisine ve görüntüdeki parça tabanlı kaybına da yer verilmiştir.



Şekil 5.1: CUT yönteminin genel mimarisi

### 5.1.2. DCLGAN ve SimDCL

DCLGAN (Han vd., 2021), iki ayrı gömülü sistem kullanarak girdi ve çıktı görüntü parçaları arasındaki özellik çıkarımını arttırarak karşılıklı bilgiyi en üst seviyeye çıkarmayı amaçlar. İkili öğrenme eğitimi stabilize etmeye yardımcı olur. Karşılıklı öğrenmedeki bazı tasarım seçeneklerini yeniden gözden geçirilmiştir. Buradaki PatchNCE kaybında küçük parçaları temsil eden RGB pikselleri kaldırılmış ve daha iyi sonuçlar elde edilmiştir. Döngü tutarlılığının gereksiz olduğu gösterilmiştir. SimDCL (Han vd., 2021) ise DCLGAN'ın varyantıdır ve mod çökmesini önemli ölçüde önler.

DCLGAN kayıp olarak tartışmalı (Adversarial) kayıp, özdeşlik (Identity) kayıp ve CUT yönteminde de kullanılan parçalı gürültü karşılaştırmalı tahminleme (PatchNCE) kaybını kullanır. SimDCL bu kayıplara ek olarak benzerlik kaybını ( $\mathcal{L}_{sim}$ ) de mod çökmesini engellemek için kullanır.

Eşitlik 5.2'de DCLGAN'nın temel formülüne yer verilmiştir.

$$\begin{aligned}
 G^*, F^* &= \underset{G, F, D_X, D_Y}{\operatorname{argmin}} \max \mathcal{L}(G, F, D_X, D_Y, H_X, H_Y) \\
 &= \lambda_{GAN} \left( \mathcal{L}_{GAN}^G(G, D_Y, X, Y) + \mathcal{L}_{GAN}^F(F, D_X, Y, X) \right) \\
 &+ \lambda_{NCE} \left( \mathcal{L}_{PatchNCE_X}(G, H_X, H_Y, X) + \mathcal{L}_{PatchNCE_Y}(F, H_X, H_Y, Y) \right) \\
 &+ \lambda_{idt}(\mathcal{L}_{identity}(G, F))
 \end{aligned} \tag{5.2}$$

Burada  $\lambda_{GAN} = 1$ ,  $\lambda_{NCE} = 2$  ve  $\lambda_{idt} = 1$  olarak alınmıştır.

DCLGAN'ın amaç fonksiyonuna benzerlik kaybı eklenmiştir ve SimDCL olarak adlandırılmıştır. Burada sim; benzerlik kaybı ve DCL; ikili karşılaştırmalı öğrenme anlamına gelmektedir. SimDCL bu kayıplara ek olarak benzerlik kaybını ( $\mathcal{L}_{sim}$ ) de mod çökmesini engellemek için kullanır.

**Sim loss.** Sezgisel olarak, aynı etki alanındaki görüntülerin bazı benzerlikleri vardır. Bu görüntüler anlamsal olarak farklı olsa da ortak stili paylaşırlar. İkili öğrenme yapılırken aynı alana ait bir gerçek ve bir sahte görüntü vardır.  $X$  ve  $Y$  olmak üzere iki alan mevcuttur. Yani kısacası mimari toplamda iki tane gerçek iki tane sahte görüntü barındırmaktadır. Dört özellik yığını elde ettikten sonra, onları 64 boyutlu vektörlerde yansıtmak için dört özellik



çıkartıcı ağ  $H_{xr}, H_{xf}, H_{yr}, H_{yf}$  kullanılır; burada  $x, y, r, f$   $X$  ve  $Y$  alanı içindeki gerçek ve buna karşılık gelen sahte görüntüleri ifade eder.

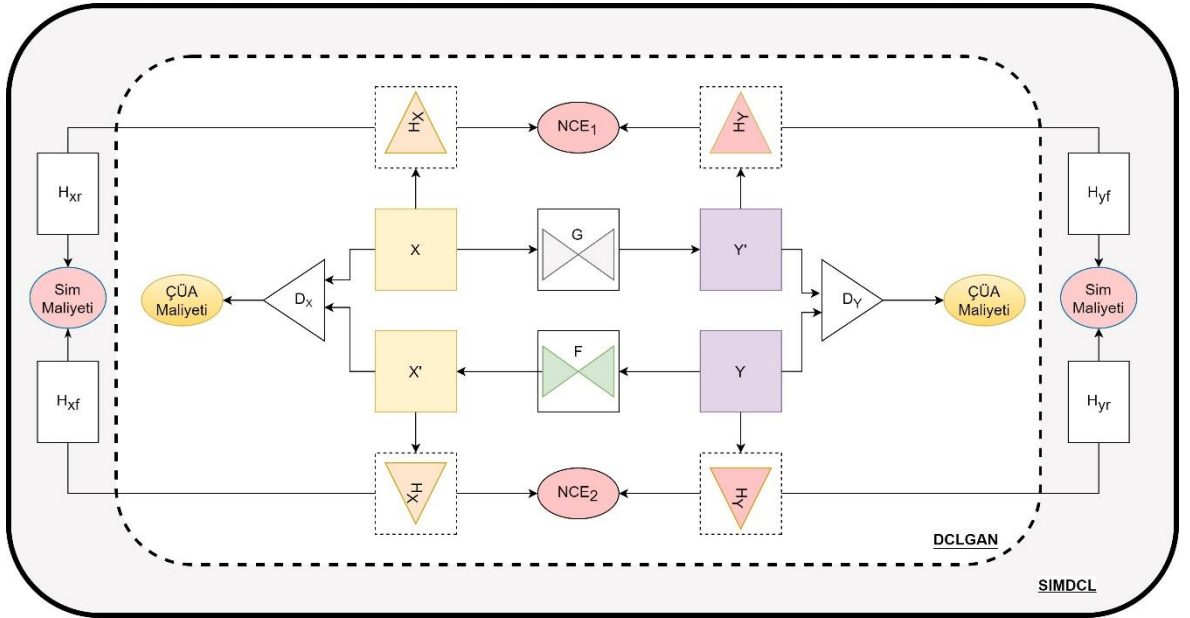
Derin özellikler üzerinde bir benzerlik kaybı uygulamak, oluşturulan ve gerçek görüntülerin derin özelliklerini benzer olmaya teşvik ederek, oluşturulan görüntüleri gerçeğe daha yakın olmaya zorlar.

SimDCL'in amaç fonksiyonu Denklem 5.3'te gösterilmiştir.

$$\begin{aligned}
 G^*, F^* &= \underset{G, F, D_X, D_Y}{\operatorname{argminmax}} \mathcal{L}(G, F, D_X, D_Y, H_X, H_Y) \\
 &= \lambda_{GAN} \left( \mathcal{L}_{GAN}^G(G, D_Y, X, Y) + \mathcal{L}_{GAN}^F(F, D_X, Y, X) \right) \\
 &+ \lambda_{NCE} \left( \mathcal{L}_{PatchNCE_X}(G, H_X, H_Y, X) + \mathcal{L}_{PatchNCE_Y}(F, H_X, H_Y, Y) \right) \\
 &+ \lambda_{sim} \mathcal{L}_{sim}(G, F, H_X, H_Y, H_{xr}, H_{xf}, H_{yr}, H_{yf}) \\
 &+ \lambda_{idt} \mathcal{L}_{identity}(G, F)
 \end{aligned} \tag{5.3}$$

Burada  $\lambda_{GAN} = 1$ ,  $\lambda_{NCE} = 2$  ve  $\lambda_{idt} = 1$  olarak alınmıştır.

Şekil 5.2'de yukarıda bahsi geçen DCLGAN ve SimDCL mimarisine yer verilmiştir.




Şekil 5.2: DCLGAN ve SimDCL mimarisini

## 5.2. Eğitim Detayları


DCLGAN ve SimDCL mimarisinde iki üretici ağ, iki özellik çıkarıcı katman ve iki ayrıştırıcı ağ bulunmaktadır. CycleGAN mimarisinde iki üretici ağ ve bir ayrıştırıcı ağ bulunmaktadır. CUT ve FastCUT yöntemleri bir üretici ağ, bir özellik çıkarıcı gömme işlemini gerçekleştiren ağ ve bir ayrıştırıcı ağ bulundurmaktadır. Yapılan çalışmada yöntemlerin iç yapılarında bulundurduğu ağ içerikleri aynıdır. Fark yöntemlerde bulunan ağların özellikleri ve sayılarıdır.

Şekil 5.3, ayrıştırıcı ağın iç yapısını göstermektedir. Ayrıştırıcı ağ PatchGAN mimarisini kullanmaktadır.




Şekil 5.3: Ayrıştırıcı ağ mimarisi

Şekil 5.4, CUT ve FastCUT yönteminde kullanılan görüntünün özelliğini çıkarıcı ve gömme işlemini gerçekleştiren ağ yapısına yer verilmiştir.

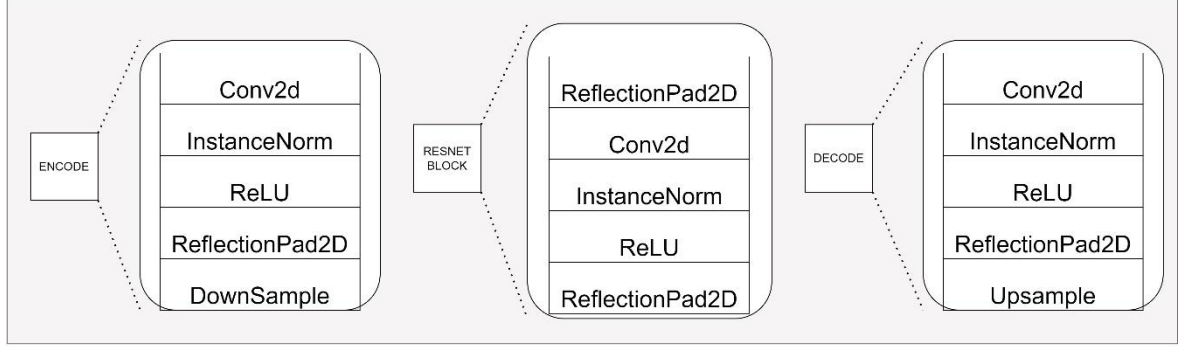


Şekil 5.4: Özellik çıkarıcı gömülü ağ mimarisi

Şekil 5.5’de üretici ağın genel yapısına ve ağ katmanlarına yer verilmiştir.



(a)



(b)


Şekil 5.5: Üretici ağ mimarisi (a) Ağın iç yapısı (b) Ağın iç yapısındaki ağ katmanlarının gösterimi

### 5.3. Veri Kümesi

Veri kümesi olarak Bölüm 3'te oluşturulan sentetik PAPSMEAR görselleri kullanılmıştır. Eğitim aşaması için 450 gerçek PAPSMEAR görüntüsü ile bu görüntülerin maskeleri kullanılmıştır. Test aşaması için ise 50 orijinal PAPSMEAR görüntüsü ve bu görüntülerin maskesini içermektedir. Veri kümesinde bulunan görseller sitoplazma, çekirdek, beyaz kan hücresi, basil ve benek nesnelere ve bu nesnelere maskelerinden oluşmaktadır. Görüntü boyutları 256x256x3 boyutundadır.


### 5.4. Deneysel Çalışmalar ve Sonuçları

Şekil 5.6'da PAPSMEAR görüntü bölütlemesi yapılırken sırasıyla CycleGAN, CUT, FastCUT, DCLGAN ve SimDCL yöntemlerinin görsel sonuçlarına yer verilmiştir. Görsel çıktı sonuçlarına bakıldığında PAPSMEAR görüntüsündeki nesne bölütlemesinin diğer yöntemler kıyaslandığında en iyi sonuçları DCLGAN ve SimDCL'in verdiği gözlemlenmektedir.



Şekil 5.6: Yöntemlerin görsel olarak görüntü bölütleme sonuçları

Şekil 5.7’de PAPSMEAR görüntü bölütlemesi yapılırken sırasıyla CycleGAN, CUT, FastCUT, DCLGAN ve SimDCL yöntemlerinin (a) orijinal çıktılarına ve (b) yakınlaştırılmış çıktılarına yer verilmiştir.



Şekil 5.7: PAPSMEAR görüntü bölütleme çıktıları. (a) Orijinal boyutlu ve (b) Yakınlaştırılmış görüntüler

Diğer yöntemler ile kıyaslandığında bölütlenmiş maskeye sırasıyla SimDCL ve DCLGAN yönteminin daha yakın sonuç ürettiği gözlemlenmiştir. CycleGAN ve FastCUT yönteminin PAPSMEAR görüntü bölütleme yapılırken başarımlarının düşük olduğu gözlemlenmiştir.

Tüm yöntemler 100 iterasyon olarak Python ortamında ve 12 GB GPU'luk bilgisayarda çalıştırılmıştır. Ölçüm metriği olarak klasik GAN yöntemlerinde kullanılan FID (Heusel vd., 2017) ve KID (Bińkowski vd., 2018) yöntemleri, CNN tabanlı LPIPS yöntemi (Zhang vd., 2018) ve geleneksel yöntem olan PSNR (wikipedia, 2021) kullanılmıştır.

Çizelge 5.1'de ölçüm metrikleri (PSNR, LPIPS, FID, KID) kullanılarak yöntemlerin bölütlenmiş maskeye benzerlik dereceleri sunulmuştur.

**Çizelge 5.1:** Yöntemlerin metriksel benzerlik sonuçları

	PSNR↑	LPIPS↓	FID↓	KID↓
<b>CUT</b>	38.003	0.136	88.184	0.036
<b>CYCLEGAN</b>	34.101	0.333	175.451	0.137
<b>DCLGAN</b>	<b>39.437</b>	<b>0.086</b>	<b>70.577</b>	<b>0.023</b>
<b>FASTCUT</b>	36.977	0.201	128.182	0.105
<b>SimDCL</b>	<u>38.920</u>	<u>0.101</u>	<u>74.203</u>	<u>0.023</u>

Çizelge 5.1 incelendiğinde PSNR, LPIPS, FID ve KID ölçüm metriklerine göre bölütlenmiş maskeye en çok benzeyen yöntem DCLGAN'dır. İkinci sırada SimDCL yöntemi gelmektedir. CycleGAN ve FastCUT yöntemi ise ölçüm metriği sonuçlarına bakıldığında kıyaslanan yöntemler arasında başarısız olduğu gözlemlenmektedir.

Bu çalışmanın ana konusu görüntü bölütleme probleminde yaygın olarak kullanılan çekişmeli üretken ağlardan CycleGAN yöntemini başlangıç olarak alan yöntemlerin verimliliğinin kıyaslanmasıdır. Parça tabanlı karşılaştırmalı öğrenme yöntemlerinden olan CUT ve FastCUT yöntemi ile CycleGAN yöntemi birleştirilerek yeni ÇÜA mimarisi olarak DCLGAN ve SimDCL geliştirilmiştir. PAPSMEAR veri kümesi bölütlemeye CycleGAN, CUT, FastCUT, DCLGAN ve SimDCL yöntemlerinin görsel bölütleme verimliliğine yer verilmiştir.

Kıyaslanan yöntemlerden görsel sonuçlar incelendiğinde en iyi sonuca sırasıyla SimDCL ve DCLGAN yöntemi olmuştur. CycleGAN ise bölütleme yaparken diğer yöntemlerin gerisinde kaldığı gözlemlenmiştir. Çizelge 5.1'deki PSNR, FID, KID, LPIPS metrikleri ile sonuçlara bakıldığında en iyi sonuçların sırası ile DCLGAN ve SimDCL yöntemlerinin verdiği gözlemlenmiştir. Çizelge 5.1'e göre CycleGAN ve FastCUT yönteminin kıyaslanan diğer yöntemlerden daha düşük olduğu gözlemlenmiştir. İki yöntemi (CycleGAN ve CUT) birleştiren mimari DCLGAN ve SimDCL'in PAPSMEAR görüntü bölütlemesinde daha verimli sonuçlar elde ettiği söylenebilir.



## 6. KONTRASTLI ÖĞRENME TABANLI ÇEKİŞMELİ ÜRETKEN AĞLAR İLE BEYİN MRI BÖLÜTLEMEDE YENİ YAKLAŞIM

Beyin MRI görüntü bölütlemesi geçmizden günümüze kadar gelen ve hala popüler bir araştırma alanıdır. Bölütlemenin iyi ve doğru sonuç vermesi hastanın kanser ya da başka beyin hastalığının teşhisinde önemli rol oynamaktadır. Bu makalede, beyin MRI(açık şekli) görüntü bölütlemesi yapılırken yeni güncel Çekişmeli Üretken Ağ önerilmiştir. Önerilen yöntem, çoğu bölütleme yöntemlerinden daha iyi bölütleme yaptığı gözlemlenmiştir. Aynı zamanda görüntü eğitilirken gerçek veri kümesindeki görüntülerin çözünürlüğünü daha iyi seviyeye çıkartıp görüntü iyileştirmesi yaptığı gözlemlenmiştir. Görüntünün iyileştirilmesi medikal alanda kullanılan veri kümelerinin görüntüyü sınıflandırmada, sentezlemede ve bölütlemede büyük öneme sahiptir. Birinci çalışmada iki boyutlu beyin MRI veri kümesi üzerinde önerilen yöntem ile mevcut son teknoloji (state-of-art) mimarilerinden CycleGAN, CUT, FastCUT, DCLGAN ve SimDCL yöntemleri karşılaştırılmıştır. İkinci çalışmada veri kümesi çözünürlüğü iyileştirilmiştir. Ve önerilen yöntem hem çözünürlüğü artırılmış veri kümesi için hem de normal veri kümesi için eğitilmiş ve sonuçlar alınmıştır. Yapılan üçüncü çalışmada ise önerilen yöntem sonuçları ile günümüzde yaygın olarak kullanılan Volbrain beyin MRI görüntü bölütleme sonuçlarına yer verilmiştir. Önerilen yöntemin üç çalışmada da tatmin edici sonuçlar verdiği gözlemlenmiştir. Bu metod otomatik görüntü bölütleme sistemi olarak kullanılabilir.

Görüntü bölütleme, nesnelerin sınır hatlarının tespiti işlemidir. Bu nesneler, tek renkli ve basit desenli sahip geometrik şekiller (kare, üçgen) olabileceği gibi birçok renk ve karmaşık desene sahip nesneler (insan ve araba gibi) de olabilmektedir. Bölütleme işlemiyle algılama, teşhis ve tanı koyma gibi birçok bilgisayar görmesi operasyonunda önsel bir iş paketi olarak sıklıkla kullanılmaktadır. Özellikle medikal görüntülerdeki nesnelerin yüksek doğrulukta ve tam otonom bölütlenmesi konusu hala aktif bir araştırma konusudur.

Bölütleme, uzun yıllar araştırmacıların üzerinde çalıştığı bir problem olduğu için oldukça doygun bir literatüre sahiptir. Bölütleme yaklaşımlarını klasik ve yenilikçi olarak ikiye ayırmak mümkündür. Klasik bölütleme yaklaşımları sadece görüntü işleme tekniklerini kullanırken, yenilikçi yaklaşımlar derin öğrenme mimarilerini kullanmaktadır.

Klasik görüntü bölütleme yaklaşımları, Thresholding (Houssein vd., 2022), Clustering methods (Pham vd., 2018), Histogram-based methods (Zhou vd., 2020), Edge detection (Vardhana vd., 2018), Region-growing methods (Shi vd., 2021), Partial differential

equation-based methods (Sun vd., 2019), Graph partitioning methods (Li vd., 2018), Watershed transformation (Beucher, 1992) listelenebilir. Klasik bölütleme teknikleri geniş kapsamda kullanılmaktadır (Shrimali,2009; Hu ve Mageras, 2009; Taha ve Hanbury, 2015). Güncel bölütleme teknikleri incelendiğinde konvolüsyonel sinir ağların (Wang vd., 2018; Gu vd., 2019; Clough vd., 2019; Kayalibay vd., 2017; Mun vd., 2017) ve çekişmeli üretken ağların (Xue vd., 2018; Khosravan vd., 2019; Zhao vd., 2018) kullanıldığı görülmektedir.

Medikal görüntü bölütleme alanı, birçok organ görseli oldukça geniş ve karmaşık yapılara sahip nesnelere içerdiğinden bu çalışmada sadece insan beyninde yer alan üç farklı yapının (GM, WM ve CSF) bölütlenmesine odaklanılmıştır. Beyin görüntü bölütlemesi oldukça karmaşıktır. Doğru şekilde bölütleme yapılması tümör, ödem ve nekrotik dokuları tespit etmede önem taşımaktadır. Klinik uygulamalarda anatomik sapma ile beyin segmentasyonu çok önemlidir. Ayrıca manyetik rezonans görüntüleme (MRI), beyin farklı bölgelerindeki anormal değişiklikleri erken aşamada tespit etmek için önemli bir görüntüleme tekniğidir. MRI görüntüleri bilgisayarlı tomografiye (BT) kıyasla iyi bir kontrasta sahiptir. Bu nedenle, tıbbi görüntü segmentasyonundaki araştırmaların çoğu MRI görüntülerini kullanır.

Beyin görüntüsünün bölütlenmesi, nörodejeneratif ve psikiyatrik bozuklukların klinik teşhisinde, tedavi değerlendirmesinde ve cerrahi planlamada da faydalıdır (Xiao ve Bruce, 2007). Otomatik ve yarı otomatik görüntü bölütleme için pek çok yöntem vardır. Ancak çoğu tıbbi görüntülerde olağan olan bilinmeyen gürültü, zayıf görüntü kontrastı ve zayıf sınırlar nedeniyle başarısız olur. Bu olumsuzlukları gidermek için araştırmacılar derin öğrenme yöntemlerini kullanarak çalışmalar yapmıştır. Milletari ve arkadaşları (Milletari vd., 2016), 2016 yılında hacimsel medikal görüntü bölütleme için tamamen evrişimli sinir ağı (V-Net) önermiştir. Deneysel sonuçlar rakip yöntemlerden daha iyi sonuç verdiği görülmüştür. Christ ve arkadaşları (Christ vd., 2016), 2016 yılında bir dizi FCN'nin ard arda yerleştiren kademeli FCN (CFCN) yöntemini önermiştir. Önceki modelin tahmin haritasından çıkarılan bağlam özelliklerini kullanan her model, bölütleme doğruluğunu iyileştirebilir. Zhou ve arkadaşları (Zhou vd., 2017a), 2017 yılında 3D bilgisayarlı tomografi (BT) görüntülerinde 19 organı bölütlemeye 2.5D yaklaşımlı FCN kullanmıştır. Bu teknolojinin karaciğer gibi büyük organlardaki doğruluğu pankreas gibi küçük organlara göre daha yüksektir. Zhou ve arkadaşları (Zhou vd., 2017b), 2017 yılında görüntüdeki arka plan ve ön plan pikselleri oranındaki dengesizlik nedeniyle oluşan yanlış pozitiflerin sayısını



azaltmak için FCN üzerinde odak kaybı uygulanmasını önermiştir. Casamitjana ve arkadaşları, 2017 yılında beyin tümörü bölütleme problemini, tüm tümörün bölütlemesi ve farklı tümör bölgelerini bölütleyerek daha basit iki işlem yapan beyin tümörünü kademeli V-Net bölütlemesini önermiştir (Casamitjana vd., 2017). Myronenko ve arkadaşları, 2018 yılında asimetrik FCN'ye dayanan ve artık öğrenme ile birleştirilmiş derin öğrenme ağı 3D MRI beyin tümörü bölütlemesi önermiştir (Myronenko vd., 2018). Nie ve arkadaşları, 2019 yılında 11 sağlıklı bebeğin T1, T2 ve difüzyon ağırlıklı modal nöral görüntülerini elde etmiştir (Nie vd., 2019). Yazarlar, bağlamsal semantik bilgileri entegrasyonu ile farklı ölçeklerin özelliklerini birleştirmiş ve 3D FCN kullanarak multimodal beyin MRI görüntülerini bölütlemiştir. Wang ve arkadaşları, 2019 yılında maliyet fonksiyonuna kenar bilgisi ekleyerek daha doğru kenar bölütlemesi sağlayan CRF tabanlı kenar algılayan FCN önermiştir (Wang vd., 2019). Modelin doğruluğu, FCN-8S ve diğer temel anlamsal bölütleme ağları ile karşılaştırıldığında %87,31 değeri ile daha yüksek olduğu gözlemlenmiştir. Borne ve arkadaşları, 2019 yılında eğitim kümesi olarak farklı heterojen veritabanlarından 62 sağlıklı beyin görüntüsü seçmiştir ve bunları 3D U-Net kullanarak bölümlere ayırmıştır (Borne vd., 2019). Sonuç %85 doğru çıkmıştır. Barzegar ve Jamzad , 2021 yılında Beyin MRI görüntülerinde glioma tümör bölütleme için ağırlıklı etiket füzyon öğrenme çerçevesi (WLFS) önermiştir (Barzegar ve Jamzad, 2021). Alçak ve yüksek dereceli glioma tümörünü içeren BRATS veri kümesi üzerinde uygulanmıştır. Karşılaştırılan rakip yöntemlere göre tüm tümör (WT) ve tümör çekirdeği (TC) bölütlemesinde en iyi sonuca ulaşmıştır. Liu ve arkadaşları, 2021 yılında sürekli frekans uzayında epizodik öğrenme yoluyla tıbbi görüntü bölütlemesinde birleşik alan genelleştirmesi (FedDG) önermiştir (Liu vd., 2021). İki medikal görüntü bölütlemesinde teknoloji ve derinlemesine ablasyon deneylerine göre üstün performans verdiği incelenmiştir.

(Moeskops vd., 2017; Rezaei vd., 2017; Giacomello vd., 2019), ÇÜA kullanılarak medikal görüntü bölütleme problemine çözümler sunulduğu görülmektedir. (Moeskops vd., 2017)'deki çalışmada beyin MRI verilerinin tamamen evrişimli ve genişlemiş kıvrımlara sahip bir ÇÜA mimarisiyle bölütlendiği görülmektedir. Rezaei ve arkadaşları (Rezaei vd., 2017) nolu çalışmada beyin tümörünün yüksek doğrulukta bölütlenebilmesi için üstün anlamsal bir bölütleme mimarisi (cGAN) önermektedir. Benzer şekilde (Giacomello vd., 2019) çalışmada da MRI verilerindeki tümörlü beyin bölgelerinin tespitine yönelik bir çalışma yapılmış ve SegAN-CAT adlı bir ÇÜA mimarisi önerilmiştir. Bu çalışmada tümörlü

alanın bölütlenmesi için BRATS-2015 ve BRATS-2019 veri kümeleri kullanılmış ve önerilen SegAN-CAT mimarisinin SegAN'den daha iyi performans sağladığı gösterilmiştir.

Park ve diğerleri tarafından 2020 yılında önerilen CUT (Contrastive Unpaired Translation) mimarisi (Park vd., 2020), farklı görüntü alanları arasındaki dönüşümün yapılmasında görüntü parçalarının kullanılmasını önermektedir. Denetimsiz bir öğrenme yaklaşımına sahiptir. CUT yöntemi tek taraflı eşlemeyi iki taraflı olarak genişleterek yerleştirmeleri öğrenmede daha iyi performans göstermiştir. DCLGAN (Han vd., 2021) (Dual Contrastive Learning for Unsupervised Image-to-Image Translation) mimarisi, CUT yöntemindeki mod çökmesi yani görüntüdeki kayıp piksellerin olmaması için önerilmiştir. Önceki yöntemlerin üstesinden gelemediği mod çökmesi sorununu da karşılıklı bilgi maksimizasyonuna dayanarak ele almıştır. Bu yöntemle denetimli ve denetimsiz yöntemler arasındaki boşluğun verimli bir şekilde kapatılabileceği gösterilmektedir. DCLGAN, denetimsiz dönüşüm yapan CycleGAN (Zhou vd., 2017) yöntemi ile CUT (Park vd., 2020), yönteminin birleştirilmesiyle oluşturulan yeni bir yaklaşımdır.

Bu çalışmada, beyin MRI verilerinin bölütlenmesine odaklanılmakta ve özellikle son yıllarda bölütleme alanında kullanılan güncel ÇÜA mimarileri ve karşılaştırmalı öğrenme tekniklerinin bölütleme performansları kıyaslamalı bir şekilde incelenmektedir. Bununla birlikte mevcut yaklaşımların bölütleme performanslarını iyileştirmek amacıyla GAN temelli yeni bir bölütleme mimarisi önerilmektedir. Önerilen mimarinin performans sonuçları, aynı segmentte yer alan klasik mimariler (CycleGAN (Zhou vd., 2017), DCLGAN ve SimDCL (Han vd., 2021)) ve güncel karşılaştırmalı öğrenme mimarileriyle (CUT ve FastCUT (Park vd., 2020)) kıyaslamalı bir şekilde sunulmaktadır.

Bu çalışmanın ana katkıları şu şekilde sıralanabilir:

- Tıp alanında hala eksilik olan görüntü çözünürlüğünü artırarak görüntülerde analiz yapmayı daha iyi bir şekilde sağlamaktadır.
- Görüntü bölütlerken state-of-art metotlardan denetimsiz olanları denetimli hale getirerek yeni ve doğruluğu yüksek bir yöntem önerilmiştir.

Önerilen yöntemin, Beyin-MRI bölütlemeye günümüzde çoğu bölütlemeye iyi sonuç veren Volbrain uygulamasına göre daha iyi sonuç verdiği gözlemlenmektedir.



Önerilen yöntem kayıp olarak tartışmalı (Adversarial) kayıp, özdeşlik (Identity) kaybı ve CUT yönteminde de kullanılan parçalı gürültü karşılaştırmalı tahminleme (PatchNCE) kaybını kullanır. SimDCL’de kullanılan benzerlik kaybını ( $\mathcal{L}_{sim}$ ) de mod çökmesini engellemek için kullanır. Aynı zamanda diğer yöntemlerden farklı olarak gerçek ve oluşturulan görüntü arasında  $L_1$  kaybını kullanmaktadır.

Önerilen yöntemin eğitim sonuçlarına bakıldığında özdeşlik sonucu oluşturulan görüntülerin çözünürlüğünün gerçek görüntülerden daha iyi olduğu gözlemlenmiştir. Denetimli öğrenmeye çevrilen ve eşlenmiş görüntüler üzerinde çalışan yöntemin gerçek görüntüye daha çok benzediği gözlemlenmiştir. Denetimli önerilen mimari Şekil 7’de açıkça gösterilmektedir.

**$L_1$  loss.** Denetimsiz olan sistemi denetimli hale getirebilmek için gerçek görüntü ile oluşturulan görüntü arasında hesaplanmaktadır. Eşitlik 2’de  $L_1$  loss’un nasıl hesaplandığına yer verilmiştir.

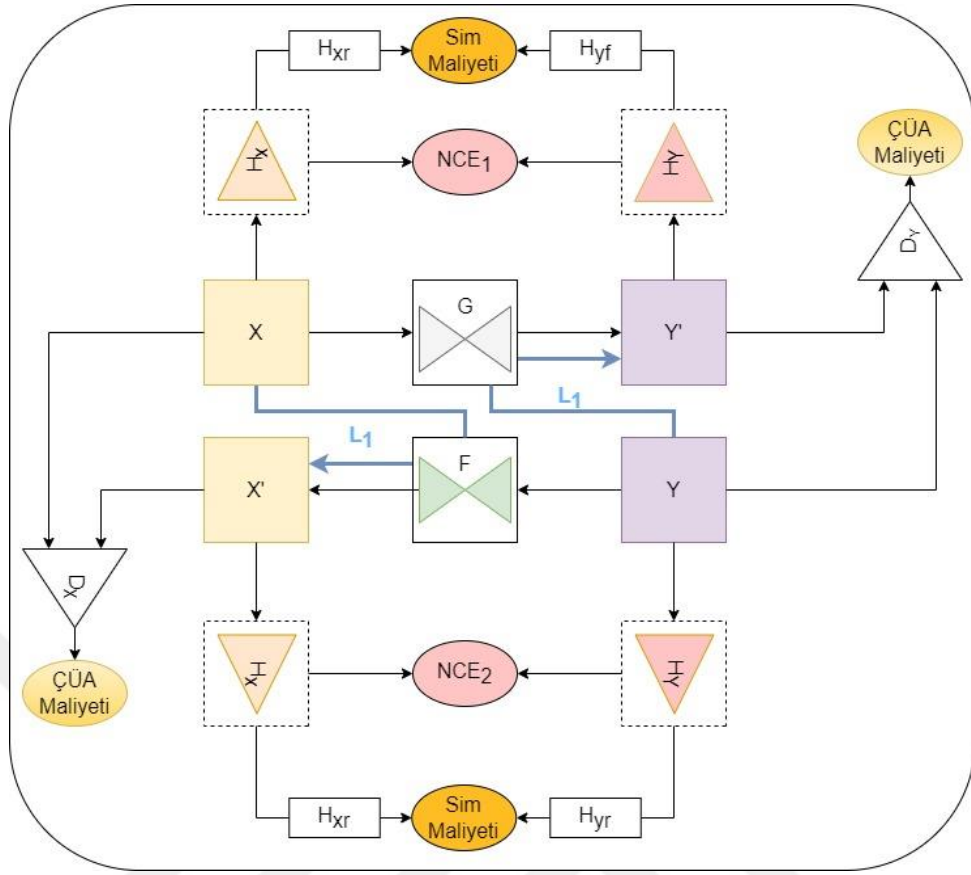
Önerilen yöntemin amaç fonksiyonu Denklem 6.1’de verilmiştir.

$$\begin{aligned}
G^*, F^* &= \underset{G, F}{\operatorname{argmin}} \underset{D_X, D_Y}{\operatorname{max}} \mathcal{L}(G, F, D_X, D_Y, H_X, H_Y) \\
&= \lambda_{GAN} \left( \mathcal{L}_{GAN}^G(G, D_Y, X, Y) + \mathcal{L}_{GAN}^F(F, D_X, Y, X) \right) \\
&+ \lambda_{NCE} \left( \mathcal{L}_{PatchNCE_X}(G, H_X, H_Y, X) \right. \\
&+ \left. \lambda_{NCE} \mathcal{L}_{PatchNCE_Y}(F, H_X, H_Y, Y) \right) \\
&+ \lambda_{sim} \mathcal{L}_{sim}(G, F, H_X, H_Y, H_{xr}, H_{xf}, H_{yr}, H_{yf}) \\
&+ \lambda_{idt} \left( \mathcal{L}_{identity}(G, F) + \mathcal{L}_{identity}(G, F, X, Y) \right)
\end{aligned} \tag{6.1}$$

Burada  $\lambda_{GAN} = 1$ ,  $\lambda_{NCE} = 2$  ve  $\lambda_{sim} = 10$  ve  $\lambda_{idt} = 1$  olarak alınmıştır.

Şekil 6.2’de ise önerilen yöntem mimarisine yer verilmiştir. Önerilen yöntem  $\mathcal{L}_{identity}(G, F)$  kaybı ile oluşturulan görüntüler piksel kaybı daha az olmaktadır. Ve çözünürlüğü daha iyi çıkmaktadır. Önerilen yöntemden  $\mathcal{L}_{identity}(G, F)$  kaybı ile oluşturulan görüntüler ile yeni veri kümesi elde edilmiştir.

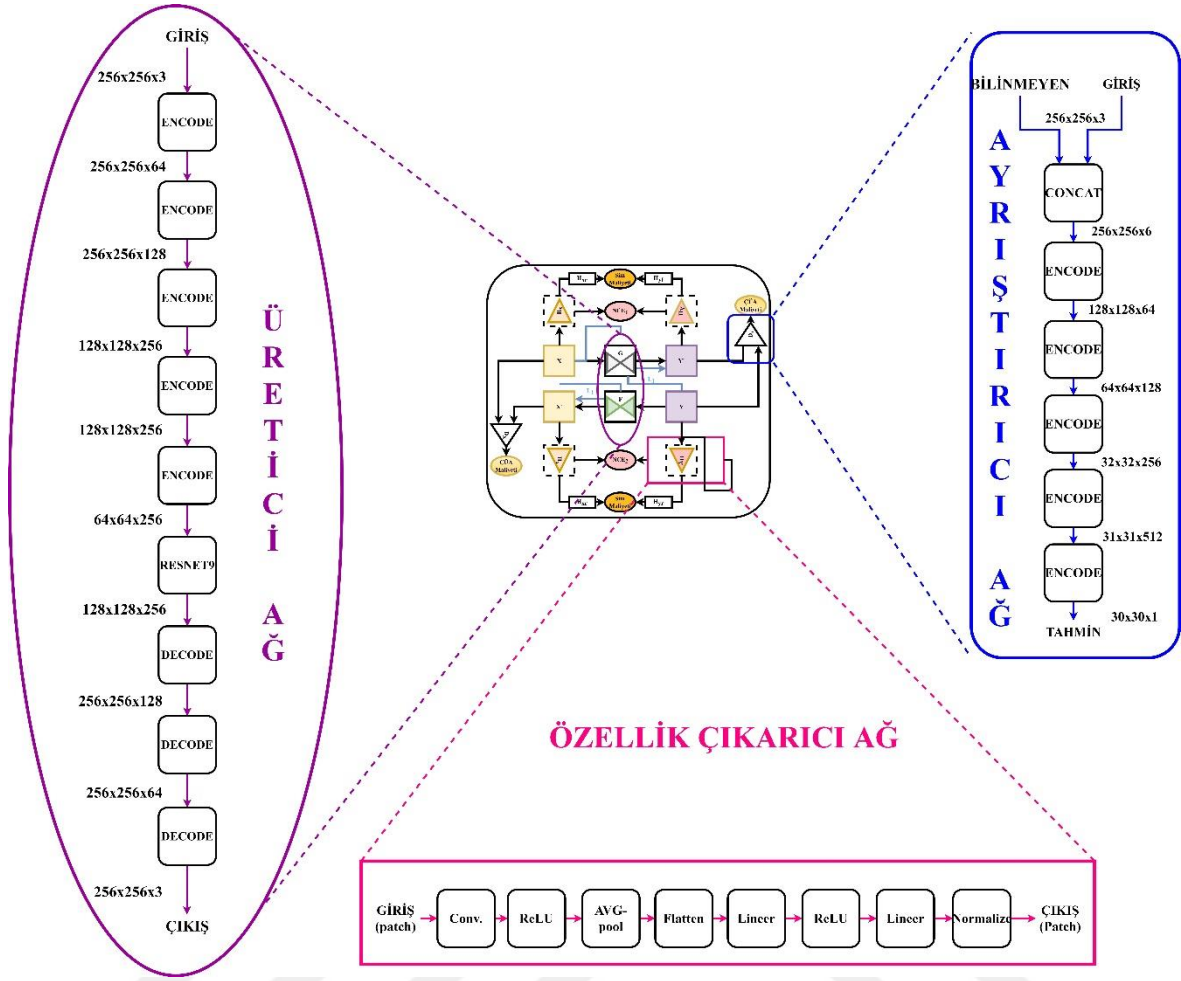
Şekil 6.3’te ise önerilen yöntemin ağ yapılarının içeriğine yer verilmiştir. Önerilen yöntemde; iki üretici, iki ayrıştırıcı ve dört özellik çıkarıcı ağ bulunmaktadır.



Şekil 6.2: Beyin MRI bölütleme için önerilen yöntemin mimarisi

## 6.2. Eğitim Detayları


Genelde önerilen methodu eğitmek için DCLGAN (Han vd., 2021) ayarları örnek alınmıştır.  $\beta_1 = 0.5$  ve  $\beta_2 = 0.999$  ile Adam optimizasyonu (Diederik ve Jimmy, 2014) kullanılmıştır. Tüm yöntemler 100 iterasyon eğitilmiş ve sonuç alınmıştır. Öğrenme oranı 0.0001 olarak alınmıştır. ResNet (Kaiming vd., 2016) tabanlı üretici ağ ve PatchGAN (Phillip Isola vd., 2017) diskriminatör kullanılmıştır. Batch size 1 olarak alınmıştır ve örnek normelleştirme (instance normalization) kullanılmıştır. Tüm eğitilecek görüntü boyutları 256x256 boyutundadır.



Şekil 6.3: Önerilen yöntemdeki ağların iç yapıları

### 6.3. Veri kümesi

İlk aşamada Beyin MRI veri kümesi oluşturulmuştur. Veri kümesi 3 boyutluyken iki boyutluya Matlab 2020b ortamında çevrilmiştir. Bu dönüşüm işlemi yapılırken slicelar 2 boyutlu görüntü olarak gözükmektedir. Toplamda 18 adet 3 boyutlu görüntü ve içerisinde 128 adet slice vardır. Beyin MRI veri kümesi iki boyutlu hale getirildiğinde 2304 adet görüntü oluşmaktadır. Elde edilen orijinal ve maske görüntüleri Şekil 6.4’de görülmektedir.



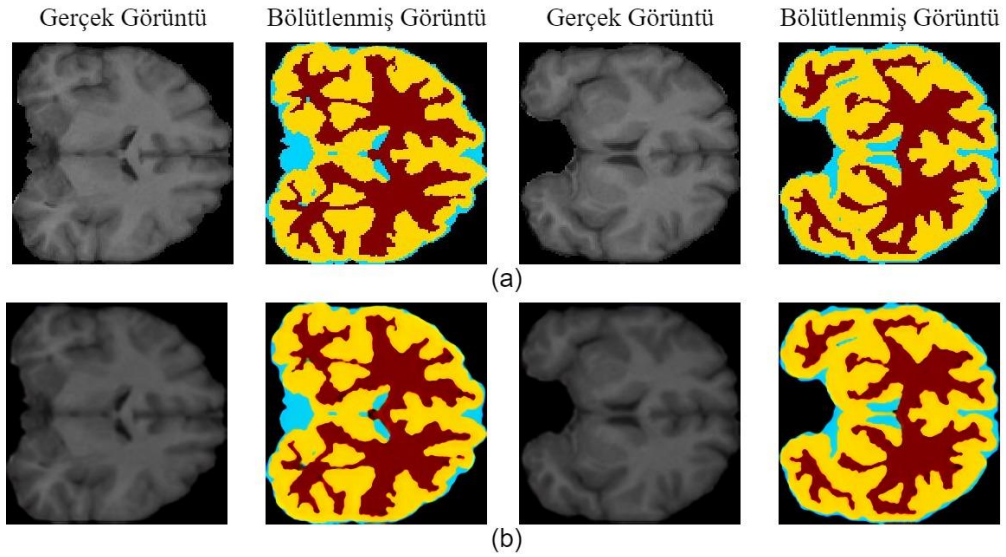
**Şekil 6.4:** 2 boyutlu beyin MRI veri kümeleri (a) Orijinal (b) Maske görüntü

Şekil 6.4’de 3 boyutlu ve 3 katmana sahip beyin MRI veri kümesi 2 boyutlu hale getirilmiştir. Bu veri kümesinde gerçek görüntüler(Şekil 6.4.(a)) ve maske görüntüleri(Şekil 6.4.(b)) mevcuttur.

Slicelar içerisinde eğitim aşamasını yanlış etkileyecek olan tamamı siyah görüntüler ve minik beyin MRI görüntüleri bulunmaktadır. 2 boyutlu oluşturulan görüntülerde tamamen siyah olan görüntüler ve küçük kısım kaplayan görüntüler çıkarılmıştır. Geriye kalan görüntülerin ise çerçeve kısmından kod ile kırpma işlemi gerçekleştirilerek 256x256 boyutunda gerçek ve maske görüntülerine yer verilmiştir (Şekil 6.5 (a)). Bu görüntüler üzerinde görüntüyü net görebilmek ve siyah alanları azaltmak için morfolojik işlemler uygulanmıştır ve veri kümesi filtrelenmiştir. Sonuç olarak 1648 adet eğitim ve 366 adet test aşamasında kullanılmak üzere 2014 adet görüntü elde edilmiştir.

#### 6.4. İyileştirilmiş Veri Kümesi

Önerilen yöntem eğitim sürecinden geçirildikten sonra identity sonucu oluşturulan görüntü çözünürlüğü ve kalitesi daha yüksektir. İyileştirilen veri kümesinde yeni veri kümesi oluşturulmuştur. Önerilen yöntem sayesinde görüntülerde iyileştirme yapılabilmektedir. Bu da medikal görüntülerin kullanılması ve analiz edilmesi açısından önemli bir gelişmedir. İyileştirilen veri kümesi 256x256 boyutunda olup orijinal görüntülerin çözünürlüğünün artırılmasıyla elde edilmiştir. Bu veri kümesinde de önceki veri kümesinde olduğu gibi 1648 adet eğitim ve 366 adet test aşamasında kullanılmak üzere 2014 adet görüntü elde edilmiştir. Şekil 6.5 (b)’de önerilen yöntemdeki eğitim sonucu oluşturulan çözünürlüğü artırılmış görüntülere yer verilmiştir.



Şekil 6.5: Beyin MRI veri kümeleri (a) Orjinal (b) Çözünürlüğü arttırılmış

## 6.5. Kullanılan Ölçüm Metrikleri

Metrikler. Temel olarak üretilen görüntülerin kalitesini ölçmek için FID (Heusel vd., 2017) ve KID (Bińkowski vd., 2018), LPIPS (Zhang vd., 2018) ve PSNR (PSNR, 2022(web)) metrikleri kullanılmıştır. FID (Heusel vd., 2017) ve KID (Bińkowski vd., 2018) metriği insan algısı ile benzer sonuçlar üretmektedir. FID, gerçek ve oluşturulan görüntü arasındaki daha az Frechet uzaklığı anlamına gelir. KID (Bińkowski vd., 2018), metriğinde iki görüntü arasındaki benzerliğin iyi olması kernel başlangıç mesafesinin az olması demektir. LPIPS (Zhang vd., 2018), yöntemi iki görüntü arasındaki uzaklığı hesaplamada evrimsel sinir ağını kullanır. Bu uzaklığın az olması LPIPS sonucunun başarılı olduğunu göstermektedir. PSNR (PSNR, 2022(web)) metriği insan algısı ile ters orantılı çalışmaktadır. PSNR (PSNR, 2022(web))'nin yüksek olması iki görüntü arasındaki benzerliğin daha iyi olduğunu göstermektedir.

Baselines. Önerilen yöntem CUT (Park vd., 2020), FastCUT (Park vd., 2020), CycleGAN (Zhou vd., 2017), DCLGAN (Han vd., 2021) ve SimDCL (Han vd., 2021) dahil olmak üzere son teknoloji(state-of-art) denetimsiz yöntemler arasında kalite karşılaştırması yapmaktadır. Aynı zamanda önerilen yöntemden oluşturulan görüntülerin orijinal görüntünün kalitesini arttırdığı gözlemlenmektedir. CUT (Park vd., 2020) ve FastCUT(Park vd., 2020) tek taraflı yöntemlerdir. CycleGAN (Zhou vd., 2017), DCLGAN (Han vd., 2021), SimDCL (Han vd., 2021) ve önerilen yöntem çift taraflı yöntemlerdir. Önerilen yöntem denetimli öğrenmeye örnektir.



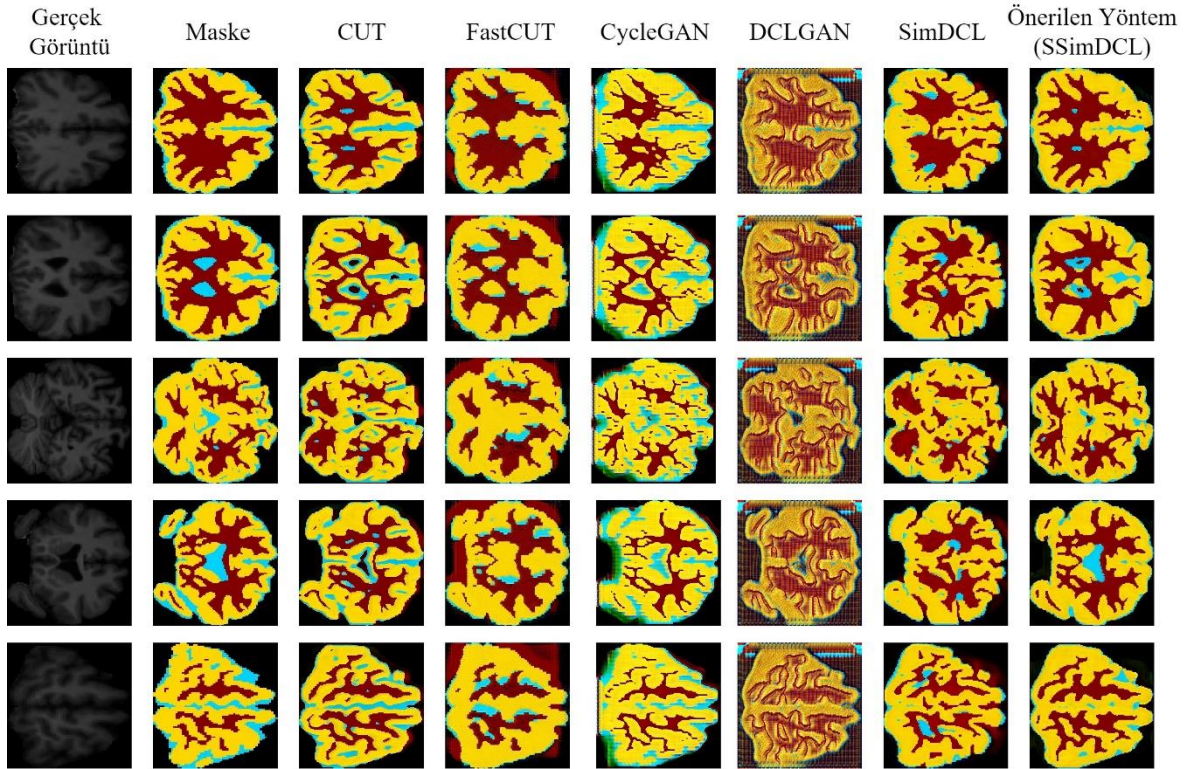
## 6.6. Deneysel Çalışmalar ve Sonuçları

Yapılan birinci çalışmada CycleGAN, CUT, FastCUT, DCLGAN, SimDCL ve önerilen yöntemin kıyaslanmasına, ikinci çalışmada önerilen yöntem ile yüksek çözünürlükte görüntü üretilmesine, üçüncü çalışmada yeni oluşturulan veri kümesinin verimliliğinin ölçülmesine, dördüncü ve en son çalışmada ise global olarak doğruluğu kanıtlanmış VolBrain sonuçları ile önerilen yöntemin sonuçlarının karşılaştırılmasına yer verilmiştir.

### 6.6.1. Çalışma 1: Farklı metodlarla karşılaştırma

Yapılan çalışmanın birinci aşamasında literatürde bulunan mevcut son teknoloji denetimsiz yöntemler ( CycleGAN, CUT, FastCUT, DCLGAN, SimDCL) ile önerilen yöntem Beyin MRI veri kümesi üzerinde eğitilmiş ve test sonuçları alınmıştır. Beyin MRI veri kümesinin yöntemlere göre test sonuçlarına yer verilmiştir.

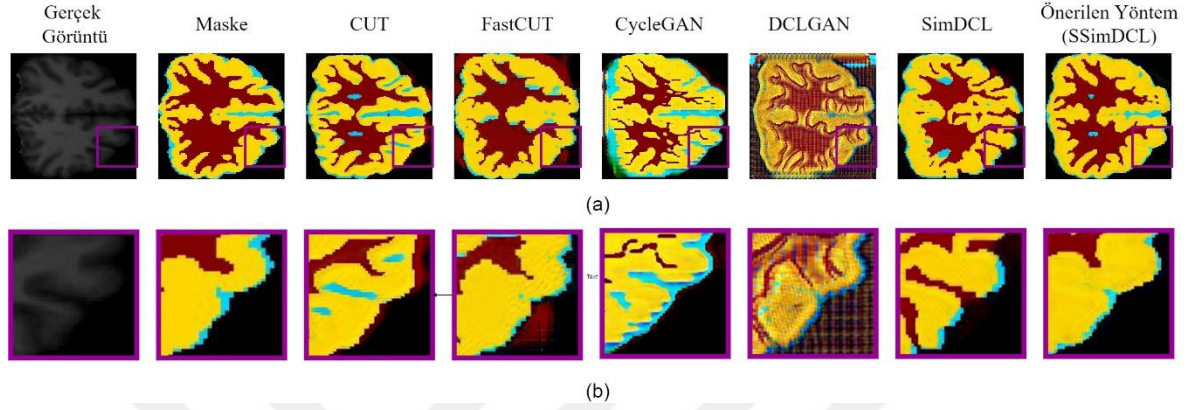
Şekil 6.6’da veri kümesinden alınan rastgele beyin MRI sonuçlarına yer verilmiştir. Bu görsel bölütleme sonuçlarına bakıldığında en iyi bölütlemeyi önerilen yöntemin yaklaştığı gözlemlenmektedir.



Şekil 6.6: Yöntem çıktılarının görsel kıyaslanması.

İlk veri kümesi olarak literatürde bulunan mevcut son teknoloji denetimsiz yöntemler ile önerilen yöntem beyin MRI veri kümesi üzerinde eğitilmiş ve test sonuçları alınmıştır.

Şekil 6.7 (a)'da yöntemlere görsel çıktılara yer verilmiştir. Şekil 6.7 (b)'de ise bu görsellerin yakınlaştırılmış haline yer verilmiştir.



Şekil 6.7: Beyin MRI veri kümesi üzerinde görsel çıktılar (a) Orijinal (b) Yakınlaştırılmış

Çizelge 6.1: Yöntemlerin metriksel benzerlik sonuçları.

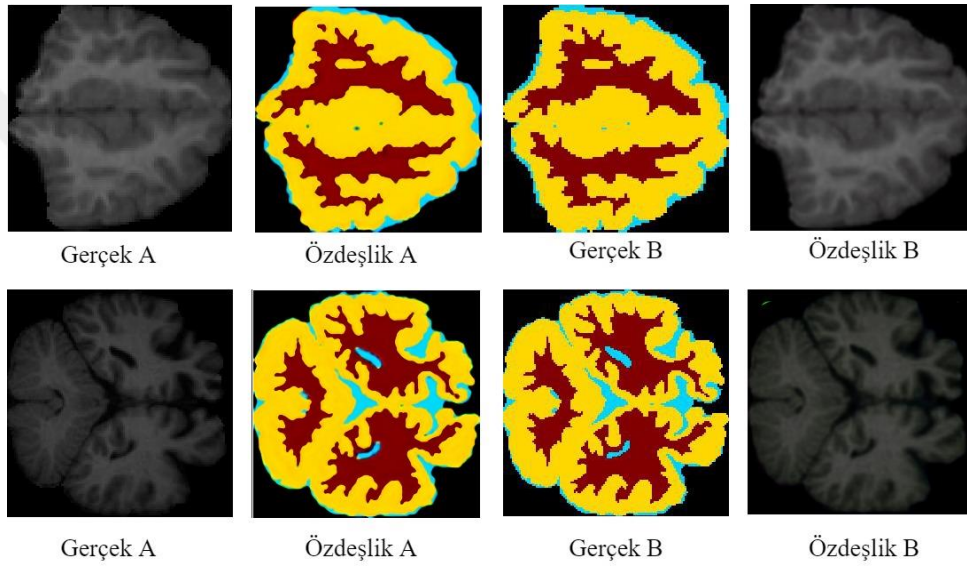
METODLAR	VERİ KÜMESİ	LPIPS ↓	PSNR ↑	FID ↓	KID ↓
CUT	<i>Beyin MRI</i>	<u>0.452</u>	<u>30.604</u>	142.740	0.146
CycleGAN	<i>Beyin MRI</i>	0.495	30.126	230.905	0.291
DCLGAN	<i>Beyin MRI</i>	0.722	28.071	273.330	0.401
FastCUT	<i>Beyin MRI</i>	0.459	30.359	133.134	0.149
SimDCL	<i>Beyin MRI</i>	0.510	30.426	<u>92.729</u>	<u>0.067</u>
<b>Önerilen yöntem (SSimDCL)</b>	<i>Beyin MRI</i>	<b>0.390</b>	<b>30.719</b>	<b>92.366</b>	<b>0.067</b>

Önerilen yöntemin görüntü benzerliği olarak iyi sonuç verdiği gözlemlenmiştir. Metrik sonuçlarına göre ikinci başarılı sonuç veren yöntemler altı çizili olarak gösterilmiştir.

Çizelge 6.1'de CycleGAN, CUT, FastCUT, DCLGAN, SimDCL ve önerilen yöntemlerin kalite karşılaştırmasına yer verilmiştir. LPIPS metriğine göre 0,390, PSNR metriğine göre 30,719, FID metriğine göre 92,366, KID metriğine göre 0,067 değeri ile en iyi sonuca önerilen yöntemin ulaştığı gözlemlenmiştir.


## 6.6.2. Çalışma 2: Önerilen yöntemle göre yüksek kaliteli görüntü oluşturulması

Yapılan ikinci çalışmada önerilen yöntemdeki identity loss sonucu oluşan görsellerin çözünürlüğünün daha iyi olduğu gözlemlenmiştir. Büyük veri kümelerini yeniden oluşturabilmek ve bölütleme yaparken görsellerin iyileştirilmesi açısından etkili olduğu düşünülmektedir. Çözünürlüğü yüksek olan görüntülerin önerilen yöntemde nasıl bir etkisi olduğunu gözlemek için yeni veri kümesi oluşturulmuştur. Özdeşlik (Identity) sonuçlarına ve gerçek görüntüye Şekil 6.8’de ayrıntılı şekilde yer verilmiştir. Bu görsel bölütleme sonuçlarına bakıldığında en iyi bölütlemeyi önerilen yöntemin yaklaştığı gözlemlenmektedir.




Şekil 6.8: Gerçek görüntüler ve özdeşlik maliyetine göre görsel sonuçlar.

Önerilen yöntemin identity görsel sonuçlarına göre oluşturulmuş yeni gerçek görüntüler ve maske görüntüleri veri kümesi örneklerine Şekil 6.9 ve Şekil 6.10’da yer verilmiştir. Önceki veri kümesinden farklılığı ise Şekil 6.11 (a,b,c,d)’de ayrıntılı şekilde zoom yapılarak gösterilmiştir.




Şekil 6.9: Beyin MRI görüntüleri (a) Gerçek (b) Önerilen yöntemle çözünürlüğü artırılmış



Şekil 6.10: Beyin MRI maske görüntüleri (a) Gerçek (b) Önerilen yöntemle çözünürlüğü artırılmış






**Şekil 6.11:** Gerçek ve çözünürlüğü artırılmış görüntüler (a) Orjinal görüntü (b) Çözünürlüğü artırılmış (c) Orjinal maske (d) Çözünürlüğü artırılmış maske

### 6.6.3. Çalışma 3: Yeni oluşturulan veri kümesinin verimliliğinin ölçülmesi

Yeni oluşturulan veri kümesinin verimliliği ölçülmek istenmiştir. Önerilen yöntem ilk olarak orjinal veri kümesine 100 iterasyon eğitildikten sonra test sonuçları elde edilmiştir. İkinci olarak maske görüntüleri identity üzerinden gelen maskeler; görüntüler ise ilk orijinal gerçek Beyin MRI görüntüleridir. Üçüncü ise önerilen yonteme hem gerçek hem de maskesi identity görüntülerinden oluşturulmuş veri kümelerinden verilerek 100 iterasyon çalıştırılmıştır. Görsel sonuçlara Şekil 6.12’de yer verilmiştir. Görsel sonuçlar incelendiğinde en iyi sonucu çözünürlüğü arttırılmış veri kümesi eğitimi sonucu verdiği gözlemlenmiştir.



Şekil 6.12: Önerilen yöntemle oluşturulan veri kümelerinin görsel çıktıları

Çizelge 6.2: Yeni Beyin MRI veri kümeleri üzerinde önerilen yöntemin kıyaslanması

	Yöntem	LPIPS ↓	PSNR ↑	FID ↓	KID ↓
<b>Orijinal veri kümesi</b>	Önerilen Yöntem	0.390	30.719	92.366	0.067
<b>%50 değiştirilmiş veri kümesi</b>	Önerilen Yöntem	<u>0.046</u>	<u>36.904</u>	<u>21.402</u>	<u>0.008</u>
<b>% 100 değiştirilmiş veri kümesi</b>	Önerilen Yöntem	<b>0.042</b>	<b>37.138</b>	<b>20.070</b>	<b>0.007</b>

Çizelge 6.2’de yeni veri kümelerine göre önerilen yöntemin PSNR, LPIPS, MSE, SSIM, FID ve KID metrikleri ile karşılaştırılması. % 100 değiştirilmiş veri kümesinin


önerilen yöntem ile eğitildikten sonra en iyi sonuç verdiği gözlemlenmiştir. Metrik sonuçlarına göre ikinci başarılı sonuç veren veri kümesi altı çizili olarak gösterilmiştir.

Veri kümelerinin verimliliğini karşılaştırmak için LPIPS, PSNR, FID ve KID metriksel sonuçlarına Çizelge 6.2’de yer verilmiştir. Çizelge 6.2’de önerilen yöntem üzerinde çözünürlüğü artırılmış veri kümesi ve orijinal veri kümesinin eğitim yapıldıktan sonraki test sonuçları gösterilmiştir. LPIPS metriğine göre 0.042, PSNR metriğine göre 37.138, FID metriğine göre 20.070, KID metriğine göre 0,007 değeri ile en iyi sonuca % 100 değiştirilmiş veri kümesinin ulaştığı gözlemlenmiştir.

#### **6.6.4. Çalışma 4: VolBrain sonuçları ile karşılaştırılması**

volBrain, girdi görüntülerinin kalitesini iyileştirmeyi ve bunları daha sonra ilgilenilen farklı yapıları/dokuları bölümlere ayırmak için belirli bir geometrik ve yoğunluk alanına yerleştirmeyi amaçlayan bir dizi görüntü işleme görevidir (Manjon vd., 2016). volBrain çevrimiçi bir MRI beyin hacim sistemidir. Tüm dünyadaki araştırmacılara, yerel sitelerinde herhangi bir altyapıya ihtiyaç duymadan MRI verilerinden otomatik olarak hacimsel beyin bilgileri elde etmelerine yardımcı olmayı amaçlamaktadır (volBrain, 2021). Çalışmanın son aşamasında genel olarak en iyi segmentasyonu gerçekleştirebilen volBrain ile karşılaştırma yapılmıştır. Çalışmanın en son aşamasında genel olarak en iyi bölütleme yapabilen VolBrain ile karşılaştırma yapılmıştır. Görsel sonuçlara Şekil 6.13’te yer verilmiştir. LPIPS, FID, KID ve PSNR metriksel sonuçlara ise Çizelge 6.3’te yer verilmiştir.





Şekil 6.13: Beyin MRI bölütmeye VolBrain ve önerilen yöntemin görsel çıktıları

Şekil 6.12'deki görsel sonuçlar incelendiğinde en iyi sonucu çözünürlüğü artırılmış veri kümesi eğitimi sonucu verdiği gözlemlenmiştir.

Çizelge 6.3: İyileştirilmiş veri kümesine göre yöntemlerin metrik benzerlik kıyaslaması

	LPIPS ↓	PSNR ↑	FID ↓	KID ↓
Önerilen yöntem	<b>0.042</b>	<b>37.138</b>	<b>20.070</b>	<b>0.007</b>
VolBrain (Manjon vd., 2016)	0.553	32.184	77.125	0.058



Çizelge 6.3'de önerilen yöntem üzerinde çözünürlüğü arttırılmış veri kümesi ve orijinal veri kümesinin eğitim yapıldıktan sonraki test sonuçları gösterilmiştir. LPIPS metriğine göre 0.042, PSNR metriğine göre 37.138, FID metriğine göre 20.070, KID metriğine göre 0,007 değeri ile en iyi sonuca % 100 değiştirilmiş veri kümesinin ulaştığı gözlemlenmiştir.

Beyin MRI görüntü bölütlemesi geçimizden günümüze kadar gelen ve hala popüler bir araştırma alanıdır. Bölütlemenin iyi ve doğru sonuç vermesi hastanın kanser ya da başka beyin hastalığının teşhisinde önemli rol oynamaktadır. Bu makalede, beyin MRI görüntü bölütlemesi yapılırken yeni güncel Çekişmeli Üretken Ağ önerilmiştir. Önerilen yöntem, çoğu bölütleme yöntemlerinden daha iyi bölütleme yaptığı gözlemlenmiştir. Aynı zamanda görüntü eğitilirken gerçek veri kümesindeki görüntülerin çözünürlüğünü daha iyi seviyeye çıkartıp görüntü iyileştirmesi yaptığı gözlemlenmiştir. Görüntünün iyileştirilmesi medikal alanda kullanılan veri kümelerinin görüntüyü sınıflandırmada, sentezlemede ve bölütlemede büyük öneme sahiptir. Birinci çalışmada iki boyutlu beyin MRI veri kümesi üzerinde önerilen yöntem ile mevcut son teknoloji (state-of-art) mimarilerinden CycleGAN, CUT, FastCUT, DCLGAN ve SimDCL yöntemleri karşılaştırılmıştır. Karşılaştırma yaparken ölçüm metriklerinden LPIPS, PSNR, FID ve KID kullanılmıştır. Metrik sonuçlarına bakıldığında 0.390 LPIPS, 30.719 PSNR, 92.366 FID ve 0.067 KID sonuçları ile en iyi sonucu verdiği gözlemlenmiştir. İkinci çalışmada veri kümesi çözünürlüğü iyileştirilmiştir. Ve önerilen yöntem hem çözünürlüğü arttırılmış veri kümesi için hem de normal veri kümesi için eğitilmiş ve sonuçlar alınmıştır. Metrik sonuçlarına bakıldığında çözünürlüğü arttırılmış veri kümesi 0.042 LPIPS, 37.138 PSNR, 20.070 FID, 0.007 KID sonuçları ile başarılı olduğu gözlemlenmiştir. Yapılan üçüncü çalışmada ise önerilen yöntem sonuçları ile günümüzde yaygın olarak kullanılan Volbrain beyin MRI görüntü bölütleme sonuçlarına yer verilmiştir. Volbrain bölütleme sonuçlarının önerilen yöntem bölütleme sonuçlarından 0.553 LPIPS, 32.184 PSNR, 77.125 FID ve 0.058 KID ile daha verimsiz sonuç verdiği gözlemlenmiştir. Önerilen yöntemin tatmin edici sonuçlar verdiği gözlemlenmiştir. Bu metod otomatik görüntü bölütleme sistemi olarak kullanılabilir.

## 7. KONTRASTLI ÖĞRENME TABANLI ÇEKİŞMELİ ÜRETKEN AĞLAR İLE MEDİKAL GÖRÜNTÜ BÖLÜTLEMEDE YENİ YAKLAŞIM

Tezin bu bölümünde, 6. Bölümde Beyin MRI veri kümesine uygulanan yeni kontrastlı öğrenme tabanlı çekişmeli üretken ağı daha iyi analiz edebilmek için ek olarak üç medikal veri kümesi kullanılarak sonuçlar elde edilmiş ve sonuçlar gözlemlenmiştir.

Görüntü bölütlemesi yapılırken son teknoloji (state-of-art) mimarilerinden CycleGAN, CUT, FastCUT, DCLGAN, SimDCL ve SSIMDCL (önerilen) yöntemleri kullanılmıştır. Veri kümeleri olarak Beyin MRI, PAPSMEAR, CHASEDB (fundus) ve XRAY (akciğer) kullanılmıştır.

Beyin MRI görüntü bölütlemesi hakkında kapsamlı bilgiye Bölüm 6'da, PAPSMEAR görüntü bölütlemesi hakkında kapsamlı bilgiye Bölüm 5'te değinilmiştir.

Fundus görüntü bölütlemesi için CHASEDB veri kümesi, akciğer görüntü bölütlemesi için XRAY veri kümesi kullanılmıştır.

Fundus görüntü alma teknolojisinin sınırlaması nedeniyle, retinanın kendisinin karmaşık ve değişken yapısı ile birlikte görüntüde genellikle çok fazla gürültü vardır. Bu, fundus görüntülerinin segmentasyonunu zorlaştırır. Birçok ÇÜA tabanlı yöntem, insan uzmanlardan daha iyi fundus görüntü segmentasyonunda performans gösterir. Fundus görüntülerinin otomatik bölütlenmesi çok zordur çünkü fundus görüntülerindeki damarların karmaşık dallanma paternleri vardır ve arka planda çok fazla gürültü vardır.

Lahiri ve arkadaşları, 2017 yılında retina kan damarlarını etkin bir şekilde segmentlere ayırmak için ilk kez ÇÜA yarı denetimli öğrenmeyi kullanmıştır (Lahiri vd., 2017). Iqbal ve Ali, 2018 yılında daha gerçekçi bir retinal görüntü üretmek ve segmentasyon görevine yardımcı olmak için bir dizi kayıp fonksiyonunu yeniden tanımladı (Iqbal ve Ali, 2018). Yang ve arkadaşları, 2020 yılında geminin kenarının ayrıntılarını doğru bir şekilde bölümlere ayırmak için üretici ve ayrıştırıcı ağ yapısını iyileştirdi (Yang vd., 2020). Wang ve arkadaşları 2021 yılında, OCT görüntülerindeki lezyonların segmentasyonu için CycleGAN tabanlı zayıf denetimli bir öğrenme ağı önerdi (Wang vd., 2021). Jiang ve diğerleri 2018 yılında ilk kez çatlak segmentasyonunu cilalamak için CGAN ve Zar kayıp fonksiyonunu uyguladı (Jiyang vd.,2018); Ouyang ve diğerleri 2019 yılında ve Yıldız ve diğerleri 2021 yılında korneayı segmentlere ayırmak için farklı ÇÜA tabanlı yöntemler kullanmışlardır (Ouyang vd., 2019; Yıldız vd., 2021) .

Tan ve diğeri 2021 yılında giriş BT taramalarının doğru akciğer bölütlemesini gerçekleştirmek için EM mesafeye dayalı kayıp fonksiyonunu ÇÜA ile birleştirmiştir (Tan vd., 2021). Her türlü akciğer hastalığı arasında akciğer kanseri en yaygın ölüm nedenlerinden biridir. Jin ve arkadaşları 2018 yılında daha gerçekçi pulmoner nodül görüntüleri oluşturmak için GAN'da yeni bir çoklu maske rekonstrüksiyon kaybı eklemiştir (Jin vd., 2018). Akciğer kanserinin varlığını doğru bir şekilde saptamak için Jain ve diğeri 2021 yılında akciğer nodülü segmentasyonu için salp shuffled shepherd optimizasyon algoritmasını kullanarak GAN modelini geliştirmiştir (Jain vd., 2021). Dai ve arkadaşları, 2018 yılında risk altındaki çoklu torasik organların otomatik segmentasyonunu gerçekleştirmek için farklı GAN'lar kullanmış, bu da radyoterapi planlarının geliştirilmesi için büyük kolaylık sağlamıştır. Guo ve arkadaşları, 2020 yılında sınır tanıma için U-net ve pektoral kas bölgelerini segmentlere ayırmak için şekil tahmini için GAN kullanmıştır (Guo vd.,2020).

Tezin bu bölümünde, medikal veri kümelerine (Beyin MRI, PAPSMEAR, CHASEDB, XRAY) ve ÇÜA mimarilerine (CUT, FASTCUT, CYCLEGAN, DCL, SimDCL ve SSimDCL (Önerilen ÇÜA mimarisi)) göre bölütleme analizi yapılmıştır. Bölütleme sonuçları hem görsel hem de nicel olarak elde edilmiştir. Sonuçlar ayrıntılı bir şekilde incelenmiştir. Önerilen yöntemin çoğu bölütleme yöntemlerinden daha iyi bölütleme yaptığı gözlemlenmiştir.

Bu çalışmanın ana katkıları şu şekilde sıralanabilir:

- Önerilen yöntemin denetimli olması görüntü bölütlemenin verimini arttırmıştır.
- Önerilen yöntemin medikal görüntü bölütlemeye günümüzde çoğu bölütlemeye iyi sonuç verdiği gözlemlenmektedir.

Çalışmanın kalan organizasyonu şu şekilde ilerlemektedir: Materyal ve metod olarak Bölüm 6.1'de bahsedilen yöntemler kullanılmıştır. Eğitim detayı olarak Bölüm 6.2'deki özelliklerin aynısı kullanılmıştır. Bahsedilen eğitim detayları Bölüm 6'da yapılan çalışma ile aynı özellikleri taşımaz. Kullanılan veri kümelerine Bölüm 7.1'de yer verilmiştir. Ölçüm metriklerine Bölüm 4'te yer verilmiştir. Deneysel çalışmalar ve sonuçlarına Bölüm 7.2'de, Bölüm 7.3'te genel sonuca verilmiştir.


## 7.1. Veri kümeleri

Beyin MRI veri kümesine Bölüm 6’da, PAPSMEAR veri kümesine Bölüm 3’te yer verilmiştir.

Fundus veri kümesi olarak CHASEDB kullanılmıştır. Eğitim için 21 adet gerçek ve bölütlenmiş fundus görüntüleri kullanılmıştır. Test için ise 7 adet gerçek ve bölütlenmiş görüntü kullanılmıştır. CHASEDB veri kümesi toplamda 28 adet gerçek ve 28 adet Bölütlenmiş olmak üzere 56 görüntü içermektedir.

Akciğer veri kümesi olarak XRAY kullanılmıştır. Eğitim aşaması için 218 çift gerçek ve maske görüntüsü (bölütlenmiş hali), test aşaması için 29 çift gerçek ve maske görüntüsü kullanılmıştır. Toplamda 247 çift gerçek ve maske görüntüden meydana gelmiştir.

Tüm görüntü boyutları 256x256x3 boyutundadır. Şekil 7.1’de veri kümeleri örneklerine rastlanmaktadır.



Şekil 7.1: Veri kümeleri (a) PAPSMEAR (b) XRAY (c) CHASEDB (d) Beyin MRI

## 7.2. Deneysel Çalışmalar ve Sonuçları

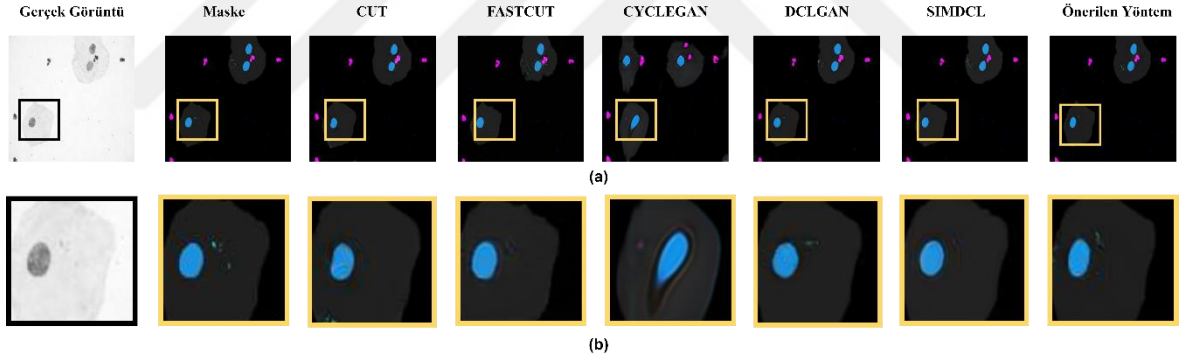
Yapılan çalışmada CycleGAN, CUT, FastCUT, DCLGAN, SimDCL ve önerilen yöntemin görüntü bölütlemesi yapılırken görsel ve nicel kıyaslanmasına yer verilmiştir.

### 7.2.1. Veri kümelerine göre görsel sonuçlar


Bu bölümde yapılan çalışmada; Beyin MRI, CHASEDB, PAPSMEAR ve XRAY veri kümelerinin ÇÜA yöntemlerine(CycleGAN, CUT, FastCUT, DCLGAN, SimDCL ve SSimDCL) göre test sonuçlarına yer verilmiştir.

Medikal görüntü bölütlerken kullanılan ve analizi yapılan veri kümesi Beyin MRI'dır. Beyin MRI ile ilgili literatür taramasına ve gerekli çalışmalara Bölüm 6'da yer verilmiştir.

Yapılan ikinci analizde PAPSMEAR veri kümesi ve ÇÜA mimarilerine göre Şekil 7.2 ve Şekil 7.3'de görsel, Çizelge 7.1'de ise metriksel sonuçlarına yer verilmiştir.



Şekil 7.2: PAPSMEAR veri kümesi üzerinde görsel çıktılar (a) Orijinal (b) Yakınlaştırılmış



Şekil 7.3: PAPSMEAR veri kümesine göre yöntemlerin görsel çıktıları

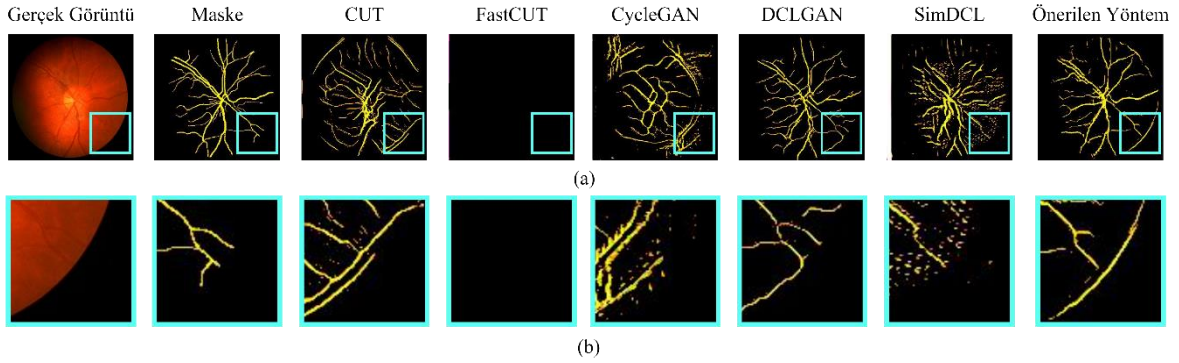
Şekil 7.2 ve Şekil 7.3 incelendiğinde maskeye en benzer sonucu DCLGAN ve önerilen yöntemin verdiği gözlemlenmiştir.

Çizelge 7.1: PAPSMEAR veri kümesinin metriksel benzerlik kıyaslaması


METODLAR	VERİ KÜMESİ	LPIPS ↓	PSNR ↑	FID ↓	KID ↓
CUT	PAPSMEAR	0.136	38.003	88.184	0.036
CycleGAN	PAPSMEAR	0.333	34.101	175.451	0.137
DCLGAN	PAPSMEAR	<u>0.086</u>	<u>39.437</u>	<b>70.577</b>	<u>0.023</u>
FastCUT	PAPSMEAR	0.201	36.977	128.182	0.105
SimDCL	PAPSMEAR	0.101	38.920	74.203	<u>0.023</u>
<b>Önerilen yöntem (SSimDCL)</b>	PAPSMEAR	<b>0.088</b>	<b>39.543</b>	<u>71.765</u>	<b>0.018</b>

Çizelge 7.1 PAPSMEAR veri kümesinin metriksel sonuçları kıyaslandığında 0.088 LPIPS, 39.543 PSNR ve 0.018 KID ile önerilen yöntemin; aynı zamanda 70.577 FID sonucu ile de DCLGAN yönteminin birinci sırada olduğu gözlemlenmiştir. İkinci sırada ise altı çizili şekilde gösterilen 0.086 LPIPS, 39.437 PSNR ve 0.023 KID ile DCLGAN ve 71.765 FID ile önerilen yöntem yer almaktadır. CycleGAN yönteminin ise 0.333 LPIPS, 34.101 PSNR, 175.451 FID ve 0.137 KID sonucu ile kıyaslanan yöntemlerin başarımı en az olanı olduğu gözlemlenmiştir.

Yapılan üçüncü analizde fundus görüntülerini içeren CHASEDB veri kümesi ve ÇÜA mimarilerine göre Şekil 7.4 ve Şekil 7.5’de görsel, Çizelge 7.2’de ise metrik sonuçlarına yer verilmiştir.



Şekil 7.4: CHASEDB veri kümesi görsel çıktılar (a) Orijinal (b) Yakınlaştırılmış



Şekil 7.5: CHASEDB veri kümesine göre yöntemlerin görsel çıktıları

Şekil 7.4 ve Şekil 7.5 incelendiğinde maskeye en benzer sonucu DCLGAN ve önerilen yöntemin verdiği gözlemlenmiştir. FastCUT yönteminin ise bölütleme yapamadığı gözlemlenmiştir.

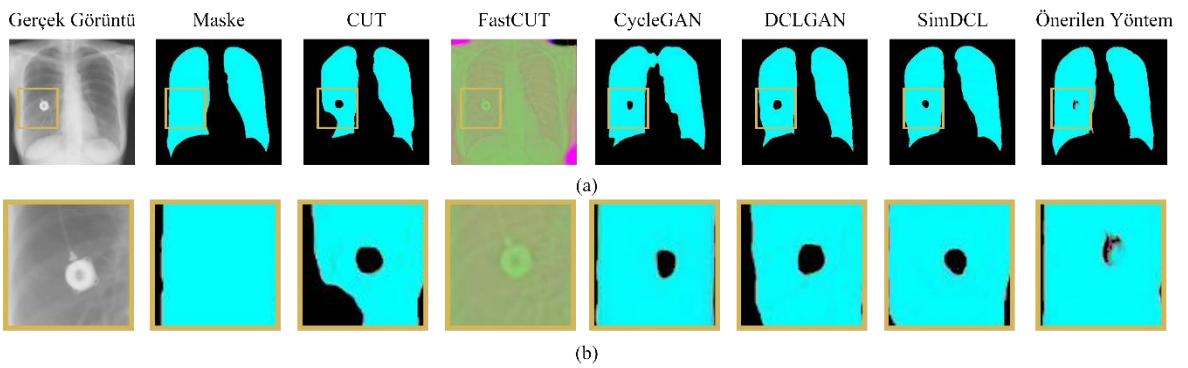


Çizelge 7.2: CHASEDB veri kümesinin metriksel benzerlik kıyaslaması

METODLAR	VERİ KÜMESİ	LPIPS ↓	PSNR ↑	FID ↓	KID ↓
CUT	<i>ChaseDB</i>	0.471	<u>31.965</u>	271.109	0.419
CycleGAN	<i>ChaseDB</i>	0.510	31.734	321.715	0.521
DCLGAN	<i>ChaseDB</i>	<u>0.437</u>	29.708	<b>195.445</b>	<b>0.232</b>
FastCUT	<i>ChaseDB</i>	0.512	28.208	513.687	0.890
SimDCL	<i>ChaseDB</i>	0.511	31.771	293.411	0.430
<b>Önerilen yöntem</b>	<i>ChaseDB</i>	<b>0.326</b>	<b>32.499</b>	<u>220.363</u>	<u>0.265</u>


Çizelge 7.2 CHASEDB veri kümesinin kullanıldığı yöntemlerin metriksel sonuçları kıyaslandığında 0.326 LPIPS, 32.499 PSNR ile önerilen yöntemin ve 195.445 FID, 0.232 KID ile DCLGAN yönteminin en başarılı olduğu gözlemlenmiştir. 0.437 LPIPS ile DCLGAN, 31.965 PSNR ile CUT, 220.363 FID ve 0.265 KID ile önerilen yöntemin ikinci sırada başarılı olduğu gözlemlenmiştir. CycleGAN yönteminin ise 0.333 LPIPS, 34.101 PSNR, 175.451 FID ve 0.137 KID sonucu ile kıyaslanan yöntemlerin başarımı en az olanı olduğu gözlemlenmiştir. FASTCUT yöntemi ise 0.512 LPIPS, 28.208 PSNR, 513.687 FID ve 0.890 KID metriksel sonuçları ile en geride kaldığı gözlemlenmiştir.

Yapılan dördüncü analizde akciğer görüntülerini içeren XRAY veri kümesi ve ÇÜA mimarilerine göre Şekil 7.6 ve Şekil 7.8’de görsel, Çizelge 7.3’de metriksel sonuçlarına yer verilmiştir.



Şekil 7.6: XRAY veri kümesi görsel çıktıları (a) Orijinal (b) Yakınlaştırılmış





Şekil 7.7: XRAY veri kümesine göre yöntemlerin görsel çıktıları

Şekil 7.6 ve Şekil 7.7 incelendiğinde maskeye en benzer sonucu SimDCL ve önerilen yöntemin verdiği gözlemlenmiştir.

Çizelge 7.3: XRAY veri kümesinin metriksel benzerlik kıyaslaması

METODLAR	VERİ KÜMESİ	LPIPS ↓	PSNR ↑	FID ↓	KID ↓
CUT	XRAY	0.222	<u>35.657</u>	122.164	0.071
CycleGAN	XRAY	0.254	35.144	166.677	0.153
DCLGAN	XRAY	0.210	35.046	130.629	0.098
FastCUT	XRAY	1.013	27.451	353.075	0.454
SimDCL	XRAY	<u>0.201</u>	35.363	<u>111.595</u>	<u>0.070</u>
<b>Önerilen yöntem</b>	XRAY	<b>0.128</b>	<b>36.138</b>	<b>106.646</b>	<b>0.065</b>

Çizelge 7.3, XRAY veri kümesinin kullanıldığı yöntemlerin metriksel sonuçları kıyaslandığında 0.128 LPIPS, 36.138 PSNR, 106.646 FID ve 0.065 KID ile önerilen yöntemin kıyaslanan diğer yöntemlerden daha iyi olduğu gözlemlenmiştir. İkinci sırada ise altı çizili şekilde gösterilen 0.201 LPIPS, 111.595 FID ve 0.070 KID değerleri ile SimDCL ve 35.657 PSNR ile CUT yöntemleri yer almaktadır. FASTCUT yönteminin ise 1.013

LPIPS, 27.451 PSNR, 353.075 FID ve 0.070 KID sonucu ile son sırada kaldığı gözlemlenmiştir.

### 7.3. Sonuç

Tezin bu bölümünde yapılan çalışmada CUT, FASTCUT, CycleGAN, DCLGAN, SimDCL ve önerilen yöntemin medikal bölütlemeye çeşitli veri kümeleri üzerindeki başarımları incelenmiştir.

Çizelgeler ve görseller genel olarak kontrol edildiğinde sırasıyla önerilen yöntem, DCLGAN ve SimDCL yöntemlerinin medikal görüntü bölütlemeye iyi sonuçlar verdiği, FASTCUT ve CycleGAN yönteminin ise verimli sonuçlar vermediği gözlemlenmiştir.

Önerilen yöntemin tatmin edici sonuçlar verdiği gözlemlenmiştir. Bu metod otomatik görüntü bölütleme sistemi olarak kullanılabilir.

## 8. ÖNERİLEN KONTRASTLI ÖĞRENME TABANLI ÇEKİŞMELİ ÜRETKEN AĞ İLE BEYİN TÜMÖRÜ ALGILAMA

Tıbbi görüntüler üzerinde analiz yapılırken MRI görüntüleri aracılığıyla beyin tümörünün tanınması oldukça zorludur. Teşhis süreci, karmaşıklığı ve tümör dokularındaki çeşitlilik bu süreci daha da zorlaştırmaktadır. Bu gibi sorunlar günümüzde tıbbi uygulamalar için tümör tanımlama yöntemlerinin gereksinimi artmaktadır.

Beyin tümörü görüntülerinin incelenip anlaşılması hem klinik tanı hakkında hem de hasta hakkında bilgi edinmeye yardımcı olur. Beyin tümörü, beyindeki hücrelerin anormal büyümesi olarak bilinir. Aynı zamanda beyinde bulunan istenmeyen hücre kümeleri de beyin tümörü olarak ifade edilmektedir. Beyinde birden fazla tümör çeşidi bulunmaktadır. Genel olarak tümörler kötü huylu ve iyi huylu olarak ikiye ayrılmaktadır. Kötü huylu tümör, akciğer veya meme gibi diğer vücut kısımlarından başlar ve beyne geçer.

Doğru beyin tümörü bölütlemesi, klinik araştırmalardaki tanı, tedavi ve ilerleyişinin izlenmesi açısından önemlidir. Beyin tümörü şekil, boyut ve konum açısından heterojen olduğu için bölütleme yapılırken zorlayıcıdır. Aynı zamanda beyin tümörü kendini beyin dokusunun içine gizlediği için ayırt edilmesi zordur. Genelde tümör bölütlemesinde kullanılan yöntem, bir uzman tarafından anatomik anormalliklerin incelenerek manuel olarak bölütlenmesidir.

Çoklu MRI görüntülerinden elde edilen T1, T1 kontrastlı (T1c), T2 ve FLAIR gibi veriler, manuel bölütlemeye daha ayrıntılı bilgi edinebilmek için entegre edilmiştir. Manuel bölütleme bu gibi engellerden dolayı zaman alıcı ve gözlemlenirken gözlemciler arası önyargıya eğilimlidir. Bu sebeplerden ötürü beyin tümöründe otomatik yöntemlerin olması klinik ortamda oldukça faydalı olacaktır.

Beyin Tümörü Bölütlemesi (BraTS) veri kümesi araştırmacıların yarışması için kullanılan açık kaynak verisidir (Brats, 2019). BraTS veri kümesi çoğunlukla ameliyat öncesi görüntüleme sonucudur. Burada beyin tümör bölgesi; tüm tümör, tümör çekirdeği ve güçlendirici çekirdeğe bölünür.

Beyin tümörünü otomatikleştirmede birçok çalışma yapılmıştır. Chen ve arkadaşları beyin tümörü bölütlemesi yaparken üstün kontrasta sahip olan T1 ve proton yoğunluğu içeren görüntüler kullanmışlardır (Chen vd., 2009). Ayrıca bölütleme tıbbi uygulamalarda (Vasilakos ve ark. 2016), memedeki lezyonların bilgisayar destekli tanınmasında (Kooi ve

diğerleri 2017), meme lezyonlarının ve pulmoner nodüllerin tanımlanmasında (Cheng ve diğerleri 2016) ve histopatolojik saptama (Litjens ve diğerleri 2016) olarak da uygulanmaktadır.

Günümüzde çoğu alanda kullanılan derin öğrenme mimarilerinden ESA (evrimsel sinir ağı), beyin MRI görüntülerinde ön işlem yaparken (Kleesiek vd., 2016), beyin tümörünün bölütlenmesinde (Havaei vd., 2017) ve tüm dokuların bulunmasında (Moeskops vd., 2016 ) yaygın olarak kullanılmaktadır.

Saoluli ve arkadaşları, beyin tümörü bölütlenmesinde uçtan uca artımlı ESA mimarisindeki tam otomatik yaklaşımlarını (3CNet, 2CNet ve EnsembleNet) kullanan toplu öğrenimi benimseyen ve sonuç olarak yüksek performans, doğru sonuç ve optimize edilmiş mimari gibi avantajları tanıtmışlardır (Saouli vd., 2018).

Wadhwa ve arkadaşları; ödem, aktif tümör ve nekroz gibi dokuların normal beyin dokularından bölütlenmesinde eşikleme, k-NN, SVM, YSA ve kümeleme tabanlı yöntemlerini kullanarak gerçekleştirmiştir (Wadhwa vd., 2019). Yapılan çalışmada farklı bölütleme yaklaşımlarının genel incelemesinden bahsedilmiştir. Bu çalışmada yapılan metriklerinin analizi, doktorların uygun tümör teşhisini sunmalarını desteklemektedir.

Chen ve arkadaşları ayrılabilir 3D U-Net kullanan S3D-UNet bölütleme yöntemini önermişlerdir (Chan vd., 2018). S3D-UNet, beyin tümörünün otomatik segmentasyonu için kullanılmaktadır. S3D konvolüsyonlarının 3D bilgiyi kullandığı varsayılmıştır. Mimari, baskın U-Net yapısını kullanan eksenel, sagittal ve koronal olmak üzere paralel bir şekilde 3 dal içermektedir.

Livne ve arkadaşlarının önerdiği ağ modeli, esas olarak serebrovasküler hastalıktan etkilenen hastalarda arteriyel beyin damarları bölütlenmesinde kullanılan kodlama, kod çözme bölümlerini içeren ESA'ya dayanmaktadır (Livne vd., 2019).

Murali ve Meena, MRI görüntülerinin tümör tespiti, lokalizasyonu ve örnek bölütlenmesinde Mask-RCNN algoritmasını kullanılır.

Gumaei ve arkadaşları, uygun beyin tümörü sınıflandırmasını gerçekleştiren yöntem önermiştir. Beynin kenarlarını ve kontrastını arttırmak için ilk aşamada min-maks normalleştirme kuralı kullanılarak ön işleme yapar. Daha sonra, hibrit özellik çıkarımı

kullanılarak tümör özelliklerini çıkartır. Son olarak, beyin tümörü tipini sınıflandırmak için RELM kullanmaktadır (Gumaei vd., 2019).

ÇÜA'lar; görüntü sınıflandırma, nesne algılama, yüksek çözünürlüklü görüntü oluşturma ve diğer birçok alanda ilgi odağı olmuştur. Tıbbi görüntü bölütlemeye ÇÜA, bölütleme sonuçlarını sürekli hale getirir ve görüntünün bölütleme sonuçlarını manuel değil de otomatik şekilde verimli bir şekilde çözer.

Luc ve arkadaşlarının yazmış olduğu “Zararlı Ağları Kullanarak Anlamsal Bölütleme” başlıklı makalesi çekişmeli ağı görüntü bölütlenme işlemine uygulayan ilk ÇÜA makalesidir (Luc vd., 2016). Li ve diğerleri, 2017 yılında beyin tümörlerini etkili bir şekilde bölütlemek için ÇÜA tabanlı yöntem kullanmışlardır (Li vd., 2017 ). Xue ve arkadaşları, ÇÜA'nın temel yapıtaşlarından olan U-net kısmını kullanarak beyin tümörlerinin doğrudan ve etkili bölütlenmesi için çok ölçekli L1 kaybı önermiştir (Xue vd., 2018). Conte ve arkadaşları eksik MRI dizilerini bölütlemeye ÇÜA kullanmışlardır. Aynı zamanda ÇÜA tarafından oluşturulan görüntülerin, bölütlemeye diğer derin öğrenme modellerine etkili bir şekilde yardımcı olabileceğini kanıtlamışlardır (Conte vd., 2021).

Tezin bu bölümünde beyin tümörü bölütlenirken günümüzde başarılı sonuçlar veren nnU-Net yöntemi ile önerilen yöntemin kıyaslanmasına yer verilmiştir. Beyin tümörü görüntüleri üç farklı veri kümesi (orijinal, fazlalıklarından arındırılmış ve iyileştirilmiş) oluşturularak sonuçlar alınmıştır. Sonuçlar görsel ve metriksel olarak incelenmiştir.

Bu çalışmanın ana katkısı, görüntüleme değişiminin görüntü eğitimdeki etkisini incelemek ve en iyi yönteme göre oluşturulan yöntemi analiz etmektir. Sonuç olarak önerilen yöntemin beyin tümörü algılayabildiği de gözlemlenmiştir.

Tezin bu bölümündeki kalan organizasyonu şu şekilde ilerlemektedir: Bölüm 8.1’de kullanılan yöntemlere (SSimDCL, nnU-Net); Bölüm 8.2’de eğitim detaylarına; Bölüm 8.3’te kullanılan veri kümesine; Bölüm 4’te bu bölüm için kullanılan ölçüm metriklerine ve Bölüm 8.4’te yapılan deneysel çalışmalar ve sonuçlarına yer verilmiştir.

## 8.1. Kullanılan Yöntemler

Bu bölümde beyin tümör veri kümesi üzerinde önerilen yöntem (SSimDCL) ile nnU-Net (Isensee vd., 2021) yöntemleri kullanılmıştır. SSimDCL yöntemine Bölüm 6’da ayrıntılı şekilde yer verilmiştir.

### 8.1.1.nnU-Net

nnU-Net, 2021 yılında Isensee ve arkadaşları tarafından önerilmiştir. Yapılan bu çalışmada, herhangi bir yeni bölütleme yapabilmek için ön işleme, ağ mimarisi, eğitim ve son işleme de dahil olmak üzere otomatik olarak yapılandırma yapan derin öğrenme tabanlı nnU-Net’i geliştirmişlerdir (Isensee vd., 2021).

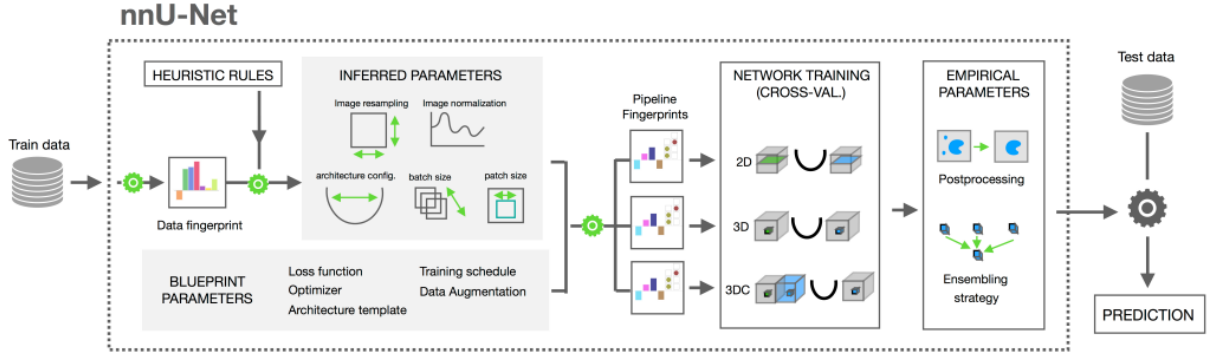
Bu süreçteki tasarım seçimleri, bir dizi sabit parametre, birbirine bağlı kurallar ve ampirik kararlar olarak modellenmektedir. nnU-Net, manuel müdahale olmadan uluslararası biyomedikal bölütleme yarışmalarında kullanılan 23 açık kaynaklı veri kümesinde son derece uzmanlaşmış çözümler de dahil olmak üzere mevcut yaklaşımların çoğunu geride bırakmıştır.

Isensee ve arkadaşları, nnU-Net’i standart ağ eğitiminin ötesinde ne uzman bilgisi ne de bilgi işlem kaynaklarına gerek duymadan son teknoloji bölütlemesini kullanıma hazır bir araç olarak herkese açık hale getirmişlerdir. nnU-Net çalışması, otomatik konfigürasyonunun genel uygulanabilirliği 13 ek veri kümesinde gösterilmiştir. Şekil ..’da kullanılan veri kümeleri gösterilmektedir. Toplamda, 53 adet bölütleme sonucunu analiz etmişlerdir. Sonuç olarak çoğu yöntemin nnU-Net’e göre geride kaldığı gözlemlenmiştir. nnU-Net, açık kaynaklı araç olarak son teknoloji bölütleme çalışmaları yapabilmede kullanıma hazır olarak eğitilebilmektedir.

nnU-Net, Medical Segmentation Decathlon (Antonelli vd., 2021) tarafından sağlanan on veri kümesi üzerinde geliştirilmiş ve doğrulanmıştır.

nnU-Net, rastgele yeni veri kümeleri için otomatik yapılandırma gerçekleştirebilir. nnU-Net, mevcut araştırma yöntemlerinin aksine bütünseldir, yani otomatik konfigürasyonu herhangi bir manuel karar olmaksızın bölütleme hattını (ağ mimarisinin temel topolojik parametreleri dahil) kapsar. nnU-Net’teki otomatik yapılandırma hızlıdır, kuralların basit bir şekilde yürütülmesini ve yalnızca birkaç deneysel seçimin yapılmasını içerir, bu nedenle standart model eğitiminin ötesinde neredeyse hiç hesaplama kaynağı gerektirmez. Son

olarak, nnU-Net veri açısından verimlidir; geniş ve çeşitli bir veri havuzuna dayalı kodlama tasarım seçimleri, sınırlı eğitim verisine sahip veri kümelerine uygulama için güçlü bir endüktif önyargı işlevi görür.



Şekil 8.1: nnU-Net mimarisi (Isense vd., 2021)

Şekil 8.1’de nnU-Net tarafından önerilen otomatik yapılandırma verilmiştir. Birinci aşamada, veri kümesi özellikleri bir “data fingerprint (veri parmak izi)” içinde önemli özelliklerine göre özetlenir. İşlem hattının veriye bağlı hiperparametrelerini çıkarmak için bu “fingerprint (parmak izi)” üzerinde bir dizi buluşsal kural çalışır (Şekil 8.1’deki HEURISTIC RULES ). Bunlar (INFERRED ve BLUEPRINT PARAMETERS), “boru hattı parmak izi (pipeline fingerprints)” oluşturmak için veriden bağımsız tasarım seçenekleri olan plan parametreleriyle tamamlanır. 5-katlı çapraz doğrulamada (5-fold cross validation) bu boru hattı parmak izlerine dayalı olarak üç mimari eğitilir. Son aşamada, nnU-Net bu mimarilerin en uygun grubunu otomatik olarak seçer ve gerekirse son işlemeyi gerçekleştirir. Böylece nnU-Net mimarisi için bölütleme işlemi gerçekleştirilmiş olur.


## 8.2. Eğitim Detayları

Genelde önerilen methodu eğitmek için DCLGAN (Han vd., 2021) ayarları örnek alınmıştır.  $\beta_1 = 0.5$  ve  $\beta_2 = 0.999$  ile Adam optimizasyonu (Diederik ve Jimmy, 2014) kullanılmıştır. Tüm yöntemler 100 iterasyon eğitilmiş ve sonuç alınmıştır. Öğrenme oranı 0.0001 olarak alınmıştır. ResNet (Kaiming vd., 2016) tabanlı üretici ağ ve PatchGAN (Phillip Isola vd., 2017) ayrıştırıcı ağ kullanılmıştır. Parti boyutu (batch size) 1 olarak alınmıştır ve örnek normalleştirme kullanılmıştır. Tüm eğitilecek görüntü boyutları 256x256 boyutundadır.

### 8.3. Veri Kümesi

Veri kümesi olarak Medical Segmentation Decathlon (Antonelli vd., 2021) tarafından sağlanan on veri kümesinden beyin tümörü üzerinde deneyler yapılmış ve sonuçlar alınmıştır. Beyin tümörü veri kümesi 4 boyutlu verilerden oluşmaktadır. nnU-Net öncelikle bu veri kümesini 3 boyutlu hale getirir. nnU-Net üzerinde beyin tümörü bölütlemesi yapılırken 3 boyutlu veriler kullanılmıştır. Eğitim aşaması için 33 adet beyin tümörü görüntüsü ve maskesi, test aşaması için 10 adet beyin MRI görüntüsü kullanılmıştır. SSIMDCL için bu 3 boyutlu görüntüler 2 boyutlu görüntülere çevrilerek kullanılmıştır. 3 boyutludan 2 boyutluya dönüşüm için Matlab 2019b ortamında yazılmış uygulama çalıştırılarak elde edilmiştir.


3 boyutlu veri kümesi 2 boyutluya çevrilirken üç aşamalı veri kümesini oluşturularak kullanılmıştır. Oluşturulan iki boyutlu görüntülerin hepsi 256x256x3 boyutundadır. Birinci aşamada oluşturulan veri kümesi 3 boyutludan direk iki boyutluya çevirilerek kullanılmıştır. Birinci aşamada oluşturulan verilerin örnekleri Şekil 8.2’de gösterilmiştir.



**Şekil 8.2:** Orijinal Veri Kümesi (a) Tüm beyin (b) a'dan elde edilen beyin tümörü


İkinci aşamada, birinci aşamada oluşturulan 2 boyutlu beyin MRI görüntüsünün köşelerinde bulunan siyahlıklar uygun yöntemlerle kırılarak sadece beyin görüntülerinin kalması istenmiştir. Matlab 2019b ortamında fonksiyon oluşturulmuştur. Oluşturulan fonksiyona göre beyin tümörünün gerçek görüntülerinin köşeleri beynin bulunduğu hizaya göre kırılmıştır ve maske görüntüleri ise bu kırma işlemine göre uygun oranda kırılmıştır. Şekil 8.3’de bu görüntülere yer verilmiştir.






**Şekil 8.3:** Fazlalıkları Elimine Edilmiş Veri Kümesi (a) Tüm beyin (b) a'dan elde edilmiş beyin tümörü

Üçüncü aşamada oluşturulan veri kümesi ise ikinci aşamada oluşturulan 2 boyutlu beyin MRI görüntüsü için iyileştirme yapılmıştır. Görüntüler üzerinde iyileştirme yapabilmek için Matlab 2019b ortamında fonksiyon oluşturulmuştur. Oluşturulan fonksiyonun ilk aşamasında görüntü ayarlaması ve görüntü keskinleştirilmesi yapılmıştır. Son aşamada ise gauss filtresi uygulanmıştır. Gauss filtresindeki standart sapma 0.2 alınmıştır. Tüm bu işlemler aşamalı olarak yapılarak beyin tümörünün ve maskesinin iyileştirilmiş görüntüleri oluşturulmuştur. Şekil 8.4'te iyileştirilmiş görüntülere yer verilmiştir.



**Şekil 8.4:** İyileştirilmiş Veri Kümesi (a) Tüm beyin (b) a'dan elde edilen beyin tümörü

Şekil 8.5'de yukarıda açıklanan veri kümeleri oluşturulurken aşamalı değişimleri kısaca gösterilmiştir.



Şekil 8.5: Veri Kümeleri (a) Orjinal (b) Fazlalıkları elimine edilmiş (c) İyileştirilmiş

#### 8.4. Deneysel Çalışmalar ve Sonuçları


Bu bölümde yapılan çalışmadaki amaç güncel en iyi yöntemlerle önerilen yöntemin incelenmesi ve analizinin yapılmasıdır. Beyin tümörü görüntüleri üzerinde VolBrain, nnU-Net ve önerilen yöntem karşılaştırılmıştır. volBrain'in sadece dokusal bölütleme yapıp beyin tümörü bölütlemesini gerçekleştiremediği gözlemlenmiştir. Bu sebeple deneysel çalışmalar olarak önerilen yöntem ile nnU-Net sonuçlarına yer verilmiştir.

İlk aşamada nnU-Net 3 boyutlu görüntüler üzerinde, önerilen yöntem bu görüntülerin 2 boyutluya çevrilmesi ile eğitilmiştir. Kıyaslama yapılırken yöntemlerin test sonuçları aynı özellikler baz alınarak 2 boyutlu görüntüler üzerinde değerlendirilmiştir.

Beyin tümörü bölütlemesi kullanılırken üç adet veri kümesi kullanılmıştır. Oluşturulan veri kümeleri bu bölümün ilgili kısmında geniş bir şekilde açıklanmıştır.


Yapılan birinci çalışmada normal veri kümesi üzerinden nnU-Net ve önerilen yöntemin beyin tümörü bölütlemedeki başarımı hem görsel hem de tablosal olarak yorumlanmıştır.

Şekil 8.6'da orjinal veri kümesine göre nnu-net ve önerilen yönteminin beyin tümörü bölütlemede görsel sonuçları gösterilmektedir.




Şekil 8.6: Orjinal veri kümesine göre nnU-Net ve önerilen yöntemin görsel kıyaslanması

Şekil 8.7’de fazlalıkları elimine edilmiş veri kümesine göre nnU-Net ve önerilen yöntemin beyin tümörü bölütlemesinde görsel sonuçları gösterilmektedir.



**Şekil 8.7:** Fazlalıkları elimine edilmiş veri kümesine göre nnU-Net ve önerilen yöntemin kıyaslanması

Şekil 8.8’de beyin tümörünü daha iyi algılayabilmek için keskinleştirip gauss filtresi eklenen veri kümesinin beyin tümörü bölütleme sonuçlarına yer verilmiştir.



Şekil 8.8: İyileştirilen veri kümesine göre nnU-Net ve önerilen yöntemin görsel kıyaslanması

Şekil 8.7, Şekil 8.8 ve Şekil 8.6 duysal analiz yapılarak incelenmiştir. Önerilen yöntemin iyileştirilmiş görüntüler üzerindeki sonuçlarının (Şekil 8.8) nnU-Net'e göre

başarılı olduğu ve hatta orijinal beyin tümörü bölütlenirken gerçek maskesinden daha yumuşak çizgileri olduğu gözlemlenmiştir.

Çizelge 8.1’de sırasıyla normal veri kümesi, düzenlenmiş veri kümesi ve iyileştirilmiş veri kümesinin öneril yöntem ve nnU-Net üzerindeki LPIPS ve PSNR metriksel sonuçlarına yer verilmiştir.

Normal veri kümesi için 0.043 LPIPS ve 43.882 PSNR ile nnU-Net yöntemi başarılıdır. Düzenlenmiş veri kümesinde 0.095 LPIPS ve 38.883 PSNR ile nnU-Net yöntemi başarılıdır. Fakat normal veri kümesi ile düzenlenmiş veri kümesindeki önerilen yöntemin sonuçları iyi yönde değişmiş olup nnU-Net ile aradaki fark azalma göstermiştir. Son olarak iyileştirilmiş veri kümesine bakıldığında 0.095 LPIPS ve 38.510 PSNR ile nnU-Net yöntemi birinci, 0.096 LPIPS ve 38.556 PSNR ile önerilen yöntem ikinci sıradadır. İyileştirme yapılmış veri kümesi sonuçlarına bakılarak nnU-Net yöntemine çok yaklaştığı gözükmektedir.

**Çizelge 8.1:** Önerilen yöntem ve nnU-Net yönteminin metriksel kıyaslanması

<b>NORMAL VERİ KÜMESİ</b>	<b>LPIPS ↓</b>	<b>PSNR ↑</b>
Önerilen Yöntem	0.092	41.288
nnU-Net	<u>0.043</u>	<u>43.882</u>
<b>DÜZENLENMİŞ VERİ KÜMESİ</b>	<b>LPIPS ↓</b>	<b>PSNR ↑</b>
Önerilen Yöntem	0.119	38.792
nnU-Net	<u>0.095</u>	<u>38.883</u>
<b>İYİLEŞTİRİLMİŞ VERİ KÜMESİ</b>	<b>LPIPS ↓</b>	<b>PSNR ↑</b>
Önerilen Yöntem	<u>0.096</u>	<u>38.556</u>
nnU-Net	<u>0.095</u>	<u>38.510</u>

## 8.5. Sonuç

Tezin bu bölümünde yapılan çalışmada nnU-Net ve önerilen yöntemin beyin tümörü bölütlemde üç aşamalı değiştirilen yani üç farklı veri kümesi üzerindeki başarımları incelenmiştir.

Üç aşamalı beyin tümörü veri kümesinin birinci aşaması, orijinal veri kümesinin direk alınmasıdır. İkinci aşaması köşelerinde fazlalık olarak bulunan siyah kısımların giderilmesidir. Üçüncü aşamadaki veri kümesi ise keskinleştirilip görüntü ayarlaması yapıldıktan sonra gauss filtresi eklenen iyileştirilmiş beyin tümörü görüntüleridir.

Bu veri kümelerine uygun sırayla nnU-Net ve önerilen yöntem göre sonuçları incelendiğinde Şekil 8.6'da nnU-Net yönteminin daha başarılı olduğu, Şekil 8.8'deki iyileştirilmiş veri kümesi üzerinde ise önerilen yöntemin diğer yöntemle kıyasla daha iyi sonuç verdiği gözlemlenmiştir.

Çizelge 8.1'de yukarıdan aşağıya veri kümelerine göre nnU-Net ve önerilen yöntemin LPIPS ve PSNR metriksel benzerlik sonuçlarına yer verilmiştir. Görüntüler iyileştikçe önerilen yöntemin daha başarılı sonuçlar verdiği gözlemlenmiştir.

Tezin bu bölümünde yapılan çalışmada sonuç Olarak, nnU-Net yönteminin başarılı bir beyin tümörü bölütleyicisi olduğu ve önerilen yöntemin ise görüntü iyileştirildikçe nnU-Net'e neredeyse benzer sonuçlar ürettiği gözlemlenmiştir.

## Teşekkür

Bu çalışma İnönü Üniversitesi Bilimsel Araştırma ve Koordinasyon birimi tarafından "FDK-2021-2675" proje numarası ile finanse edilmiştir. İnönü Üniversitesi'ne teşekkürlerimizi sunarız.

## KAYNAKLAR

- Altun, S., & Talu, M. F.** (2022). Çekişmeli üretken ağlarla PAPSMEAR görüntüsü oluşturmada yeni bir yaklaşım. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(3), 1401-1410.
- Altun, S., Sahin, E., Talu, M. F.** (2022). Çekişmeli Üretken Ağların Evrimsel Sinir Ağı Tabanlı Algısal Benzerlik Metrikleri ile Görüntü Sentezlemesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* (Değerlendirme aşamasında)(Gönderim Tarihi 21.10.2021).
- Altun Güven, S., & Talu, M.F.** (2022). Brain Mri High Resolution Image Creation And Segmentation With The New Gan Method. *Biomedical Signal Processing and Control* (Review aşamasında)(Gönderim tarihi: 02/03/2022).
- Altun, S., & Talu, M. F.** (2021). Investigation of Hyperparametry Methods and Kits for Deep Neural Networks. *Dicle University Journal of Engineering*, 12(2), 1.
- Altun, S., & Talu, M. F.** (2021). Sentetik PAPSMEAR Hücre Çekirdeği Üretiminde Üretici Çekişmeli Ağların Kullanılması. *Avrupa Bilim ve Teknoloji Dergisi*, (23), 781-786.
- Altun, S., & Talu, M. F.** (2021). Görüntüden Görüntüye Dönüşüm ve Görüntü Sentezleme Yapan Üretici Çekişmeli Ağların İncelenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 53-60.
- Altun, S., & Talu, M. F.** (2022). Kontrastlı Öğrenme Tabanlı Çekişmeli Üretken Ağlar İle PAPSMEAR Görüntü Bölütleme. *Anatolian Science - Bilgisayar Bilimleri Dergisi*.
- Altun, S., & Talu, M. F.** (2019, October). Aynı Şartlar Altında Farklı Üretici Çekişmeli Ağların Karşılaştırılması. *In 2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-6). IEEE.
- Antonelli, M., Reinke, A., Bakas, S., Farahani, K., Landman, B. A., Litjens, G., ... & Cardoso, M. J.** (2021). The medical segmentation decathlon. *arXiv preprint arXiv:2106.05735*.
- Azadi, S., Tschannen, M., Tzeng, E., Gelly, S., Darrell, T., & Lucic, M.** (2019) Semantic bottleneck scene generation, *arXiv preprint arXiv:1911.11357*.
- Barzegar, Z., & Jamzad, M.** (2021). WLFS: Weighted label fusion learning framework for glioma tumor segmentation in brain MRI. *Biomedical Signal Processing and Control*, 68, 102617.
- Beers, A., Brown, J., Chang, K., Campbell, J. P., Ostmo, S., Chiang, M. F., & Kalpathy-Cramer, J.** (2018). High-resolution medical image synthesis using progressively grown generative adversarial networks. *arXiv preprint arXiv:1805.03144*.
- Bińkowski, M., Sutherland, D. J., Arbel, M., & Gretton, A.** (2018). Demystifying mmd gans. *arXiv preprint arXiv:1801.01401*.



- Borne, L.; Rivière, D.; Mangin, J.F.** (8-10 July 2019). Combining 3D U-Net and bottom-up geometric constraints for automatic cortical sulci recognition. *In Proceedings of the International Conference on Medical Imaging with Deep Learning*, London, UK.
- BRATS.** (erişim: 20.05.2022). Bmultimodal brain tumor segmentation challenge 2019. 2019. <http://braintumorsegmentation.org/>
- C. Shakuntala** (2016). Cervical cancer preventable, treatable, but continues to kill women, *Medknow Publications*, 1.
- Casamitjana, A.; Catà, M.; Sánchez, I.; Combalia, M.; Vilaplana, V.** (14 September 2017). Cascaded V-Net using ROI masks for brain tumor segmentation. *In Proceedings of the International MICCAI Brainlesion Workshop*, Quebec City, QC, Canada,; pp. 381–391.
- Chen, P. F., Steen, R. G., Yezzi, A., & Krim, H.** (2009, April). Brain MRI T1-Map and T1-weighted image segmentation in a variational framework. *In 2009 IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 417-420). IEEE.
- Chen, W., Liu, B., Peng, S., Sun, J., & Qiao, X.** (2018, September). S3D-UNet: separable 3D U-Net for brain tumor segmentation. *In International MICCAI Brainlesion Workshop* (pp. 358-368). Springer, Cham.
- Cheng, J. Z., Ni, D., Chou, Y. H., Qin, J., Tiu, C. M., Chang, Y. C., ... & Chen, C. M.** (2016). Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans. *Scientific reports*, 6(1), 1-13.
- Choi, Y., Choi, M., Kim, M., Ha, J. W., Kim, S., & Choo, J.** (2018). Stargan: Unified generative adversarial networks for multi-domain image-to-image translation, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 8789-8797.
- Christ, P.F.; Elshaer, M.E.A.; Ettliger, F.; Tatavarty, S.; Bickel, M.; Bilic, P.; Rempfler, M.; Armbruster, M.; Hoffman, F.; D’Anastasi, M.; et al.** ( 17–21 October 2016) Automatic liver and lesion segmentation in CT using cascaded fully convolutional neural networks and 3D conditional random fields. *In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*, Athens, Greece,; pp. 415–423.
- Clough, J. R., Byrne, N., Oksuz, I., Zimmer, V. A., Schnabel, J. A., & King, A. P.** (2019). A topological loss function for deep-learning based image segmentation using persistent homology. *arXiv preprint arXiv:1910.01877*.
- Conte, G. M., Weston, A. D., Vogelsang, D. C., Philbrick, K. A., Cai, J. C., Barbera, M., ... & Erickson, B. J.** (2021). Generative adversarial networks to synthesize missing T1 and FLAIR MRI sequences for use in a multisequence brain tumor segmentation model. *Radiology*, 299(2), 313-323.
- Dai, W., Dong, N., Wang, Z., Liang, X., Zhang, H., & Xing, E. P.** (2018). Scan: Structure correcting adversarial network for organ segmentation in chest x-rays. *In Deep learning in medical image analysis and multimodal learning for clinical decision support* (pp. 263-273). Springer, Cham.

- Deng, L.** (2012). The mnist database of handwritten digit images for machine learning research. *IEEE Signal Processing Magazine*, 29(6), 141–142.
- Diederik P Kingma and Jimmy Ba.** (2014). Adam: A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*.
- Ding, K., Ma, K., Wang, S., & Simoncelli, E. P.** (2020). Image quality assessment: Unifying structure and texture similarity. *arXiv preprint arXiv:2004.07728*
- Ding, K., Ma, K., Wang, S., & Simoncelli, E. P.** (2021). Comparison of full-reference image quality models for optimization of image processing systems. *International Journal of Computer Vision*, 129(4), 1258-1281.
- Fardo F A., Conforto V H., Oliveira F C., Rodrigues P.** (2016). A Formal Evaluation of PSNR as Quality Measurement Parameter for Image Segmentation Algorithms. *ArXiv*, abs/1605.07116.
- G. Hu, and Mageras.** (2009). “Survey of recent volumetric medical image segmentation techniques,” *Biomedical Engineering*, Vukovar, Croatia: In-Tech, pp. 3216, 2009.
- Gatys, L. A., Ecker, A. S., & Bethge, M.** (2015). A neural algorithm of artistic style. *arXiv preprint arXiv:1508.06576*.
- Gautam, S., Jith, N., Sao, A. K., Bhavsar, A., & Natarajan, A.** (2018) Considerations for a PAP smear image analysis system with CNN features, *arXiv preprint arXiv:1806.09025*.
- Giacomello, E.; LoIacono, D.; Mainardi, L.** (2019) Brain MRI Tumor Segmentation with Adversarial Networks. *arXiv*, arXiv:1910.02717.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y.** (2014). Generative adversarial nets. *In Advances in neural information processing systems* (pp. 2672-2680).
- Gu, Z., Cheng, J., Fu, H., Zhou, K., Hao, H., Zhao, Y., ... & Liu, J.** (2019). Ce-net: Context encoder network for 2d medical image segmentation. *IEEE transactions on medical imaging*, 38(10), 2281-2292.
- Gumaei, A., Hassan, M. M., Hassan, M. R., Alelaiwi, A., & Fortino, G.** (2019). A hybrid feature extraction method with regularized extreme learning machine for brain tumor classification. *IEEE Access*, 7, 36266-36273.
- Guo, Y., Zhao, W., Li, S., Zhang, Y., & Lu, Y.** (2020). Automatic segmentation of the pectoral muscle based on boundary identification and shape prediction. *Physics in Medicine & Biology*, 65(4), 045016.
- Han, J., Shoeiby, M., Petersson, L., & Armin, M. A.** (2021). Dual Contrastive Learning for Unsupervised Image-to-Image Translation. *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 746-755).

- Hanbay K.** (2020). Hyperspectral image classification using convolutional neural network and twodimensional complex Gabor transform , *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (1), 443-456.
- Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., ... & Larochelle, H.** (2017). Brain tumor segmentation with deep neural networks. *Medical image analysis*, 35, 18-31.
- Hertzmann, A., Jacobs, C. E., Oliver, N., Curless, B., & Salesin, D. H.** (2001, August). Image analogies. In *Proceedings of the 28th annual conference on Computer graphics and interactive techniques* (pp. 327-340).
- Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S.** (2017). Gans trained by a two time-scale update rule converge to a local nash equilibrium. *Advances in neural information processing systems*, 30.
- Houssein, E. H., Helmy, B. E. D., Oliva, D., Jangir, P., Premkumar, M., Elngar, A. A., & Shaban, H.** (2022). An efficient multi-thresholding based COVID-19 CT images segmentation approach using an improved equilibrium optimizer. *Biomedical Signal Processing and Control*, 73, 103401.
- Huang, X., Liu, M. Y., Belongie, S., & Kautz, J.** (2018). Multimodal unsupervised image-to-image translation. In *Proceedings of the European conference on computer vision (ECCV)*, 172-189.
- Isensee, F., Jaeger, P. F., Kohl, S. A., Petersen, J., & Maier-Hein, K. H.** (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature methods*, 18(2), 203-211.
- Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A.** (2017) Image-to-image translation with conditional adversarial networks, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 1125-1134.
- Iqbal, T., & Ali, H.** (2018). Generative adversarial network for medical images (MI-GAN). *Journal of medical systems*, 42(11), 1-11.
- Jain, S., Indora, S., & Atal, D. K.** (2021). Lung nodule segmentation using Salp Shuffled Shepherd Optimization Algorithm-based Generative Adversarial Network. *Computers in biology and medicine*, 137, 104811. <https://doi.org/10.1016/j.compbiomed.2021.104811>
- Jiang, H., Ma, Y., Zhu, W., Fan, Y., Hua, Y., Chen, Q., & Chen, X.** (2018). cGAN-Based Lacquer Cracks Segmentation in ICGA Image. In *Computational Pathology and Ophthalmic Medical Image Analysis* (pp. 228-235). Springer, Cham.
- Jin, D., Xu, Z., Tang, Y., Harrison, A. P., & Mollura, D. J.** (2018, September). CT-realistic lung nodule simulation from 3D conditional generative adversarial networks for robust lung segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 732-740). Springer, Cham.

- Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun.** (2016). Deep residual learning for image recognition. *In IEEE Conference on Computer vision and pattern recognition (CVPR)*, pages 770–778.
- Kasim, Ö., & Kuzucuoğlu, A.** (2015). Detection And Classification Of Leukocyte Cells From Smear Image, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 30(1),95-109.
- Kaya, H., Cavusoglu, A., Çakmak, H. B., Sen, B., & Delen, D.** (2016) Supporting the diagnosis process and processes after treatment by using image segmentation and image simulation techniques: Keratoconus example, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 31(3), 0-0.
- Kayalibay, B., Jensen, G., & van der Smagt, P.** (2017). CNN-based segmentation of medical imaging data. *arXiv preprint arXiv:1701.03056*.
- Khosravan, N.; Mortazi, A.; Wallace, M.; Bagci** (13–18 October 2019) U. Pan: Projective adversarial network for medical image segmentation. *In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*, Shenzhen, China, pp. 68–76.
- Kim, T., Cha, M., Kim, H., Lee, J. K., & Kim, J.** (July 2017). Learning to discover cross-domain relations with generative adversarial networks, *In International Conference on Machine Learning*, 1857-1865, PMLR.
- Kleesiek, J., Urban, G., Hubert, A., Schwarz, D., Maier-Hein, K., Bendszus, M., & Biller, A.** (2016). Deep MRI brain extraction: A 3D convolutional neural network for skull stripping. *NeuroImage*, 129, 460-469.
- Kooi, T., Litjens, G., Van Ginneken, B., Gubern-Mérida, A., Sánchez, C. I., Mann, R., ... & Karssemeijer, N.** (2017). Large scale deep learning for computer aided detection of mammographic lesions. *Medical image analysis*, 35, 303-312.
- Lahiri, A., Ayush, K., Kumar Biswas, P., & Mitra, P.** (2017). Generative adversarial learning for reducing manual annotation in semantic segmentation on large scale microscopy images: Automated vessel segmentation in retinal fundus image as test case. *In Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 42-48).
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P.** (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Li, Z., Wang, Y., & Yu, J.** (2017, September). Brain tumor segmentation using an adversarial network. *In International MICCAI brainlesion workshop* (pp. 123-132). Springer, Cham.
- Lin, J., Chen, Z., Xia, Y., Liu, S., Qin, T., & Luo, J.** (2019) Exploring explicit domain supervision for latent space disentanglement in unpaired image-to-image translation, *IEEE transactions on pattern analysis and machine intelligence*.
- Liu, M. Y., Breuel, T., & Kautz, J.** (2017) Unsupervised image-to-image translation networks, *arXiv preprint arXiv:1703.00848*.

- Liu, Q., Chen, C., Qin, J., Dou, Q., & Heng, P. A.** (2021). Feddg: Federated domain generalization on medical image segmentation via episodic learning in continuous frequency space. *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 1013-1023).
- Litjens, G., Sánchez, C. I., Timofeeva, N., Hermsen, M., Nagtegaal, I., Kovacs, I., ... & Van Der Laak, J.** (2016). Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. *Scientific reports*, 6(1), 1-11.
- Livne, M., Rieger, J., Aydin, O. U., Taha, A. A., Akay, E. M., Kossen, T., ... & Madai, V. I.** (2019). A U-Net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease. *Frontiers in neuroscience*, 97.
- Long, J., Shelhamer, E., & Darrell, T.** (2015). Fully convolutional networks for semantic segmentation. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3431-3440).
- Luc, P., Couprie, C., Chintala, S., & Verbeek, J.** (2016). Semantic segmentation using adversarial networks. *arXiv preprint arXiv:1611.08408*.
- Malm, P., Brun, A., & Bengtsson, E.** (2015). Simulation of bright-field microscopy images depicting pap-smear specimen. *Cytometry Part A*, 87 (3), 212-226.
- Manjón, J. V., & Coupé, P.** (2016). volBrain: an online MRI brain volumetry system. *Frontiers in neuroinformatics*, 10, 30.
- Mejjati, Y. A., Richardt, C., Tompkin, J., Cosker, D., & Kim, K. I.** (2018) Unsupervised attention-guided image to image translation. *arXiv preprint arXiv:1806.02311*.
- Milletari, F., Navab, N., & Ahmadi, S. A.** (2016, October). V-net: Fully convolutional neural networks for volumetric medical image segmentation. *In 2016 fourth international conference on 3D vision (3DV)* (pp. 565-571). IEEE.
- Mihelich M., Dognin C., Shu Y., Blot M.** (2020). A Characterization of Mean Squared Error for Estimator with Bagging. *ArXiv*, abs/1908.02718.
- Moeskops, P.; Veta, M.; Lafarge, M.W.; Eppenhof, K.A.J.; Pluim, J.P.W.** (2017). Adversarial training and dilated convolutions for brain MRI segmentation. *In Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*; Springer: Cham, Switzerland, pp. 56–64.
- Moeskops, P., Viergever, M. A., Mendrik, A. M., De Vries, L. S., Benders, M. J., & Išgum, I.** (2016). Automatic segmentation of MR brain images with a convolutional neural network. *IEEE transactions on medical imaging*, 35(5), 1252-1261.
- Mun, J., Jang, W. D., Sung, D. J., & Kim, C. S.** (2017, September). Comparison of objective functions in CNN-based prostate magnetic resonance image segmentation. *In 2017 IEEE International Conference on Image Processing (ICIP)* (pp. 3859-3863). IEEE.
- Murali, E., & Meena, K.** (2019). Stochastic gradient descent optimizer for segmentation of brain tumor using Mask R-CNN.

- Myronenko, A.** (17 October 2018) 3D MRI brain tumor segmentation using autoencoder regularization. In *Proceedings of the International MICCAI Brainlesion Workshop*, Shenzhen, China, pp. 311–320.
- Nie, D.; Wang, L.; Adeli, E.; Lao, C.; Lin, W.; Shen, D.** (2019). 3-D fully convolutional networks for multimodal isointense infant brain image segmentation. *IEEE Trans. Cybern.*, 49, 1123–1136. [CrossRef] [PubMed]
- Nilsson, J., & Akenine-Möller, T.** (2020). Understanding ssim. *arXiv preprint arXiv:2006.13846*.
- Ouyang, J., Mathai, T. S., Lathrop, K., & Galeotti, J.** (2019). Accurate tissue interface segmentation via adversarial pre-segmentation of anterior segment OCT images. *Biomedical Optics Express*, 10(10), 5291-5324.
- Park, T., Efros, A. A., Zhang, R., & Zhu, J. Y.** (2020, August). Contrastive learning for unpaired image-to-image translation. In *European Conference on Computer Vision* (pp. 319-345). Springer, Cham.
- Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, and Alexei A Efros.** (2017) Image-to-image translation with conditional adversarial networks. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- PSNR.** (Erişim Tarihi: 31.12.2021). [https://en.wikipedia.org/wiki/Peak\\_signal-to-noise\\_ratio](https://en.wikipedia.org/wiki/Peak_signal-to-noise_ratio).
- Reisenhofer, R., Bosse, S., Kutyniok, G., & Wiegand, T.** (2018). A Haar wavelet-based perceptual similarity index for image quality assessment. *Signal Processing: Image Communication*, 61, 33-43.
- Rezaei, M.; Harmuth, K.; Gierke, W.; Kellermeier, T.; Fischer, M.; Yang, H.; Meinel, C.** (14 September 2017). A conditional adversarial network for semantic segmentation of brain tumor. In *Proceedings of the International MICCAI Brainlesion Workshop*, Quebec City, QC, Canada, pp. 241–252.
- R. S. A. V. K. V. Shrimali.** (2009). “Current trends in segmentation of medical ultrasound B-mode images: A review,” *IETE Tech. Rev.*, Vol. 1, no. 817, pp. 26, 2009.
- Saouli, R., Akil, M., & Kachouri, R.** (2018). Fully automatic brain tumor segmentation using end-to-end incremental deep neural networks in MRI images. *Computer methods and programs in biomedicine*, 166, 39-49.
- Sheikh, H. R., & Bovik, A. C.** (2006). Image information and visual quality. *IEEE Transactions on image processing*, 15(2), 430-444.
- Simonyan, K., & Zisserman, A.** (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Taha, A. A., & Hanbury, A.** (2015). Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC medical imaging*, 15(1), 1-28.

- Wang, T. C., Liu, M. Y., Zhu, J. Y., Tao, A., Kautz, J., & Catanzaro, B.** (2018). High-resolution image synthesis and semantic manipulation with conditional gans. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 8798-8807.
- Wang, Z., Simoncelli, E. P., & Bovik, A. C.** (2003, November). Multiscale structural similarity for image quality assessment. *In The Thrity-Seventh Asilomar Conference on Signals, Systems & Computers*, 2003 (Vol. 2, pp. 1398-1402). Ieee.
- Wang, G., Li, W., Zuluaga, M. A., Pratt, R., Patel, P. A., Aertsen, M., ... & Vercauteren, T.** (2018). Interactive medical image segmentation using deep learning with image-specific fine tuning. *IEEE transactions on medical imaging*, 37(7), 1562-1573.
- Wang, S.; Yi, L.; Chen, Q.; Meng, Z.; Dong, H.; He, Z.** (24–26 May 2019) Edge-aware Fully Convolutional Network with CRF-RNN Layer for Hippocampus Segmentation. *In Proceedings of the 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC)*, Chongqing, China, pp. 803–806.
- Wang, J., Li, W., Chen, Y., Fang, W., Kong, W., He, Y., & Shi, G.** (2021). Weakly supervised anomaly segmentation in retinal OCT images using an adversarial learning approach. *Biomedical optics express*, 12(8), 4713-4729.
- Wadhwa, A., Bhardwaj, A., & Verma, V. S.** (2019). A review on brain tumor segmentation of MRI images. *Magnetic resonance imaging*, 61, 247-259.
- Xiao Han and Bruce Fischl.** (2007) Atlas renormalization for improved brain MR image segmentation across scanner platforms. *IEEE transactions on medical imaging*, 26(4):479–486, 2007.
- Xiong, F., Wang, Q., & Gao, Q.** (2019). Consistent embedded GAN for image-to-image translation. *IEEE Access*, 7, 126651-126661, 2019.
- Xue, Y.; Xu, T.; Zhang, H.; Long, L.R.; Huang, X.** (2018). SegAN: Adversarial Network with Multi-scale L1 Loss for Medical Image Segmentation. *Neuroinformatics*, 16, 383–392.
- Tan, J., Jing, L., Huo, Y., Li, L., Akin, O., & Tian, Y.** (2021). Lgan: Lung segmentation in ct scans using generative adversarial network. *Computerized Medical Imaging and Graphics*, 87, 101817.
- volBrain**, (Erişim tarihi: 31.12.2021) <https://www.volbrain.upv.es/>.
- Vasilakos, A. V., Tang, Y., & Yao, Y.** (2016). Neural networks for computer-aided diagnosis in medicine: a review. *Neurocomputing*, 216, 700-708.
- Yao, S., Tan, J., Chen, Y., & Gu, Y., A.** (2021) weighted feature transfer gan for medical image synthesis. *Machine Vision and Applications*, 32 (1), 1-11.
- Yang, T., Wu, T., Li, L., & Zhu, C.** (2020). SUD-GAN: deep convolution generative adversarial network combined with short connection and dense block for retinal vessel segmentation. *Journal of digital imaging*, 33(4), 946-957.

- Yıldız, E., Arslan, A. T., Taş, A. Y., Acer, A. F., Demir, S., Şahin, A., & Barkana, D. E.** (2021). Generative Adversarial Network Based Automatic Segmentation of Corneal Subbasal Nerves on In Vivo Confocal Microscopy Images. *Translational Vision Science & Technology*, 10(6), 33-33.
- Yurt, M., Dar, S. U., Erdem, A., Erdem, E., Oguz, K. K., & Çukur, T.** (2021). Mustgan: Multi-stream generative adversarial networks for MR image synthesis. *Medical Image Analysis*, 70, 101944.
- Zhang, R., Isola, P., Efros, A. A., Shechtman, E., & Wang, O.** (2018). The unreasonable effectiveness of deep features as a perceptual metric. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 586-595).
- Zhang, L., Zhang, L., Mou, X., & Zhang, D.** (2011). FSIM: A feature similarity index for image quality assessment. *IEEE transactions on Image Processing*, 20(8), 2378-2386.
- Zhang, L., Shen, Y., & Li, H.** (2014). VSI: A visual saliency-induced index for perceptual image quality assessment. *IEEE Transactions on Image processing*, 23(10), 4270-4281.
- Zhao, M.; Wang, L.; Chen, J.; Nie, D.; Cong, Y.; Ahmad, S.; Ho, A.; Yuan, P.; Fung, S.H.; Deng, H.H. et al.** (16–20 September 2018). Craniomaxillofacial bony structures segmentation from MRI with deep-supervision adversarial learning. *In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*, Granada, Spain, pp. 720–727.
- Zhu, J. Y., Zhang, R., Pathak, D., Darrell, T., Efros, A. A., Wang, O., & Shechtman, E.** (2017). Toward multimodal image-to-image translation. *arXiv preprint arXiv:1711.11586*.
- Zhu, J. Y., Park, T., Isola, P., & Efros, A. A.** (2017) Unpaired image-to-image translation using cycle-consistent adversarial networks, *In Proceedings of the IEEE international conference on computer vision*, 2223-2232.
- Zhou, Y. F., Jiang, R. H., Wu, X., He, J. Y., Weng, S., & Peng, Q.** (2019). Branchgan: Unsupervised mutual image-to-image transfer with a single encoder and dual decoders, *IEEE Transactions on Multimedia*, 21 (12), 3136-3149.
- Zhou, X.Y.; Shen, M.; Riga, C.; Yang, G.-Z.; Lee, S.-L.**(2017a) Focal fcn: Towards small object segmentation with limited training data. *arXiv 2017a*, arXiv:1711.01506.



## ÖZGEÇMİŞ

**Ad-Soyad** : Sara ALTUN GÜVEN

### ÖĞRENİM DURUMU:

**Lisans** : 2013, İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

**Yüksek Lisans** : 2017, İnönü Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı

**Doktora** : 2022, İnönü Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı

### MESLEKİ DENEYİM:

2013-2016 Bayburt Üniversitesi / Mühendislik Fakültesi/ Bilgisayar Mühendisliği Bölümü/ BAYBURT

2016-2022 İnönü Üniversitesi / Mühendislik Fakültesi/ Bilgisayar Mühendisliği Bölümü/ MALATYA

**DOKTORA TEZİNDEN TÜRETİLEN ÇALIŞMALAR**  
(Tezler, Bildiriler, Patentler v.b.)

**SCI**

1. **Altun, S., & Talu, M. F. (2022).** Çekişmeli üretken ağlarla PAPSMEAR görüntüsü oluşturmada yeni bir yaklaşım. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(3), 1401-1410.
2. **Altun, S., Sahin, E., Talu, M. F. (2022).** Çekişmeli Üretken Ağların Evrimsel Sinir Ağı Tabanlı Algısal Benzerlik Metrikleri ile Görüntü Sentezlemesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* (Değerlendirme aşamasında)(Gönderim Tarihi 21.10.2021).
3. **Altun Güven, S., & Talu, M.F. (2022).** Brain MRI High Resolution Image Creation And Segmentation With The New Gan Method. *Biomedical Signal Processing and Control* (Review aşamasında)(Gönderim tarihi: 02/03/2022).

**SCI DIŞINDA KALAN ULUSLARARASI ALAN İNDEKSLİ DERGİ**

1. **Altun, S., & Talu, M. F. (2022).** Kontrastlı Öğrenme Tabanlı Çekişmeli Üretken Ağlar İle PAPSMEAR Görüntü Bölütleme. *Anatolian Journal of Computer Sciences*, 2022.

**TRDİZİN**

1. **Altun, S., & Talu, M. F. (2021).** Investigation of Hyperparametry Methods and Kits for Deep Neural Networks. *Dicle University Journal of Engineering*, 12(2), 1.
2. **Altun, S., & Talu, M. F. (2021).** Sentetik PAPSMEAR Hücre Çekirdeği Üretiminde Üretici Çekişmeli Ağların Kullanılması. *Avrupa Bilim ve Teknoloji Dergisi (EJOSAT)*, (23), 781-786.
3. **Altun, S., & Talu, M. F. (2021).** Görüntüden Görüntüye Dönüşüm ve Görüntü Sentezleme Yapan Üretici Çekişmeli Ağların İncelenmesi. *Avrupa Bilim ve Teknoloji Dergisi (EJOSAT)*, (26), 53-60.

**BİLDİRİ**

1. **Altun, S., & Talu, M. F. (2019, October).** Aynı Şartlar Altında Farklı Üretici Çekişmeli Ağların Karşılaştırılması. *In 2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-6). IEEE.

**BAP**

İnönü Üniversitesi Bilimsel Araştırma ve Koordinasyon Birimi (BAP) tarafından “FDK-2021-2675” nolu proje numarasıyla desteklenmektedir.