

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



ÇEKİŞMELİ ÜRETİCİ AĞLAR İLE BEYİN MR
GÖRÜNTÜLERİNİN SENTETİK ÜRETİMİ VE
DEĞERLENDİRİLMESİ

Canan KOÇ

Yüksek Lisans Tezi

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

Yazılım Mühendisliği Bilim Dalı

TEMMUZ 2024

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

ÇEKİŞMELİ ÜRETİCİ AĞLAR İLE BEYİN MR GÖRÜNTÜLERİNİN SENTETİK ÜRETİMİ VE DEĞERLENDİRİLMESİ

Tez Yazarı
Canan KOÇ

Danışman
Doç. Dr. Fatih ÖZYURT

TEMMUZ 2024
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı: Çekişmeli Üretici Ağlar ile Beyin MR Görüntülerinin Sentetik Üretimi ve Değerlendirilmesi
Yazarı: Canan KOÇ
İlk Teslim Tarihi: 03.06.2024
Savunma Tarihi: 05.07.2024

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Fatih ÖZYURT Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Doç. Dr. Ahmet Arif AYDIN İnönü Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Prof. Dr. Fatih ÖZKAYNAK Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım ‘‘Çekişmeli Üretici Ağlar ile Beyin MR Görüntülerinin Sentetik Üretimi ve Değerlendirilmesi’’ Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

05.07.2024

Canan KOÇ



ÖNSÖZ

Son zamanlarda yapılan Yapay Zekâ çalışmalarında veri setleri önemli bir yere sahiptir. Çalışmalarda kullanılan bu veri setlerinin yetersiz kaldığı ve özellikle sağlık alanında erişimin sıkıntılı olduğu durumlara Çekişmeli Üretici Ağlar yaklaşımı ile çözüm getirilmektedir. Etik izinlerin alınmasında sıkıntı yaşanan durumlarda sentetik verilerin kullanılması veri güvenliğini sağlamakta ve çalışmaların sonuçlarındaki başarı oranlarını artırmaktadır. Üretilen sentetik görüntüler ile tıbbi görüntüleme alanında erken teşhis ve tedavinin sağlanmasının ölüm oranlarını düşüreceği düşünülmektedir.

Akademik yolculuğuma başladığım ilk günden itibaren her zaman yol gösteren, tez çalışma sürecimin; planlanmasında, araştırılmasında ve yürütülmesinde ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım değerli danışman hocam Doç. Dr. Fatih ÖZYURT'a teşekkür ve minnetimi belirtmek istiyorum. Yine, Yüksek lisans sürecimde manevi desteğini ve ışık veren fikir ve düşüncelerini esirgemeyen değerli hocam Prof. Dr. Fatih ÖZKAYNAK'a teşekkürlerimi sunuyorum. Beni bu günlere sevgi ve saygı kelimelerinin anlamlarını bilecek şekilde yetiştirerek getiren ve benden hiçbir zaman desteğini esirgemeyen bu hayattaki en büyük şansım olan aileme sonsuz teşekkürler.

Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından MF.22.27 protokol numaralı proje ile desteklenmiştir. Ayrıca KOSGEB ARGE, ÜRGE ve İnovasyon destek programı kapsamında desteklenmektedir.

Canan KOÇ
ELAZIĞ, 2024

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	iv
İÇİNDEKİLER	v
ÖZET	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	ix
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	1
1.1. Tezin Amacı	3
1.2. Tezin Organizasyonu	4
2. LİTERATÜR TARAMASI	5
2.1. ÇÜA Mimarisi ile Yapılan Sentetik Tıbbi Görüntü Çalışmaları	5
3. ÇEKİŞMELİ ÜRETİCİ AĞ TÜRLERİ VE UYGULAMA ALANLARI	11
3.1. Koşullu Çekişmeli Üretici Ağ (Conditional GAN – CGAN)	11
3.2. Süper Çözünürlüklü Çekişmeli Üretici Ağ (Super – Resolution Generative Adversarial Network – SRGAN)	13
3.3. Döngü Tutarlı Çekişmeli Üretici Ağ (Cycle – Consistent GAN – CycleGAN)	15
3.4. Pix2Pix	17
3.5. StyleGAN	18
4. DEĞERLENDİRME METRİKLERİ	21
4.1. Nitel Metrikler	21
4.2. Nicel Metrikler	21
4.2.1. Başlangıç Skoru – BS (Inception Score – IS)	22
4.2.2. Frechet Başlangıç Mesafesi – FBM (Frechet Inception Score – FID)	22
5. MATERYAL VE METOT	23
5.1. Veri Seti	23
5.2. Metot	24
5.2.1. Derin Evrişimli Çekişmeli Üretici Ağ (Deep Convolutional GAN – DCGAN)	25
5.2.2. Frechet Başlangıç Mesafesi – FBM (Frechet Inception Distance – FID)	28
5.2.3. Başlangıç Skoru – BS (Inception Score – IS)	29
6. BULGULAR VE TARTIŞMALAR	32
7. SONUÇLAR	41
ÖNERİLER	42
KAYNAKLAR	43
ÖZGEÇMİŞ	

ÖZET

Çekişmeli Üretici Ağlar ile Beyin MR Görüntülerinin Sentetik Üretimi ve Değerlendirilmesi

Canan KOÇ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Yazılım Mühendisliği Anabilim Dalı

Temmuz 2024, Sayfa: x + 46

Tıbbi görüntüler ile yapılan yapay zekâ çalışmalarında veri sayısı ve kalitesi çok önemli bir yere sahiptir. Özellikle etik izinlerin alınamaması çalışmaları sekteye uğratmaktadır. Bu çalışmanın da temel amacı sağlık alanında yapılan çalışmalardaki veri sorununa çözüm getirmektir. DCGAN kullanılarak etik izne ihtiyaç duyulmayan sentetik görüntüler üretilerek bu sorunun önüne geçilmektedir. Üretilen sentetik görüntülerin kalitesi ise Frechet Başlangıç Mesafesi (FBM) ve Başlangıç Skoru (BS) ile ölçülerek değerlendirilmektedir. Çalışmada yapılmak istenen eğitim süresinin ve gerçek veri sayısının artışının üretilen sentetik görüntülerin kalitesine olan etkisine bakılmaktadır.

Çalışmada açık kaynaktan alınan beyin tümörü MR görüntülerinden oluşan veri setleri kullanılmıştır. Kullanılan veri setleri 3 sınıftan oluşmaktadır: Gliom tümörü, hipofiz bezi tümörü ve tümörün olmadığı. Çalışma ise iki kısımdan oluşmaktadır: az veri ve çok veri ile yapılan. Her iki çalışmada da sınıflar farklı epoch eğitim süreleri ile eğitilmiş ve her eğitimde FBM ve BS skoru hesaplanmıştır. Sonuç olarak ise veri sayısının ve eğitim süresinin artmasının DCGAN ile üretilen sentetik görüntülerin kalitesini olumlu yönde etkilediği görülmüştür. Sağlık alanında yaşanan veri sorununa sentetik verilerin çözüm olarak kullanılabileceği öngörülmektedir.

Anahtar Kelimeler: Sentetik Görüntü Üretimi, Tıbbi Görüntü, Frechet Inception Distance, Inception Score

ABSTRACT

Synthetic Generation and Evaluation of Brain MRI Images with Generative Adversarial Networks

Canan KOÇ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Software Engineering

July 2024, Pages: x + 46

The number and quality of data are very important in artificial intelligence studies with medical images. Especially the failure to obtain ethical permissions interrupts the studies. The main purpose of this study is to provide a solution to the data problem in health studies. Using DCGAN, this problem is avoided by producing synthetic images that do not require ethical permission. The quality of the synthetic images is evaluated by measuring the Frechet Inception Distance (FID) and Inception Score (IS). The aim of this study is to investigate the effect of increasing the training time and the number of real data on the quality of the synthetic images produced.

The study used datasets consisting of brain tumor MRI images from open source. The datasets used consist of 3 classes: Glioma tumor, pituitary tumor, and no tumor. The study consists of two parts: with little data and with a lot of data. In both studies, the classes were trained with different epoch training times and FID and IS scores were calculated for each training. As a result, it is seen that increasing the number of data and training time positively affects the quality of synthetic images produced with DCGAN. It is predicted that synthetic data can be used as a solution to the data problem in the health field.

Keywords: Synthetic Image Generation, Medical Image, Frechet Inception Distance, Inception Score

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 3.1. CGAN mimarisi.....	12
Şekil 3.2. SRGAN ile yüksek çözünürlüğe getirilen görüntü örneği [11].....	14
Şekil 3.3. CycleGAN kullanım örneği.....	16
Şekil 3.4. Pix2Pix kullanılarak yapılan eskiz dönüştürülmesi ve renklendirme çalışmaları [7]	17
Şekil 5.1. Veri setlerinden karma örnekler	24
Şekil 5.2. Çalışmanın Akış Diyagramı	25
Şekil 5.3. DCGAN mimarisi.....	26
Şekil 6.1. Az veriye sahip gliom tümörü veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler	34
Şekil 6.2. Çok veriye sahip gliom tümörü veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler ..	34
Şekil 6.3. Az veriye sahip Tümör bulunmayan veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler	37
Şekil 6.4. Çok veriye sahip Tümör bulunmayan veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler	37
Şekil 6.5. Az veriye sahip hipofiz bezi tümörü veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler	40
Şekil 6.6. Çok veriye sahip hipofiz bezi tümörü veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler	40

TABLolar LİSTESİ

	Sayfa
Tablo 2.1. FBM skorunun kullanıldığı çalışmaların literatür taraması	8
Tablo 2.2. PSNR ve SSIM skorunun kullanıldığı çalışmaların literatür taraması	9
Tablo 2.3. Kullanılan karmaşıklık matrisi metriklerinin literatür taraması.....	10
Tablo 3.1. Tıbbi görüntüleme de kullanılan ÇÜA modelleri	19
Tablo 6.1. Gliom tümörü veri seti ile üretilen görüntülerin FBM skorları	32
Tablo 6.2. Gliom tümörü veri seti ile üretilen görüntülerin BS skorları	33
Tablo 6.3. Tümörsüz veri seti ile üretilen görüntülerin FBM skorları	35
Tablo 6.4. Tümörsüz veri seti ile üretilen görüntülerin BS skorları.....	36
Tablo 6.5. Hipofiz bezi tümörü veri seti ile üretilen görüntülerin FBM skorları.....	38
Tablo 6.6. Hipofiz bezi tümörü veri seti ile üretilen görüntülerin BS skorları	39

SİMGELER VE KISALTMALAR

Simgeler

D	: Ayırt edici
G	: Üretici
$G(z)$: Üretilen sentetik görüntü
\mathcal{L}_D	: Ayırt Edici Kayıp Fonksiyonu
\mathcal{L}_G	: Üretici Kayıp Fonksiyonu
$P_z(z)$: Gürültü vektörünün dağılımı
Z	: Rastgele gürültü vektörü
f	: Haritalama ağı
w	: Stil vektörü
x_i	: Giriş Aktivasyonu
μ	: Girişin ortalaması
σ	: Girişin standart sapması

Kısaltmalar

YZ	: Yapay Zekâ
BS	: Başlangıç Skoru
CGAN	: Conditional Generative Adversarial Network
CycleGAN	: Cycle – Consistent Generative Adversarial Network
ÇÜA	: Çekişmeli Üretici Ağ
DCGAN	: Deep Convolutional Generative Adversarial Network
FBM	: Frechet Başlangıç Mesafesi
FID	: Frechet Inception Distance
GAN	: Generative Adversarial Network
IS	: Inception Score
SRGAN	: Super – Resolution Generative Adversarial Network

1. Giriş

Yapay Zekâ (YZ) teknolojilerinin hızlı ilerlemesi, daha karmaşık ve sofistike modellerin geliştirilmesine olanak tanımaktadır. Bu gelişmeler, YZ sistemlerinin doğru ve etkili bir şekilde çalışabilmesi için büyük miktarda veriye olan ihtiyacı artırmaktadır. Dolayısıyla, veri toplama, işleme ve analiz süreçleri, YZ araştırmalarında ve uygulamalarında kritik bir rol oynamaktadır. Çalışmalar için önemli bir yerde olan veriler, eksik ya da etiketsiz olmaları durumunda çalışmanın sonucunu ciddi oranda etkilemektedir. Özellikle sağlık alanında kullanılacak olan verilerde, etik izinlerin alınmaması önemli bir sorun olarak karşımıza çıkmaktadır. Sağlık verileri, kişisel ve hassas nitelikte olduklarından 6698 sayılı Kişisel Verilerin Korunması Kanunu (KVKK) kapsamında sıkı düzenlemelere tabidir. Bu durum, veri sahiplerinin mahremiyetini korumak için gerekli olsa da, YZ araştırmalarında gerekli verilerin elde edilmesini zorlaştırmakta ve projelerin ilerlemesini engelleyebilmektedir. Bütün bu veri eksikliği sorunlarının önüne geçilmesi için yeni bir yaklaşım olan Çekişmeli Üretici Ağlar – ÇÜA (Generative Adversarial Networks- GANs) önerilmiştir.

Günümüzde ÇÜA gibi derin öğrenme modelleri, gerçek dünya verilerine benzer yüksek kaliteli sentetik görüntüler üretme yetenekleri nedeniyle büyük ilgi görmeye başlamıştır [1], [2], [3]. Bu ilgiden dolayı ÇÜA'lar modern bilgisayar bilimleri ve YZ araştırmalarındaki önemli gelişmelerden biri haline gelmiştir. İki ayrı sinir ağı modelinin birbiriyle rekabet ettiği bu yapı, gerçek dünya verilerinden ayırt edilemeyecek kadar yüksek kalitede ve aynı zamanda gerçekçi çeşitli sentetik görüntüler üretilmesini sağlamaktadır [4]. ÇÜA'ların başarısı, farklı alanlarda büyük yenilikler ve gelişmeler sağlamaktadır. Görsel içerik üretiminde daha gerçekçi ve yaratıcı sonuçlar elde edilmesine yardımcı olurken, güvenlik sistemlerinde ise daha hassas ve güvenilir tanıma tekniklerinin geliştirilmesini sağlamaktadır. Ayrıca, sanat ve tıbbi görüntüleme oyun geliştirmeye kadar geniş bir yelpazede, ÇÜA'lar yenilikçi uygulamaların önünü açarak bu alanlardaki ilerlemeleri hızlandırmaktadır.

Bir derin sinir ağı yaklaşımı olan ÇÜA mimarisi ilk olarak Haziran 2014'te Ian Goodfellow tarafından gerçek verilere benzer sahte veriler üreterek veri kümelerindeki eksik veya kayıp veri sorununu çözmek için geliştirilmiştir [5]. ÇÜA'lar, iki ağdan oluşan ve birbirleriyle rekabet ederken öğrenen bir tür yapay zekâ modelidir. Bu yapı, üretici (generator) ve ayırt edici (discriminator) olmak üzere iki temel ağdan oluşmaktadır [6]. Üretici ağ, gerçekçi veri örnekleri oluşturmayı amaçlarken, ayırt edici ağ bu örneklerin gerçek verilere mi yoksa üretici tarafından üretilen sentetik verilere mi ait olduğunu ayırt etmeye çalışmaktadır. Bu süreç, bir nevi kapalı kutu optimizasyon problemi olarak düşünülebilmektedir, burada her iki model de birbirlerinin performansını artırıcı yönde sürekli bir iyileşme ve adaptasyon süreci içindedir. Üretici ağ, gerçekçi veri üretmeye yönelik girdileri rastgele gürültüden (noise) almakta ve bu gürültüyü gerçekçi benzeyen veriye

dönüştürmeye çalışmaktadır. Ayırt edici ağ ise, hem gerçek veri setinden alınan örnekleri hem de üretici model tarafından üretilen sentetik örnekleri inceleyerek, hangilerinin gerçek hangilerinin sentetik olduğunu belirlemeye çalışmaktadır. Bu sürecin sonunda, üretici ağ gerçek verilere çok benzer sentetik veriler üretebilecek şekilde gelişirken, ayırt edici ağ da sentetik ve gerçek verileri ayırt etme konusunda ustalaşmaktadır. Farklı amaçlara hizmet eden birçok farklı ÇÜA modeli vardır: Pix2Pix [7], CycleGAN [8], DCGANs [9], StyleGAN [10], SRGAN [11], CGAN [12].

ÇÜA'ların en önemli özelliklerinden biri, hiçbir insan müdahalesine gerek kalmadan son derece gerçekçi veriler üretebilmeleridir. Bu yetenek, karmaşık ve detaylı veri üretiminde büyük bir avantaj sunmaktadır. Özellikle sınırlı veri erişimi olan durumlarda, ÇÜA'lar mevcut veri setlerini genişletmek ve çeşitlendirmek için etkili bir çözüm sunmaktadır. Bu sayede, araştırmacılar ve geliştiriciler, daha zengin ve çeşitli veri setleri üzerinde çalışabilmektedirler. Gerçekçilik derecesi yüksek bu veriler, model eğitimlerini daha başarılı kılmakta ve daha doğru sonuçlar elde edilmesini sağlamaktadır. Dolayısıyla, ÇÜA'lar veri erişimindeki kısıtlamaları aşmak için güçlü bir araç olarak öne çıkmaktadır. ÇÜA'ların görüntü, video, metin ve ses üretimi gibi çok çeşitli alanlarda kullanılarak, sanal gerçeklikten otomatik içerik üretimine, tıbbi görüntü analizinden sanat ve tasarıma kadar geniş bir yelpazede yenilikçi uygulamalara imkân tanımaktadır.

Her alanda yapılan çalışmaların önemi ayrı olsa da, sağlık alanında yapılan çalışmalar, özellikle hastalığın tanı ve teşhis sürecindeki iyileştirmeler ve yenilikler açısından insanlık için büyük bir değer taşımaktadır. Sağlık alanında elde edilen verilerle yapılan araştırmalar, hastalıkların daha hızlı ve doğru bir şekilde tanınmasını ve tedavi edilmesini sağlamaktadır. Ancak, bu tür çalışmalar için gerekli olan verilere ulaşmak, bireylerin hakları ve mahremiyet kaygıları nedeniyle oldukça zordur. Özellikle, sağlık verilerinin hassasiyeti göz önünde bulundurulduğunda, etik izinlerin alınması süreci karmaşık ve bazen de imkânsız hale gelmektedir. Bu durum, araştırmacılar için büyük bir engel teşkil ederken, veriye dayalı yenilikçi çözümlerin geliştirilmesini de yavaşlatmaktadır.

Bu zorluklara ek olarak, Avrupa Birliği'nin Genel Veri Koruma Yönetmeliği (GDPR) ve Türkiye'de yürürlükte olan Kişisel Verilerin Korunması Kanunu (KVKK) gibi yasal düzenlemeler, sağlık verilerine erişim daha da kısıtlamaktadır. Bu kanunlar, bireylerin kişisel verilerinin korunmasını amaçlayarak veri işleme süreçlerine sıkı kurallar getirmektedir. Bu nedenle, sağlık alanında yapılacak araştırmalarda hem veri miktarının yetersizliği hem de sorunlarının üstesinden gelmek için ÇÜA yaklaşımı büyük bir potansiyel sunmaktadır. ÇÜA'lar, mevcut verilerden yararlanarak insan müdahalesine ihtiyaç duymadan gerçekçi ve çeşitlendirilmiş veri setleri oluşturulabilmektedir. Bu sayede, sağlık araştırmalarında karşılaşılan veri eksikliği ve erişim zorlukları büyük ölçüde aşılmakta, yenilikçi çözümler geliştirilmeye başlanmaktadır.

ÇÜA'lar özellikle görüntü işleme alanında devrim yaratan yenilikler sunmuştur [13]. Gerçekçi insan yüzleri, sanatsal eserler veya yeni video oyunu sahneleri oluşturmak için

kullanılabilmektedir. Bunun yanı sıra, tıbbi görüntüleme, astronomi ve moda endüstrisi gibi çeşitli alanlarda da uygulamaları bulunmaktadır. Sentetik görüntü üretimi ise, makine öğrenmesinin bir alt dalıdır. Makine öğrenmesi, bir bilgisayarın verilerden öğrenme yeteneğini geliştirmekte ve bu öğrenmeyi kullanarak tahminlerde bulunma veya verileri oluşturma becerisini ifade etmektedir. Makine öğrenmesi algoritmaları, genellikle eğitim verilerini kullanarak bir modeli oluşturmaktadır ve bu model, yeni verileri tahmin etmek veya üretmek için kullanılmaktadır. Ek olarak sentetik görüntü üretimi, veriye dayalı öğrenmenin bir türüdür. Makine öğrenmesi algoritmaları, genellikle büyük miktarda veriye dayalı olarak öğrenmektedir ve bu verileri kullanarak desenleri tanımlamaktadır. Sentetik görüntü üretiminde de model, eğitim verileri üzerinden insan yüzleri veya diğer nesnelere anlamak ve bu bilgiyi yeni görüntüler oluşturmak için kullanılmaktadır. ÇÜA'ların bu başarısı, sentetik görüntü üretimi alanında devrim yaratmış ve akademik araştırmalardan sanal gerçeklik uygulamalarına kadar çeşitli alanlarda kullanılarak veri eksikliği gibi sorunların üstesinden gelinmesinde önemli bir rol oynamıştır. Bu gelişmeler hem teknolojik yenilikleri hem de bu teknolojilerin uygulandığı alanlardaki gelişmeleri hızlandırma potansiyeline sahiptir. ÇÜA'lar ve makine öğrenmesi aracılığıyla elde edilen sentetik görüntü üretimi, geleceğin teknolojik sınırlarını zorlayarak yeni ve heyecan verici olanakların kapısını aralamaktadır. Yapılan çalışmaların temelini oluşturan veri setlerini sentetik olarak oluşturmak için kullanılan ÇÜA'ların ürettiği bu sentetik verileri değerlendirmek de bir o kadar önemlidir. Üretilen verinin kalitesi yine aynı şekilde çalışmanın başarısını doğrudan etkilemektedir. Özellikle sağlık alanında yapılacak olan tanı için verilerin doğru etikete ve kaliteye sahip olması çok önemlidir. Bunun için kullanılan nicel ve nitel olacak şekilde birçok metrik bulunmaktadır. Fakat en sık kullanılan ve sonuçlarına güvenilen Frechet Başlangıç Mesafesi – FBM (Frechet Inception Distance – FID) skorudur. Elde edilen verilerin FBM skorunun düşük olması verinin gerçeğe çok yakın olduğunu göstermektedir. ÇÜA ile üretilen sentetik verilerde özellikle buna dikkat edilmesi gerekmektedir.

1.1. Tezin Amacı

Bu çalışmanın temel amacı, özellikle sağlık alanında yaşanan veri problemini çözmeye yöneliktir. Sağlık araştırmaları için gerekli olan verilerin elde edilmesi, etik izinlerin alınmasının zorluğu ve kişisel veri koruma yasaları nedeniyle büyük bir engel teşkil etmektedir. Bu sorunun üstesinden gelmek için, Derin Konvolüsyonel Çekişmeli Üretici Ağlar (Deep Convolutional Generative Adversarial Network – DCGAN) kullanılarak sentetik görüntülerin üretilmesi ve bu şekilde veri eksikliğinin giderilmesi planlanmaktadır. Sentetik verilerin kalitesi, araştırma ve uygulamaların başarısı açısından kritik bir öneme sahiptir. Bu çalışmanın ana hedefi, üretilen sentetik görüntülerin kalitesini FBM ve BS ile ölçerek değerlendirmektir.

Çalışma kapsamında, açık kaynaktan toplanan beyin MR görüntülerinden oluşan birden fazla veri seti birleştirilerek sentetik görüntüler üretilmiştir. Veri setleri, tümörün olmadığı, gliom tümörü ve

hipofiz bezi tümörü olmak üzere üç farklı sınıftan oluşmaktadır. Çalışma iki ana bölümden oluşmaktadır. İlk bölümde, Kaggle'dan alınan etiketli tümörü MRI veri seti kullanılarak, veri sayısının az olduğu durumlarda eğitim süresinin sentetik görüntülerin kalitesi üzerindeki etkisi incelenmiştir. İkinci bölümde, sınıflardaki veri sayısının ve eğitim süresinin artışının görüntü kalitesi üzerindeki etkisi değerlendirilmiştir. Her sınıftaki veri sayısı ortalama dört kat artırılmış ve yine farklı epoch süreleriyle eğitim yapılarak FBM ve IS skorları hesaplanmıştır.

Sonuçlar, sağlık verilerinde DCGAN kullanılarak sentetik veri üretiminin, veri sayısının ve eğitim süresinin artmasıyla verilerin kalitesinin doğru orantılı olarak arttığını göstermiştir. Bu bulgu, sağlık alanında yaşanan veri probleminin sentetik veri kullanımıyla etkili bir şekilde çözülebileceğini ve araştırmacılara önemli bir kolaylık sağlayacağını ortaya koymaktadır. Bu çalışma, sentetik verilerin kalite değerlendirmesi ve sağlık araştırmalarında kullanımı konusunda önemli katkılar sunarak, gelecekteki araştırmalar için sağlam bir temel oluşturmaktadır.

1.2. Tezin Organizasyonu

Bu tez çalışmasında bir ÇÜA çeşidi olan DCGAN mimarisi kullanılarak beyin MR görüntüleri sentetik olarak üretilmiştir. Üretilen sentetik görüntülerin kalitesi ise FBM skoru ile değerlendirilmiştir. Çalışma içerisinde veri eksikliği ve ÇÜA yaklaşımı hakkında bilgi verilip literatürden örnek çalışmalar “Literatür Taraması” bölümde incelenmiştir. “Çekişmeli Üretici Ağ türleri ve uygulamaları” bölümünde ise çeşitli ÇÜA mimarilerinden bahsedilmiştir. Üretilen sentetik görüntülerin kalitesinin değerlendirilmesi sürecinde kullanılan metrikler ise “Değerlendirme Metrikleri” bölümünde anlatılmıştır. DCGAN mimarisi ve FBM skoru ise “Materyal ve Metot” bölümünde detaylı olarak ele alınmıştır. Ayrıca çalışmada kullanılan veri setleri de yine bu bölümde anlatılmıştır. “Bulgular ve Tartışmalar” bölümünde ise üretilen sentetik görüntülerin örnekleri ve her sınıfa ait FBM skorları verilmiştir.

2. LİTERATÜR TARAMASI

2.1. ÇÜA Mimarisi ile Yapılan Sentetik Tıbbi Görüntü Çalışmaları

Günümüzde YZ ve makine öğrenimi, son on yılda bilgi teknolojileri ve veri işleme alanlarında önemli ilerlemeler sağlamıştır. Yapılan bu çalışmalarda ise en önemli yeri veri setleri almaktadır. Veri setlerinin eksikliği veya etiketsiz olması durumunda çalışmaların başarı oranları olumsuz etkilenmektedir. Veri eksikliği sorunu en çok sağlık alanında karşımıza çıkmaktadır. Etik izinlerin alınamaması araştırmacıların en sık karşılaştığı en önemli sorunlardan biridir. Bu sorunun önüne geçmek için ÇÜA yaklaşımı önerilmektedir [14].

ÇÜA'lar, gerçekçi sentetik veri üretimi konusunda devrim yaratan bir teknoloji olarak ortaya çıkmıştır ve bu alanda pek çok alt dalı bünyesinde barındırmaktadır. İlk olarak Ian GOODFELLOW ve çalışma arkadaşları tarafından 2014 yılında tanıtılan bu yöntem, bir üretici ve bir ayırt edici olmak üzere iki temel sinir temel sinir ağından oluşmaktadır [5]. Üretici ağ, gerçek veri setlerinden öğrendiği bilgiyi kullanarak yeni veri örnekleri üretmeye çalışırken, ayırt edici ağ bu üretilen verilerin gerçek verilere ne kadar benzediğini değerlendirmektedir.

ÇÜA'lar kullanılarak birçok veri sorununa çözüm olarak yapılan birçok çalışma bulunmaktadır. Özellikle sağlık alanında yapılan çalışmalar ise alınan sonuçlar sebebiyle literatürde önemli bir yer tutmaktadır. Tıbbi görüntü alanında veri artırma, görüntü iyileştirme, görüntü restorasyonu ve farklı modaliteler arasında dönüşüm sağlama gibi birçok uygulama alanında ÇÜA yaklaşımı kullanılmaktadır. Özellikle tıbbi veri setlerinin sınırlı ve etik kaygılarla erişiminin zor olduğu durumlarda, bu teknoloji araştırmalara ve klinisyenlere sentetik veri üreterek eğitim ve analiz süreçlerinde önemli kolaylıklar sunmaktadır. Bu süreçlerin tıbbi görüntü kalitesini artırma ve tanı süreçlerini iyileştirme potansiyeli, sağlık sektöründe büyük ilgi görmesine sebep olmaktadır.

Literatürde bu ilgiye örnek vermek gerekirse 2020 yılında Wang ve arkadaşları tarafından yapılan çalışmada tıbbi görüntü üretimi için ÇÜA yaklaşımı kullanılmıştır [15]. Çalışmada kullanılan geleneksel ÇÜA mimarilerinin sebep olduğu mod çökmesi sorununun önüne geçilmesi için AE-COT-GAN (Autoencoder-based Conditional Optimal Transport GAN) modelini kullanılmıştır. Önerilen bu model özellikle tıbbi görüntüleri farklı kategorilerde üretmek için kullanılmıştır. Kullanılan açık kaynak veri setlerinden (DermaMNIST ve BloodMYST [16]) elde edilen görüntülerden yararlanılarak sentetik verilerin üretilmesinde başarılı sonuçlar elde edildiği görülmüştür. Üretilen sentetik görüntülerin değerlendirilmesi FBM skoru kullanılarak yapılmış ve 8.36 gibi başarılı bir sonuca ulaşılmıştır. Aynı yıl Lei ve arkadaşları tarafından yapılan başka tıbbi görüntü çalışmasında cilt lezyonlarının segmentasyonunda ÇÜA yaklaşımı kullanılmıştır [17]. Bu çalışmada cilt lezyonlarının belirlenmesinde ve ayrılmasında araştırmacıların önerdiği çift ayırt edici ağına sahip Dual Adversarial GAN – DAGAN modeli kullanılmıştır. Çift ayırt edici ağ, modelin

daha hassas ve doğru sonuçlar vermesini sağlamıştır. Çalışma sonucunda önerilen çift ayırt edici ağ kullanan ÇÜA modelinin cilt lezyonlarının segmentasyonunda geleneksel modellere göre daha başarılı bir sonuç olan %93,5 doğruluk sonucu verdiği görülmüştür. Yine 2020 yılında Xie ve arkadaşları fundus hastalıklarının tespitinde ÇÜA yaklaşımını kullanmışlardır [18]. Önerdikleri AMD-GAN modeli, dikkatli kodlayıcı ve çok dallı yapı kullanmaktadır. Taramalı lazer oftalmoskopi (SLO) görüntüleri kullanılarak geliştirilen bu model, görüntülerdeki parazitleri azaltarak temel özelliklerin daha iyi çıkarılmasını sağlamaktadır. Çalışma sonucunda ise AMD-GAN kullanılarak fundus hastalıklarının tespitinde %81,84 doğruluk oranı elde edildiği görülmüştür.

2021 yılında çalışmalara bakılacak olursa, Wang ve arkadaşları denetimsiz meme kanseri histoloji görüntü sınıflandırmasında ÇÜA yaklaşımını kullanmışlardır [19]. Önerdikleri Prototype Transfer GAN (PTGAN) modeli, etiketlenmemiş verileri kullanarak büyük miktarda etiketli verilere duyulan ihtiyaç azaltılmaya çalışılmıştır. BreakHis açık kaynak veri seti kullanılarak yapılan çalışmada PTGAN ortalama %90 doğruluk oranı vererek üstün performans gösterdiği görülmüştür. Yine aynı yıl yapılan başka çalışmada ise Jiang ve arkadaşları düşük çözünürlüklü MRI görüntülerinden yüksek çözünürlüklü görüntüler elde etmek için Fused Attentive GAN (FA-GAN) modelini önermişlerdir [20]. Çeşitli konvolüsyon çekirdeklerini farklı ölçeklerde görüntü çıkarmak için kullanan yerel füzyon bloğu içeren bu model, 3 farklı veri setinde FBM skoru elde edilmiş ve skorun SRGAN modeline göre daha düşük olduğu görülmüştür. Bu da FA-GAN modelinin MRI görüntü çözünürlüğü artırmadaki başarısını gözler önüne sermektedir. 2021 yılında yapılan başka çalışmada ise anatomik ve fonksiyonel verilerin birleştirilmesi için DSAGAN ismi verilen model önerilmiştir [21]. Fu ve arkadaşlarının yaptıkları bu çalışmada DSAGAN kullanılarak görüntülerin önemli özellikleri güçlendirilmektedir. Elde edilen sonuçlar ise DSAGAN modelinin görüntü birleştirme performansının diğer modellere göre daha üstün olduğunu göstermektedir.

2022 yılında yapılan çalışmalarda ilk göze çarpan farklı bir veri seti olan deri lezyonlarının kullanıldığı çalışmadır [22]. Salvi ve arkadaşları ışıklandırılmaları farklı deri lezyonlarının görüntülerinin renk değişkenliğini azaltarak doğru ve erken teşhis için DermoCC-GAN modelini önermişlerdir. Bu model, görüntülerdeki bu renk değişimi problemini renk sabitleme göreviyle çözmeye çalışmaktadır. Sonuç olarak ise mevcut renk sabitleme algoritmalarına göre DermoCC-GAN modelinin daha başarılı olduğu gözler önüne serilmiştir. Lezyon sınıflandırma alanında DermoCC-GAN kullanımının sınıflandırmada daha doğru sonuçlar vereceğini göstermektedir. Aynı yıl başka çalışma ise Duan ve arkadaşları tarafından 434 hastadan toplanan karaciğer ultrason görüntüleri kullanılmıştır [23]. ÇÜA, karaciğer fibrozisini evrelemek ve sirozu tahmin etmek amacıyla kullanılmıştır. Sonuç olarak ise geleneksel yöntemlere göre daha başarılı olan yaklaşık %89 AUC oranı elde edilmiştir. Yuan ve arkadaşları aynı sene içinde yaptıkları çalışmada RNA ikincil yapısını tahmin etmek için ÇÜA yaklaşımını kullanmışlardır [24]. Gerçek RNA ikincil

yapısı ve gri tonlamalı görüntülere dönüştürülmüş RNA verilerinin kullanıldığı çalışmada Multi – Scale Feature Fusion Conditional Deep Convolutional Generative Adversarial Network (MSFF-CDCGAN) modeli önerilmiştir. CDCGAN, Conditional GAN (CGAN) ve Deep Convolutional GAN modellerinin kombinasyonudur. Üretilen sentetik görüntüleri FBM skoru ile değerlendirilmiştir. Önerilen modelin kullanımında ise başarılı bir sonuç olan 77 FBM skoru elde edilmiştir.

2023 yılında Song ve arkadaşları tarafından yapılan yüksek ve düşük çözünürlüklü Glioma içeren MR görüntülerinden oluşan veri seti kullanılmıştır [25]. Çözünürlüğü artırmak ve daha net görüntüler elde etmek için dikkat mekanizması ile geliştirilmiş CGAN kullanılmıştır. CGAN, SRGAN modelinin temel bloğunun kanal dikkat mekanizmasına dayalı artık yoğun bloğu ile değiştirmiş ve göreceli ortalama ayırmacısını kullanmıştır. Değerlendirme metrikleri olarak ise PSNR ve SSIM kullanılmıştır. Yapılan çalışmanın sonucunda CGAN modelinin mevcut modellere göre üstün başarı gösterdiği gözlemlenmiştir. Yine aynı yıl yapılan bir başka çalışma ise Peng ve arkadaşlarının yaptığı beyin MRI görüntülerinin CT görüntülerine dönüştürülmesi çalışmasıdır [26]. Her hastadan hem MRI hem de CT görüntüleri almak zaman alıcı ve pahalı bir işlem olduğundan dolayı araştırmacılar ÇÜA kullanarak MRI görüntülerinden gerçek CT görüntülerinin yüksek kalite ve sinyal – gürültü oranını taklit eden sentetik CT görüntüleri elde edilmiştir. Histogram tabanlı ÇÜA modeli kullanılarak gerçekleştirilen çalışmanın sonucunda yüksek kaliteli sentetik CT görüntüleri üretildiği gözlenmiştir. ÇÜA performansı PSNR ve SSIM metrikleri ile değerlendirilmiştir ve geleneksel yöntemlere göre daha başarılı sonuçlar elde edilmiştir. Tripathi ve arkadaşları optik koherens tomografi (OCT) B-Tarama görüntülerinin diyabetik makula ödemi (DME) tanısında sentezlenmesi amacıyla ÇÜA yaklaşımını kullanmışlardır [27]. Yaptıkları çalışmada manuel yorumlamalardan kaynaklanabilecek hataları azaltarak daha güvenilir ve tutarlı teşhis edebilmeyi sağlamak amaçlanmıştır. Beş farklı ÇÜA modeli kullanılmış ve en iyi performans gösteren ÇÜA modeliyle birlikte Parçacık Sürü Optimizasyonu (PSO) uygulanmıştır. Çalışmanın sonucunda ise önerilen yöntemin diğer yöntemlere göre daha üstün performans gösterdiği belirlenmiştir. Modellerin performansı PSNR ve SSIM gibi metriklerin yanında FBM skoru ile de değerlendirilmiştir.

2024 yılındaki bir çalışmada ise omurga görüntüleri üzerinde sentetik görüntü üretimi çalışması yapılmıştır. Vrettos ve arkadaşları tarafından yapılan çalışma özellikle tıbbi görüntülerin kalitesini artırmak ve teşhis doğruluğunu geliştirmek amacıyla ÇÜA kullanılmaktadır [28]. ÇÜA'lar intervertebral boşlukların sanal ince dilim görüntülerini oluşturmak ve insan omurlarının sentetik görüntülerini oluşturmak ve tahminde bulunmak için ÇÜA mimarisinden yararlanılmıştır. Yapılan çalışmanın en yenilikçi sonucu ise CT görüntülerini MRI görüntülerine dönüştüren ÇÜA'lerin, MRI görüntüleri olmadan CT görüntüleri kullanılarak neredeyse MRI görüntüleri üretilebildiğidir. Bu sadece hem tıpta veri artışı hem de teşhis doğruluğunun iyileştirilmesinde önemli bir adım

olduğu görülmektedir. Bunun alakalı bir başka ÇÜA çalışması ise Wei ve arkadaşları MRI görüntülerinden CT görüntüleri sentezlemek için frekans dikkati şartlı GAN (FACGAN) modeli önerilmiştir [29]. Yapılan çalışmada MRI'den elde edilen görüntülerin yüksek frekanslı bileşenlerini vurgulayarak CT görüntülerinin daha doğru ve ayrıntılı sentezlenmesi sağlanmıştır. Bulunan bu yöntem sayesinde geleneksel modellere göre FACGAN kullanımı görüntü kalitesini artırmış ve teşhis doğruluğunu geliştirmiştir. Aynı yıl içinde Noor ve arkadaşları yaptıkları çalışmada eksik örneklenmiş MR görüntülerinin yeniden yapılandırılması için ÇÜA modeli önermişlerdir [30]. Önerilen Deep Learning GAN (DLGAN) modelinin, MR görüntülerinin daha hızlı ve verimli yapılmasını sağladığı görülmüştür. Mevcut geleneksel yöntemlerle kıyaslandığında ise daha iyi görsel kalite ve SSIM değeri elde edilmiştir. Yapılan çalışmalarda FBM skorunun kullanıldığı çalışmalar Tablo 2.1'de, PSNR ve SSIM metriklerinin kullanıldığı çalışmalar Tablo 2.2'de ve karmaşıklık matrisi metriklerinin kullanıldığı çalışmalar ise Tablo 2.3'de özetlenmiştir.

Tablo 2.1. FBM skorunun kullanıldığı çalışmaların literatür taraması

Yıl	Yazarlar	Kullanılan ÇÜA Mimarisi	Veri Seti	Sonuç
2020	Jun Wang, Bohan Lei, Liya Ding, Xiaoyin Xu, Xianfeng Gu, Min Zhang	Autoencoder-based Conditional Optimal Transport Generative Adversarial Network (AE-COT-GAN)	DermaMNIST BloodMNIST	FBM skoru: 8,36
2021	Mingfeng Jiang, Minghao Zhi, Liyang Wei, Xiaocheng Yang, Jucheng Zhang, Yongming Li, Pin Wang, Jiahao Huang, Guang Yang	Fused Attentive Generative Adversarial Network (FA-GAN)	Kalp, beyin, diz	Kalp FBM: 18,97 Beyin FBM: 12,43 Diz FBM: 33,59
2023	Aditya Tripathi, Preetham Kumar, Veena Mayya, Akshat Tulsani	Derin Evrişimli GAN, Koşullu GAN, CycleGAN, StyleGAN2 ve StyleGAN3	Optik Koherens Tomografi (OCT) B- Tarama görüntüleri Duke Eye veri seti	DCGAN FBM: 37,443 CGAN FBM: 34,429 CycleGAN FBM: 25,838 StyleGAN2 FBM: 18,840 StyleGAN3 FBM: 203,399

Tablo 2.2. PSNR ve SSIM skorunun kullanıldığı çalışmaların literatür taraması

Yıl	Yazarlar	Kullanılan ÇÜA Mimarisi	Veri Seti	Sonuç
2021	Jun Fu, Weisheng Li, Jiao Du, Liming Xu	Dual-Stream Attention Mechanism Generative Adversarial Network (DSAGAN)	MRI-PET ve MRI-SPECT	SSIM
2023	Zhaoyang Song, Defu Qiu, Xiaoqiang Zhao, Dongmei Lin, Yongyong Hui	Channel Attention Generative Adversarial Network (CGAN)	Beyin Gliom Tümörü MRI görüntüleri	PSNR: 28,41 SSIM: %84,1
2023	YanJun Peng, Jindong Sun, Yande Ren, Dapeng Li, Yanfei Guo	Histogram-Driven Generative Adversarial Network (HisGAN)	Manyetik Rezonans Görüntüleme (MRI) ve Bilgisayarlı Tomografi (CT)	PSNR: 37,91 SSIM: %80,7
2024	Konstantinos Vrettos, Emmanouil Koltsakis, Aristeidis H. Zibis, Apostolos H. Karantanas, Michail E. Klontzas	ÇÜA	Sekanslardan yağ baskılanmış T2 ağırlıklı (fsT2W) görüntüler	PSNR: 60,07 SSIM: %91
2024	Kexin Wei, Weipeng Kong, Liheng Liu, Jian Wang, Baosheng Li, Bo Zhao, Zhenjiang Li, J ian Zhu, Gang Yu	Frequency Attention Conditional Generative Adversarial Network (FACGAN)	Beyin ve pelvik bölgesi MR görüntüleri	PSNR: 31,82 SSIM: %90,5 PSNR: 26,80 SSIM: %92,7
2024	Rida Noor, Abdul Wahid, Sibghat Ullah Bazai, Asad Khan, Meie Fang, Syam M.S., Uzair Aslam Bhatti, Yazeed Yasin Ghadi	Deep Learning Generative Adversarial Network (DLGAN)	Beyin Ve Diz MRI görüntüleri	PSNR: 38,60 SSIM: %98 PSNR: 34,98 SSIM: %95

Tablo 2.3. Kullanılan karmaşıklık matrisi metriklerinin literatür taraması

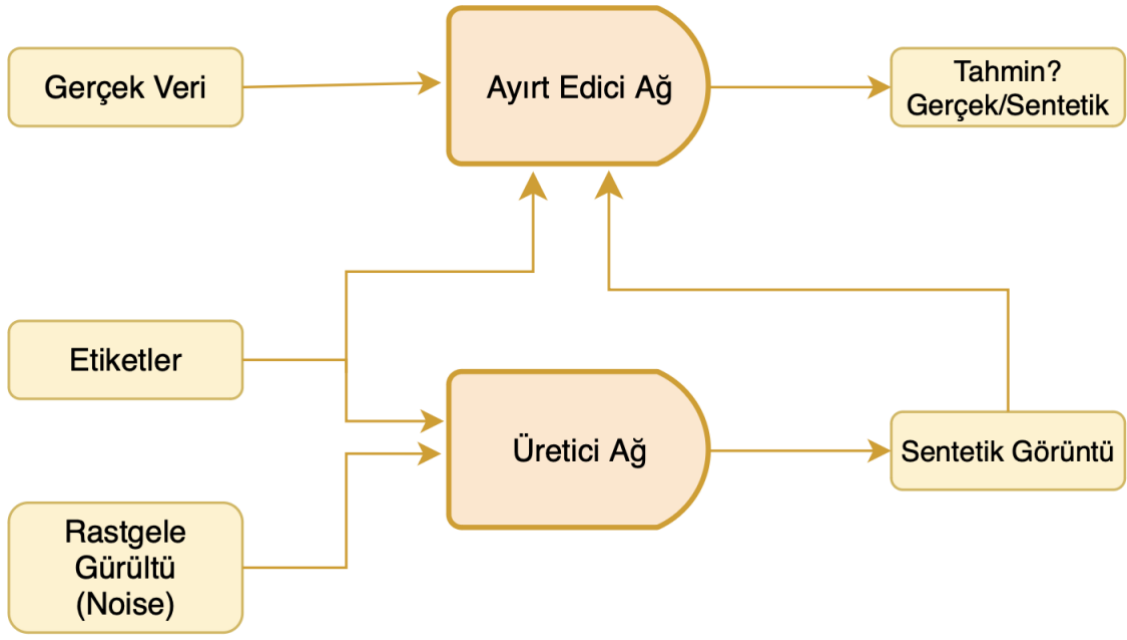
Yıl	Yazarlar	Kullanılan ÇÜA Mimarisi	Veri Seti	Sonuç
2020	Jiancheng Yang, Rui Shi, Donglai Wei, Zequan Liu, Lin Zhao, Billian Ke, Hanspeter Pfister, Bingbing Ni	Dual Adversarial Generative Adversarial Network (DAGAN)	ISIC 2017	Doğruluk: %93,5
2020	Hai Xie, Haijun Lei, Xianlu Zeng, Yejun He, Guozhen Chen, Ahmed Elazab, Guanghui Yue, Jiantoo Wang, Guoming Zhang, Baiying Lei	AMD-GAN based on the attention encoder (AE) and multi-branch (MB)	SLO	Doğruluk: %81,84
2021	Dan Wang, Zhen Chen, Hongwei Zhao	Prototype Transfer Generative Adversarial Network (PTGAN) [19]	BreaKHis	Doğruluk: Yaklaşık %90
2022	Massimo Salvi, Francesco Branciforti, Federica Veronese, Elisa Zavattaro, Vanessa Tarantino, Paola Savoia, Kristen M. Meiburger	Dermatological Color Constancy Generative Adversarial Network (DermoCC-GAN)	Deri lezyonları	Doğruluk: %79,2
2022	Y.-Y. Duan, J. Qin, W.-Q. Qiu, S.-Y. Li, C. Li, A.-S. Liu, X. Chen, C.-X. Zhang	GAN	Karaciğer ultrason görüntüleri	AUC değeri: ortalama %89
2022	Shuai Yuan, Yunfei Gong, Gang Wang, Borui Zhang, Yuanning Liu, Hao Zhang	Multi – Scale Feature Fusion Conditional Deep Convolutional Generative Adversarial Network (MSFF-CDCGAN)	RNA verileri	F1 skoru: %77

3. ÇEKİŞMELİ ÜRETİCİ AĞ TÜRLERİ VE UYGULAMA ALANLARI

ÇÜA mimarisi birçok alanda veri sorunun önüne geçmektedir. Özellikle sağlık alanında yaşanan sıkıntılarının önüne görüntü sentezi, veri artırma, stil transferi ve görüntü iyileştirme gibi birçok uygulamayla önemli başarılar elde edilmiştir. Fakat zaman içerisinde özellikle tıbbi görüntü işlemede temel ÇÜA mimarisi çeşitli sorunlarla karşılaşmıştır ve bu sorunlarla başa çıkmak için birçok farklı ÇÜA türü geliştirilmiştir. Bu sorunun önüne geçerken ise farklı ÇÜA çeşitleri kullanılmaktadır. Bu bölümde Pix2Pix [7], CycleGAN [8], StyleGAN [10], SRGAN [11], CGAN [12] gibi çeşitli ÇÜA türleri ve bu türlerin temel yapıları ve uygulamaları alanları anlatılmıştır.

3.1. Koşullu Çekişmeli Üretici Ağ (Conditional GAN – CGAN)

Sentetik veri üretimini belirli koşullar altında yapan ÇÜA mimarisi Koşullu Çekişmeli Üretici Ağ (Conditional Generative Adversarial Network – CGAN) olarak isimlendirilmektedir. Geleneksel ÇÜA yapısında olan üretici ve ayırt edici ağlara ek olarak CGAN mimarisinde ağlara koşullu bilgiler eklemektedir [31]. Bu bilgiler, verilerin etiketleri veya ek veriler olabilmektedir. Eklediği koşullar sayesinde daha kontrollü ve anlamlı sentetik verilerin üretilmesini sağlamaktadır [32]. CGAN tıpkı klasik ÇÜA modeli gibi birbiriyle çekişme halinde olan iki sinir ağından oluşmaktadır. Üretici ağ noise olarak isimlendirilen rastgele gürültü verilerini girdi olarak alarak sentetik görüntüler üretmektedir. Ayırt edici ağ ise girdi olarak üretici ağ tarafından üretilen sentetik görüntüleri ve gerçek veri setinden alınan verileri almaktadır. Burada klasik ÇÜA modelinin ayırt edici ağından farklı olarak CGAN mimarisinin ayırt edici ağına aynı zamanda girdi olarak koşullu bilgi verilmektedir (Şekil 3.1). Amaç gerçek verilerle sentetik verileri birbirinden ayırt etmektedir. Üretici ağ, rastgele gürültü vektörünü ve bir koşullu bilgiyi alarak sentetik veri üretmektedir. Bu girdi verileri ise evrişimli katmanlar kullanılarak işlenmektedir. Böylece istenilen koşullarda gerçeğe en yakın sentetik veriler üretilmektedir. Ayırt edici ağ, koşullu bilgiyi de kendisine girdi olarak almaktadır ve üretilen sentetik görüntünün koşullu bilgiye uygun olup olmadığına bakarak değerlendirme yapmaktadır.



Şekil 3.1. CGAN mimarisi

Klasik ÇÜA mimarisinde ağların nasıl sentetik veri ürettiği kayıp fonksiyonu ile açıklanmaktadır. Her bir ağın kendine özgü kayıp fonksiyonu bulunmaktadır. Ayırt edici ağ, gerçek ve sentetik verileri birbirinden ayırt etmeye çalışmaktadır. Bu süreçte gerçek veriler için belirlenen olasılık (1), üretilen sentetik veriler için belirlenen olasılık (0) olarak tahmin edilmeye çalışılmaktadır. Ayırt edici ağ, kayıp fonksiyonu 3.1.1'deki denklemde tanımlanmaktadır [33].

$$\mathcal{L}_D = -\mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x)] - \mathbb{E}_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (3.1.1)$$

Bu denklemde (D_z), ayırt edici ağın gerçek veriler için tahmini iken, $D(G(z))$ ise üretilen sentetik görüntüler için tahminidir. Üretici ağ için kayıp fonksiyonu ise 3.1.2'deki denklemde görüldüğü gibidir [33].

$$\mathcal{L}_G = -\mathbb{E}_{z \sim p_z(z)} [\log D(G(z))] \quad (3.1.2)$$

Bu kısımda üretici ağın temel amacı ayırt edici ağın sentetik verileri gerçek olarak sınıflandırma olasılığını maksimum seviyeye çıkarmaktır. CGAN'da ise klasik ÇÜA mimarisine ek olarak koşullu bilgi olan etiketler dahil olmaktadır. Yani ayırt edici ağ, gerçek veri ve koşullu bilgiyi birlikte değerlendirmektedir. Ayırt edici ağ için kayıp fonksiyonu denklemi 3.1.3'de görüldüğü gibidir [33].

$$\mathcal{L}_D = -\mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x | y)] - \mathbb{E}_{z \sim p_z(z)} [\log (1 - D(G(z | y) | y))] \quad (3.1.3)$$

Bu denklemde $D(x|y)$, ayırt edici ağın koşullu bilgi ile birlikte gerçek verilerin tahmini iken, $D(G(z|y)|y)$ ise koşullu bilgi ile sentetik verilerin tahminini temsil etmektedir. Üretici ağın kayıp fonksiyonu ise 3.1.4'deki denklemde gösterilmiştir [33].

$$\mathcal{L}_G = -\mathbb{E}_{z \sim p_z(z)}[\log D(G(z|y)|y)] \quad (3.1.4)$$

Üretici ağ, ayırt edici ağın koşullu bilgiye sahip sentetik verileri gerçek olarak sınıflandırma olasılığını maksimum seviyeye çıkarmaktadır.

Koşullu bilginin ağlara eklenmesi sentetik veri üretimini daha spesifik yapmakta ve üretilen sentetik verilerin daha kaliteli olmasını sağlamaktadır. Fakat bunun yanı sıra, koşullu bilgiler ağın eğitiminin daha karmaşık olmasına sebep olabilmektedir. Aynı zamanda yeterli miktarda ve çeşitli koşullu bilgi gerektirmektedir.

CGAN'lar kontrollü sentetik veri üretimini sağlamaktadır. Belirli özelliklere sahip sentetik görüntülerin üretilmesini sağlamaktadır; örneğin belirli anatomik yapılar veya patolojik durumlar. Bunun yanı sıra ek koşullandırma bilgisi sayesinde CGAN'lar, geleneksel ÇÜA modellerine göre daha yüksek ve gerçekçi görüntüler üretebilmektedir. Uygulama alanları ise, CGAN kullanılarak MRI görüntülerinin çözünürlüğü artırılabilir ve bu sayede görüntü kalitesi ve tanı kullanışlılığı önemli ölçüde iyileştirilebilmektedir. MRI görüntülerini CT görüntülerine çevirmek içinde CGAN'lar kullanılabilir. Sonuç olarak CGAN'lar, yüksek kaliteli ve belirli koşullara uygun tıbbi görüntülerin üretilmesi için güçlü ve esnek bir çerçeve sunmaktadır.

3.2. Süper Çözünürlüklü Çekişmeli Üretici Ağ (Super – Resolution Generative Adversarial Network – SRGAN)

Çalışmalarda kullanılan verilerin çözünürlükleri düşük olduğu zaman çalışmanın sonuçları olumsuz etkilenebilmektedir. Bu soruna çözüm olarak SRGAN, düşük çözünürlüklü görüntüleri yüksek çözünürlüklü görüntülere dönüştürmek için kullanılmaktadır [34]. SRGAN modeli, foto-gerçekçi detaylar üretme kapasitesiyle öne çıkmaktadır.



Şekil 3.2. SRGAN ile yüksek çözünürlüğe getirilen görüntü örneği [11]

Geleneksel ÇÜA mimarisi gibi, SRGAN modeli iki temel yapıdan oluşmaktadır: üretici ve ayırt edici. Üretici ağ, düşük çözünürlüklü görüntüyü girdi olarak almaktadır. Yapılmak istenen, alınan bu düşük çözünürlüklü görüntüleri yüksek çözünürlüklü hale getirmektir. Bu işlemi yapmak için ise artık bloklar (residual blocks) ve up – sampling katmanları kullanılmaktadır. Artık bloklar, giriş ve çıkış arasında doğrudan bağlantılar kurmaktadır. Kurulan bu bağlantılar sayesinde ağın daha derin katmanlarına bilgi aktarımı yapmak daha kolay hale gelmektedir. Up – sampling katmanlarında genellikle pixel shuffle yöntemiyle işlemler yapılmaktadır [11]. Şekil 3.2’de görüldüğü gibi bu yöntem, düşük çözünürlüklü bir görüntünün kanallarını yeniden düzenlemektedir. Bu sayede düşük çözünürlüklü görüntü yüksek çözünürlüklü görüntüye dönüştürülmektedir. Ayırt edici ağda ise, üretilen sentetik yüksek çözünürlüklü görüntüyü ve gerçek yüksek çözünürlüklü görüntüyü girdi olarak almaktadır.

Her iki görüntü grubu arasındaki farkı ayırt etmeye çalışmaktadır. Yapılmak istenen işlem geleneksel ÇÜA mimarisindeki gibi gerçek ve sentetik görüntüyü birbirinden ayırt etmeye çalışmaktır.

SRGAN modelinin eğitim aşamasında üretici ve ayırt edici ağın birlikte eğitilmesi gerekmektedir. Bu süreçte rekabetçi kayıp ve içerik kaybı kullanılmaktadır. Denklem 3.2.1 üretici ağ için rekabetçi kayıp, denklem 3.2.2 ise ayırt edici ağ içindir [11].

$$\mathcal{L}_{Gen} = \mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} [\log (1 - D(G(\mathbf{z})))] \quad (3.2.1)$$

$G(\mathbf{z})$: üretilen sentetik görüntü

D : ayırt edici

\mathbf{Z} : rastgele gürültü vektörü

$P_z(\mathbf{z})$: gürültü vektörünün dağılımı

Denkleimde verilen $\log(1 - D(G(\mathbf{z})))$ kısım ise üretici, ayırt edici ağıın sentetik görüntüleri gerçek olarak sınıflandırmasını sağlamak amacıyla minimize edilmektedir.

$$\mathcal{L}_{\text{Dis}} = \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})}[\log D(\mathbf{x})] + \mathbb{E}_{\mathbf{z} \sim p_{\mathbf{z}}(\mathbf{z})}[\log(1 - D(G(\mathbf{z})))] \quad (3.2.2)$$

X: gerçek görüntü

$P_{\text{data}}(\mathbf{x})$: gerçek görüntülerin dağılımı

$\log(1 - D(G(\mathbf{z})))$ fonksiyonu ve $\log D(\mathbf{x})$ ayırt edici ağ tarafından maksimize edilmeye çalışılmaktadır.

Rekabetçi kayıp hem üretici hem de ayırt edici ağıın eğitiminde kullanılmaktadır. Bu kayıp fonksiyonu, her iki ağ arasında bir rekabet ortamı oluşturmaktadır. Böylece daha gerçekçi görüntüler üretmeyi ve gerçek sentetik arasındaki ayırımı yapmayı öğrenmektedir.

İçerik kayıp fonksiyonu VGG ağıından çıkan özellikleri kullanılmaktadır. Düşük ve yüksek çözünürlüklü görüntüler arasındaki fark bu fonksiyon ile hesaplanmaktadır. İçerik fonksiyonu denklemi 3.2.3'te verildiği gibidir.


$$\mathcal{L}_{\text{Content}} = \mathbb{E}_{\mathbf{x}, \mathbf{y}}[\|\phi(\mathbf{y}) - \phi(G(\mathbf{x}))\|^2] \quad (3.2.3)$$

Tıbbi görüntü uygulamalarında SRGAN sıklıkla kullanılmaktadır. Bu alanda görüntülerin detaylarının kritik olduğu ve tanı doğruluğunu artırdığı bilinmektedir. Bu sebeple kullanılan SRGAN özellikle MRI ve CT taramalarının çözünürlüğünü artırarak daha net ve detaylı görüntüler elde etmeye sağlamaktadır. Aynı zamanda veri setlerini zenginleştirerek modellerin eğitiminin daha etkili yapılmasını sağlamaktadır.

3.3. Döngü Tutarlı Çekişmeli Üretici Ağ (Cycle – Consistent GAN – CycleGAN)

CycleGAN mimarisi, 2017 yılında Zhu ve arkadaşları tarafından veri setleri arasında görüntü çevirisini gerçekleştirebilmek amacıyla geliştirilmiştir [8]. Bu dönüşümü iki farklı domain arasında gerçekleştirip bu işlemi yaparken de veri eşleşmesine gerek kalmadan yapmaktadır. Eşleşmemiş veri setleriyle çalışma yeteneği döngü tutarlılık kaybı (cycle consistency loss) adı verilen özel bir kayıp fonksiyonu kullanmasına dayanmaktadır. Bahsi geçen kayıp fonksiyonu iki kısımdan oluşmaktadır. İlk kısım ilk veri setindeki görüntülerin iki ağdan geçtikten sonra aynı görüntüye geri dönüştürülmesini sağlamaktadır. İkinci kısımda ise bir çizim görüntüsünün her iki ağdan geçtikten sonra aynı görüntüye tekrar dönüştürülmesini sağlamaktadır.

CycleGAN özellikle dengesiz ve gece gündüz gibi karmaşık verilere sahip problemlerde kullanılmak için elverişlidir. Görüntüden görüntüye çeviri uygulamalarında da sıklıkla CycleGAN mimarisi kullanılmaktadır (Şekil 3.3).



Şekil 3.3. CycleGAN kullanım örneği

CycleGAN mimarisi genel olarak Pix2Pix mimarisine benzemektedir [35]. 2016 yılında Pix2Pix mimarisinde yapılan gelişmeler sonucunda CycleGAN mimarisi geliştirilmiştir. İki mimari arasındaki temel fark ise Pix2Pix eşleştirilmiş görüntü verilerine ihtiyaç duyarken CycleGAN buna ihtiyaç duymamaktadır. CycleGAN mimarisi, geleneksel mimariden farklı olarak iki üretici ağ ve iki ayırt edici ağdan oluşmaktadır [7], [8]. Bu çift yönlü yapı, ileri ve geri dönüşümleri mümkün kılmaktadır. Bu durumda daha tutarlı ve gerçekçi dönüşümler yapılmasını sağlamaktadır. Üretici ağlar içerisinde birinci ağ kaynaktan hedefe dönüştürürken diğer ağ hedeften kaynağa görüntüleri dönüştürmektedir. Ayırt edici ağlarda ise ilk ağ hedef domain görüntülerinin gerçek mi sentetik mi olduklarını belirlemeye çalışırken, ikinci ağ kaynak domain görüntülerinin gerçek ve sentetik olduklarını ayırt etmeye çalışmaktadır. Her iki ağda çekişmeli kayıp (Adversarial Loss) adı verilen klasik GAN mimarisinin kayıp fonksiyonuna sahiptir. İlk üretici ve ilk ayırt edici ağların 3.3.1’de kayıp fonksiyonu verilmiştir.

$$\mathcal{L}_{GAN}(G, D_Y, X, Y) = \mathbb{E}_{y \sim p_{\text{data}}(y)} [\log D_Y(y)] + \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log (1 - D_Y(G(x)))] \quad (3.3.1)$$

İkinci üretici ve ikinci ayırt edici ağların 3.3.2’de kayıp fonksiyonu verilmiştir.

$$\mathcal{L}_{GAN}(F, D_X, Y, X) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D_X(x)] + \mathbb{E}_{y \sim p_{\text{data}}(y)} [\log (1 - D_X(F(y)))] \quad (3.3.2)$$

Üretici ve ayırt edici ağlar ileri ve geri olacak şekilde dönüşümler yapmaktadır. Bu dönüşümler ise Döngü Tutarlılık Kayıp (Cycle Consistency Loss) fonksiyonu ile gerçekleştirilmektedir. Görüntü verisinin önce bir domain’e sonra tekrar orijinal domaine dönüştürüldüğünde aynı görüntü verisi

elde edilmelidir. Bu durumu da Döngü Tutarlılık Kayıp fonksiyonu ile sağlanmaktadır. 3.3.3’de bu fonksiyonun denklemi verilmiştir.

$$\mathcal{L}_{cyc}(G, F) = \mathbb{E}_{x \sim p_{data}(x)} [\|F(G(x)) - x\|_1] + \mathbb{E}_{y \sim p_{data}(y)} [\|G(F(y)) - y\|_1] \quad (3.3.2)$$

Üretici ve ayırt edici ağlar ileri ve geri olacak şekilde dönüşümler yapmaktadır. Bu dönüşümler ise Döngü Tutarlılık Kayıp (Cycle Consistency Loss) fonksiyonu ile gerçekleşmektedir. Görüntü verisinin önce bir domain’e sonra tekrar orijinal domaine dönüştürüldüğünde aynı görüntü verisi elde edilmelidir. Bu durumu da Döngü Tutarlılık Kayıp fonksiyonu ile sağlanmaktadır. 3.3.3’de bu fonksiyonun denklemi verilmiştir.

$$\mathcal{L}_{cyc}(G, F) = \mathbb{E}_{x \sim p_{data}(x)} [\|F(G(x)) - x\|_1] + \mathbb{E}_{y \sim p_{data}(y)} [\|G(F(y)) - y\|_1] \quad (3.3.3)$$

Çekişmeli Kayıp ve Döngü Tutarlılık Kayıp fonksiyonlarının toplamı ise toplam kayıp olarak tanımlanmaktadır (3.3.4’teki denklem).

$$\mathcal{L}(G, F, D_X, D_Y) = \mathcal{L}_{GAN}(G, D_Y, X, Y) + \mathcal{L}_{GAN}(F, D_X, Y, X) + \lambda \mathcal{L}_{cyc}(G, F) \quad (3.3.4)$$

CycleGAN mimarisi birçok farklı alanda veri sorununa çözüm getirmektedir. Sanat ve stil transferi, tıbbi görüntüleme, sanal gerçeklik ve oyun geliştirme, tarım ve çevre bilimi gibi birçok alanda uygulamalara sahip olan CycleGAN, GAN mimarileri arasında önemli bir yere sahiptir.

3.4. Pix2Pix

Derin evrişimli sinir ağından oluşan Pix2Pix’in temeli ÇÜA mimarisine dayanmaktadır. Yapılan işlem görüntüden görüntüye çeviri işlemidir. Girdi olarak verilen görüntü başka bir hedef görüntüsüne çıktı olarak dönüştürülmektedir [7]. Siyah beyaz görüntülerin renklendirilmesi çalışması ya da çizimlerden görseller üretilmesi bu alanı açıklayan en iyi örneklerdendir (Şekil 3.4).



Şekil 3.4. Pix2Pix kullanılarak yapılan eskiz dönüştürülmesi ve renklendirme çalışmaları [7]

Pix2Pix modeli, geleneksel ÇÜA mimarisinde olduğu gibi iki ana ağdan oluşmaktadır: üretici ve ayırt edici. Üretici ağ, U-Net mimarisini kullanmaktadır. Düşük çözünürlükte olan özellik

haritalarının yüksek çözünürlüklere çıkarmaya çalışmaktadır. Bu işlem yapılırken encoder ve decoder yapısı kullanılmaktadır. Aynı zamanda simetrik katmanlar bulunmakta ve bu katmanların arasında da doğrudan bağlantılar yer almaktadır. Ayırt edici ağ ise görüntünün bütünü yerine yamaları üzerinde çalışan PatchGAN yapısını kullanmaktadır. Geleneksel ÇÜA modelinde görüntünün bütünü gerçek mi yoksa sentetik mi diye değerlendirilmekteyken, bu yapı sayesinde her bir yama gerçek mi sentetik mi olarak değerlendirilmektedir. Genel olarak ayırt edici ağın çalışma mantığı geleneksel ÇÜA ile aynıdır.

Pix2Pix modeli çekişmeli kayıp ve L1 kayıp isimli iki temel kayıp fonksiyonundan oluşmaktadır. Çekişmeli kayıp fonksiyonu denklemi 3.4.1’de verilmiştir.

$$\mathcal{L}_{CGAN}(G, D) = \mathbb{E}_{x,y}[\log D(x, y)] + \mathbb{E}_{x,z}[\log (1 - D(x, G(x, z)))] \quad (3.4.1)$$

Denklem 3.4.1’de verilen G üretici ağı, D ise ayırt edici ağı temsil etmektedir. x giriş görüntüsünü, y gerçek hedef görüntüyü ve z ise rastgele gürültüyü temsil etmektedir. L1 kayıp fonksiyonu ise 3.4.2’de verilmiştir.

$$\mathcal{L}_{L1}(G) = \mathbb{E}_{x,y,z}[\|y - G(x, z)\|_1] \quad (3.4.2.)$$

L1 kayıp fonksiyonu üretilen sentetik görüntü ile gerçek görüntü arasındaki farkı piksel olarak minimize etmektedir. Bu iki kayıp fonksiyonu toplam kayıp fonksiyonunda birleştirilmektedir. Modelin eğitim sürecinde hem gerçeklik hem de doğruluk açısından maksimum performansın gösterilmesi için kullanılmaktadır. Denklem 3.4.3’te toplam kayıp fonksiyonu verilmiştir. λ , L1 kaybının ağırlıklandırma faktörüdür.

$$G^* = \arg \min_G \max_D \mathcal{L}_{CGAN}(G, D) + \lambda \mathcal{L}_{L1}(G) \quad (3.4.3)$$

Pix2Pix modeli kapsamlı etiketlenmiş veri setleri ile kolayca eğitilebildiği için segmentasyon, görüntü iyileştirme ya da restorasyon ve modalite dönüşümü gibi görevlerde kullanılmaktadır. Diğer ÇÜA mimarilerinin yanı sıra Pix2Pix modelinin seçilmesinin sebebi, çeşitli görüntüden görüntüye çeviri uygulamalarında daha esnek kullanılabilmesidir. Ayrıca U-Net ve PatchGAN yapılarını kullanması yüksek ve detaylı görüntülerin üretilebilmesini sağlamaktadır.

3.5. StyleGAN

Yüksek kaliteli ve kontrol edilebilir görüntü üretiminde kullanılan StyleGAN NVIDIA tarafından üretilmiş ÇÜA modelidir [10]. Stil transferi ve varyasyonunu kontrol edebilme kapasitesi ile dikkat çeken bu model, foto-gerçekçi görüntüler üretebilme yeteneği sayesinde diğer ÇÜA modellerinden ayrılmaktadır. Geleneksel ÇÜA modelinden farklı olarak stil bazlı bir üretim sürecine sahiptir. Bu süreçte stil vektörü ve haritalama ağı bileşenlerini kullanmaktadır.

Haritalama ağı, rastgele gürültü vektörünü daha anlamlı bir uzaya dönüştürmektedir. Bu işlemleri tam bağlantılı katmanları ile gerçekleştirmektedir. Girdi olarak alınan z rastgele gürültü vektörü style vektör (w) olarak adlandırılan vektöre dönüştürülmektedir [36].

StyleGAN sentetik görüntüleri sentez ağı kullanarak üretmektedir. Çözünürlüğü adım adım arttıran katmanlardan oluşan yapı, her bir katmanda stil vektörlerini kullanarak görüntüye belirli özellikler eklemektedir. Stil vektörlerini farklı çözünürlük seviyelerinde görüntüye entegre etmek için AdaIN (Adaptive Instance Normalization) kullanılmaktadır. Bu normalizasyon işlemini ise stil vektörlerinden gelen bilgilerle koşullandırmaktadır.

StyleGAN modelinde yapılan işlemlerin matematiksel denkleminde hem haritalama hem de sentez ağında kullanılan işlemlerden oluşmaktadır. Denklem 3.5.1 ve 3.5.2 haritalama ağı ve AdaIN işlemlerine aittir [10].

$$w = f(z) \quad (3.5.1)$$

3.5.1'deki denklemde z rastgele gürültü vektörünü, f haritalama ağını ve w stil vektörünü temsil etmektedir.

$$\text{AdaIN}(x_i, y) = \gamma(y) \left(\frac{x_i - \mu(x_i)}{\sigma(x_i)} \right) + \beta(y) \quad (3.5.2)$$

Burada x_i giriş aktivasyonunu, y ise stil vektörünü temsil etmektedir. μ ve σ girişin ortalama ve standart sapmasıdır. γ ve β ise stil vektöründen hesaplanan ölçekleme ve kaydırma parametrelerinin temsilleridir.

StyleGAN görüntü sentezi, anomali tespiti ve görüntü iyileştirme gibi uygulama alanlarında kullanılmaktadır. Özellikle stil transferi ve varyasyon kontrolü sayesinde yüksek kaliteli ve detaylı görüntüler üretebilme yeteneği sayesinde diğer ÇÜA modellerinden ayrılmaktadır.

Pix2Pix, CycleGAN, StyleGAN, SRGAN ve CGAN modellerinin özetlendiği tablo gösterilmiştir.

Tablo 3.1. Tıbbi görüntüleme için kullanılan ÇÜA modelleri

ÇÜA Türü	Farklar	Avantajlar	Dezavantajlar	Kullanıldığı Veri Türleri
Pix2Pix	Koşullu GAN, görüntüden görüntüye çeviri; U-Net mimarisi kullanır.	Yüksek kaliteli görüntü dönüşümü sağlar.	Etiketlenmiş veri gerektirir; eğitim için büyük veri setleri gerekir.	MRI-CT dönüşümü, görüntü segmentasyonu
CycleGAN	Koşulsuz GAN, eşlenmemiş veri setleri üzerinde çalışır; ileriye	Eşlenmemiş veri estleri ile çalışabilir, bu da veri toplama sürecini kolaylaştırır.	Eğitim süreci daha karmaşıktır.	MRI-PET dönüşümü, histopatoloji görüntüleri arasında dönüşüm

	ve geri dönüşüm ağırları kullanır.			
StyleGAN	Stil tabanlı üretici süreç kullanır; stil vektörü ve AdaIN içerir.	Yüksek kaliteli ve kontrol edilebilir görüntüler üretir; detay ve varyasyon kontrolü sağlar	Hesaplama maliyeti yüksektir; eğitim süreci uzun sürer.	Histopatoloji görüntüleri, yüksek çözünürlüklü beyin taramaları, göz retinası görüntüleri
SRGAN	Süper çözünürlük için optimize edilmiş ÇÜA; artık bloklar ve piksel shuffle kullanır.	Düşük çözünürlüklü görüntüleri yüksek çözünürlüklü hale getirir; detayları artırarak tıbbi görüntülerin tanı doğruluğunu iyileştirir.	Hesaplama maliyeti yüksektir; bazı durumlarda görsel artefaktlar oluşabilir.	Düşük çözünürlüklü MRI ve CT taramaları, PET taramaları, ultrason görüntüleri
CGAN	Koşullu GAN, belirli koşullar altında görüntü üretir; giriş verilerine ek olarak koşul verilerini kullanır.	Belirli koşullara göre hedeflenen görüntülerin üretimini sağlar; veri artırma ve eğitim setlerinin zenginleşmesinde etkilidir.	Koşul verilerinin doğru ve yeterli olması gerekir; eğitim sürecinde karmaşık olabilir.	Belirli hastalıkları temsil eden MRI görüntüleri, tümör türüne göre sınıflandırılmış görüntüler, genetik marker'larla işaretlenmiş görüntüler

Tablo 3.1, tıbbi görüntüleme için kullanılan çeşitli ÇÜA modellerinin özelliklerini, avantajlarını, dezavantajlarını ve kullandıkları veri türlerini özetlemektedir. Pix2Pix modeli, U-Net mimarisi kullanarak görüntüden görüntüye dönüşüm sağlamak ve yüksek kaliteli görüntüler üretebilmektedir ancak etiketlenmiş veri ve büyük veri setleri gerektirmektedir. CycleGAN, eşlenmemiş veri setleriyle çalışabilmekte ve veri toplama sürecini kolaylaştırmaktadır ancak eğitim süreci daha karmaşıktır. StyleGAN, stil tabanlı üretici süreç kullanılarak yüksek kaliteli ve kontrol edilebilir görüntüler üretmektedir, ancak yüksek hesaplama maliyeti ve uzun eğitim süreci gerektirmektedir. SRGAN, süper çözünürlük için optimize edilmiştir ve düşük çözünürlüklü görüntüleri yüksek çözünürlüklü hale getirmektedir, fakat bazı durumlarda görsel artefaktlar oluşturabilmektedir. CGAN, belirli koşullar altında görüntü üretmekte ve hedeflenen görüntülerin üretiminde esneklik sağlamaktadır, ancak koşul verilerinin doğruluğu ve yeterliliği önemlidir ve eğitim süreci karmaşık olabilmektedir. Bu modeller, MRI-CT dönüşümü, görüntü segmentasyonu, histopatoloji görüntüleri, beyin taramaları, göz retinası görüntüleri, düşük çözünürlüklü MRI ve CT taramaları, PET taramaları, ultrason görüntüleri gibi çeşitli tıbbi veri türleri ile kullanılmaktadır.

4. DEĞERLENDİRME METRİKLERİ

ÇÜA ile üretilen veriler, üretilen verilerin güvenilir kullanımı için değerlendirilmelidir. Ancak, bir ÇÜA'nın üreticini değerlendirmek için bir kayıp fonksiyonu yoktur. Bu nedenle eğitime devam etmenin ve modelin kalitesini sadece kayıp üzerinden değerlendirmenin bir yolu yoktur. Kayıp fonksiyonu yerine bir ÇÜA modelinin performansını değerlendirmek için nitel ve nicel teknikler geliştirilmiştir.

4.1. Nitel Metrikler

Bir ölçü olarak üretilen sentetik görüntünün kalitesi, üretilen sentetik görüntülerin değerlendirilmesi için kullanılmaktadır. Kalitenin değerlendirilmesi, farklı iterasyon adımlarından üretilen bu sentetik görüntülerin manuel olarak gözden geçirilmesi ve değerlendirilmesidir. Bu yöntem, ÇÜA'ları değerlendirmek için kullanılan en yaygın yöntemlerden biridir. Modellerin gözden geçirilmesine ve ayarlanmasına yardımcı olması, hızlı ve sezgisel bir yol olması gibi faydalarının yanı sıra bazı dezavantajları da vardır [37]. Üretilen görüntünün kalitesine ilişkin bir inceleme, eleştirmenin önyargılarını içerebilmektedir. Ayrıca görüntü sayısı ile de sınırlı olabilmektedir. Bir model tarafından üretilen görüntülerin gizli alanını niteliksel olarak değerlendirmek, incelemek ve keşfetmek için literatürde ağ içlerini araştırmak ve görselleştirmek, üretilen görüntülerin en yakın komşusunu bulmak ve üretici ağın ürettiği verilerde çeşitliliğin sağlanamaması sorunu olarak adlandırılan modun çökmesini değerlendirmek gibi yöntemler bulunmaktadır [37]. Bir değerlendirme ve tercih kararı uygulanırken, görüntüyü değerlendiren kişiye farklı örnekler sunulmakta ve hangi örnekleri tercih ettiği sorulmaktadır. Denton ve arkadaşlarının kullandığı gibi hızlı aşama kategorizasyon sırasında görüntüyü değerlendiren kişi için üretilen sentetik görüntüler kısaca gösterilmektedir. Sonuç olarak gerçek ya da sentetik olarak sınıflandırılması istenmektedir [38].

4.2. Nicel Metrikler

Nicel metriklerin temeli matematiksel ifadelerle dayanmaktadır ve sonuçların en net şekilde değerlendirildiği yöntemlerdir. Bu yöntem, gerçek ve üretilen sentetik görüntüler arasındaki niceliksel farklılıkları yakalamaya çalışmaktadır. Nicel yöntemlerin en büyük faydası sonuçların doğru değerlendirilmesini sağlamaktır. Birden fazla nicel değerlendirme yöntemi vardır, ancak GAN yaklaşımı için en popüler nicel değerlendirme yöntemleri Başlangıç Skoru – BS (Inception Score – IS) ve Frechet Başlangıç Mesafesi – FBM (Frechet Inception Distance – FID)'dir [39].

4.2.1. Başlangıç Skoru – BS (Inception Score – IS)

Başlangıç Skoru, Salimans ve arkadaşları tarafından 2016 yılında “GAN'ları Eğitmek için Geliştirilmiş Teknikler” başlıklı makalede önerilmiştir [39]. Bu skorun geliştirilmesinin temel nedeni, görüntüler için öznel insan görüşünü ortadan kaldırmaktır. Belirli bir nesneye benzeyen ve çeşitli nesnelere üreten bu tür görüntülerin iki ana amacı vardır. Oluşturulan görüntüleri sınıflandırmak için önceden eğitilmiş Inception V3 modeli olarak adlandırılan bir derin öğrenme sınıflandırma modelinin kullanımını içermektedir [40]. Süreç kısaca her bir görüntünün hangi sınıfta oluşturulduğunun olasılığını tahmin etmek ve ardından bunu BS ile özetlemektir. Burada bahsedilen olasılık, sınıf etiketleri gibi koşullu bir olasılıktır. Üretilen sentetik görüntüler, diğer tüm sınıflarla karşılaştırıldığında, gerçek görüntünün en güçlü özelliklerine sahip olan ve yüksek kaliteye işaret eden bir sınıfta sınıflandırılmaktadır. Bu nedenle, koleksiyondaki tüm üretilen görüntülerin daha az koşullu entropiye sahip olması gerekmektedir [39].

4.2.2. Frechet Başlangıç Mesafesi – FBM (Frechet Inception Score – FID)

Gerçek görüntü ile oluşturulan görüntüler arasındaki özellik mesafesini ölçmek için kullanılan bu metrik, eğriler arasındaki benzerliğin bir ölçüsü olarak tanımlanmaktadır [41]. Eğriler boyunca noktaların konumu ve sırası dikkate alınırken iki dağılım arasındaki mesafeyi ölçmek için kullanılmaktadır. Inception V3 modeli, Inception Score'da kullanıldığı gibi bu değerlendirme yönteminde de kullanılmaktadır. Her bir görüntüyü özetlemek için Inception V3 modelinden aktivasyonların kullanılmasına FBM denir. Bu aktivasyon sonradan bir önceki toplama katmanından alınır. Burada kullanılan Inception V3 modeli çeşitli gerçek görüntülerden oluşan ImageNet veri kümesi ile eğitildiğinden, FBM'yi çok farklı veri kümelerine uygulamak aldatıcı olabilmektedir. Bununla birlikte, FBM değerlendirme yönteminin insan kararlarına benzer olduğu ve ayrımcılık, sağlamlık ve hesaplama verimliliği açısından iyi performans gösterdiği gösterilmiştir [37].

5. MATERYAL VE METOT


5.1. Veri Seti

Dünya çapında beyin kanseri en yaygın kanser türlerinden ve ölüm nedenlerinden biridir. Bu sebeple erken teşhis ve tedavi bu alanda önemli bir yer tutmaktadır. Bu tez çalışmasında, beyin MR görüntülerinden oluşan beş farklı açık kaynak veri setinin birleşimi kullanılmıştır. Genel olarak beyin MR görüntüleri üç farklı sınıfa ayrılmaktadır: gliom, hipofiz bezi tümörü ve tümör olmayan beyin görüntüleri.

Çalışmanın ilk kısmında, YOLOv7 modelinin eğitimi amacıyla geniş bir beyin tarama veritabanı kullanılmıştır [42]. Bu veri seti, MRI dahil olmak üzere çeşitli görüntüleme modalitelerinden elde edilen beyin taramalarını içermektedir. Seçilen veri seti, hipofiz bezi tümörü, gliom tümörü ve tümör bulunmayan vakaları kapsayan klinik durumların geniş bir yelpazesini temsil edecek şekilde özenle hazırlanmıştır. Kaggle platformu ve Hayatabad Tıbbi Kompleksi, Peşaver tarafından sağlanan veri seti, ekstenel, koronal ve sagittal olmak üzere birden fazla görüntüleme düzlemini içermekte ve her bir sınıfın kapsamlı bir görsel tasvirini sunmaktadır. Bu örnekler, uzman bir radyolog tarafından detaylı bir şekilde incelenmiş ve seçilmiştir, bu da veri setinin güvenilirliğini artırmaktadır.

Daha sonra, veri sayısını artırmak ve çalışmanın kapsamını genişletmek amacıyla, geriye kalan dört veri seti ilk veri seti ile birleştirilerek kullanılmıştır. İkinci veri seti, iki farklı sınıfa ayrılmış verilerden oluşmaktadır: tümürlü ve tümörsüz [43]. Bu veriler, 2018 yılında 25-75 yaş arasındaki kişilerden alınmış olup, 500x500 piksel boyutunda PNG formatında görüntüler içermektedir. Üçüncü veri seti ise hipofiz bezi tümörü, gliom ve tümör bulunmayan üç sınıfa ayrılmış veri örneklerini kapsamaktadır [44]. Dördüncü veri seti de üç sınıfa ayrılmış olup hipofiz bezi tümörü, gliom tümörü ve tümör bulunmayan beyin görüntülerini içermektedir [45]. Son olarak, tez çalışmasında kullanılan beşinci veri seti, figshare, SARTAJ dataset ve Br35H isimli veri setlerinin birleşiminden oluşmaktadır [46]. Bu veri seti de hipofiz bezi tümörü, gliom tümörü ve tümör bulunmayan üç farklı sınıftan oluşmaktadır.

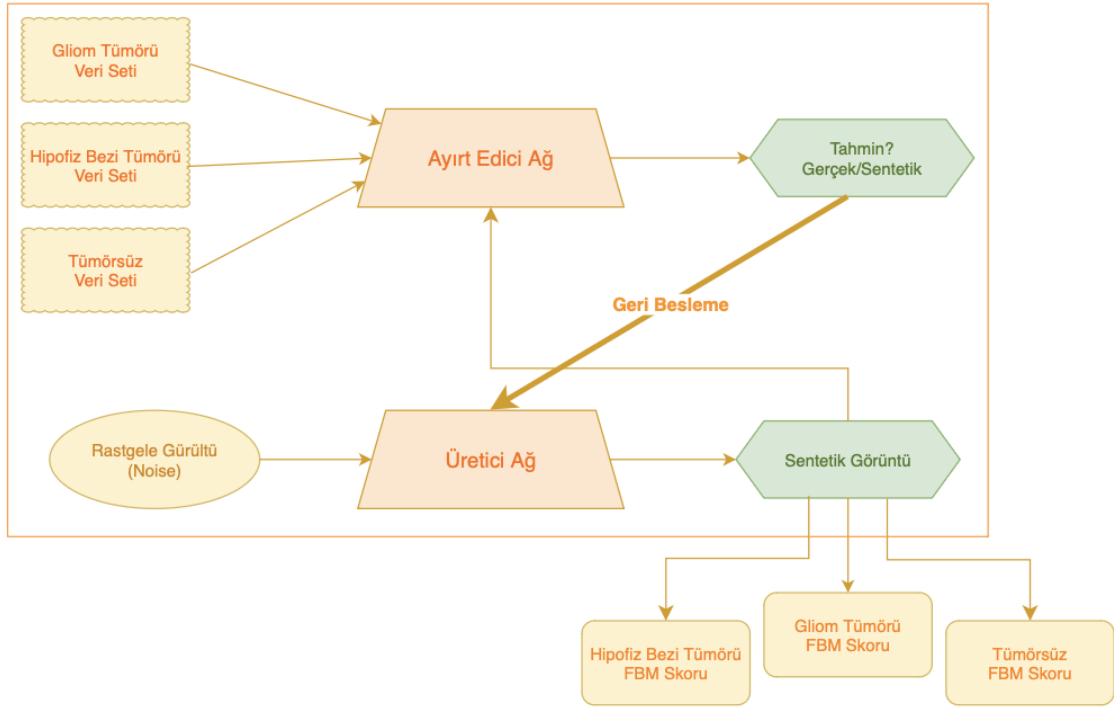
Her bir sınıftaki veri sayısını ortalama dört katına çıkaracak şekilde, veri setlerindeki gliom sınıfları, hipofiz tümörü sınıfları ve tümör olmayan sınıflar birleştirilmiştir. Şekil 5.1’de görüldüğü gibi bu kapsamlı veri birleşimi, modelin eğitiminde daha geniş ve çeşitli bir veri tabanı sağlayarak modelin performansını artırmıştır.



Şekil 5.1. Veri setlerinden karma örnekler

5.2. Metot

Bu tezde, Beyin MRI görüntüleri ÇÜA kullanılarak sentetik olarak üretilmekte ve üretilen görüntülerin kalitesine bakılmaktadır. Eğitim süresinin ve veri setindeki veri artışının üretilen sentetik görüntülerin kalitesini nasıl etkilediğine bakılmak çalışmanın amacı olarak belirlenmiştir. Yapılan çalışma temelde 2 kısımdan oluşmaktadır. Çalışmanın ilk kısmında ilk veri seti tek başına kullanılmıştır. 3 farklı sınıftan oluşan veri setinde gliom tümörü sınıfında 455 ve tümörsüz sınıfında 550, hipofiz bezi tümörü sınıfında da 620 veri olmak üzere toplamda 1720 veri bulunmaktadır. Her bir sınıf sırasıyla 100, 150 ve 200 epoch şeklinde eğitim sürelerine tabi tutulmuş ve her eğitimin FBM skoru hesaplanmıştır. Çalışmanın ikinci kısmında ise karma veri setleri kullanılarak veri sayısının artışı sağlanmıştır. Gliom tümörü sınıfında 2330, tümörsüz sınıfında 2540 ve hipofiz bezi tümörü sınıfında ise 2515 veri bulunmaktadır. Sınıflar yine sırasıyla 100, 150 ve 200 epoch sürelerine tabi tutulmuş ve her eğitimin sonunda FBM skoru hesaplanmıştır. Çalışmanın akış diyagramı şekil 5.2’de verilmiştir.



Şekil 5.2. Çalışmanın Akış Diyagramı

5.2.1. Derin Evrişimli Çekişmeli Üretici Ağ (Deep Convolutional GAN – DCGAN)

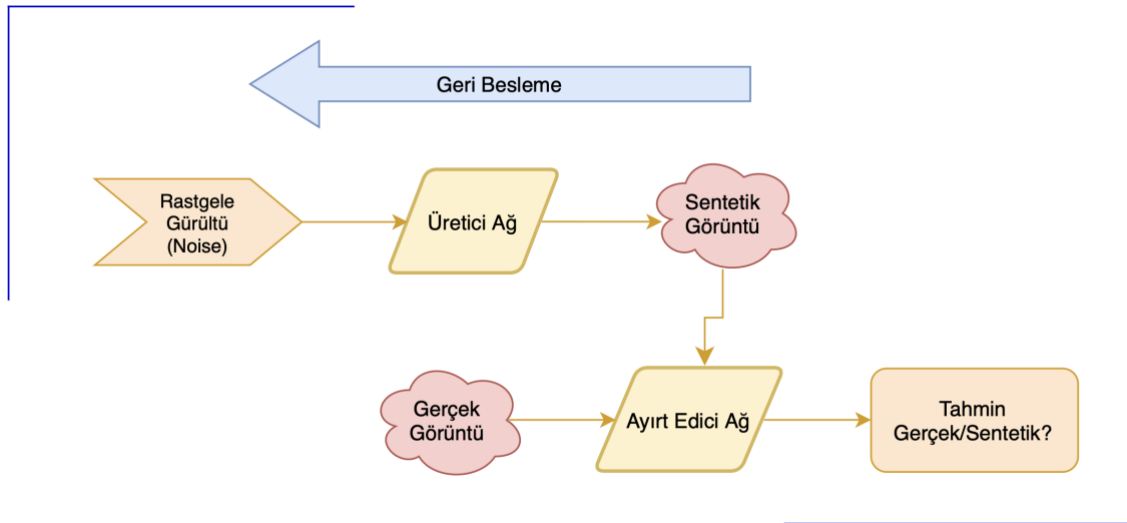
Sentetik veri üretimi, YZ araştırmalarının öncelikli konuları arasında yer almaktadır. Bu teknoloji, gerçek dünya verilerine benzemektedir, ancak tamamen yapay olan verilerin oluşturulmasını mümkün kılmaktadır. Gelişmiş YZ modelleri, görsel, işitsel ve yazılı materyaller dahil olmak üzere çeşitli türde veriler üretebilmektedir. Bu modeller, insan yüzleri gibi karmaşık görselleri gerçeklerinden ayırt edilemeyecek düzeyde yüksek kalitede üretebilme yeteneğine sahiptir. Ayrıca, belirli bir sanatçının stilini taklit ederek, o sanatçıya özgü eserler oluşturabilmektedir. Bu, YZ'nın, öğrenme ve örüntü çıkarma kabiliyetlerinin somut bir göstergesidir.

Medikal alanda, sentetik veri üretimi özellikle önemli bir role sahiptir. Mevcut veri setlerinden yararlanarak, ihtiyaç duyulan verilerin çoğaltılması, tıbbi araştırmalar ve uygulamalar için kritik bir öneme sahiptir [15]. Örneğin, nadir hastalıkların teşhis ve tedavisinde kullanılan YZ modelleri, gerçek hasta verilerinin sınırlı olması nedeniyle eğitimde zorluklarla karşılaşabilmektedir. Sentetik veri üretimi, bu tür durumlarda, modelin daha geniş ve çeşitli veri setleri üzerinde eğitilmesini sağlayarak, modelin genel performansını ve doğruluğunu artırmaktadır. Bu yaklaşım, medikal görüntüleme, hastalık tespiti ve tedavi planlaması gibi alanlarda YZ'nın uygulama potansiyelini önemli ölçüde genişletmektedir.

2014 yılı itibariyle YZ araştırmalarında ön plana çıkan konulardan biri, Variatinal Autoencoders (VAEs) ve ÇÜA olmuştur. Bu teknolojiler sayesinde, görüntülerin saklı uzayı örneklenerek mevcut

görsellerin modifiye edilmesi veya tamamen yeni görsellerin üretilmesi mümkün kılınmaktadır. Ian GOODFELLOW tarafından geliştirilen ÇÜA yaklaşımı, istatistiksel olarak gerçekle ayırt edilemeyecek düzeude sentetik verilerin üretilmesi konusunda bir devrim niteliğindedir [5]. Bu süreç, başlangıçta basit taklitler üreten bir sistem olarak başlamaktadır ancak zamanla taklit yeteneği gelişmekte ve orjinaline oldukça benzeyen, ancak tamamen benzersiz yeni ürünler ortaya çıkarmaktadır. Bu teknolojiler, derin öğrenme ve YZ dünyasında, veri üretimi ve görsel işleme alanlarında yeni bir dönemin başlangıcını işaret etmektedir.

YZ'nın sentetik veri üretimi kabiliyeti, örüntülerin başarılı şekilde çıkarılmasına dayanmaktadır. Bu süreç, derin öğrenme ve özellikle ÇÜA'lar gibi tekniklerin kullanımını içermektedir. ÇÜA'lar, birbirleriyle rekabet eden iki ağı (üretici ve ayırt edici) eş zamanlı olarak eğitilmesiyle çalışmakta ve bu sayede gerçekçilikten ayırt edilemeyecek düzeyde sentetik veriler üretebilmektedir (Şekil 5.3). Bu teknoloji, YZ'nın yaratıcı ve yenilikçi potansiyelini göstermekte ve çeşitli disiplinlerde, sanattan tıba, birçok yenilikçi uygulamanın kapısını aralamaktadır. Sentetik veri üretiminin devam eden gelişimi, YZ'nın insan hayatındaki rolünü daha da derinleştirecek ve genişletecek, yeni araştırma ve uygulama alanları ortaya çıkaracaktır.



Şekil 5.3. DCGAN mimarisi

ÇÜA'ların farklı sorunlar ve alanlar için birçok çeşidi bulunmaktadır. Bu makalede yapılan çalışmada öne çıkan ise evrişimli ağdan oluşan Deep Convolutional Generative Adversarial Network (DCGAN)'dır. DCGAN, ÇÜA modelinin bir evrimidir ve özellikle görüntü tabanlı uygulamalarda kullanılmak üzere tasarlanmıştır [47]. Radford, Metz ve Chintala tarafından 2015 yılında geliştirilen DCGAN, derin öğrenme ve YZ alanlarında önemli bir ilerleme olarak kabul edilmektedir [48]. DCGAN mimarisi, ÇÜA'ların temel prensiplerini kullanarak, üretici ve ayırt edici olmak üzere iki ağdan oluşmaktadır; ancak, özellikle görüntü işleme görevlerinde daha iyi

performans göstermek üzere Evrişimli Sinir Ağları – ESA (Convolutional Neural Network – CNN) ile zenginleştirilmiştir. Bu yapı, üretici ağın daha gerçekçi görüntüler üretmesini ve ayırt edici ağın bu görüntüleri daha etkin bir şekilde gerçek ve sentetik olarak sınıflandırmasını sağlamaktadır.

DCGAN, derin öğrenme ve YZ alanında çığır açan bir yenilik olarak karşımıza çıkmaktadır. DCGAN, geleneksel ÇÜA mimarisini derinlemesine geliştiren ve bu alanda karşılaşılan zorluklara yenilikçi çözümler sunan özel teknikler ve mimari düzenlemelerle donatılmıştır. Bu model, özellikle ESA gücünden yararlanarak, görsel veri işleme konusunda devrim niteliğinde bir ilerleme sağlamaktadır.

DCGAN'ın eğitim sürecindeki kararlılığı, tüm evrişimli katmanlarda batch normalization tekniğinin kullanılmasından kaynaklanmaktadır. Bu yöntem, eğitim sırasında veri dağılımlarının normalleştirilmesini sağlayarak, modelin daha hızlı ve daha kararlı bir şekilde eğitilmesine olanak tanımaktadır. Özellikle, eğitim sürecinde ortaya çıkabilecek mod colaps problemi, yani modelin aynı veya çok benzer görüntüleri tekrar tekrar üretme eğilimi, batch normalization sayesinde büyük ölçüde azaltılmaktadır. Bu, DCGAN'ın çeşitlilik açısından zengin ve yüksek kaliteli sentetik görüntüler üretebilmesinin önünü açmaktadır.

Ayrıca, DCGAN mimarisi, yüksek çözünürlüklü ve detaylı görüntüler üretebilme kapasitesiyle öne çıkmaktadır. Bu yetenek, DCGAN'ı sanat eserlerinin oluşturulması, tıbbi görüntüleme verilerinin zenginleştirilmesi, video oyunlarında gerçekçi ortamların ve karakterlerin tasarlanması ve daha birçok alanda kullanılmak üzere ideal bir araç haline getirmektedir. DCGAN tarafından üretilen görüntülerin kalitesi ve çeşitliliği, bu modelin uygulama alanlarını genişletmekte ve YZ tabanlı görsel içerik üretiminde yeni standartlar belirlemektedir. Bu gelişmiş özellikler, DCGAN'ı sadece bir görüntü üretme aracı olmaktan çıkarıp, derin öğrenme modelleri için bir referans noktası haline getirmektedir. DCGAN'ın sunduğu mimari iyileştirmeler ve teknik çözümler, derin öğrenme araştırmalarında karşılaşılan pek çok zorluğun üstesinden gelmekte ve bu teknolojinin daha geniş bir kullanım alanı bulmasını sağlamaktadır. Dolayısıyla, DCGAN, YZ alanındaki ilerlemelerin öncüsü olarak kabul edilebilmekte ve bu teknolojinin gelecekteki gelişimine dair önemli ipuçları sunmaktadır.

DCGAN'ın geliştirilmesi, YZ ve derin öğrenme alanlarında sentetik veri üretimi konusunda yeni kapılar açmıştır. Özellikle, veri kısıtlı durumlarında veya veri gizliliği konularında, DCGAN gibi modeller, gerçek veri setlerinin tamamlayıcısı olarak kullanılabilir. Bu, hem araştırma hem de endüstriyel uygulamalar için önemli fırsatlar sunmaktadır. DCGAN ve benzeri teknolojilerin sürekli gelişimi, YZ'nin potansiyelini genişletmekte ve gelecekteki inovasyonlar için sağlam bir temel oluşturmaktadır.

5.2.2. Fréchet Başlangıç Mesafesi – FBM (Fréchet Inception Distance – FID)

Fréchet Başlangıç Mesafesi – FBM (Inception Distance – FID) skoru, generative modeller tarafından oluşturulan görüntülerin kalitesinin değerlendirilmesinde kullanılan önemli bir metriktir. Özellikle ÇÜA tarafından üretilen görüntülerin, gerçek dünya görüntüleri ile olan benzerliğini ölçmede kullanılmaktadır. 2017 yılında tanıtılan bu metrik, bir generative model tarafından üretilen görüntülerin dağılımını, gerçek görüntülerin ("zemin gerçeği") dağılımı ile karşılaştırarak, modelin ürettiği görüntülerin kalitesini objektif bir şekilde değerlendirme imkanı sunmaktadır [49]. Bu karşılaştırma, hem üretilen görüntülerin çeşitliliğini hem de gerçeklik derecesini kapsamlı bir şekilde analiz etmektedir.

FBM, üretilen görüntüler ile gerçek görüntü setleri arasındaki istatistiksel dağılım farklarını matematiksel olarak değerlendirmektedir. Bu değerlendirme süreci, derin öğrenme modeli olan Inception v3 üzerinden elde edilen görüntü özelliklerine dayanmaktadır. Model, her iki görüntü setinden de özellikler çıkarmakta ve bu özellikler üzerinden çok boyutlu Gauss dağılımları hesaplamaktadır.

FBM skoru hesaplaması, üretilen ve gerçek görüntü setlerinin özellik dağılımları arasındaki Fréchet mesafesini kullanarak yapılmaktadır. Fréchet mesafesi, iki çok boyutlu Gauss dağılımı arasındaki uzaklığı ölçen bir metriktir ve bu bağlamda, görüntü özelliklerinin dağılımını temsil etmektedir. Düşük bir FBM skoru, model tarafından üretilen görüntülerin gerçek görüntülerle benzer bir özellik dağılımına sahip olduğunu göstermektedir. Bu, üretilen görüntülerin gerçek görüntülere yüksek derecede benzerliği ve dolayısıyla yüksek kalitesi anlamına gelmektedir. Yüksek kaliteli görüntüler, gerçekçilik, çeşitlilik ve görsel açıdan tatmin edici detaylar açısından gerçek dünya görüntülerine yakın özellikler sergilemektedir.

Matematiksel olarak, FBM skoru iki çok boyutlu Gauss dağılımı arasındaki Fréchet mesafesini ölçmektedir: biri üretilen görüntülerden elde edilen özelliklerin dağılımı için, diğeri ise gerçek görüntülerden elde edilen özelliklerin dağılımı için. Bu özellikler genellikle, derin öğrenme modeli olan Inception v3 modeli kullanılarak elde edilmektedir. FBM skoru, bu iki dağılım arasındaki uzaklığı hesaplayarak, üretilen görüntülerin gerçek görüntülere ne kadar benzediğini matematiksel olarak ifade etmektedir.

Matematiksel olarak şöyledir [50]:

$$FBM = ||\mu_x - \mu_g||^2 + \text{Tr}(\Sigma_x + \Sigma_g - 2(\Sigma_x \Sigma_g)^{1/2}) \quad (5.2.2.1)$$

Burada:

- $||\mu_x - \mu_g||^2$ terimi, gerçek görüntülerin özellik vektörlerinin ortalama değeri (μ_x) ile üretilen görüntülerin özellik vektörlerinin ortalama değeri (μ_g) arasındaki Euclidean mesafesinin karesidir.

- $\text{Tr}(\Sigma_x + \Sigma_g - 2(\Sigma_x \Sigma_g)^{1/2})$ terim, gerçek (Σ_x) ve üretilen (Σ_g) görüntülerin özellik vektörlerinin kovaryans matrisleri arasındaki farkı ifade etmektedir. Burada Tr işlemi, bir matrisin izini (yani, diagonal elemanlarının toplamını) almayı ifade eder ve $(\Sigma_x \Sigma_g)^{1/2}$ ifadesi, iki kovaryans matrisinin çarpımının karekökünü temsil etmektedir.

FBM skoru, üretilen ve gerçek görüntüler arasındaki bu uzaklığı ölçerek, üretilen görüntülerin gerçekliğini ve çeşitliliğini bir sayısal değer üzerinden sunmaktadır. Düşük bir FBM skoru, üretilen görüntülerin gerçek görüntülere daha benzer olduğunu ve dolayısıyla daha yüksek kalitede olduğunu göstermektedir. Bu nedenle, FBM skoru, ÇÜA'lar gibi üretici modellerin performansını değerlendirmede sıkça kullanılan bir ölçüttür [51].

FBM skoru, yalnızca üretilen görüntülerin kalitesini değil, aynı zamanda modelin çeşitlilik kapasitesini de değerlendirmektedir. Bu, özellikle ÇÜA'lar gibi modellerin eğitiminde kritik bir öneme sahiptir, çünkü modelin sadece birkaç tür görüntüyü tekrar üretmesi yerine, geniş bir yelpazede çeşitli ve gerçekçi görüntüler üretmesi hedeflenmektedir. FBM skoru, bu yönüyle, generative modellerin geliştirilmesi sürecinde önemli bir geri bildirim mekanizması sağlamakta ve araştırmacılara modelin görsel çıktılarının kalitesini ve çeşitliliğini sürekli olarak iyileştirmek için gerekli bilgileri sunmaktadır. Bu özellikler, FBM skorunu, ÇÜA'lar başta olmak üzere çeşitli generative modellerin performansını objektif ve kapsamlı bir şekilde değerlendirmek için güvenilir bir araç haline getirmektedir.

FBM skorunun kullanımı, YZ ve derin öğrenme ile ilgili görüntü üretimi araştırmalarında güçlü bir metodolojik altyapı oluşturmaktadır. Bu sayede, model geliştiricilerine, ürettikleri görüntülerin kalitesini ve çeşitliliğini sürekli olarak izleme ve iyileştirme fırsatı sunulmaktadır. Ayrıca, FBM skoru, modelin performansını zaman içinde takip etmeye ve geliştirmelere yönelik kritik geri bildirimler sağlamaya yardımcı olmaktadır. Bu özellikleri ile FBM skoru, YZ tabanlı görüntü üretimi ve analizi çalışmalarında, modellerin kalitesini güvenilir ve objektif bir biçimde değerlendirme konusunda vazgeçilmez bir araç olarak kabul edilmektedir.

Sonuç olarak, FBM skoru, geliştiricilerin ve araştırmacıların generative modellerin performansını daha iyi anlamalarını, değerlendirmelerini ve iyileştirmelerini sağlayan kritik bir metriktir. Görüntü üretimi teknolojilerinin ilerlemesiyle birlikte, FBM skorunun önemi artmaya devam etmekte ve YZ alanında yapılan çalışmalarda model kalitesinin belirlenmesinde merkezi bir role sahip olmaktadır. Bu, özellikle gerçekçilik ve çeşitlilik gibi kriterlerin generative modellerdeki başarısının ölçümünde temel bir ölçüt olarak ön plana çıkmaktadır.

5.2.3. Başlangıç Skoru – BS (Inception Score – IS)

Başlangıç Skoru (BS), generatif modellerin ürettiği görüntülerin kalitesini ve çeşitliliğini değerlendirmek için kullanılan bir metriktir. BS, özellikle ÇÜA gibi modellerin performansını değerlendirmek amacıyla geliştirilmiştir. Bu metrik, üretilen görüntülerin hem netlik ve gerçekçilik

açısından yüksek kalitede olup olmadığını hem de modelin çeşitli ve geniş bir yelpazede görüntüler üretebilme kapasitesini değerlendirir. BS, bu iki özelliği ölçerek, bir üretici modelin ne kadar başarılı olduğunu belirlemeye yardımcı olur.

Matematiksel olarak BS şu şekilde ifade edilir:

$$IS(G) = \exp \left(\mathbb{E}_{x \sim P_G} [D_{KL}(p(y | x) \parallel p(y))] \right) \quad (5.2.3.1)$$

Burada G üretici modeli temsil etmektedir ve $x \sim P_G$ model G tarafından üretilen bir görüntü x 'in dağılımını ifade etmektedir. $p(y | x)$, görüntü x için sınıf etiketi y 'nin tahmin edilen olasılık dağılımıdır ve genellikle önceden eğitilmiş bir Inception v3 modelinden elde edilmektedir. $p(y)$ ise tüm üretilen görüntülerin üzerinden sınıf etiketlerinin marjinal dağılımıdır. D_{KL} Kullback – Leibler diverjansını göstermektedir ve bu, iki dağılım arasındaki farklılığı ölçmektedir. BS, bu iki entropinin birleşiminden elde edilen bir skor olarak, üretilen görüntülerin kalitesini ve çeşitliliğini değerlendirmektedir.

BS'nin temel amacı, üretici modellerin performansını değerlendirmektir. Bu metrik, iki ana özelliği ölçer: üretilen görüntülerin belirginliği ve modelin ürettiği görüntülerin çeşitliliği. Belirginlik, modelin ürettiği her bir görüntünün belirli bir sınıfa yüksek olasılıkla atanabilmesini ifade etmektedir. Yani, görüntüler net ve anlamlı olmalıdır. Çeşitlilik ise, modelin farklı sınıflarda geniş bir yelpazede görüntüler üretebilme yeteneğini ifade etmektedir. Bu iki özellik birlikte değerlendirildiğinde, yüksek bir BS, modelin hem yüksek kaliteli hem de çeşitli görüntüler üretebildiğini göstermektedir.

ÇÜA'larda BS, modelin ürettiği görüntülerin gerçekçi olup olmadığını ve modelin ne kadar çeşitli görüntüler üretebildiğini ölçmek için kullanılmaktadır. ÇÜA'lar, eğitim sürecinde hem gerçek görüntüleri hem de model tarafından üretilen görüntüleri kullanarak öğrenmektedirler. BS, bu sürecin sonunda modelin performansını değerlendirmek için kritik bir araçtır. BS, modelin eğitim sürecindeki ilerlemesini izlemek ve son performansını belirlemek için önemli bir gösterge sağlamaktadır. Bu metrik, yüksek çeşitlilik ve kaliteye sahip görüntüler üreten modellerin tespit edilmesinde etkili bir araçtır.

BS hem araştırma hem de uygulama alanlarında ÇÜA'ların geliştirilmesinde önemli bir rol oynamaktadır. Bu metrik, üretici modellerin başarısını objektif bir şekilde ölçmek için standart bir araç olarak kabul edilmektedir. Araştırmacılar ve geliştiriciler, BS kullanarak farklı modellerin performansını karşılaştırabilir ve iyileştirme alanlarını belirleyebilmektedirler. Özellikle ÇÜA'lar gibi karmaşık üretici modellerin performansını değerlendirmek için BS, basit ve etkili bir yöntem sunmaktadır.

Sonuç olarak, BS, üretici modellerin performansını değerlendirmek için kullanılan önemli bir metriktir. Üretilen görüntülerin kalitesini ve çeşitliliğini ölçerek, modelin ne kadar başarılı olduğunu belirlemeye yardımcı olmaktadır. BS, özellikle ÇÜA'ların geliştirilmesinde ve değerlendirilmesinde kritik bir araçtır. Bu metrik, modelin ürettiği görüntülerin hem belirginliğini hem de çeşitliliğini ölçerek, yüksek kaliteli ve çeşitli görüntüler üreten modellerin tespit edilmesinde ve geliştirilmesinde önemli bir rol oynamaktadır.



6. BULGULAR VE TARTIŞMALAR

Bu tezde, Beyin MRI görüntüleri ÇÜA kullanılarak sentetik olarak üretilmekte ve üretilen görüntülerin kalitesine bakılmaktadır. Eğitim süresinin ve veri setindeki veri artışının üretilen sentetik görüntülerin kalitesini nasıl etkilediği ise FBM ve BS skoru kullanılarak yapılmaktadır. Yapılan çalışma temelde 2 kısımdan oluşmaktadır. Çalışmanın ilk kısmında ilk veri seti tek başına kullanılmıştır. 3 farklı sınıftan oluşan veri setinde gliom sınıfında 455, hipofiz tümörü sınıfında 620 ve tümörsüz sınıfında 550 veri bulunmaktadır. Her bir sınıf sırasıyla farklı epochlarla eğitim sürelerine tabi tutulmuştur. Bunların başlangıcı 100 epoch iken devamında 150 ve 200 epoch kullanılmıştır. Çalışma 200 epoch'tan fazla eğitim süreleri de kullanılmış olup başarılı sonuçların 200 epoch ile elde edildiği görülmüştür.

Tablo 6.1. Gliom tümörü veri seti ile üretilen görüntülerin FBM skorları

Eğitim Süresi	FBM Skoru (455 veri)	FBM Skoru (2330 veri)
100 Epoch	322,587	105,213
150 Epoch	204,568	96,132
200 Epoch	202,989	90,34

İlk olarak DCGAN modeli gliom tümörü içeren veri seti kullanılarak eğitilmiştir. Gerçek verilerin olduğu bu sınıfta toplamda 455 veri bulunmaktadır. Eğitim süresi başlangıçta 100 epoch olarak belirlendiğinde 322,587 FBM skoru elde edildiği görülmektedir. Eğitim süresi 150 epoch'a çıkarıldığında 204,568 FBM skoru elde edilmiştir. Bu durumda modelin performansında önemli oranda başarı sağladığı görülmektedir. Daha sonrasında 200 epoch'ta ise FBM skorunun 202,989'a düştüğü görülmektedir. İyileşme hızındaki düşüş ve 200 epoch'tan fazla sürelerde eğitildiğinde elde edilen sonuçlar FBM skorunda iyileşme olmadığını göstermektedir. Optimal eğitim süresi bu veri seti için 200 epoch civarında belirlenmektedir. Tablo 6.1'de de görüldüğü gibi eğitim süresi arttıkça FBM skoru düşmektedir. FBM skoru ile sentetik görüntünün kalitesi arasında ters orantı bulunmaktadır. FBM skoru düştükçe sentetik görüntünün kalitesi artmaktadır.

Çalışmanın ikinci kısmında ise gliom tümörü veri sınıfındaki veri sayısı 2330'a çıkarılmış ve DCGAN ile sentetik olarak görüntüler üretilmiştir. Çalışmanın eğitim süresi yine 100, 150 ve 200 epoch olacak şekilde deneyler yapılmıştır. Eğitim süresi 100 epoch olarak belirlendiğinde 105,213 FBM skoru elde edilirken, 200 epoch'da 90,34 FBM skoruna düşülmüştür. Tablo 6.1'de görüldüğü gibi FBM skorlarında eğitim süresi arttıkça azalma yaşanmıştır. Aynı zamanda dikkat edilmesi gereken bir diğer önemli detay ise veri sayısının kaliteyi olumlu yönde etkilemiş olmasıdır. Modelin daha fazla bilgi ile eğitilmesi modelin performansını olumlu yönde etkilemiştir. 455'den 2330'a

veri sayısı çıkarıldığında 100 epoch eğitim süresi ile alınan FBM skorunda da ciddi anlamda azalma yaşanmıştır. Bu da veri sayısının fazla olmasının üretilen sentetik görüntünün kalitesini arttırdığını göstermektedir.

Tablo 6.2. Gliom tümörü veri seti ile üretilen görüntülerin BS skorları


	455 Veri		2515 Veri	
	Küçük standart		Küçük standart	
	BS	sapma (±)	BS	sapma (±)
100 Epoch	1.07	0.021	1.532	0.132
150 Epoch	1.092	0.030	1.658	0.128
200 Epoch	1.04	0.0114	1.621	0.138

Tablo 6.2, DCGAN modeli kullanılarak gliom tümörü sınıfı için sentetik görüntü üretiminde elde edilen Başlangıç Skorları (BS) ve bu skorların standart sapmalarını farklı epoch sürelerinde göstermektedir. İki farklı veri seti büyüklüğünde (455 ve 2330 veri) ve üç farklı epoch süresi (100, 150, 200) için BS değerleri ve standart sapmalar karşılaştırılmıştır. 455 verilik set kullanıldığında, modelin 100 epoch sonunda elde ettiği BS değeri 1.07 ve standart sapma 0.021 olarak gözlemlenmiştir. Epoch süresi 150'ye çıkarıldığında, BS değeri 1.092'ye yükselmiş ve standart sapma 0.030 olmuştur, bu da modelin daha fazla eğitildiğinde performansının arttığını göstermektedir. Ancak, epoch süresi 200'e çıkarıldığında BS değeri 1.04'e düşmüş ve standart sapma 0.0114 olmuştur, bu durum aşırı öğrenme olasılığına işaret etmektedir.


2330 verilik set kullanıldığında ise, modelin 100 epoch sonunda elde ettiği BS değeri 1.532 ve standart sapma 0.132 olarak belirlenmiştir. Bu, daha büyük veri setinin model performansını önemli ölçüde artırdığını göstermektedir. Epoch süresi 150'ye çıkarıldığında, BS değeri 1.658'e yükselmiş ve standart sapma 0.128 olmuştur. Bu, modelin daha uzun eğitim süresi ile daha yüksek kaliteli görüntüler ürettiğini ve performansının daha da iyileştiğini ortaya koymaktadır. Ancak, epoch süresi 200'e çıkarıldığında BS değeri 1.621'e düşmüş ve standart sapma 0.138 olmuştur. Bu sonuç, modelin optimal eğitim süresine ulaştığını ve daha uzun eğitim süresinin performansı düşürdüğünü göstermektedir.

Genel olarak, elde edilen bulgular veri seti büyüklüğünün ve eğitim süresinin model performansı üzerindeki etkilerini net bir şekilde ortaya koymaktadır. Daha büyük veri seti kullanımı (2330 veri), modelin daha yüksek BS değerleri elde etmesine ve daha tutarlı sonuçlar üretmesine olanak tanımıştır. Epoch süresinin başlangıçta artırılması model performansında iyileşmeye neden olmuş, ancak çok uzun eğitim süreleri aşırı öğrenme veya modelin kapasitesinin sınırlarına ulaşmasına neden olmuştur. Bu durum, optimal eğitim süresi ve veri seti büyüklüğünün dikkatli bir şekilde belirlenmesinin model performansı açısından kritik olduğunu göstermektedir.

Çalışmada üretilen görüntüler Şekil 6.1 ve Şekil 6.2’de görüldüğü gibi 100 epoch ile eğitilen görüntüye kıyasla 200 epoch ile eğitilen görüntünün kalitesi çok daha nettir.



Şekil 6.1. Az veriye sahip gliom tümörü veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler



Şekil 6.2. Çok veriye sahip gliom tümörü veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler

Tablo 6.3, DCGAN modeli kullanılarak tümör bulunmayan veri seti ile yapılan çalışmada, farklı epoch sürelerinde elde edilen Frechet Başlangıç Mesafesi (FBM) skorlarını göstermektedir. FBM skoru, üretilen görüntülerin gerçek görüntülere ne kadar benzediğini ölçen bir metriktir; düşük FBM skorları daha iyi performansı gösterir. İlk olarak, 550 verilik veri seti kullanılarak elde edilen sonuçlara bakıldığında, 100 epoch süresinde FBM skoru 233,035 olarak belirlenmiştir. Bu yüksek değer, modelin ürettiği sentetik görüntülerin gerçek görüntülerden oldukça farklı olduğunu ve modelin yeterince iyi performans göstermediğini göstermektedir. Eğitim süresi 150 epocha çıkarıldığında, FBM skoru değişmemiştir ve 233,035 olarak kalmıştır, bu da eğitim süresinin artırılmasının modelin performansını iyileştirmediğini ortaya koymaktadır. Ancak, eğitim süresi 200 epocha çıkarıldığında FBM skoru önemli ölçüde düşerek 189,085 olmuştur. Bu, eğitim

süresinin artırılmasının modelin ürettiği görüntülerin gerçek görüntülere daha fazla benzemesini sağladığını ve modelin performansını iyileştirdiğini göstermektedir.

Daha büyük bir veri seti kullanılarak elde edilen sonuçlar ise farklı bir tablo çizmektedir. 2540 verilik veri seti kullanılarak yapılan çalışmada, 100 epoch süresinde elde edilen FBM skoru 140,109 olarak belirlenmiştir. Bu, daha büyük veri setinin model performansını artırdığını ve üretilen görüntülerin gerçek görüntülere daha çok benzediğini göstermektedir. Eğitim süresi 150 epocha çıkarıldığında, FBM skoru daha da düşerek 130,029 olmuştur, bu da modelin performansının daha uzun eğitim süresi ile iyileştiğini göstermektedir. Ancak, 200 epoch süresinde FBM skoru çok az bir artış göstererek 130,033 olmuştur. Bu, modelin performansının bu noktada stabilize olduğunu ve daha uzun eğitim süresinin önemli bir iyileşme sağlamadığını göstermektedir. Genel olarak, elde edilen bulgular veri seti büyüklüğünün ve epoch süresinin model performansı üzerindeki etkilerini net bir şekilde ortaya koymaktadır. Daha büyük veri seti kullanıldığında (2540 veri), modelin performansı belirgin bir şekilde iyileşmiş ve daha düşük FBM skorları elde edilmiştir, bu da üretilen görüntülerin gerçek görüntülere daha fazla benzediğini göstermektedir. Eğitim süresi artırıldığında, her iki veri seti için de model performansında iyileşme görülmüştür. Ancak, 550 verilik veri setinde, modelin performansı 150 epoch süresinden sonra önemli ölçüde iyileşmiş ve 200 epoch süresinde daha da iyileşmiştir. 2540 verilik veri setinde ise, modelin performansı 150 epoch süresinden sonra stabilize olmuştur. Bu bulgular, modelin eğitiminde veri seti büyüklüğü ve eğitim süresinin dikkatli bir şekilde seçilmesinin önemini vurgulamaktadır.

Tablo 6.3. Tümörsüz veri seti ile üretilen görüntülerin FBM skorları

Eğitim Süresi	FBM Skoru (550 veri)	FBM Skoru (2540 veri)
100 Epoch	233,035	140,109
150 Epoch	233,035	130,029
200 Epoch	189,085	130,033

Tablo 6.4, DCGAN modeli kullanılarak tümörsüz sınıfının sentetik üretiminde farklı epoch sürelerinde elde edilen Başlangıç Skorları (BS) ve bu skorların küçük standart sapmalarını göstermektedir. İki farklı veri seti büyüklüğünde (455 ve 2330 veri) ve üç farklı epoch süresi (100, 150, 200) için BS değerleri ve standart sapmalar karşılaştırılmıştır. 455 verilik veri seti kullanıldığında, 100 epoch sonunda modelin elde ettiği Başlangıç Skoru 1.379 ve standart sapma 0.106 olarak belirlenmiştir. Bu skor, modelin ürettiği sentetik görüntülerin belirli bir kaliteye sahip olduğunu, ancak performansın artabileceğini göstermektedir. Eğitim süresi 150 epocha çıkarıldığında, BS değeri 1.463'e yükselmiş ve standart sapma 0.107 olmuştur, bu da modelin daha uzun süre eğitildiğinde performansının iyileştiğini ve üretilen görüntülerin kalitesinin arttığını

ortaya koymaktadır. 200 epoch süresinde ise BS değeri 1.481'e çıkmış ve standart sapma 0.152 olmuştur. Bu, modelin daha uzun eğitim süresi ile performansının daha da iyileştiğini, ancak standart sapmadaki artışın üretilen görüntülerin tutarlılığında bir miktar dalgalanma olduğunu işaret edebilir.


Daha büyük veri seti ile yapılan çalışmada, 100 epoch sonunda elde edilen BS 1.6 ve standart sapma 0.225 olarak belirlenmiştir. Bu sonuç, daha büyük veri setinin model performansını artırdığını ve daha yüksek kaliteli sentetik görüntüler ürettiğini göstermektedir. 150 epoch süresinde BS değeri 1.658'e yükselmiş ve standart sapma 0.318 olmuştur. Eğitim süresinin artırılması, modelin performansında iyileşme sağlamış ve görüntü kalitesini daha da artırmıştır. Ancak, standart sapmadaki artış, üretilen görüntülerin tutarlılığında bir miktar dalgalanma olduğunu göstermektedir. 200 epoch süresinde ise BS değeri 1.51'e düşmüş ve standart sapma 0.128 olmuştur. Bu durum, eğitim süresinin fazla uzun olmasının modelin performansını olumsuz etkilediğini ve aşırı öğrenme olasılığını göstermektedir. Standart sapmanın azalması ise modelin daha tutarlı görüntüler ürettiğini işaret etmektedir.

Veri seti büyüklüğünün ve epoch süresinin model performansı üzerindeki etkileri, bu tabloda net bir şekilde görülmektedir. Daha büyük veri seti (2330 veri) kullanıldığında, modelin performansı belirgin bir şekilde iyileşmiş ve daha yüksek BS değerleri elde edilmiştir. Bu, üretilen görüntülerin gerçek görüntülere daha fazla benzediğini göstermektedir. Eğitim süresi artırıldığında, her iki veri seti için de model performansında başlangıçta iyileşme gözlemlenmiştir. 150 epoch süresi, her iki veri seti için de en iyi sonuçları vermiştir. Ancak, 200 epoch süresinde performans düşüşü yaşanmış ve bu durum aşırı öğrenme veya modelin kapasitesinin sınırlarına ulaşması ile açıklanabilir. Bu bulgular, optimal eğitim süresi ve veri seti büyüklüğünün dikkatli bir şekilde seçilmesinin model performansını maksimize etmek için kritik öneme sahip olduğunu vurgulamaktadır.


Tablo 6.4. Tümörsüz veri seti ile üretilen görüntülerin BS skorları

	455 Veri		2515 Veri	
	BS	Küçük standart sapma (\pm)	BS	Küçük standart sapma (\pm)
100 Epoch	1.379	0.106	1.6	0.225
150 Epoch	1.463	0.107	1.658	0.318
200 Epoch	1.481	0.152	1.51	0.128

Şekil 6.3 ve Şekil 6.4'te DCGAN ile üretilen sentetik görüntü kalitesindeki artış gösterilmektedir.



Şekil 6.3. Az veriye sahip Tümör bulunmayan veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler



Şekil 6.4. Çok veriye sahip Tümör bulunmayan veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler

Tablo 6.5, DCGAN modeli kullanılarak hipofiz bezi tümörü veri seti ile yapılan çalışmada farklı epoch sürelerinde elde edilen Frechet Başlangıç Mesafesi (FBM) skorlarını göstermektedir. FBM skoru, üretilen görüntülerin gerçek görüntülere ne kadar benzediğini ölçen bir metriktir; daha düşük FBM skorları daha iyi performansı gösterir. Tablo, iki farklı veri seti büyüklüğünde (620 ve 2515 veri) ve üç farklı epoch süresi (100, 150, 200) için FBM değerlerini karşılaştırmaktadır.

620 verilik veri seti kullanıldığında, 100 epoch sonunda modelin elde ettiği FBM skoru 239,027 olarak belirlenmiştir. Bu yüksek değer, modelin ürettiği sentetik görüntülerin gerçek görüntülerden oldukça farklı olduğunu göstermektedir. Eğitim süresi 150 epocha çıkarıldığında, FBM skoru 172,241'e düşmüştür, bu da eğitim süresinin artırılmasının modelin performansında önemli bir

iyileşme sağladığını ortaya koymaktadır. 200 epoch süresinde ise FBM skoru 163,575'e kadar düşmüştür. Bu, daha uzun eğitim süresinin modelin ürettiği görüntülerin gerçek görüntülere daha fazla benzemesini sağladığını ve modelin performansını iyileştirdiğini göstermektedir.

Daha büyük bir veri seti kullanılarak yapılan çalışmada, 100 epoch sonunda elde edilen FBM skoru 117,94 olarak belirlenmiştir. Bu sonuç, daha büyük veri setinin model performansını önemli ölçüde artırdığını ve daha düşük FBM skorları elde edilmesini sağladığını göstermektedir. 150 epoch süresinde FBM skoru 115,473'e düşmüştür, bu da modelin performansının daha uzun eğitim süresi ile iyileştiğini ve daha kaliteli sentetik görüntüler ürettiğini göstermektedir. 200 epoch süresinde ise FBM skoru 103,559'a düşmüştür. Bu, daha uzun eğitim süresinin model performansını daha da iyileştirdiğini ve üretilen görüntülerin gerçek görüntülere daha çok benzediğini göstermektedir.

Genel olarak, tablo veri seti büyüklüğünün ve epoch süresinin model performansı üzerindeki etkilerini net bir şekilde göstermektedir. Daha büyük veri seti (2515 veri) kullanıldığında, modelin performansı belirgin bir şekilde iyileşmiş ve daha düşük FBM skorları elde edilmiştir. Bu, üretilen görüntülerin gerçek görüntülere daha fazla benzediğini ve modelin genel performansının arttığını göstermektedir. Eğitim süresi artırıldığında, her iki veri seti için de model performansında iyileşme gözlemlenmiştir. 200 epoch süresi, her iki veri seti için de en iyi sonuçları vermiştir, bu da daha uzun eğitim süresinin modelin performansını optimize etmek için önemli olduğunu göstermektedir. Bu bulgular, modelin eğitiminde veri seti büyüklüğü ve eğitim süresinin dikkatli bir şekilde seçilmesinin önemini vurgulamaktadır.

Tablo 6.5. Hipofiz bezi tümörü veri seti ile üretilen görüntülerin FBM skorları

Eğitim Süresi	FBM Skoru (620 veri)	FBM Skoru (2515 veri)
100 Epoch	239,027	117,94
150 Epoch	172,241	115,473
200 Epoch	163,575	103,559

Tablo 6.6, DCGAN modeli kullanılarak hipofiz bezi tümörü sınıfının sentetik üretiminde farklı epoch sürelerinde elde edilen Başlangıç Skorları (BS) ve bu skorların küçük standart sapmalarını göstermektedir. İki farklı veri seti büyüklüğünde (455 ve 2330 veri) ve üç farklı epoch süresi (100, 150, 200) için BS değerleri ve standart sapmalar karşılaştırılmıştır.

455 verilik veri seti kullanıldığında, 100 epoch sonunda modelin elde ettiği BS 1.186 ve standart sapma 0.054 olarak belirlenmiştir. Bu skor, modelin ürettiği sentetik görüntülerin belirli bir kaliteye sahip olduğunu, ancak daha fazla eğitildiğinde iyileşme potansiyelinin bulunduğunu göstermektedir. Eğitim süresi 150 epocha çıkarıldığında, BS değeri 1.296'ya yükselmiş ve standart sapma 0.068 olmuştur, bu da modelin daha uzun süre eğitildiğinde performansının iyileştiğini ve

üretilen görüntülerin kalitesinin arttığını ortaya koymaktadır. 200 epoch süresinde ise BS değeri 1.353'e çıkmış ve standart sapma 0.115 olmuştur. Bu, modelin daha uzun eğitim süresi ile performansının daha da iyileştiğini, ancak standart sapmadaki artışın üretilen görüntülerin tutarlılığında bir miktar dalgalanma olduğunu işaret edebilir.


Daha büyük bir veri seti kullanılarak yapılan çalışmada, 100 epoch sonunda elde edilen BS 1.481 ve standart sapma 0.1 olarak belirlenmiştir. Bu sonuç, daha büyük veri setinin model performansını önemli ölçüde artırdığını ve daha yüksek kaliteli sentetik görüntüler ürettiğini göstermektedir. 150 epoch süresinde BS değeri 1.551'e yükselmiş ve standart sapma 0.124 olmuştur, bu da modelin performansının daha uzun eğitim süresi ile iyileştiğini ve daha kaliteli sentetik görüntüler ürettiğini göstermektedir. 200 epoch süresinde ise BS değeri 1.629'a yükselmiş ve standart sapma 0.19 olmuştur. Bu, daha uzun eğitim süresinin modelin performansını daha da iyileştirdiğini ve üretilen görüntülerin gerçek görüntülere daha çok benzediğini göstermektedir, ancak standart sapmadaki artış, üretilen görüntülerin tutarlılığında bir miktar dalgalanma olduğunu işaret edebilir.

Genel olarak, tablo veri seti büyüklüğünün ve epoch süresinin model performansı üzerindeki etkilerini net bir şekilde göstermektedir. Daha büyük veri seti (2330 veri) kullanıldığında, modelin performansı belirgin bir şekilde iyileşmiş ve daha yüksek BS değerleri elde edilmiştir. Bu, üretilen görüntülerin gerçek görüntülere daha fazla benzediğini ve modelin genel performansının arttığını göstermektedir. Eğitim süresi artırıldığında, her iki veri seti için de model performansında başlangıçta iyileşme gözlemlenmiştir. 200 epoch süresi, her iki veri seti için de en iyi sonuçları vermiştir, bu da daha uzun eğitim süresinin modelin performansını optimize etmek için önemli olduğunu göstermektedir. Bu bulgular, modelin eğitiminde veri seti büyüklüğü ve eğitim süresinin dikkatli bir şekilde seçilmesinin önemini vurgulamaktadır.


Tablo 6.6. Hipofiz bezi tümörü veri seti ile üretilen görüntülerin BS skorları

	455 Veri		2515 Veri	
	BS	Küçük standart sapma (±)	BS	Küçük standart sapma (±)
100 Epoch	1.186	0.054	1.481	0.1
150 Epoch	1.296	0.068	1.551	0.124
200 Epoch	1.353	0.115	1.629	0.19

Çalışmada üretilen görüntüler Şekil 6.5 ve Şekil 6.6'de görüldüğü gibi 100 epoch ile eğitilen görüntüye kıyasla 200 epoch ile eğitilen görüntünün kalitesi çok daha nettir.



Şekil 6.5. Az veriye sahip hipofiz bezi tümörü veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler



Şekil 6.6. Çok veriye sahip hipofiz bezi tümörü veri sınıfının eğitim sürelerine göre örnek sentetik görüntüler

7. SONUÇLAR

Tezde yapılan çalışma, tıbbi görüntülerin sentetik olarak üretilmesinde görüntü kalitesinin değerlendirilmesinde önemli bir yaklaşımı ele almaktadır. Özellikle ölüm oranı yüksek olan beyin tümörlerinin DCGAN kullanılarak sentetik olarak üretilmesi, yapay zekâ çalışmalarında önemli bir yer tutacaktır. Çalışmada, farklı eğitim sürelerinin ve kullanılan gerçek veri setindeki veri sayısının fazla olmasının sentetik verinin kalitesine etkisi hem Frechet Başlangıç Mesafesi (FBM) skoru hem de Başlangıç Skoru (BS) kullanılarak incelenmiştir. Farklı eğitim sürelerinde yapılan deneyler sonucunda, en sağlıklı sonuçların 200 epoch ile elde edildiği belirlenmiştir. Bu epoch süresi, modelin ürettiği sentetik görüntülerin gerçek görüntülere en fazla benzediği ve en düşük FBM skorlarının elde edildiği süre olarak öne çıkmıştır. Aynı zamanda, daha büyük veri setlerinin kullanımı, modelin performansını belirgin şekilde iyileştirmiş ve daha yüksek BS değerleri ile daha kaliteli sentetik görüntüler üretilmiştir.

Çalışmanın sonuçları, tıbbi görüntülerin sentetik olarak üretilmesinde DCGAN kullanımının başarılı sonuçlar vereceğini göstermektedir. Özellikle eğitim süresinin artırılması ve modele verilen ek verilerle daha fazla bilgi sağlanması, sentetik görüntülerin kalitesini ciddi oranda artırmaktadır. 455 ve 2330 verilik veri setleri kullanılarak yapılan çalışmalarda, daha büyük veri seti ile daha yüksek IS değerlerine ulaşılmış ve görüntü kalitesinin arttığı gözlemlenmiştir. Gelecek çalışmalarda, eğitim süresinin optimal seviyede tutulması ve daha büyük veri setlerinin kullanılması ile tıbbi görüntülerin kalitesinin daha da iyileştirileceği düşünülmektedir. Bu alanda yapılacak yenilikler ve geliştirilecek modellerle, sentetik görüntülerin kalitesinin daha da artırılarak, tıbbi teşhis ve tedavi süreçlerine önemli katkılar sağlanacaktır.

ÖNERİLER

Gelecekteki çalışmalar için, daha büyük ve çeşitli veri setlerinin kullanılması, farklı Çekişmeli Üretici Ağ (ÇÜA) modellerinin ve algoritmalarının denenmesi, eğitim sürelerinin optimize edilmesi, veri ön işleme ve artırma tekniklerinin kullanılması önerilmektedir. Ayrıca, çapraz doğrulama ve hiperparametre optimizasyonu ile model performansının artırılması, sentetik görüntülerin klinik uygulamalarda test edilmesi, multimodal veri kullanımı, gerçek zamanlı uygulamaların geliştirilmesi ve etik ile gizlilik konularının dikkate alınması büyük önem taşımaktadır. Bu öneriler, tıbbi görüntülerin sentetik olarak üretilmesi alanında daha ileri düzeyde gelişmeler sağlanmasına katkı sağlayabilir.



KAYNAKLAR

- [1] R. Wang, Z. Chen, S. Zhang, ve W. Li, “Dual-Attention generative adversarial networks for fault diagnosis under the Class-Imbalanced Conditions,” *IEEE Sensors Journal*, vol. 22, no. 2, pp. 1474–1485, Jan. 2022, doi: 10.1109/jsen.2021.3131166.
- [2] S.-W. Huang, C.-T. Lin, S.-P. Chen, Y.-Y. Wu, P.-H. Hsu, ve S.-H. Lai, “AugGAN: Cross Domain Adaptation with GAN-Based Data Augmentation,” in *Lecture notes in computer science*, 2018, pp. 731–744. doi: 10.1007/978-3-030-01240-3_44.
- [3] A. Bissoto, E. Valle, ve S. Avila, “GAN-Based Data Augmentation and Anonymization for Skin-Lesion Analysis: A Critical review,” *arXiv (Cornell University)*, Jan. 2021, doi: 10.48550/arxiv.2104.10603.
- [4] J. He, Y. Xu, Y. Pan, ve Y. Wang, “Adaptive weighted generative adversarial network with attention mechanism: A transfer data augmentation method for tool wear prediction”, *Mech. Syst. Signal Process.*, c. 212, s. 111288, Nis. 2024, doi: 10.1016/j.ymsp.2024.111288.
- [5] I. J. Goodfellow *et al.*, “Generative adversarial networks,” *arXiv.org*, Jun. 10, 2014. <http://arxiv.org/abs/1406.2661>
- [6] C. Koç ve F. Özyurt, “An examination of synthetic images produced with DCGAN according to the size of data and epoch”, *Firat Univ. J. Exp. Comput. Eng.*, c. 2, sy 1, Art. sy 1, Şub. 2023, doi: 10.5505/fujece.2023.69885.
- [7] P. Isola, J.-Y. Zhu, T. Zhou, ve A. A. Efros, “Image-to-Image Translation with Conditional Adversarial Networks”, içinde *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Tem. 2017, ss. 5967-5976. doi: 10.1109/CVPR.2017.632.
- [8] J.-Y. Zhu, T. Park, P. Isola, ve A. A. Efros, “Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks”, içinde *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice: IEEE, Eki. 2017, ss. 2242-2251. doi: 10.1109/ICCV.2017.244.
- [9] A. Radford, L. Metz, ve S. Chintala, “Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks”. *arXiv*, 07 Ocak 2016. Erişim: 02 Nisan 2024. [Çevrimiçi]. Erişim adresi: <http://arxiv.org/abs/1511.06434>
- [10] T. Karras, S. Laine, ve T. Aila, “A Style-Based Generator Architecture for Generative Adversarial Networks”. *arXiv*, 29 Mart 2019. doi: 10.48550/arXiv.1812.04948.
- [11] C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang ve W. Shi, “Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network”. *arXiv*, 25 Mayıs 2017. doi: 10.48550/arXiv.1609.04802.
- [12] M. Mirza ve S. Osindero, “Conditional Generative Adversarial Nets”. *arXiv*, 06 Kasım 2014. doi: 10.48550/arXiv.1411.1784.
- [13] C. Han, T. Ma, J. Huyan, Z. Tong, H. Yang, ve Y. Yang, “Multi-stage generative adversarial networks for generating pavement crack images”, *Eng. Appl. Artif. Intell.*, c. 131, s. 107767, May. 2024, doi: 10.1016/j.engappai.2023.107767.
- [14] J. Islam ve Y. Zhang, “GAN-based synthetic brain PET image generation”, *Brain Inform.*, c. 7, sy 1, s. 3, Mar. 2020, doi: 10.1186/s40708-020-00104-2.
- [15] J. Wang, B. Lei, L. Ding, X. Xu, X. Gu, ve M. Zhang, “Autoencoder-based conditional optimal transport generative adversarial network for medical image generation”, *Vis. Inform.*, c. 8, sy 1, ss. 15-25, Mar. 2024,

doi: 10.1016/j.visinf.2023.11.001.

- [16] J. Yang, R. Shi, D. Wei, Z. Liu, L. Zhao, B. Ke, H. Pfister ve B. Ni, "MedMNIST v2 - A large-scale lightweight benchmark for 2D and 3D biomedical image classification", *Sci. Data*, c. 10, sy 1, s. 41, Oca. 2023, doi: 10.1038/s41597-022-01721-8.
- [17] B. Lei, Z. Xia, F. Jiang, X. Jiang, Z. Ge, Y. Xu, J. Qin, S. Chen, T. Wang ve S. Wang, "Skin lesion segmentation via generative adversarial networks with dual discriminators", *Med. Image Anal.*, c. 64, s. 101716, Ağu. 2020, doi: 10.1016/j.media.2020.101716.
- [18] H. Xie, H. Lei, X. Zeng, Y. He, G. Chen, A. Elazab, G. Yue, J. Wang, G. Zhang ve B. Lei, "AMD-GAN: Attention encoder and multi-branch structure based generative adversarial networks for fundus disease detection from scanning laser ophthalmoscopy images", *Neural Netw.*, c. 132, ss. 477-490, Ara. 2020, doi: 10.1016/j.neunet.2020.09.005.
- [19] D. Wang, Z. Chen, ve H. Zhao, "Prototype transfer generative adversarial network for unsupervised breast cancer histology image classification", *Biomed. Signal Process. Control*, c. 68, s. 102713, Tem. 2021, doi: 10.1016/j.bspc.2021.102713.
- [20] M. Jiang, M. Zhi, L. Wei, X. Yang, J. Zhang, Y. Li, P. Wang, J. Huang ve G. Yang, "FA-GAN: Fused attentive generative adversarial networks for MRI image super-resolution", *Comput. Med. Imaging Graph.*, c. 92, s. 101969, Eyl. 2021, doi: 10.1016/j.compmedimag.2021.101969.
- [21] J. Fu, W. Li, J. Du, ve L. Xu, "DSAGAN: A generative adversarial network based on dual-stream attention mechanism for anatomical and functional image fusion", *Inf. Sci.*, c. 576, ss. 484-506, Eki. 2021, doi: 10.1016/j.ins.2021.06.083.
- [22] M. Salvi, F. Branciforti, F. Veronese, E. Zavattaro, V. Tarantino, P. Savoia ve K. M. Meiberger, "DermoCCGAN: A new approach for standardizing dermatological images using generative adversarial networks", *Comput. Methods Programs Biomed.*, c. 225, s. 107040, Eki. 2022, doi: 10.1016/j.cmpb.2022.107040.
- [23] Y.-Y. Duan, J. Qin, W. Q. Qiu, S. Y. Li, C. Li, A. S. Liu, X. Chen ve C. X. Zhang, "Performance of a generative adversarial network using ultrasound images to stage liver fibrosis and predict cirrhosis based on a deep-learning radiomics nomogram", *Clin. Radiol.*, c. 77, sy 10, ss. e723-e731, Eki. 2022, doi: 10.1016/j.crad.2022.06.003.
- [24] S. Yuan, Y. Gong, G. Wang, B. Zhang, Y. Liu, ve H. Zhang, "MSFF-CDCGAN: A novel method to predict RNA secondary structure based on Generative Adversarial Network", *Methods*, c. 204, ss. 368-375, Ağu. 2022, doi: 10.1016/j.ymeth.2022.04.004.
- [25] Z. Song, D. Qiu, X. Zhao, D. Lin, ve Y. Hui, "Channel attention generative adversarial network for super-resolution of glioma magnetic resonance image", *Comput. Methods Programs Biomed.*, c. 229, s. 107255, Şub. 2023, doi: 10.1016/j.cmpb.2022.107255.
- [26] Y. Peng, J. Sun, Y. Ren, D. Li, ve Y. Guo, "A histogram-driven generative adversarial network for brain MRI to CT synthesis", *Knowl.-Based Syst.*, c. 277, s. 110802, Eki. 2023, doi: 10.1016/j.knosys.2023.110802.
- [27] A. Tripathi, P. Kumar, V. Mayya, ve A. Tulsani, "Generating OCT B-Scan DME images using optimized Generative Adversarial Networks (GANs)", *Heliyon*, c. 9, sy 8, s. e18773, Ağu. 2023, doi: 10.1016/j.heliyon.2023.e18773.
- [28] K. Vrettos, E. Koltsakis, A. H. Zibis, A. H. Karantanas, ve M. E. Klontzas, "Generative adversarial networks for spine imaging: A critical review of current applications", *Eur. J. Radiol.*, c. 171, s. 111313, Şub. 2024, doi: 10.1016/j.ejrad.2024.111313.
- [29] K. Wei, K. Wei, W. Kong, L. Liu, J. Wang, B. Li, B. Zhao, Z. Li, J. Zhu ve G. Yu, "CT synthesis from MR

- images using frequency attention conditional generative adversarial network”, *Comput. Biol. Med.*, c. 170, s. 107983, Mar. 2024, doi: 10.1016/j.compbiomed.2024.107983.
- [30] R. Noor, A. Wahid, S. U. Bazai, A. Khan, M. Fang, S. M. S., U. A. Bhatti ve Y. Y. Ghadi , “DLGAN: Undersampled MRI reconstruction using Deep Learning based Generative Adversarial Network”, *Biomed. Signal Process. Control*, c. 93, s. 106218, Tem. 2024, doi: 10.1016/j.bspc.2024.106218.
- [31] M. Son, S. Jung, J. Moon, ve E. Hwang, *BCGAN-Based Over-Sampling Scheme for Imbalanced Data*. 2020, s. 160. doi: 10.1109/BigComp48618.2020.00-83.
- [32] H. Woldehailasse ve S. Tesfamariam, “Data augmentation using conditional generative adversarial network (cGAN): Application for prediction of corrosion pit depth and testing using neural network”, *J. Pipeline Sci. Eng.*, c. 3, sy 1, s. 100091, Mar. 2023, doi: 10.1016/j.jpse.2022.100091.
- [33] G. Douzas ve F. Baao, “Effective data generation for imbalanced learning using Conditional Generative Adversarial Networks”, *Expert Syst. Appl.*, c. 91, Eyl. 2017, doi: 10.1016/j.eswa.2017.09.030.
- [34] A. inar ve E. Ünlü, “SRGAN ile Süper Çözünürlüklü OCT Görüntüleri Oluşturma”, program adı: International Journal of Advanced Natural Sciences and Engineering Researches, Tem. 2023. doi: 10.59287/ijanser.1344.
- [35] E. ŞahiN ve M. F. Talu, “Bıyık Deseni Üretiminde Çekişmeli Üretici Ağların Performans Karşılaştırması”, *Bitlis Eren Üniversitesi Fen Bilim. Derg.*, c. 10, sy 4, ss. 1575-1589, Ara. 2021, doi: 10.17798/bitlisfen.985861.
- [36] T. Karras, S. Laine, M. Aittala, J. Hellsten, J. Lehtinen, ve T. Aila, “Analyzing and Improving the Image Quality of StyleGAN”. arXiv, 23 Mart 2020. doi: 10.48550/arXiv.1912.04958.
- [37] A. Borji, “Pros and Cons of GAN Evaluation Measures”. arXiv, 23 Ekim 2018. doi: 10.48550/arXiv.1802.03446.
- [38] T. Salimans, I. Goodfellow, W. Zaremba, V. Cheung, A. Radford, ve X. Chen, “Improved Techniques for Training GANs”. arXiv, 10 Haziran 2016. doi: 10.48550/arXiv.1606.03498.
- [39] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, ve Z. Wojna, “Rethinking the Inception Architecture for Computer Vision”. arXiv, 11 Aralık 2015. doi: 10.48550/arXiv.1512.00567.
- [40] “Fréchet distance”, *Wikipedia*. 13 Mayıs 2024. Erişim: 26 Mayıs 2024. [Çevrimiçi]. Erişim adresi: https://en.wikipedia.org/w/index.php?title=Fr%C3%A9chet_distance&oldid=1223694034
- [41] S. Liu, Y. Wei, J. Lu, ve J. Zhou, “An Improved Evaluation Framework for Generative Adversarial Networks”. arXiv, 19 Temmuz 2018. doi: 10.48550/arXiv.1803.07474.
- [42] “Labeled MRI brain Tumor dataset,” Kaggle, Dec. 31, 2023. <https://www.kaggle.com/datasets/ammaraahmed310/labeled-mri-brain-tumor-dataset>
- [43] “Brain MRI images for brain tumor detection,” Kaggle, Mar. 21, 2024. <https://www.kaggle.com/datasets/emmanuelkibet1/brain-scans>
- [44] “/kaggle/input/brain-tumor-classification-mri,” Mar. 08, 2024. <https://www.kaggle.com/datasets/hiteshodulapalli/kaggleinputbrain-tumor-classification-mri>
- [45] “Brain Tumor Segmentation Dataset,” Kaggle, Feb. 04, 2024. <https://www.kaggle.com/datasets/atikaakter11/brain-tumor-segmentation-dataset>
- [46] “Brain Tumor MRI dataset,” Kaggle, Sep. 24, 2021. <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>

- [47] A. Öcal ve L. Özbakır, “Supervised deep convolutional generative adversarial networks”, *Neurocomputing*, c. 449, ss. 389-398, Ağu. 2021, doi: 10.1016/j.neucom.2021.03.125.
- [48] G. Antipov, M. Baccouche, ve J.-L. Dugelay, “Face Aging With Conditional Generative Adversarial Networks”. arXiv, 30 Mayıs 2017. Erişim: 02 Nisan 2024. [Çevrimiçi]. Erişim adresi: <http://arxiv.org/abs/1702.01983>
- [49] M. Heusel, H. Ramsauer, T. Unterthiner, B. Nessler, and S. Hochreiter, “GANs trained by a two Time-Scale update rule converge to a local Nash equilibrium,” *arXiv (Cornell University)*, Jan. 2017, doi: 10.48550/arxiv.1706.08500.
- [50] V. Costa, N. Lourenço, ve P. Machado, “Coevolution of Generative Adversarial Networks”, c. 11454, 2019, ss. 473-487. doi: 10.1007/978-3-030-16692-2_32.
- [51] L. F. Buzuti ve C. E. Thomaz, “Fréchet AutoEncoder Distance: A new approach for evaluation of Generative Adversarial Networks”, *Comput. Vis. Image Underst.*, c. 235, s. 103768, Eki. 2023, doi: 10.1016/j.cviu.2023.103768.



4. F. Ozyurt, J. Majidpour, T. A. Rashid, ve C. Koc, "Offline Handwriting Signature Verification: A Transfer Learning and Feature Selection Approach". arXiv, 05 Ocak 2024. doi: 10.48550/arXiv.2401.09467.
5. P. D. Barua, S. Kirik, S. Dogan, C. Koc, F. Ozkaynak, M. Baygin, T. Tuncer, R. Tan, U. R. Acharya, "ExDarkLBP: a hybrid deep feature generation-based genetic malformation detection using facial images", Multimed. Tools Appl., c. 83, ss. 1-18, Eki. 2023, doi: 10.1007/s11042-023-17057-3.

Bildiriler:

1. C. Koc, F. Ozyurt, "Review of Evaluation Metrics for Generative Adversarial Networks", 6th International ICONTECH Conference on Innovative Surveys in Positive Sciences, Rijeka, Hırvatistan, 2022, s. 25-30
2. C. Koc, F. Ozyurt, "Elektrokardiyogram Sinyal Spektrumlarının Konvolüsyonel Sinir Ağı Tabanlı Otomatik Sınıflandırılması", Ist-International Congress on Modern Sciences, Taşkent, Özbekistan, 2022, s. 982 - 989
3. C. Koc, F. Ozyurt, "Classification of Eurosat Dataset Using Convolutional Neural Networks", UMTEB – XIII International Scientific Research Congress, Paris, Fransa, 2023, s. 170 – 176
4. C. Koc, F. Ozyurt, "Evaluation of Problems Encountered in The Training of Generative Adversarial Networks", 8th International New York Conference On Evolving Trends In Interdisciplinary Research & Practices, New York, ABD, 2023, s. 24 – 28
5. C. Koc, F. Ozyurt, "DCGAN-Based Synthetic Brain MR Imaging: An FID Score Analysis", 16 th International Conference on Engineering & Natural Sciences, Girne, Kıbrıs, 2024, s. 127-137

Projeler:

1. KOSGEB – ARGE, ÜRGE ve İnovasyon Destek Programı
Pratik Uygulamalar için Sentetik Yüz Üretme
2. FÜBAP MF.22.27