

**ÜRETKEN ÇEKİŞMELİ AĞLARIN (GAN) TIP ALANINDAKİ
UYGULAMALARI: GÖRÜNTÜ İŞLEME VE TANI
SÜREÇLERİNDE GAN'LARIN ROLÜ**

HAMİT OLĞAÇ

HAZİRAN 2024

DIYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÜRETKEN ÇEKİŞMELİ AĞLARIN(GAN) TIP ALANINDAKİ
UYGULAMALARI: GÖRÜNTÜ İŞLEME VE TANI
SÜREÇLERİNDE GAN'LARIN ROLÜ

HAMİT OLGAÇ

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV
YÖNETMELİĞİNİN BİR PARÇASI OLARAK
ELEKTRİK-ELEKTRONİK ANA BİLİM DALINDA
YÜKSEK LİSANS TEZİ
OLARAK HAZIRLANMIŞTIR

HAZİRAN 2024

DİYARBAKIR

**ÜRETKEN ÇEKİŞMELİ AĞLARIN(GAN) TIP ALANINDAKİ
UYGULAMALARI: GÖRÜNTÜ İŞLEME VE TANI SÜREÇLERİNDE
GAN'LARIN ROLÜ**

Hamit OLĞAÇ tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Elektrik-Elektronik Ana Bilim Dalı'nda Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Dr. Öğr. Üyesi İsa ATAŞ
Danışman, **Bilgisayar Teknolojileri Bölümü,**
Dicle Üniversitesi

Sınav Jürisi:

Doç. Dr. Emrullah ACAR (*)
Elektrik-Elektronik Mühendisliği Bölümü,
Batman Üniversitesi

Dr. Öğr. Üyesi İsa ATAŞ (**)
Bilgisayar Teknolojileri Bölümü, Dicle Üniversitesi

Dr. Öğr. Üyesi Muhittin BAYRAM
Elektrik-Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi



Savunma Tarihi: 27/ 06 / 2024

(*) Jüri Başkanı.

(**) Tez Danışmanı.

Anne ve Babama...

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılıyıp kaynak gösterdiğimi beyan ederim. Beyanıyla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Hamit OLĞAÇ

İmza:

TEŞEKKÜR

Öncelikle, danışmanım Dr. Öğr. Üyesi İsa ATAŞ'a, çalışmanın fikir aşamasından başlayarak, örnekleme, deney setlerini oluşturma, analizlerin yorumlanması ve tez taslağındaki düzeltmeler konularında gösterdiği destek ve sabır için sonsuz teşekkürlerimi sunarım. Ayrıca, jüri üyelerime, bu tezin daha nitelikli bir hale gelmesi için yaptıkları eleştiri ve öneriler için teşekkür ederim.

Beni büyütüp yetiştiren ve her zaman desteğini ve dualarını esirgemeyen sevgili anneme ve babama, her zaman destekleriyle yanımda olan kardeşlerime gönülden teşekkür ederim. Ayrıca bana çok emeği geçen, hakkını hiçbir zaman ödeyemeyeceğim öğretmenim Gülseda ENSARİ Hocam'a minnettarım. Onun desteği ve varlığı, bu çalışmamı çok daha anlamlı ve değerli kıldı.

Özel olarak, her zaman ve her yerde beni destekleyen ve sayısız iyiliğiyle her zaman yanımda olan sevgili Ümran TANIŞ'a en içten teşekkürlerimi sunmak istiyorum.

İÇİNDEKİLER

TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	viii
TABLOLAR LİSTESİ.....	ix
SİMGELER VE KISALTMALAR LİSTESİ	x
ÖZET.....	xii
ABSTRACT.....	xiii
1. GİRİŞ	1
1.1 Biyomedikal Alanda Problemin Tanımı	2
1.2 Biyomedikal Görüntü Analizi ve Üretimi Neden Önemlidir.....	5
1.3 Tezin Amacı.....	5
1.4 Tezin Yöntemi.....	6
2. ÖNCEKİ ÇALIŞMALAR.....	7
3. MALZEME VE YÖNTEM	10
3.1 Malzeme.....	10
3.1.1 Veri seti	10
3.1.2 Tıbbi görüntüleme teknikleri.....	12
3.1.3 X-ışınları	12
3.1.4 Manyetik rezonans (MR) görüntüleme	14
3.1.5 Bilgisayarlı tomografi (BT veya CT).....	16
3.2 Yöntem.....	18
3.2.1 Veri ön işleme	18
3.2.2 Üretken çekişmeli ağ (GAN)	21
3.2.3 Hiperparametre seçimi	30
3.2.4 Performans değerlendirmesi.....	33

4. BULGULAR ve tartışma	39
4.1 Kurulum	39
4.2 Deneysel Sonuçlar.....	39
4.2.1 Birinci Uygulama.....	39
4.2.2 İkinci Uygulama.....	44
5. SONUÇLAR VE ÖNERİLER.....	49
5.1 Sonuçlar.....	49
5.2 Öneriler	52
KAYNAKLAR	55
ÖZGEÇMİŞ	59

ŞEKİLLER LİSTESİ

Şekil 3.1 Kaggle veri setinden alınmış örnek CT-MR görüntüler	11
Şekil 3.2 Kaggle veri setinden alınmış örnek Alzheimer MR görüntüler.....	11
Şekil 3.3 X-ışınları kullanılarak elde edilen bazı tıbbi görüntüler	13
Şekil 3.4 X-ışınları kullanılarak elde edilen bazı tıbbi görüntüler	13
Şekil 3.5 Manyetik alana maruz kalan hidrojen atomlarının tepkileri	15
Şekil 3.6 Bazı MR sekanslarıyla oluşturulmuş beyin MR görüntüleri	15
Şekil 3.7 Beyin CT tarama görüntüleri	17
Şekil 3.8 Veri setindeki görüntülerin ön işlemlerden sonraki örnek görüntüleri.....	19
Şekil 3.9 Veri artırma görüntüleri	21
Şekil 3.10 Vanilya GAN modeli	22
Şekil 3.11 DCGAN modeli	25
Şekil 3.12 LSGAN modeli	27
Şekil 3.13 Cycle-GAN mimarisi	28
Şekil 3.14 Basit bir Cycle-GAN modeli	28
Şekil 3.15 Eşlenmemiş Cycle-GAN'ın üretici ve ayırt edici mimarisi	29
Şekil 4.1 Eğitimde kullanılan Kaggle örnek beyin MR görüntüleri	40
Şekil 4.2 Eğitimde kullanılan Kaggle örnek beyin CT görüntüleri	40
Şekil 4.3 MR-CT-MR dönüşümü.....	41
Şekil 4.4 CT-MR-CT dönüşümü.....	42
Şekil 4.5 MR-MR dönüşümü / CT-CT dönüşümü.....	43
Şekil 4.6 GAN modelleri için eğitimde kullanılan Kaggle örnek beyin MR görüntüleri	45
Şekil 4.7 DCGAN modelinin belli epoch'larda sahte MR görüntüleri.....	46
Şekil 4.8 DCGAN modelinin 500 epoch sonrası üretici ve ayırt edici kayıp grafiği. 46	
Şekil 4.9 LSGAN modelinin belli epoch'larda sahte MR görüntüleri.....	46
Şekil 4.10 LSGAN modelinin 500 epoch sonrası üretici ve ayırt edici kayıp grafiği 47	
Şekil 4.11 WGAN modelinin belli epoch'larda sahte MR görüntüleri.....	47
Şekil 4.12 WGAN modelinin 500 epoch sonrası üretici ve ayırt edici kayıp grafiği 48	

TABLolar LİSTESİ

Tablo 3.1 GAN varyantların karşılaştırılması.....	31
Tablo 3.2 Karmaşıklık Matrisi (Confusion Matrix).....	33
Tablo 4.1 Model eğitiminde kullanılan parametreler.....	40
Tablo 4.2 Modelin eğitim aşamasında gerçekleşen üretici, ayırt edici ve dögüsel kayıp değerleri.....	43
Tablo 4.3 SSIM FID metrikleri.....	44
Tablo 4.4 Model eğitiminde kullanılan parametreler.....	44
Tablo 4.5 GAN modellerinin niceliksel FID performans karşılaştırması.....	48
Tablo 4.6 GAN modellerinin niceliksel IS performans karşılaştırması.....	48

SİMGELER VE KISALTMALAR LİSTESİ

Simge	Açıklama
D	Ayırt Edici Ağın Parametreleri
G	Üretici Ağın Parametreleri
V_{WGAN}	WGAN Kayıp Fonksiyonu
V_{DCGAN}	DCGAN Kayıp Fonksiyonu
V_{LSGAN}	LSGAN Kayıp Fonksiyonu
\mathbb{E}	Beklenen Değer
z	Rastgele Gürültü Vektörü
x	Gerçek Veri Örneğini
P_z	Gürültü Vektörünün Olasılık Dağılımını
P_{data}	Gerçek Verinin Olasılık Dağılımını
λ	Döngü Tutarlılığı Kaybının Ağırlık Katsayısı
Σ	Kovaryans Matrisi
μ	Ortalama Özellik Vektörü
Tr	Bir Matrisin Diyagonal Elemanlarının Toplamı
D_{KL}	Kullback-Leibler Divergansı
μ_x, μ_y	Ortalama Parlaklık Değerleri
σ_x, σ_y	Standart Sapma Değerleri
σ_{xy}	İki Görüntü Arasındaki Kovaryans Değeri
α, β, γ	SSIM Parametresinde Bileşenlerin Ağırlıkları

Kısaltma**Açıklama**

GAN	Üretken Çekişmeli Ağlar
DCGAN	Derin Evrişimli GAN
WGAN	Wasserstein GAN
CNN	Evrişimsel Sinir Ağı
MR	Manyetik Rezonans
CT	Bilgisayarlı Tomografi
CAD	Bilgisayar Destekli Tanı
GPU	Grafik İşlem Birimleri
RF	Radyo Frekansı
LSGAN	En Küçük Kareler GAN
TP	Doğru Pozitif
TN	Doğru Negatif
FP	Yanlış Pozitif
FN	Yanlış Negatif
FID	Frechet Başlangıç Mesafesi
IS	Başlangıç skoru
SSIM	Yapısal Benzerlik Endeksi Ölçüsü

ÖZET

ÜRETKEN ÇEKİŞMELİ AĞLARIN (GAN) TIP ALANINDAKİ UYGULAMALARI: GÖRÜNTÜ İŞLEME VE TANI SÜREÇLERİNDE GAN'LARIN ROLÜ

OLĞAÇ, Hamit

Yüksek Lisans, Elektrik-Elektronik Mühendisliği Bölümü

Danışman: Dr. Öğr. Üyesi İsa ATAŞ

Haziran 2024, 73 sayfa

Günümüz dünyasında en hızlı büyüyen alanlardan biri veri analizidir. Veri analizi, tıbbi uygulamalarda, yapay zekâ ve daha birçok alanda önemli sayıda araştırma ve geliştirmenin yolunu açmıştır. Toplanan veriler, gerekli sonuçların sağlanmasında çok önemli bir rol oynar ve kritik kararların ve tahminlerin alınmasına yardımcı olur. Ancak etik kısıtlamalardan dolayı bilim insanlarının verilere ulaşması zordur. Tıbbi görüntü veri setlerine erişilememesi sağlık alanında derin öğrenme çalışmalarını sınırlamaktadır. Üretken rakip ağlar (GAN'lar), gerçek görüntülerle karşılaştırılabilir verileri sentezleyerek bu boşluğu doldurabilir. GAN'lar, son yıllarda tıbbi görüntüleme ve tanı alanında ilgi gören ve derin öğrenme tekniklerini kullanarak veri kümesi içeriğini taklit eden üretken bir modelleme yaklaşımıdır. Vanilya GAN, görüntüleri sentezleyecek kadar uyumlu olmadığından varyantları geliştirilmiştir. Geliştirilen GAN varyantları TIP alanında; MR veya CT gibi tıbbi görüntüleme teknikleri ile elde edilen görüntülerin iyileştirilmesinde, nadir hastalıklarda mevcut ve sınırlı olan görüntü sayısını artırma sürecinde, nesne tanıma (tümör), sınıflandırma (alzheimer) veya segmentasyon (lezyon) gibi tıbbi görüntüleme tekniklerinde ve nörolojik hastalıkların tanısı ve tahmini yönünde tıbbi uygulamalara destek vermektedir. Bu tez çalışmasında tıbbi görüntü işleme ve tanı sürecinde GAN modellerinden yararlanılmış ve Kaggle beyin veri seti görüntüleri referans alınmıştır. Cycle-GAN modeli ile MR görüntülerinden CT tarama görüntülerine ve CT tarama görüntülerden MR görüntülere sentezlenmesi kapsamında deneysel analizler gerçekleştirilmiş ve performansları nicel metrikler ile değerlendirilmiştir. Ayrıca MR görüntülerinden sahte örnek veriler oluşturmak amacıyla literatürde yaygın olarak kullanılan DCGAN, LSGAN ve WGAN modellerinin nitel ve nicel performansları karşılaştırılmıştır. Elde edilen sonuçların güvenilirliğini artırmak ve en iyi performansı elde etmek için yapılan deneyler GAN modellerinin farklı hiperparametreleri ile tekrarlanmış ve sonuçlar paylaşılmıştır. Sonuç olarak tıbbi görüntülerde kullandığımız Cycle-GAN, DCGAN, LSGAN ve WGAN modellerinde hiperparametrelerin değiştirilmesinin etkisi ve üretilen görüntülerin niceliksel sonuçlarla uyumluluğu rapor edilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Tıbbi Görüntü İşleme, GAN (Üretken Çekişmeli Ağlar), Tıbbi Görüntü Sentezleme, Metrikler

ABSTRACT

APPLICATIONS OF GENERATIVE ADVERSARIAL NETWORKS (GAN) IN MEDICINE: THE ROLE OF GANS IN IMAGE PROCESSING AND DIAGNOSTIC PROCESSES

OLĞAÇ, Hamit

Master of Science in Department of Electrical and Electronics Engineering

Supervisor: Assist. Prof. Dr. İsa ATAŞ

June 2024, 73 pages

In today's world, one of the fastest-growing fields is data analysis. Data analysis has paved the way for significant research and development in medical applications, artificial intelligence, and many other areas. Collected data plays a critical role in providing the necessary results and aids in making critical decisions and predictions. However, due to ethical restrictions, it is difficult for scientists to access data. The inaccessibility of medical imaging datasets limits deep learning studies in the healthcare field. Generative Adversarial Networks (GANs) can fill this gap by synthesizing data comparable to real images. GANs are a generative modeling approach that has gained attention in recent years in the field of medical imaging and diagnosis, using deep learning techniques to fake dataset content. Variants of GANs have been developed because vanilla GAN is not sufficiently compatible to synthesize images. The developed GAN variants support medical applications in the field of medicine; improving images obtained with medical imaging techniques such as MR or CT, increasing the number of available and limited images in rare diseases, and supporting medical applications in object recognition (tumor), classification (alzheimer), or segmentation (lesion), and in the diagnosis and prediction of neurological diseases. In this thesis, GAN models were utilized in the medical image processing and diagnosis process, with reference to Kaggle brain dataset images. Experimental analyses were conducted and their performances evaluated with quantitative metrics in the context of synthesizing MR images from CT scan images and vice versa using the Cycle-GAN model. Additionally, the qualitative and quantitative performances of DCGAN, LSGAN, and WGAN models, which are commonly used in the literature to create synthetic sample data from MR images, were compared. To increase the reliability of the results and obtain the best performance, the experiments were repeated with different hyperparameters of the GAN models and the results were shared. As a result, the impact of changing hyperparameters in the Cycle-GAN, DCGAN, LSGAN, and WGAN models used in medical images and the compliance of the generated images with quantitative results were reported.

Keywords: Deep Learning, Medical Image Processing, Generative Adversarial Networks, Medical Image Synthesis, Metrics

1. GİRİŞ

Biyomedikal alan, insan sađlığını anlamak ve iyileřtirmek için vazgeçilmez bir rol oynayan kapsamlı ve çok boyutlu verilerin elde edildiđi bir alan olarak önemini giderek artırmaktadır. Günümüzde, medikal görüntüleme cihazlarının hızla gelişmesiyle birlikte, radyolojik görüntüler, mikroskobik görüntüler, histopatolojik kesitler ve diđer biyomedikal veriler büyük miktarda ve yüksek çözünürlüklü olarak elde edilmektedir. Bu veri zenginliđi, hastalıkların teşhisi, tedavi planlaması ve takibi için yeni ve daha hassas yöntemlerin geliştirilmesini mümkün kılmaktadır. Biyomedikal görüntü analizi, elde edilen bu büyük veri havuzundan anlamlı bilgilerin çıkarılmasını amaçlayan hayati bir süreçtir. Geleneksel yöntemlerin sınırlamaları ve manuel analizin zorluđu göz önüne alındığında, yapay zeka ve derin öğrenme gibi teknolojiler biyomedikal görüntü analizinde devrim niteliğindedir. Bu bağlamda, Generative Adversarial Networks adıyla bilinen “Üretken Çekişmeli Ağlar” (ÜÇA veya GAN) [1], son yıllarda Yapay Zeka ve makine öğrenimi alanında büyük ilgi gören ve veri çeşitlendirme gibi birçok alanda etkileyici sonuçlar sađlayan güçlü bir yapay zeka yaklaşımıdır.

Bazen yapay zeka modellerinin de biyomedikal görüntü analizinde yetersiz kaldıđı durumlar oluşabilmektedir. Biyomedikal alanda kullanılan veriler genellikle uzmanlar tarafından etiketlenmekte ve bu da uzun zamanlara ve maliyetlere sebep olabilmektedir. Ayrıca, bazı biyomedikal veri türleri, özellikle nadir durumlar veya özel durumlar için yeterli miktarda etiketli veriye sahip olmayabilir. Biyomedikal verilerin kullanımıyla ilgili en büyük endişelerden biri, hastaların gizliliğini korumaktır. Bu durum, hastaların kişisel sađlık bilgilerinin ifşa edilme riskini artırabilir. Biyomedikal veriler genellikle hassas kişisel sađlık bilgilerini içerdiđinden, veri paylaşımı ve kullanımı sıkı etik ve yasal düzenlemelere tabidir. Bu tür verilerin paylaşımı hasta gizliliđi ihlallerine yol açtıđından, modellerin eğitiminde kullanılacak yeterli miktarda veri toplamak zor olabilir, özellikle nadir hastalıklar veya özgün durumlar söz konusu olduđunda. Bu veri eksikliđi, yapay zeka modellerinin öğrenme yeteneđini olumsuz etkilemektedir.

Biyomedikal alanda, GAN'lar çeşitli uygulamalara sahip olmuş ve tıp alanında büyük bir potansiyel sunmuştur. GAN'lar, gerçek tıbbi görüntülerin istatistiksel özelliklerini

yakalayarak, yeni ve gerçekçi görüntüler üretebilirler [2]. Bu uygulama, tıbbi eğitim, yapay veri oluşturma ve daha fazla eğitim verisinin elde edilmesi gibi alanlarda büyük potansiyele sahiptir. Örneğin, radyoloji eğitimi için örnek görüntülerin sentezlenmesi veya ender görülen hastalıkların analizi için gerekli sayıda görüntünün üretilmesi gibi durumlarda GAN'lar kullanılabilir. Kanser teşhisi ve değerlendirme gibi kritik tıbbi karar süreçlerine GAN'lar, kanserli hücrelerin ve dokuların karakteristik özelliklerini öğrenerek gerçekçi kanser hücresi görüntüleri üretebilir [3]. Bu, tıp uzmanlarının kanser türlerini daha iyi anlamalarına ve teşhis süreçlerini geliştirmelerine yardımcı olabilir. Ayrıca, hastalığın seyri ve tedaviye yanıt gibi değerlendirmelerde de GAN'lar kullanılarak daha doğru tahminler elde edilebilir.

Hücresele düzeyde görüntü analizi, biyomedikal araştırmada temel bir öneme sahiptir. GAN'lar, hücresele yapıların ve etkileşimlerin daha iyi anlaşılmasına yardımcı olmak için kullanılabilir. Bu uygulamada GAN'lar, mikroskop altında elde edilen hücresele görüntülerin analizini yapabilir ve belirli hücresele özellikleri veya yapıları vurgulayabilir. Bu sayede, hastalıkların hücresele düzeydeki etkileri daha iyi anlaşılabilir ve tedavi stratejileri geliştirilebilir [4]. Radyolojik görüntülerin segmentasyonu, tıbbi teşhis ve tedavi planlaması için kritik bir adımdır. GAN'lar, bu alanda otomatik segmentasyon yöntemleri geliştirmek için kullanılabilir. GAN'lar, radyolojik görüntülerdeki farklı anatomik yapıları veya patolojik bölgeleri tanımlayabilir ve izole edebilir. Bu, tıp uzmanlarının hastalıkları daha iyi teşhis etmelerine ve tedavi stratejilerini optimize etmelerine yardımcı olabilir [5].

1.1 Biyomedikal Alanda Problemin Tanımı

Görüntü işleme, tıbbi görüntülerin analiz edilmesi ve yorumlanmasında kullanılan temel bir araç haline gelmiştir. Gelişmiş algoritmalar ve bilgisayar sistemleri sayesinde, sağlık uzmanlarına hastalıkların teşhisinde ve tedavisinde daha hassas ve etkili bir şekilde yardımcı olur. Ancak, tıbbi görüntü işleme alanında karşılaşılan çeşitli zorluklar ve problemler, bu tekniklerin tam potansiyelini kullanılmasını engellemektedir. Görüntü kalitesi, eksik görüntü verisi, Veri bütünlüğü ve yetersiz veri miktarı gibi faktörler, tıbbi görüntüleme ve tanılamada ciddi engeller oluşturmaktadır. Görüntü kalitesi, tıbbi görüntülerin doğruluğunu ve güvenilirliğini belirleyen temel bir faktördür. Bu kalite, bir dizi faktörün etkisi altındadır ve çeşitli nedenlerden dolayı

elde edilen görüntülerde kalite kaybı meydana gelebilir. Örneğin, hasta hareketi, çekim sırasında cihaz hataları, ışık yetersizliği veya teknik sınırlamalar gibi faktörler, görüntülerin netliğini ve anlaşılabilirliğini azaltabilir. Hasta hareketi, özellikle hareketli organlar üzerinde yapılan görüntülemelerde sıkça karşılaşılan bir sorundur ve net görüntüler elde etmeyi zorlaştırır. Benzer şekilde, cihaz hataları veya teknik sınırlamalar da görüntü kalitesini etkileyerek doğru bir tanının konmasını engelleyebilir. Bu tür kalite kayıpları, tıbbi görüntülerin yorumlanmasını güçleştirir ve yanıltıcı sonuçlara neden olur. Bu nedenle, görüntü kalitesini artırmak ve kalite kayıplarını en aza indirmek, tıbbi görüntüleme ve tanı süreçlerinin temel hedeflerinden biridir.

Eksik görüntü verisi konusu ise, tıbbi görüntüleme süreçlerinde sıkça karşılaşılan bir başka sorundur. Bu durum, hastalığın tam bir görüntüsünün elde edilememesi veya belirli bir bölgeye ait görüntülerin eksik olması şeklinde ortaya çıkabilir. Özellikle nadir görülen hastalıklar veya belirli patolojik durumlar söz konusu olduğunda, uygun görüntüleme tekniklerinin uygulanması zor olacağı ve bunun da eksik veriye neden olacağı görülebilir. Ancak, eksik görüntü verisi, doğru bir tanı konmasını engeller veya tedavi planlamasını olumsuz yönde etkileyebilir. Örneğin, belirli bir bölgenin eksik görüntüsü, lezyonların tespit edilmesini zorlaştırır veya hastalığın yayılma derecesinin tam olarak belirlenmesini engeller. Bu nedenle, eksik görüntü verisinin giderilmesi veya eksikliklerin etkilerinin azaltılması, tıbbi görüntüleme ve tanı süreçlerinin iyileştirilmesi için kritik öneme sahiptir [2].

Yetersiz veri miktarı, tıbbi görüntüleme ve tanı süreçlerinde sıklıkla karşılaşılan bir diğer önemli zorluktur. Özellikle nadir hastalıklar veya belirli klinik durumlar gibi özel alanlarda çalışıldığında, yeterli sayıda örneğe erişmek zor olabilir. Bu durum, özellikle modern tıbbi uygulamalarda yaygın olarak kullanılan makine öğrenmesi ve derin öğrenme gibi veriye dayalı yaklaşımlar için büyük bir kısıtlama olarak ortaya çıkar. Nadir hastalıkların veya spesifik klinik durumların incelenmesi, genellikle sınırlı hasta popülasyonları ile ilişkilidir. Bu durumda, yeterli sayıda ve çeşitlilikte veri elde etmek zor olabilir. Özellikle derin öğrenme gibi veriye dayalı yöntemler, geniş ve temsilci bir veri setine ihtiyaç duyar ve yetersiz veri miktarı, modelin doğruluğunu ve genelleme yeteneğini olumsuz yönde etkileyebilir.

Makine öğrenmesi ve derin öğrenme algoritmaları, genellikle büyük veri setlerinden öğrenir ve bu nedenle sınırlı veri ile çalıştıklarında etkili olmayabilirler. Bu durum, nadir hastalıkların veya özel durumların tanınması ve sınıflandırılmasında güçlükler çıkartabilir. Ayrıca, modelin genelleme yeteneğini azaltabilir ve yeni vakalarla karşılaştığında doğru tahminler yapma yeteneğini olumsuz yönde etkileyebilir. Bu nedenle, yetersiz veri miktarı, tıbbi görüntüleme ve tanı süreçlerinde karşılaşılan önemli bir kısıtlama olarak dikkate alınmalıdır. Bu kısıtlamaların üstesinden gelmek için yeni yöntemler ve stratejiler geliştirilmesi gerekmektedir.

Veri bütünlüğü, tıbbi görüntüleme ve tanı süreçlerinde kritik bir öneme sahiptir. Görüntü verilerinin doğruluğu ve bütünlüğü, tanısal kararların güvenilirliğini ve etkinliğini belirler. Ancak, tıbbi görüntü verileri genellikle çeşitli kaynaklardan elde edilir ve bu verilerin bütünlüğünü korumak zor olabilir. Özellikle tıbbi görüntüleme süreçlerinde, görüntü verilerinin toplandığı çeşitli cihazlar ve platformlar bulunmaktadır. Farklı cihazlar ve protokoller, veri toplama süreçlerinde farklılıklara neden olabilir ve bu da veri bütünlüğünü etkileyebilir. Örneğin, farklı çözünürlüklerde veya farklı formatlarda görüntüler elde edilmesi, veri uyumluluğu sorunlarına yol açabilir ve veri bütünlüğünü zayıflatabilir.

Ayrıca, tıbbi görüntü verilerinin saklanması ve iletilmesi sırasında da bütünlük sorunları ortaya çıkabilir. Veri iletimi sırasında oluşabilecek hatalar veya veri depolama sistemlerindeki arızalar, görüntü verilerinin bütünlüğünü tehlikeye atabilir. Bu durum, veri aktarımı veya depolama işlemlerindeki güvenilirlik sorunlarına bağlı olarak veri kaybına veya bozulmasına neden olabilir. Tıbbi görüntü verilerinin bütünlüğünün korunması, doğru tanı ve tedavi planlaması için hayati öneme sahiptir. Veri bütünlüğü sorunları, yanlış sonuçlara veya hatalı tanıya yol açabilir ve hastaların sağlık durumunu olumsuz yönde etkileyebilir. Bu nedenle, tıbbi görüntü verilerinin toplanması, saklanması ve iletilmesi süreçlerinde bütünlüğün korunması için gerekli önlemler alınmalı ve uygun veri bütünlüğü yönetimi stratejileri uygulanmalıdır. Bu hem sağlık hizmeti sağlayıcıları hem de araştırmacılar için önemli bir sorumluluktur ve tıbbi görüntüleme ve tanı süreçlerinin etkinliğini ve güvenilirliğini artırmaya yönelik bir adımdır.

1.2 Biyomedikal Görüntü Analizi ve Üretimi Neden Önemlidir

Biyomedikal alan, insan sağlığını anlamak ve iyileştirmek için vazgeçilmez bir rol oynayan kapsamlı ve çok boyutlu verilerin elde edildiği bir alan olarak önemini giderek artırmaktadır. Günümüzde, medikal görüntüleme cihazlarının hızla gelişmesiyle birlikte, radyolojik görüntüler, mikroskopik görüntüler, histopatolojik kesitler ve diğer biyomedikal veriler büyük miktarda ve yüksek çözünürlüklü olarak elde edilmektedir. Bu veri zenginliği, hastalıkların teşhisi, tedavisi ve takibi için yeni ve daha hassas yöntemlerin geliştirilmesini mümkün kılmaktadır. Biyomedikal görüntü analizi, elde edilen bu büyük veri havuzundan anlamlı bilgilerin çıkarılmasını amaçlayan hayati bir süreçtir. Geleneksel yöntemlerin sınırlamaları ve manuel analizin zorluğu göz önüne alındığında, yapay zeka ve derin öğrenme gibi teknolojiler biyomedikal görüntü analizinde devrim niteliğindedir. Bu bağlamda, GAN'lar gibi yapay zeka yöntemleri, biyomedikal görüntü analizindeki potansiyeli artırmak ve daha iyi sonuçlar elde etmek için etkili araçlar olarak ortaya çıkmıştır.

Biyomedikal görüntü üretimi ise, yapay zeka destekli sistemler aracılığıyla gerçekçi ve tutarlı biyomedikal görüntülerin sentezlenmesini ifade eder. Bu, deneysel verilerin eksik olduğu veya nadir görülen durumların incelenmesi gerektiği durumlarda özellikle faydalıdır. Aynı zamanda, biyomedikal görüntü üretimi, eğitim verilerinin artırılması ve model öğreniminin iyileştirilmesi için de kullanılabilir [6]. Biyomedikal görüntü analizi ve üretiminin vazgeçilmez önemini göz önüne aldığımızda, GAN'lar gibi yapay zeka yöntemleri bu alanda mevcut veri zenginliğini en etkili şekilde kullanmayı ve hastalıkların erken teşhisinden tedaviye kadar uzanan kritik süreçlerde daha derinlemesine bilgi sağlamayı amaçlamaktadır. Gelecekteki çalışmalar, biyomedikal alanın bu hayati yönünü keşfetmek için GAN teknolojisinin nasıl entegre edilebileceğini ve biyomedikal görüntü analizi ve üretimindeki potansiyelini detaylı bir şekilde ele almaya devam edecektir.

1.3 Tezin Amacı

Bu tez, biyomedikal alanın hızla gelişen ve büyüyen bir disiplin olduğu günümüzde, GAN teknolojisinin tıp alanındaki kullanımının önemini vurgulamaktadır. İnsan sağlığını anlama, hastalıkları teşhis etme ve tedavi etme amacıyla elde edilen büyük ve karmaşık biyomedikal verilerin analizi, tıp bilimindeki önemli bir sorundur.

GAN'lar gibi yapay zeka yöntemleri, bu verileri daha verimli bir şekilde analiz etme ve yorumlama potansiyeline sahiptir. Bu çalışma, GAN'ların biyomedikal görüntüleme, tanı, eğitim ve araştırma süreçlerine getirebileceği yenilikleri ve iyileştirmeleri vurgulayarak, tıp alanında daha etkili ve hassas teşhislerin ve tedavilerin geliştirilmesine katkı sağlamayı amaçlamaktadır. Ayrıca, bu çalışma, biyomedikal alanındaki GAN tabanlı çözümlerin gelecekteki potansiyelini anlamamıza yardımcı olarak, insan sağlığını daha iyi anlama ve iyileştirme çabalarını desteklemektedir. Sonuç olarak, bu tez, biyomedikal alandaki önemli bir teknolojik ilerlemenin altını çizerek, tıp bilimine ve sağlık hizmetlerine değerli bir katkı sunmayı amaçlamaktadır.

1.4 Tezin Yöntemi

Tezimizde, tıp alanındaki uygulamalarda görüntü işleme ve tanı süreçlerindeki rolünü analiz etmek için derin öğrenme modeli olan GAN varyantlarından bazılarını yer verilmiştir. Biyomedikal uygulamalarda GAN'ların eğitimi için görüntü veri seti toplama ve hazırlamada literatürde genelde kullanılan görüntü veri setleri referans alınmıştır. Eğitilen GAN modellerinin performans değerlendirmeleri (gerçek ve üretilen görüntülerin dağılımları arasındaki farkı, üretilen görüntülerin kalitesi ve gerçekliği) için çeşitli metriklerden yararlanılmıştır.

2. ÖNCEKİ ÇALIŞMALAR

Tıp alanındaki görüntü işleme ve tanı süreçleri, yapay zeka teknolojilerinin etkisi altında büyük bir dönüşüm yaşamaktadır. Bu teknolojiler, tıbbi görüntüleme, patoloji, radyoloji ve nöroloji gibi çeşitli tıp alt alanlarında önemli rol oynamaktadır. GAN'lar, tıp alanında çeşitli uygulamalarda büyük bir potansiyele sahiptir. Aşağıda, GAN'ların tıp alanındaki bazı çalışmalarına ilişkin literatür özeti sunulmuştur.

Adar ve arkadaşları 2018 yılındaki makalesinde, veri artırma teknikleri üzerine bir çalışmayı sunmuştur. Bu çalışma, GAN'lar kullanarak sahte tıbbi görüntüler üretmek için karaciğer lezyonu sınıflandırma görevinde sınırlı veriye sahip olmanın üstesinden gelmek için bir yöntem önermektedir [7].

Shin ve ekibi, 2018 yılında tıbbi görüntü işleme ve tanı süreçlerinde GAN'ların kullanımını araştıran bir çalışma yapmışlardır. Çalışmada tıbbi görüntüleme veri setlerinin genellikle patolojik bulguların dengesiz ve nadir olduğu yerlerde sahte görüntüler oluşturma için yeni bir yöntem sunmaktadır. Ayrıca, üretken modellerin bir anonimleştirme aracı olarak kullanılabilirliği önerilmekte ve gerçek hasta verileri yerine sahte verilerle eğitilen derin öğrenme modellerinin, tümör segmentasyonu gibi görevlerde benzer sonuçlar elde edebileceğini göstermeyi amaçlamaktadır [8].

Han ve arkadaşlarının 2018'de yayınladığı makalede hem Deep Convolutional GAN (DCGAN) hem de Wasserstein GAN (WGAN) üzerinde durulmaktadır. Bu iki farklı GAN mimarisi, sahte beyin MR görüntüleri oluşturmak için kullanılmış ve bu görüntülerin gerçekçiliği ve kalitesi üzerinde karşılaştırmalı bir değerlendirme yapılmıştır. Bu çalışmada, DCGAN ve WGAN gibi GAN mimarilerinin tıbbi görüntüleme alanında sahte görüntü üretimindeki etkinliği incelenmiş olup, her iki model de gerçek beyin MR görüntülerini farklı sekanslarda (T1, T1c, T2, FLAIR) sahte olarak üretmek için kullanılmıştır. Ayrıca bu iki yöntemin başarısı, sahte görüntülerin gerçek örneklerden ne kadar gerçekçi olduğunu belirlemek için yapılan görsel Turing testi aracılığıyla değerlendirilmiştir [9].

Kazemina ve arkadaşları 2020 yılında yaptıkları çalışmalarında, tıbbi görüntülerin sentezlenmesi ve bu sahte verilerin veri artırma amacıyla kullanılmasının, karaciğer lezyonları sınıflandırma görevinde derin öğrenme yöntemlerinden Convolutional Neural Network (CNN) performansını artırmak için nasıl kullanılabileceğini araştırmıştır. Bu çalışma, tıbbi görüntüleme alanında veri artırma ve sınıflandırma performansını geliştirmeyi amaçlayan önemli bir katkı sunmaktadır [10].

Suganthi ve ekibinin 2021 yılında yayımladığı makale, Generative Adversarial Networks (GANs) yöntemlerinin tıbbi görüntü sentezine etkilerini incelemekte ve yüksek kaliteli yapay görüntülerin oluşturulmasının, tıbbi görüntülerde belirli hastalıkların teşhisi için önemini vurgulamaktadır. GAN'lar, düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntülere geçiş yapmak için kullanılan derin öğrenme yöntemleri arasında bulunmasından dolayı, özellikle bilgisayarlı tomografi (BT) görüntüsünden manyetik rezonans görüntüsü (MR) oluşturmak gibi çeşitli uygulamalara odaklanmaktadır. Bu çalışma, GAN prensibinin ve çeşitli varyantlarının genel bir incelemesine, tıbbi görüntü sentezi için kullanılan farklı GAN mimarilerine ve GAN'ların tıbbi görüntü sentezindeki uygulamalarına ayrılmış bölümler içermekle birlikte, özellikle Cycle-GAN, MGAN, ACGAN, DCGAN ve WGAN gibi farklı GAN mimarilerinin tıbbi görüntü analizinde nasıl kullanılabileceğini ele almaktadır [11].

Laino ve arkadaşları 2022 yılında yaptıkları çalışmalarında, doktorlar ve sağlık profesyonelleri için klinik ve araştırma rutinlerinde GAN'ların nasıl yardımcı olabileceğini ve tıbbi görüntüleme süreçlerindeki rolünü ele almışlardır. Bu çalışma, yapay zeka teknolojisinin radyoloji alanındaki önemli etkisini ve GAN'lar gibi derin öğrenme yöntemlerinin radyolojideki potansiyelini açıklamaktadır [12].

Ataş, 2023 yılında yayımladığı makalesinde, diyabetik retinopati görüntüleri üzerinde bir karşılaştırma yaparak, farklı GAN varyantlarının tıp alanında nasıl kullanılabileceğini incelemiş ve değerlendirmiştir. Bu çalışma, tıp alanındaki derin öğrenme tekniklerinin kullanılabilirliğini ve hangi GAN varyantlarının daha iyi sonuçlar verdiğini anlamak isteyen araştırmacılara yöneliktir [13].

Thakur ve arkadaşlarının 2024'te yayımladığı çalışmada, tıbbi görüntüleme alanında yapay veri üretim tekniklerine odaklanılmış ve görüntüleme verilerinin genellikle sınırlı boyut ve çeşitlilikte olduğu, bu durumun güçlü analiz algoritmalarının geliştirilmesini engellediği belirtilmiştir. Bu kısıtlamaların üstesinden gelmek için yapay zeka teknikleri kullanılarak sahte veri üretim yöntemlerinin önemine vurgu yapılmıştır. Bu çalışmada, altı yaygın GAN mimarisi (DCGAN, LSGAN, WGAN, StyleGAN, BigGAN, SPADE) çeşitli tıbbi görüntüleme veri setlerinde eğitilerek, bu mimarilerin etkinliği değerlendirilmiştir. Bu çalışmadaki sonuçlar, bazı ileri düzey GAN'ların gerçekçi tıbbi görüntüler üretebildiğini gösterdiği, ancak bu sahte verilerin özelleştirilmiş görevlerde gerçek veri kümelerine göre tutarlı bir şekilde performans göstermediği belirtilmiştir. Bu sonuçlar, GAN ile üretilen tıbbi görüntülerin dikkatsizce kullanılmasının sakıncalarına işaret ederken, özel GAN çözümlerinin geliştirilmesi gerekliliği vurgulanmıştır [14].

Sonuç olarak literatürde yapılan çalışmalar, GAN teknolojisinin tıp alanında nasıl kullanılabileceğini ve tıbbi görüntülerin işlenmesi ve analizi için ne kadar etkili olduğunu göstermektedir. Bu çalışmalar, GAN'ların medikal görüntüleri yeniden oluşturma, veri artırma, otomatik tanı ve daha birçok alanda başarılı bir şekilde kullanılmaktadır. Özellikle, bu çalışmalar, tıbbi görüntülerin kalitesini artırmak, hızlı ve doğru teşhisler yapmak, tedavi süreçlerini optimize etmek ve hastaların yaşam kalitesini artırmak gibi önemli hedeflere katkı sağlamaktadır.

3. MALZEME VE YÖNTEM

Bu bölümde yapılan tez çalışmasında kullanılan malzeme ve yöntemler açıklanacaktır.


3.1 Malzeme

3.1.1 Veri seti

Veri seti olarak görüntü işleme ve tanı süreçlerinde kullanılmak üzere özel olarak oluşturulmuş tıbbi görüntülerinden; beyin veri setleri açıklanacaktır. Bu veri setleri, belirli tıbbi araştırma veya tanı amaçları için toplanmış ve genellikle yüksek kaliteli ve yeterli miktarda veri içermektedir. Her bir veri seti, çeşitli medikal görüntüleme tekniklerinden elde edilen görüntülerden oluşur.


Tıbbi görüntü veri setleri Kaggle gibi bir veri bilimi platformundan elde edilebilmektedir. Kaggle platformları, çeşitli kullanıcılar tarafından paylaşılan zengin veri setlerine erişim sağlayarak, araştırmacıların, öğrencilerin ve profesyonellerin çeşitli alanlarda projeler yapmalarını mümkün kılar. Bu çalışmada, iki farklı Kaggle beyin setinden yararlanılmıştır.

Bunlardan birincisi, “Bilgisayarlı Tomografi” (BT veya CT) ve “Manyetik Rezonans” (MR) görüntülerini içeren beyin veri setidir [15]. Veri seti, farklı tıbbi görüntüleme teknikleriyle elde edilmiş beyin görüntülerini içermektedir ve toplamda dört klasörden oluşmaktadır. Train A klasörü 1744 adet beyin CT görüntüsünü içermektedir. Test A klasörü 744 adet beyin CT görüntüsünü içermektedir. Görüntüler PNG formatındadır. Train B klasörü, 1742 adet beyin MR görüntüsünü içermektedir. Test B klasörü, 742 adet beyin MR görüntüsünü içermektedir. Görüntüler JPG formatındadır. Beyin görüntülerin boyutları A alanı için 512×512 pikseldir. Ancak B etki alanındaki görüntüler farklı piksellerdedir. Bu veri seti, beyin CT ve MR görüntülerinin eğitim ve test setlerini içerecek şekilde yapılandırılmıştır. Eğitim setleri (Train A ve Train B) modelin eğitimi için kullanılırken, test setleri (Test A ve Test B) modelin performansını değerlendirmek için kullanılmaktadır. Şekil 3.1’de bu veri setinden alınmış örnek CT ve MR görüntüleri gösterilmiştir.



Şekil 3.1 Kaggle veri setinden alınmış örnek CT-MR görüntüler [15]

Çalışmada kullanılan ikinci veri seti demanslı ve demanssız beyin MR görüntülerini içeren veri setidir [16]. Veri seti, train ve test adında 2 adet klasörden oluşmaktadır. Train klasörü orta demanslı 52, hafif demanslı 717, çok hafif demanslı 1792, ve demanssız 2560 adet olmak üzere toplamda 5121 adet MR görüntüden oluşmaktadır. Test klasörü ise orta demanslı 12, hafif demanslı 179, çok hafif demanslı 448 ve demanssız 640 adet olmak üzere toplamda 1279 adet MR görüntüden oluşmaktadır. Tüm görüntüler 176×208 boyutlarında olup JPG formatındadırlar. Train klasöründeki görüntüler modelin eğitimi için kullanılırken, Test klasöründeki görüntüler modelin performansını değerlendirmek için kullanılmaktadır. Şekil 3.2’de bu veri setinden alınmış örnek MR görüntüleri gösterilmiştir.



Şekil 3.2 Kaggle veri setinden alınmış örnek Alzheimer MR görüntüler [16]

Çalışmamızda, referans alınan veri setleri kullanılarak görüntülerin işlenmesi, sahte görüntülerin elde edilmesi ve sonuç görüntülerinin analiz edilmesi ile birlikte bazı GAN modelleri kullanılarak beyin görüntülerinin iyileştirilmesi ve tanı süreçlerindeki rolü incelenecektir.

3.1.2 Tıbbi görüntüleme teknikleri

1970 ve öncesi dönemlerde, bilgisayarlar daha çok araştırma laboratuvarlarında ve büyük sağlık kuruluşlarında kullanılmaktaydı. Bu bilgisayarlar, tıbbi görüntülerin analog formatlardan dijital formata dönüştürülmesini ve basit işlemlerin yapılmasını sağlamıştır. Ancak, bu dönemdeki bilgisayarlar sınırlı işlem gücüne sahipti ve tıbbi görüntülerin karmaşık analizlerini gerçekleştirmek için yeterli değildi [17]. 1980'lere gelindiğinde kişisel bilgisayarların popülerlik kazanması, tıbbi görüntü işleme alanında bir devrim yaptı. Daha güçlü ve erişilebilir bilgisayarlar, tıbbi görüntülerin dijital formatlarda depolanmasını ve işlenmesini mümkün kıldı. Bu dönemde, görüntü işleme algoritmaları ve yazılımları, “bilgisayar destekli tanı” (CAD) sistemleri olarak ilk kez kullanılmaya başlandı [18]. 1990'larda bilgisayar teknolojisinin hızla gelişmesiyle birlikte, tıbbi görüntü işleme alanında önemli ilerlemeler kaydedildi. Daha hızlı işlemciler, artan bellek kapasiteleri ve gelişmiş “grafik işlem birimleri” (GPU), büyük miktarda görüntü verisinin hızlı bir şekilde işlenmesini sağladı. Ayrıca, bu dönemde paralel işlemcilerin kullanımı da yaygınlaştı ve tıbbi görüntü işleme için özel donanımların geliştirilmesine yol açtı [19]. 2000'ler ve sonrasında ise yapay zeka ve derin öğrenme gibi ileri bilgisayar bilimi tekniklerinin kullanımının artması, tıbbi görüntü işlemenin daha da gelişmesini sağladı. Derin öğrenme algoritmaları, büyük veri setlerinden karmaşık desenleri öğrenmek ve tıbbi görüntülerdeki yapıları tanımak için kullanılmaktadır. Bu teknikler, otomatik tarama yorumlaması, görüntü segmentasyonu ve hastalık teşhisi gibi birçok alanda kullanılmaktadır [20].

Tıp alanındaki görüntüleme cihazlarının gelişimiyle birlikte önemli bir dönüşüm göstermiş ve bu dönüşüm X-ışınlarından MR görüntülemeye ve CT taramaya kadar bir dizi görüntüleme tekniğinin keşfi ve evrimiyle şekillenmiştir. Gelişen bilgisayar gücü ve algoritmaları, bu görüntüleme yöntemlerinden elde edilen büyük veri kümelerinin analiz edilmesini ve tıbbi teşhis, tedavi planlaması ve hastalıkların izlenmesi gibi alanlarda kullanılmasını mümkün kılmıştır [21].

3.1.3 X-ışınları

1895 yılında Wilhelm Conrad Röntgen tarafından X-ışınları keşfedildi. Bu keşif, radyoloji alanının doğuşunu işaret etti ve röntgen teknolojisi tıbbi görüntülemenin temel taşlarından biri haline geldi. Bu teknoloji, vücut içerisindeki yapıları

görselleştirmek için X-ışınlarının kullanılmasını sağlar. X-ışınları görüntüleme, kırıkların tespiti, akciğer hastalıklarının teşhisi ve diş hekimliği gibi birçok tıbbi alanda kullanılmaktadır [22]. Şekil 3.3’de 1896’da Wilhelm Röntgen tarafından oluşturulan, eşi Anna Bertha'nın elinin X ışını görüntüsü gösterilmiştir.



Şekil 3.3 X-ışınları kullanılarak elde edilen bazı tıbbi görüntüler [22]

X-ışınları, elektromanyetik spektrumun bir parçası olan yüksek enerjili fotonlardır. X-ışınları, insan gözü tarafından algılanamayan ancak bir film veya dedektör üzerinde görüntü oluşturabilen elektromanyetik radyasyondur. Tıpta, diş hekimliğinde, endüstride, güvenlik kontrollerinde ve bilimsel araştırmalarda kullanılmaktadırlar. Bu sayede kemik kırıkları, iç organların durumu, diş problemleri ve birçok tıbbi durumun teşhisi kolaylaşır [23]. Şekil 3.4’de vücuttaki içyapıları görüntülemek için sıklıkla kullanılan bazı X-ışını radyografileri gösterilmiştir.




Şekil 3.4 X-ışınları kullanılarak elde edilen bazı tıbbi görüntüler [24]

3.1.4 Manyetik rezonans (MR) görüntüleme

İlk MR görüntüleme deneyi 1971 yılında uygulandı. MR görüntüleme teknolojisi, vücuttaki dokuların ayrıntılı görüntülerini elde etmek için manyetik alanlar ve radyo dalgaları kullanır. MR görüntüleme, yumuşak dokuları, organları ve beyin aktivitesini incelemek için yaygın olarak kullanılmaktadır. Gelişen MR görüntüleme teknolojisi, yüksek çözünürlüklü görüntüler elde etme yeteneğini artırmış ve tıbbi teşhislerde önemli bir rol oynamıştır [25].


MR görüntüleme, vücudun iç yapısını detaylı bir şekilde gösteren bir tıbbi görüntüleme tekniğidir. MR görüntüleme, radyasyon kullanmadan vücuttaki organların, dokuların ve diğer yapıların ayrıntılı görüntülerini elde etmek için güçlü mıknatıslar, radyo dalgaları ve bir bilgisayar kullanır. MR görüntüleme, özellikle beyin, omurilik, sinirler, kaslar, ligamentler ve eklemler gibi yumuşak dokuların görüntülenmesinde son derece etkilidir. MR görüntüleme işleminin temel prensibi, vücudun büyük bir kısmının su moleküllerinden oluşması ve bu su moleküllerinin hidrojen atomları içermesidir. MR görüntüleme işlemi sırasında, vücut güçlü bir manyetik alana yerleştirilir. Bu, vücuttaki hidrojen atomlarının (özellikle hidrojen protonlarının) manyetik alana hizalanmasına neden olur. Hasta, MR görüntüleme makinesinin içine yerleştirildiğinde, makine tarafından üretilen güçlü bir manyetik alan vücuttaki hidrojen atomlarını (özellikle su ve yağ moleküllerinde bolca bulunan) hizaya getirir. Daha sonra, spesifik bir "radyo frekansı" (RF) impuls, manyetik alana maruz kalan bölgeye gönderilir. Bu impuls, hidrojen atomlarının enerji seviyelerini geçici olarak değiştirir ve atomlar "uyarılır". RF impuls kesildiğinde, uyarılmış hidrojen atomları normal enerji seviyelerine geri dönerken radyo dalgaları şeklinde enerji yayımlarlar. Bu enerji, MR görüntüleme makinesi tarafından algılanır ve sinyaller haline getirilir. Şekil 3.5'te manyetik alana maruz kalan hidrojen atomlarının tepkileri gösterilmiştir. Algılanan sinyaller, bir bilgisayar tarafından işlenir ve vücudun kesitsel görüntüleri olarak görselleştirilir. Farklı dokuların hidrojen atomları farklı hızlarda enerji yaydığı için, dokular arasındaki kontrast bu sinyal farklılıklarına dayanarak oluşturulur. Bu sayede, doktorlar dokular arasındaki farkları net bir şekilde görebilirler. MR görüntülemede kullanılan farklı sıralama veya sekanslar, farklı türde dokuların ve patolojilerin görüntülenmesine olanak tanır. "Sekans" terimi bir dizi işlem veya adımı ifade eder. MR görüntülemede, bir sıralama veya görüntüleme tekniği genellikle bir

dizi işlemi içerir. Bu işlemler, manyetik alanların uygulanması, radyo dalgalarının gönderilmesi, sinyallerin alınması ve işlenmesini içerebilir. Yaygın olarak kullanılan bazı MR görüntüleme sekansları aşağıda tanımlanmıştır [26].



Şekil 3.5 Manyetik alana maruz kalan hidrojen atomlarının tepkileri [27]

“T1-Ağırlıklı Sekans”, dokuların T1 rahatlatma sürelerine (relaxation times) göre görüntülediği bir sıralamadır. T1-ağırlıklı görüntüler, yağ dokusu gibi belirli dokuları daha iyi gösterir. “T2-Ağırlıklı Sekans”, dokuların T2 rahatlatma zamanlarına göre görüntülediği bir sıralamadır. T2-ağırlıklı görüntüler, sıvılar gibi belirli dokuları daha iyi gösterir ve lezyonların tespit edilmesine yardımcı olabilir. “Sıvı Bastırılmış Ters Kurtarma (FLAIR) Sekansı”, sıvıların (beyin omurilik sıvısı gibi) görüntüden bastırılmasıyla lezyonların daha iyi görünmesine olanak tanır. Özellikle beyin lezyonlarının değerlendirilmesinde yaygın olarak kullanılır. Şekil 3.6’da bazı MR görüntüleme sekanslarıyla oluşturulmuş beyin MR görüntüleri gösterilmiştir.



Şekil 3.6 Bazı MR sekanslarıyla oluşturulmuş beyin MR görüntüleri [28]

MR görüntülemenin temel avantajları arasında, radyasyon içermemesi ve yumuşak dokular arasındaki kontrastın mükemmel olması yer alır. Bu özellikler, özellikle beyin, omurilik gibi sinir sistemi bileşenleri ve kas-iskelet sistemi gibi yumuşak dokuların incelenmesi için MR görüntülemeyi ideal kılar. Ayrıca, MR görüntüleme fonksiyonel bilgiler sağlayabilen gelişmiş tekniklerle donatılmıştır. Fonksiyonel MR görüntüleri, beyin aktivitesini ve kan akışını görüntüleyerek, beyin fonksiyonlarının ve hastalıklarının daha iyi anlaşılmasını sağlar [29].


3.1.5 Bilgisayarlı tomografi (BT veya CT)

1972 yılında CT teknolojisi ilk kez tanıtıldı. CT taramaları, vücut içinde kesitsel görüntüler elde etmek için X-ışınlarının kullanıldığı bir görüntüleme tekniğidir. CT, vücut içerisindeki kesitsel görüntülerin elde edilmesini sağlayan bir görüntüleme tekniğidir. X-ışınları kullanılarak vücudun farklı açılardan kesitleri alınır ve bilgisayarlar aracılığıyla bu kesitlerin 3D görüntüleri oluşturulur. CT taramaları, iç organların ve dokuların detaylı bir şekilde incelenmesini sağlar ve birçok tıbbi durumun teşhisinde önemli bir rol oynar. Hasta, bir masa üzerine yatar ve bu masa, bir tünelin içinden geçerken çeşitli açılardan X-ışınlarına maruz kalır. Bu X-ışınları, vücuttan geçerken detektörler tarafından algılanır. Bilgisayarlar, bu detektörlerden gelen verileri işleyerek kesitsel görüntüleri oluşturur [30].

CT taramaları, iç organların, kemiklerin, kan damarlarının ve diğer dokuların detaylı görüntülerini elde etmek için kullanılır. Tıbbi teşhis, hastalıkların tanınması, tedavi planlaması ve cerrahi müdahaleler için önemli bir araçtır. Örneğin, beyin, akciğer, kalp, karaciğer, böbrekler, omurga gibi birçok vücut bölgesinin incelenmesinde CT taramaları yaygın olarak kullanılmaktadır. CT ve X-ışını taramaları, benzer bir prensibe dayanır: vücut içerisinde görüntü oluşturmak için X-ışınları kullanılır. Ancak, aralarında bazı önemli farklar vardır. CT, kesitsel (3B) görüntüler sağlar. Bu, vücut içindeki yapıların üç boyutlu bir haritasını sunar. Örneğin, bir CT taramasıyla bir insanın beyninin, kalbinin veya karaciğerinin iç yapısını detaylı bir şekilde görebiliriz. Bu, hastalıkları daha hassas bir şekilde teşhis etmemizi sağlar. X-ışını taramaları ise genellikle tek bir düzlemde (2B) görüntü elde eder. Yani, vücuttaki bir bölgenin sadece bir "kesiti" hakkında bilgi verir. CT daha detaylı ve kapsamlı bir inceleme sağlar. Çünkü bu teknoloji, birçok farklı açıdan X-ışınları kullanarak görüntüler oluşturur ve

ardından bu görüntüleri bilgisayar programlarıyla birleştirir. Bu, dokuların ve organların daha net bir şekilde görüntülenmesini sağlar [31].

Ancak, bu detaylı görüntüler daha yüksek radyasyon dozlarına ihtiyaç duyar. CT taramaları, X-ışını taramalarına göre daha fazla radyasyon içerir. Bu da bazı durumlarda özellikle çocuklar ve hamile kadınlar gibi hassas gruplarda endişe kaynağı olabilir. Bu nedenle, CT taramaları genellikle belirli durumlar için ve belirli bir teşhis yapılması gerektiğinde tercih edilir. CT ile taranmış bir örnek görüntü Şekil 3.7’de gösterilmiştir.



Şekil 3.7 Beyin CT tarama görüntüleri [32]

CT, X-ışını ve MR taramaları, farklı görüntüleme teknikleri ve kullanım alanlarına sahiptir. CT, detaylı üç boyutlu görüntüler sağlar ve acil durumlarda hızlı teşhis için uygundur. Ancak, yüksek radyasyon dozları gerektirebilir. X-ışını, düşük maliyetli ve hızlı sonuçlar sağlar, ancak sadece düzlemsel görüntüler elde eder ve radyasyon riski taşır. MR, yumuşak dokuların daha iyi görüntülenmesini sağlar, radyasyon içermez ve tekrarlanan taramalarda daha güvenlidir, ancak daha pahalı ve zaman alıcı olabilir. CT, acil durumlar ve kemik, kan damarları gibi durumların teşhisi için yaygın olarak kullanılırken, X-ışını kırıklar, akciğer enfeksiyonları gibi basit durumlar için sıklıkla tercih edilir. MR görüntüleme ise beyin, kaslar gibi yumuşak dokuların incelemesi ve

belirli durumların teşhisi için daha uygundur. Her bir tarama yöntemi, hastanın durumuna, teşhis gereksinimlerine ve radyasyon hassasiyetine bağlı olarak seçilir [33].

3.2 Yöntem

Tıbbi görüntüleme teknolojisinin ilerlemesi, tıp alanında birçok gelişmeye neden olmuştur. Bu görüntüler üzerine yapılan yapay zeka çalışmalarındaki artış, hastalıkların tanı ve tedavi süreçlerini olumlu yönde etkilemiştir. Ancak yapay zeka çok büyük veri setlerine ihtiyaç duymaktadır. Kullanılacak veri seti ne kadar büyük olursa, model o kadar çok şey öğrenir ve daha doğru kararlar verir. Bu alanda yapılan çalışmalarda, özellikle nadir hastalıklar söz konusu olduğunda, etik değerler nedeniyle istenilen miktarda veri bulunamayabilir. Bu nedenle GAN'lar yardımıyla sahte oluşturulan yeni görüntülerle veri sayısını arttırarak modellerin daha kararlı ve daha doğru eğitilmesiyle tedavi ve tanı süreçlerinde daha güvenilir sonuçlar alınabilmektedir.

Bu tez çalışmasının bulgular bölümünde, Cycle-GAN modeli kullanılarak MR görüntülerinden CT taramalarına ve CT taramalarından MR görüntülerine çeviri deneyleri yapılmış ve elde edilen metrik sonuçlar analiz edilmiştir. Ayrıca, MR beyin veri seti ile GAN varyantlarından WGAN, LSGAN ve DCGAN modelleri eğitilerek üretilen sahte görüntülerin nitel ve nicel sonuçların karşılaştırması yapılmıştır.


3.2.1 Veri ön işleme

Veri ön işleme, GAN tabanlı görüntü işleme ve tanı süreçlerinde kritik bir adımdır. Bu süreç, kullanılacak görüntü veri setlerinin toplanması, analizi ve hazırlanması adımlarını içerir. Bu adımlar veri setinin temizlenmesi, standardizasyonu, gürültünün azaltılması ve veri artırımı (data augmentation) gibi işlemleri içerebilir. Her adımın amacı, modelin eğitim sürecini iyileştirmek ve doğru sonuçlar elde etmek için gereklidir.

3.2.1.1 Görüntü normalizasyonu

Görüntü veri setlerinin eğitim sürecinde başarıyla kullanılabilmesi için, görüntülerin farklı boyutlarda ve renk uzaylarında temsil edilmesi gereken bir standart formata getirilmesi önemlidir. Bu amaçla, görüntü normalizasyonu adı verilen işlemler

gerçekleştirilir. Görüntü normalizasyonu işlemi, veri setindeki görüntülerin standart boyutlara ve renk uzayına dönüştürülmesini içerir. Örneğin, görüntüler belirli bir piksel boyutuna yeniden boyutlandırılır. Bu adım, veri setindeki tüm görüntülerin aynı boyutta olmasını sağlar, böylece modelin eğitimi sırasında tutarlılık sağlanır. Renk uzayı normalizasyonu ise, görüntülerin renk skalasını belirli bir aralığa dönüştürme işlemidir. Bu işlem genellikle görüntülerin belirli bir renk aralığında yeniden ölçeklenmesini içerir. Örneğin, RGB renk uzayındaki piksel değerleri 0 ile 255 arasında değişiyorsa, normalizasyon işlemi bu değerleri 0 ile 1 arasına ölçekler. Bu adım, görüntülerin renklerinin birbirine daha yakın olmasını sağlar ve modelin renkler arasındaki ilişkileri daha iyi öğrenmesine yardımcı olur. Bu adımlar, görüntü veri setlerinin homojen bir formatta olduğundan ve modelin doğru şekilde eğitildiğinden emin olmak için önemlidir. Görüntülerin standart boyutlarda ve renk skalasında olması, modelin daha tutarlı ve güvenilir sonuçlar üretmesine yardımcı olur. Bu nedenle, GAN tabanlı görüntü işleme ve tanı süreçlerinde normalizasyon adımları kritik bir öneme sahiptir. Kaggle veri setindeki görüntülerin ön işlemlerden sonraki örnek görüntüler Şekil 3.8’de gösterilmiştir.



Şekil 3.8 Veri setindeki görüntülerin ön işlemlerden sonraki örnek görüntüleri (a) Demansız, (b) Çok hafif demanslı, (c) Hafif demanslı, (d) Orta demanslı

3.2.1.2 Gürültü azaltma ve kalıntı temizleme


Görüntü veri setleri genellikle çeşitli kaynaklardan elde edilir ve bu kaynaklardan kaynaklanan gürültüler veya istenmeyen yapay öğeler (kalıntılar) içerebilir. Bu nedenle, veri ön işleme sürecinde, görüntülerdeki gürültüyü azaltmak ve kalıntıları

temizlemek önemlidir. Gürültü azaltma işlemi, görüntülerdeki istenmeyen gürültüyü azaltmayı amaçlar. Gürültü, rastgele piksel değerlerinde veya düzensiz desenlerde ortaya çıkabilir ve genellikle görüntü kalitesini düşürebilir. Bu nedenle, gürültü azaltma algoritmaları kullanılarak, görüntülerdeki gürültü seviyeleri azaltılır ve görüntüler daha temiz hale getirilir. Bu işlem, modelin doğru özellikleri öğrenmesine ve daha keskin sonuçlar üretmesine yardımcı olur. Kalıntı temizleme, görüntülerdeki istenmeyen gürültüleri kaldırılmasını içerir. Bu gürültüler, genellikle görüntüleme veya saklama sürecinden kaynaklanır ve görüntülerin doğru şekilde yorumlanmasını engelleyebilir. Kalıntı temizleme işlemi, bu yapay öğeleri algılar ve kaldırır, böylece modelin gerçek görüntü özelliklerini daha iyi yakalamasına olanak tanır. Bu adım, özellikle tıbbi görüntüleme gibi hassas alanlarda doğru teşhislerin yapılabilmesi için kritiktir.

Gürültü azaltma ve kalıntı temizleme işlemleri, görüntü veri setlerinin kalitesini artırır ve modelin daha doğru şekilde eğitilmesine katkıda bulunur. Bu adımlar, GAN tabanlı görüntü işleme ve tanı süreçlerinde kullanılan veri setlerinin güvenilirliğini artırmak için önemlidir.

3.2.1.3 Veri çeşitlendirme (data augmentation)

Görüntü veri setlerinin genellikle sınırlı olduğu tıbbi görüntüleme uygulamalarında, veri çeşitlendirme önemli bir rol oynar. Veri çeşitlendirme, GAN tabanlı görüntü işleme ve tanı süreçlerinde kullanılan veri setlerinin çeşitliliğini artırmak ve modelin genelleme yeteneğini geliştirmek için kullanılan bir tekniktir. Bu teknik, eldeki sınırlı veri setini çeşitli dönüşümler uygulayarak yeni ve çeşitli örnekler oluşturmayı amaçlar. Bu da görüntü veri setinin boyutunu artırırken, aynı zamanda modelin performansını artırır. Görüntü veri setlerinde veri çeşitlendirme, birçok farklı yöntemle gerçekleştirilebilir. Bunlar arasında görüntü döndürme, yansıtma, kesme, kaydırma, büyütme/küçültme, renk değiştirme, parazit ekleme veya gürültü eklemeyi içerebilir. Şekil 3.9'da beyin CT-MR görüntülerinden veri artırma yöntemleri ile elde edilen görüntüler gösterilmiştir.



Şekil 3.9 Veri artırma görüntüleri


Bu yöntemler, görüntülerin farklı bakış açılarını, pozisyonlarını ve özelliklerini temsil ederek modelin daha geniş bir veri yelpazesini öğrenmesini sağlar. Örneğin, görüntü döndürme yöntemi, mevcut görüntüleri belirli derecelerde döndürerek yeni örnekler oluşturur. Yansıtma yöntemi ise, görüntüleri yatay veya dikey olarak yansıtarak yeni görüntüler elde eder. Kesme yöntemi, mevcut görüntülerin belirli bölgelerini kırparak veya yeniden boyutlandırarak yeni örnekler oluşturur. Bu yöntemlerin kullanılması, veri setindeki örnek sayısını artırırken, aynı zamanda modelin çeşitli koşullara, deformasyonlara ve gürültülere karşı daha dirençli olmasını sağlar. Bu da modelin gerçek dünya verileriyle daha iyi performans göstermesine olanak tanır.

Veri çeşitlendirme, özellikle sınırlı miktarda veriyle çalışıldığında veya modelin aşırı uyumu (overfitting) önlemek için önemlidir. Modelin daha genel ve çeşitli örüntüler öğrenmesine yardımcı olurken, aynı zamanda veri setinin dengesini artırır ve modelin daha iyi genelleme yapmasını sağlar. Bu nedenle, GAN tabanlı görüntü işleme ve tanı süreçlerinde veri çeşitlendirme genellikle önemli bir adımdır. Veri ön işleme süreci, GAN tabanlı görüntü işleme ve tanı süreçlerinde kullanılacak veri setlerinin hazırlanması için gereklidir. Doğru ve dikkatli bir veri ön işleme süreci, modelin eğitim sürecini iyileştirebilir ve kaynakların daha etkin bir şekilde kullanılarak başarılı sonuçlar elde etmeyi sağlayabilir.

3.2.2 Üretken çekişmeli ağ (GAN)

GAN, 2014 yılında Ian Good Fellow ve arkadaşları tarafından önerilmiştir. GAN, bir üretici ağın belirli bir amaç fonksiyonunu maksimize etmeye çalışırken, aynı amaç fonksiyonunu minimize etmeye çalışan bir ayırt edici ağ arasında eğitilen derin bir

üretken modeldir. Bu, her iki ağın kendi hedeflerini başarmak için optimize edildiği anlamına gelir. Üretici ağ gerçekçi örnekler oluşturmak zorundayken, ayırt edici ağ, üretici örneklerini reddetmekte ve gerçek örnekleri kabul etmekte deneyimli olmalıdır [1]. Şekil 3.10’da GAN mimarisi gösterilmiştir.



Şekil 3.10 Vanilya GAN modeli [34]

Üretici çıktılarının (sahte verilerin) gerçek olarak tanınma olasılığını maksimize etmeye çalışırken, ayırt edici aynı değeri minimize etmeye çalışır. Üretici, rastgele gürültü vektörü ile gerçek görüntü verisi arasında bir denklik kurar, Ayırt edici ise üretilen çıktının gerçek veya sahte olup olmadığını belirler. Bu iki sinir ağı, verilen V (D, G) amaç fonksiyonuna sahip iki rakip olarak düşünülebilir, çünkü hem Ayırt edici hem de Üretici eğitim sırasında karşıt kayıp fonksiyonlarını optimize etmeye çalışırlar. Amaç fonksiyonu aşağıdaki gibidir:

$$\min_G \max_D V(G, D) = \mathbb{E}_{x \sim P_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim P_z(z)} [\log (1 - D(G(z)))] \quad (1)$$

Burada “ D ” ayırt edici ağın parametrelerini, “ G ” üretici ağın parametrelerini, “ $P_{data}(x)$ ” gerçek verilerin dağılımını, “ $P_z(z)$ ” gürültü dağılımını, “ $\mathbb{E}_{x \sim P_{data}(x)} [\log D(x)]$ ” gerçek verilerin ayırt edici tarafından doğru sınıflandırılma olasılığının beklenen değerini, “ $\mathbb{E}_{z \sim P_z(z)} [\log (1 - D(G(z)))]$ ” üretilen verilerin yanlış sınıflandırılma olasılığının beklenen değerini, “ $V(G, D)$ ” GAN’ın hedef fonksiyonunu ifade etmektedir.

GAN’ın işleyişindeki temel fikir, gerçek verilerden oluşan bir veri seti girildiğinde, bu veri setindeki verilere benzer veriler elde etmektir. $D(x)$ ve $G(z)$ sırasıyla ayırt edici

ve üretici ağlardır. GAN mimarisi, Üreticiyi ve Ayırt ediciyi eş zamanlı olarak eğitir. Üretici, rastgele gürültü vektörü kullanarak gerçeğe benzer sahte veriler üretir. Ancak Ayırt edici, verilerin ne kadar benzer olduğunu değerlendirir. GAN'lar, diğer üretken modellere göre daha yüksek kalitede örnekler (daha net ve daha keskin görüntüler) üretebilir. Ancak GAN modelinin serbest ve kontrolsüz olması nedeniyle bir önyargı sorunu vardır. Bu nedenle, GAN'ların performansını iyileştirmek için birçok değişik GAN yöntemi geliştirilmiştir.

GAN'ların eğitimi ve tahmini zor olabilir çünkü eğitim sırasında üretici ve ayırt edici ağlar arasında rekabet vardır. Bir ağın diğerinden daha hızlı öğrenmemesi durumunda ağ yakınsamaz ve istenmeyen eğitim sorunları ortaya çıkabilir. En sık belgelenen GAN eğitim sorunları mod çökmesi ve yakınsamama başarısızlığıdır. Mod çökmesi, dengesiz GAN eğitiminin ana nedenlerinden biridir. Yakınsamama başarısızlığı ise eğitim sonrası kaliteli sonuçların elde edilmesini zorlaştırır. GAN'ların yüksek kalitede örnekler üretebilmesi, bu alanda birçok gelişmeye kapı açmasına ve GAN'lar üzerinde yapılan çalışmaların artmasına neden olmuştur. Bu çalışmaların sonucunda çeşitli alanlarda kullanılan GAN varyantları ortaya çıkmıştır. Bu tez kapsamında referans alınan GAN varyantları aşağıda tanımlanmıştır.

3.2.2.1 Wasserstein GAN (WGAN)

WGAN, geleneksel GAN'ların karşılaştığı temel zorlukları çözmek için geliştirilmiş bir GAN türüdür ve mimari olarak GAN'a benzer. Arjovsky, Chintala ve Bottou tarafından 2017 yılında tanıtılan WGAN, eğitim sürecindeki kararsızlık ve çökme problemlerine odaklanmaktadır. WGAN, eğitim sürecini daha kararlı hale getirmek ve gradyan tıkanması sorunlarını azaltmak için Wasserstein mesafesini kullanır. WGAN'ın önemli farkı, ayırt edici ağın (critic olarak adlandırılır) kayıp fonksiyonunda kullanılan mesafe ölçüsüdür. Geleneksel GAN'lardan farklı olarak, iki olasılık dağılımı arasındaki benzerliği ölçmek için Wasserstein mesafesi kullanılır. Bu değişiklik, ayırt edici ağın gerçek ve sahte dağılımlar arasındaki farkı daha iyi ölçmesine olanak tanır ve daha kararlı bir eğitim süreci sağlar [35]. Üretici ve ayırt edici için amaç fonksiyonları (2) ve (3) olarak verilmiştir.

$$\max_D V_{WGAN}(D) = \mathbb{E}_{x \sim P_{data(x)}}[D(x)] - \mathbb{E}_{z \sim P_{z(z)}}[D(G(z))] \quad (2)$$

$$\min_G V_{WGAN}(G) = \mathbb{E}_{x \sim P_z(z)} [D(G(z))] \quad (3)$$

Burada " $V_{WGAN}(G)$ " üretici için WGAN'in kayıp fonksiyonunu, " $V_{WGAN}(D)$ " ayırt edici ağı WGAN'in kayıp fonksiyonunu, " \mathbb{E} " beklenen değeri, " z " rastgele gürültü vektörünü, " x " gerçek veri örneğini, " P_z " gürültü vektörünün olasılık dağılımını, " P_{data} " gerçek verinin olasılık dağılımını, " G " üretici ağı, " D " ayırt edici ağı, " $D(x)$ " gerçek verinin ayırt edici ağ tarafından gerçek olarak sınıflandırma oranını, " $G(z)$ " üretici ağ tarafından üretilen sahte veri örneğini, " $D(G(z))$ " üretici ağı üretilen sahte verinin ayırt edici ağ tarafından gerçek olarak sınıflandırma olasılığını ifade eder.


WGAN, geleneksel GAN'lara göre daha kararlı bir eğitim süreci sunar. Bu özellikle uzun eğitim süreçleri ve karmaşık veri kümeleriyle çalışırken avantaj sağlar. Wasserstein mesafesi, gradyan tıkanması problemlerini önemli ölçüde azaltır ve modelin daha gerçekçi ve yüksek kaliteli görüntüler üretmesini sağlar, bu da çeşitli uygulamalarda performans artışına yol açar.

3.2.2.2 Deep Convolutional GAN (DCGAN)

Radford ve arkadaşları, evrimsel ağların topolojisine belirli kısıtlamalar getirerek stabil bir mimariye sahip ve daha üstün sonuçlar veren derin evrimsel bir GAN olan DCGAN'ı önerdiler. DCGAN'ın gözetimsiz öğrenme bağlamında güçlü bir katkı sağladığı ve çeşitli görüntü sınıflandırma görevlerinde en son teknolojiyi sunduğu gösterildi. DCGAN'lar genellikle yüksek kaliteli ve yüksek çözünürlüklü görüntüler üretmek ve büyük veri kümeleriyle kullanılmak üzere tasarlanmıştır. Eğitim sırasında daha istikrarlıdır ve büyük ve karmaşık veri kümeleri için uygundur [36].

Stabil bir DCGAN'da, ayırt edici modeli tüm havuzlama katmanlarını basit evrişimle değiştirirken, üretici modeli transpoz evrişim kullanır. Ayrıca, tüm üretici katmanlarda ReLU aktivasyon fonksiyonu kullanılırken, son katman TanH aktivasyonunu kullanır. Ayırt edici katmanlarında ise LeakyReLU aktivasyon fonksiyonu tercih edilir. Basit ve transpoz evrişimler, DCGAN modelinin temel bileşenleri olarak eğitim sırasında

kullanılarak GAN'ın mükemmel küçültme ve büyütme işlemlerini öğrenmesine olanak sağlar. Bu örnekleme işlemleri, görüntü sentezini iyileştirmeye yardımcı olur. Şekil 3.11'de, DCGAN modelinin üretici ve ayırt edici katmanlarını göstermektedir. DCGAN modeli, GAN'ların sıfır toplamı oyun fikrini temel alır; ayırt edici ve üretici için DCGAN modelinin amaç fonksiyonları (4) ve (5) olarak tanımlanmıştır.



Şekil 3.11 DCGAN modeli [13]

$$\max_D V_{DCGAN}(D) = \mathbb{E}_{x \sim P_{data}} [\log D(x)] + \mathbb{E}_{z \sim P_z} [\log (1 - D(z))] \quad (4)$$

$$\min_G V_{DCGAN}(G) = \mathbb{E}_{x \sim P_z} [\log (D(G(z)))] \quad (5)$$

Burada " $V_{DCGAN}(G)$ " üretici için DCGAN'in kayıp fonksiyonunu, " $V_{DCGAN}(D)$ " ayırt edici için DCGAN'in kayıp fonksiyonunu, " \mathbb{E} " beklenen değeri, " z " rastgele gürültü vektörünü, " x " gerçek veri örneğini, " P_z " gürültü vektörünün olasılık dağılımını, " P_{data} " gerçek verinin olasılık dağılımını, " G " üretici ağı, " D " ayırt edici ağı, " $D(x)$ " gerçek verinin ayırt edici ağ tarafından gerçek olarak sınıflandırma oranını, " $G(z)$ " üretici ağ tarafından üretilen sahte veri örneğini, " $D(G(z))$ " üretici ağın ürettiği sahte verinin ayırt edici ağ tarafından gerçek olarak sınıflandırma olasılığını ifade eder.

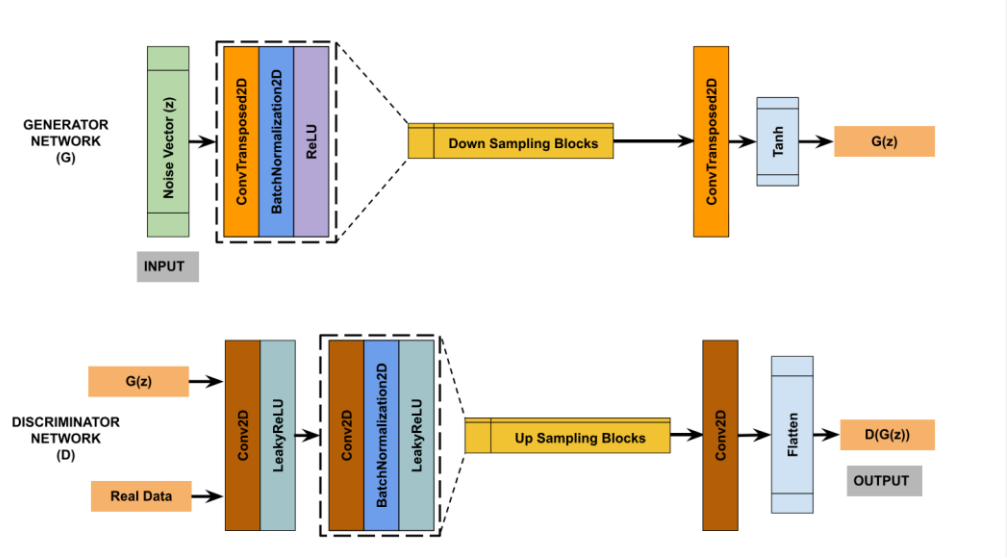
3.2.2.3 Least Squares GAN (LSGAN)

Mao ve arkadaşları, LSGAN modelini başka bir gan modeli olan vanilya GAN'lardan daha stabil bir performans sağlamak için önerdiler. Vanilya GAN'da, sigmoid çapraz-entropi kaybı işlevi nedeniyle kaybolan gradyanlar sorunu ortaya çıkar. Bu sorunu çözmek için LSGAN'da en küçük kareler kaybı fonksiyonu kullanılır. Bu en küçük kareler kaybı, sahte üretilmiş görüntüleri karar sınırından olan mesafelerine dayanarak cezalandırır. Bu, gerçek veriden çok farklı olan sahte görüntüler için güçlü bir gradyan sağlar [37]. Ayrıca, üretilen verilerin gerçek veriye daha yakın olmasını sağlar. LSGAN'ın üretici ve ayırt edici katmanları Şekil 3.12'de gösterilmiştir. Ayrıca, üretici ve ayırt edici için amaç fonksiyonları (6) ve (7) olarak verilmiştir. Ayırt edicinin amacı, gerçeği gerçek olarak ve sahteyi sahte olarak değerlendirmektir; üreticinin amacı ise ayırt edicinin sahte olanı gerçek sanmasını sağlamaktır.

$$\min_D V_{LSGAN}(D) = \frac{1}{2} \mathbb{E}_{x \sim P_{data(x)}} [\log(D(x) - b)^2] + \mathbb{E}_{z \sim P_z(z)} [\log(D(G(z)) - c)^2] \quad (6)$$

$$\min_G V_{LSGAN}(G) = \frac{1}{2} \mathbb{E}_{x \sim P_z(z)} [\log(D(G(z)) - a)^2] \quad (7)$$

Burada " $V_{LSGAN}(G)$ " üretici için DCGAN'in kayıp fonksiyonunu, " $V_{LSGAN}(D)$ " ayırt edici için DCGAN'in kayıp fonksiyonunu, " \mathbb{E} " beklenen değeri, " z " rastgele gürültü vektörünü, " x " gerçek veri örneğini, " P_z " gürültü vektörünün olasılık dağılımını, " P_{data} " gerçek verinin olasılık dağılımını, " G " üretici ağı, " D " ayırt edici ağı, " $D(x)$ " gerçek verinin ayırt edici ağ tarafından gerçek olarak sınıflandırma oranını, " $G(z)$ " üretici ağ tarafından üretilen sahte veri örneğini, " $D(G(z))$ " üretici ağın ürettiği sahte verinin ayırt edici ağ tarafından gerçek olarak sınıflandırma olasılığını, " a ", " b " ve " c " hedef etiketleri ifade eder.

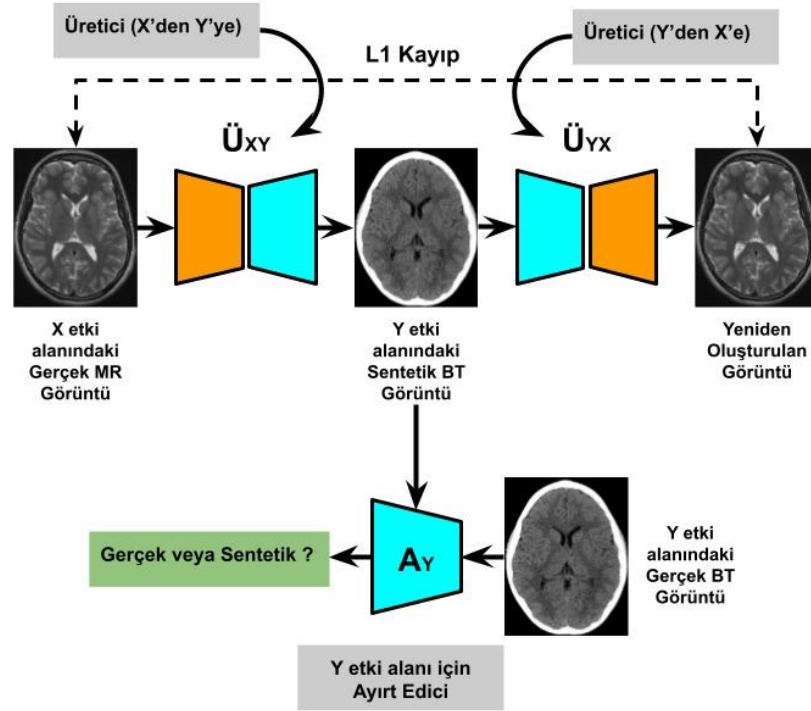


Şekil 3.12 LSGAN modeli [13]


3.2.2.4 Cycle-GAN

Cycle-GAN, GAN ailesinin bir üyesi olup, iki farklı görüntü alanı arasında çevirme (translation) işlemlerini denetimsiz bir şekilde gerçekleştiren derin öğrenme modelidir. İlk olarak 2018 yılında Jun-Yan Zhu ve arkadaşları tarafından tanıtılan Cycle-GAN, eşlenik olmayan veri kümeleri arasında dönüşüm yapabilme yeteneği ile öne çıkar. Bu özellik, özellikle tıp alanında, farklı modaliteler arasındaki görüntü dönüşümleri için büyük bir avantaj sağlar [38]. Şekil 3.13’de Cycle-GAN’ın çalışma mimarisi gösterilmiştir.

Cycle-GAN, iki çift üretici ve ayırt edici ağlar kullanır. Bir çift, X alanındaki görüntüleri Y alanına çevirirken, diğer çift Y alanındaki görüntüleri X alanına çevirir. Cycle-GAN, GAN yapısını temel alır ve özellikle dögüsel kısıtların eklenmesiyle birlikte çift yönlü dönüşümler gerçekleştirir. Tıbbi görüntüleme alanında, özellikle farklı görüntü modaliteleri arasında dönüşümler yapmak için tercih edilir. Cycle-GAN, dögü tutarlılığı kaybını (cycle-consistency loss) kullanarak eşleşmemiş veri setleri arasında dönüşüm yapar. Şekil 3.14’te Cycle-GAN’ın basit modeli gösterilmiştir. Cycle-GAN’ın temel bileşenleri ve kayıp fonksiyonları şu şekildedir.



Şekil 3.13 Cycle-GAN mimarisi [34]



Şekil 3.14 Basit bir Cycle-GAN modeli [38]

Cycle-GAN, iki adet GAN kullanır. Biri $G: X \rightarrow Y$ dönüşümünü, diğeri ise $F: Y \rightarrow X$ dönüşümünü öğrenir. Bu iki GAN, her biri kendi düşman kaybı (adversarial loss) fonksiyonuna sahip olup bu fonksiyonlar (8) ve (9)'da gösterilmiştir.

$$L_{GAN}(G, D_Y, X, Y) = \mathbb{E}_{y \sim P_{data(y)}} [\log D_Y(y)] + \mathbb{E}_{x \sim P_{x(x)}} [\log (1 - D_Y(G(x)))] \quad (8)$$

$$L_{GAN}(F, D_X, Y, X) = \mathbb{E}_{x \sim P_{data(x)}} [\log D_X(x)] + \mathbb{E}_{y \sim P_{y(y)}} [\log (1 - D_X(F(y)))] \quad (9)$$

Burada "G" X alanından Y alanına dönüşüm yapan üretici ağı, "F" Y alanından X alanına dönüşüm yapan üretici ağı, "D_Y" Y alanındaki verinin gerçek olup olmadığını

ayırt eden ayırt edici ağı, " D_X " X alanındaki verinin gerçek olup olmadığını ayırt eden ayırt edici ağı, " x " X alanından gelen gerçek veri örneğini, " y " Y alanından gelen gerçek veri örneğini, " E " beklenen değer operatörü, ortalama alma işlemini ifade eder.

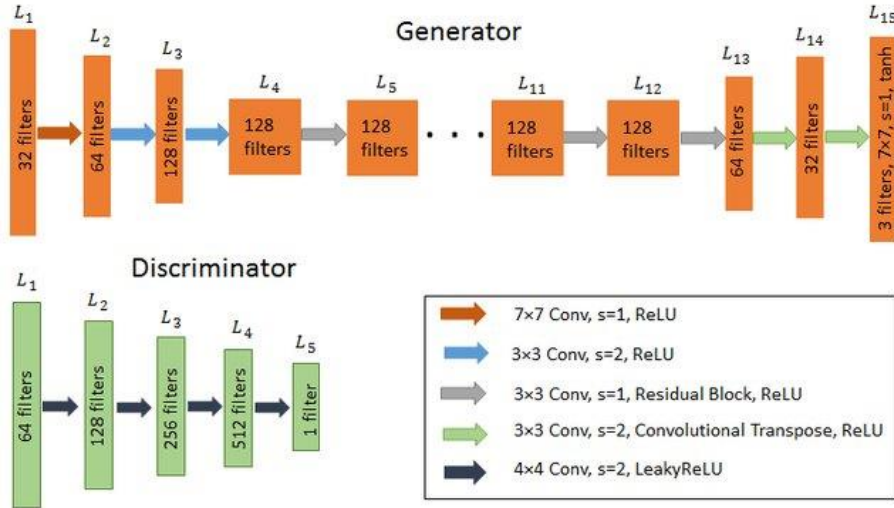
Cycle-GAN, döngü tutarlılığı kaybını (Cycle Consistency Loss) kullanarak modelin çıktısının girişle tutarlı olmasını sağlar. Döngü tutarlılığı kaybı (10)'da gösterilmiştir.

$$L_{CYC}(G, F) = \mathbb{E}_{x \sim P_{data(x)}} [|F(G(x) - x)|] + \mathbb{E}_{y \sim P_{data(y)}} [|G(F(y) - y)|] \quad (10)$$

Cycle-GAN, düşman kaybı ve döngü tutarlılığı kaybının toplamını minimize eder. Toplam kayıp (11)'de gösterilmiştir.

$$L(G, F, D_X, D_Y) = L_{GAN}(G, D_Y, X, Y) + L_{GAN}(F, D_X, Y, X) + \lambda L_{CYC}(G, F) \quad (11)$$

Burada " λ " döngü tutarlılığı kaybının ağırlık katsayısını ifade eder. Bu değer genellikle 10 olarak seçilir. Şekil 3.15'de eşlenmemiş Cycle-GAN'ın üreticinin ve ayırt edicinin mimarisi gösterilmiştir.



Şekil 3.15 Eşlenmemiş Cycle-GAN'ın üretici ve ayırt edici mimarisi [39]

Üreticiye gelen giriş görüntüsü, artan kanal sayısı ile gösterimi daraltan bir dizi üç evrişimli katman ile beslenir. Filtre sayıları sırasıyla 32, 64 ve 128 olarak ayarlanmıştır. Daha sonra bunu, her biri 128 filtrelilik 9 bloklu oluşan bir seri takip

eder. Nihai görüntüyü oluşturmak için gösterimi büyütme amacıyla akış, transpoze evrişimli katmanlar kullanılarak daha da genişletilir. Seçilen filtre sayıları sırasıyla 64, 32 ve 3'tür. Yeniden yapılandırma için son katmandaki TanH hariç her katmanı bir örnek normalleştirme ve aktivasyon fonksiyonu olarak ReLU takip eder. Tam görüntü ayırıcısıyla karşılaştırıldığında daha az parametreye sahiptir, daha az hesaplama maliyeti vardır ve isteğe bağlı görüntü boyutunu işleyebilir. Kararlı ve daha iyi eğitim sonuçları için, geleneksel negatif log olabilirlik fonksiyonu yerine en küçük kare kayıp fonksiyonu kullanılır. Ayırıcı, filtre sayısı sırasıyla 64, 128, 256, 512 ve 1'e ayarlanmış beş katmandan oluşur. İlk dört evrişimli katman, bir nöron aktif olmadığında küçük bir pozitif gradyan sağlamak için 4×4 filtre boyutuna ve Leaky ReLU aktivasyon fonksiyonuna sahiptir. Son katman sigmoid fonksiyonuyla biter [39].

Cycle-GAN, iki farklı domain arasında dönüşümler gerçekleştirmek için iki adet üretici ve iki adet ayırt edici ağı içerir. Üretici ağlar, giriş görüntülerini hedef domainine dönüştürmek için kullanılırken, ayırt edici ağlar, gerçek ve dönüştürülmüş görüntüler arasındaki farkı öğrenmek için kullanılır. GAN yapısında olduğu gibi, Cycle-GAN da bir düşman kaybı kullanır. Üretici ağlar, ayırt edici ağların tahminlerini optimize ederken, ayırt edici ağlar gerçek ve dönüştürülmüş görüntüler arasındaki farkı en aza indirmek için eğitilir. Cycle-GAN'ın temel yeniliği, döngüsel kısıtların eklenmesidir. Bu kısıtlar, A domaininden B domainine yapılan dönüşümün tersini alıp başlangıçtaki A görüntüsünü elde etme ve benzer şekilde B domaininden A domainine yapılan dönüşümün tersini alıp başlangıçtaki B görüntüsünü elde etme yeteneğiyle ilgilidir. Bu, döngüsel tutarlılığın sağlanmasını ve daha gerçekçi dönüşümler elde edilmesini sağlar. Cycle-GAN ayrıca, iki domain arasında benzer görüntülerin eşleştirilmesini sağlamak için çapraz tutarsızlık kaybı kullanır. Bu kayıp, bir domaindeki bir görüntünün dönüştürüldüğü diğer domaindeki görüntüyle benzer olmasını sağlar. Kullanılan GAN modeller karşılaştırmalı olarak Tablo 3.1'de verilmiştir.

3.2.3 Hiperparametre seçimi

GAN modellerinde hiperparametrelerin doğru bir şekilde belirlenmesi, modelin performansını ve kararlılığını önemli ölçüde etkiler. Aşağıda, GAN'larda yaygın olarak ayarlanan bazı temel hiperparametreler ve bu hiperparametrelerin nasıl seçilmesi gerektiği üzerine detaylı bir inceleme sunulmaktadır.

Tablo 3.1 GAN varyantların karşılaştırılması

Kriterler	WGAN	DCGAN	LSGAN	Cycle-GAN
Mimari	Çok katmanlı algılayıcı	Kısıtlı CNN	VGG modeli	Kısıtlı CNN
Optimizasyon ve Öğrenme	RMS-Prop Denetimsiz	Adam Denetimsiz	Adam Denetimsiz	Adam Denetimsiz
Avantajları	Lipschitz sürekli fonksiyonlar kullanarak daha stabil eğitim, daha iyi performans sağlar	Batch normalizasyon algoritmasını kullanarak gradient sorunlarını çözer, stabil çalışır	Sahte görüntü kalitesini artırır, eğitim sürecini iyileştirir, yakınsamayı hızlandırır	Çift yönlü dönüşümü zorunlu kılan döngü tutarlılığı kaybı ile modelin çıktı-girdi tutarlılığını sağlar
Dezavantajları	Eğitim sırasında zorlayıcı gradient gereksinimleri vardır	Görüntü boyutu arttığında veya parametre ayarlamalarında gradientlerde kayıplar oluşur	Aykırı değerler için aşırı cezalar uygular, örnek çeşitliliğinde azalmaya neden olur	Eğitim süresi uzundur ve daha fazla hesaplama gücü gerektirir
Sınırlamalar	Gradient patlaması veya kaybolmasıdır	Mod çökmesi ve parametre ayarlama zorluklarıdır	Görüntü örneklerinde sınıf ve anlamsal çeşitliliktir	Büyük veri setlerinde geçen eğitim süresi ve karmaşık model yapısından kaynaklı gereksinimlerdir

Öğrenme hızı, modelin her bir eğitim adımında ağırlıklarını ne kadar değiştirdiğini belirleyen kritik bir hiperparametredir. GAN modellerinde genellikle düşük bir öğrenme hızı tercih edilir, çünkü bu, modelin eğitim süreci boyunca daha kararlı olmasını sağlar. Öğrenme hızı GAN modeline göre değişmekle birlikte, genellikle 0.0002 olarak seçilmektedir. Parti boyutu (batch size), her bir eğitim adımında kullanılan veri örneği sayısını ifade eder. GAN modellerinde kullanılan varyanta göre değişik ebatlarda parti boyutları kullanılır. Parti boyutunun modelin belleği ve işlem gücü kapasitesine uygun olması önemlidir. WGAN, DCGAN ve LSGAN’larda daha büyük olan 64 veya 128 gibi parti boyutları tercih edilirken, Cycle-GAN’larda, 1 veya

4 gibi daha küçük parti boyutları tercih edilmektedir. Epoch sayısı, tüm veri setinin model üzerinden geçirilme sayısını ifade eder. Epoch sayısı, veri setinin büyüklüğüne ve modelin karmaşıklığına bağlı olarak belirlenmelidir. Özellik haritaları (Feature Maps), her bir konvolüsyon katmanında kullanılan filtre sayısını ifade eder. Giriş ve çıkış boyutlarına göre ayarlanmalıdır. Örneğin, ilk katmanlarda 64 filtre kullanılırken, daha derin katmanlarda 128 veya 256 filtre kullanılabilir. Ağırlıkların güncellenme yöntemi olarak Adam optimizasyon yöntemi yaygın olarak kullanılır. Adam optimizasyonu kullanıldığında $\beta_1=0.5$ ve $\beta_2=0.999$ gibi değerler seçilebilir. Bu değerler, modelin öğrenme sürecinde daha kararlı olmasını sağlar. Kayma Katsayısı (Momentum), ağırlık güncellemelerinde ivme etkisini ve öğrenme sürecini hızlandırır. Momentum değeri genellikle 0.5 ile 0.9 arasında seçilmektedir. Ayırt edici ve Üretici Güncelleme Oranı (Discriminator and Generator Update Ratio), ayırt edici ve üretici modellerin her epoch'ta kaç kez güncelleneceğini belirler. Genellikle 1:1 oranı kullanılır, ancak belirli durumlarda bu oran değiştirilebilir. Bu, modellerin birbirine karşı rekabet ederken dengeli olmasını sağlar. Aktivasyon fonksiyonları, her katmanın çıktısının doğrusal olmayan bir şekilde dönüştürülmesini sağlar. Üretici modelinde genellikle ReLU veya Leaky ReLU, ayırt edici modelinde ise Sigmoid veya TanH aktivasyon fonksiyonları tercih edilmektedir.

Cycle-GAN'ın diğer GAN varyantlarından farklı olarak, iki yönlü çeviriyi zorunlu kılan döngü tutarlılığı kaybı (Cycle-Consistency Loss) bulunmaktadır. Bu kayıp, modelin çıktısının giriş verisi ile tutarlı olmasını sağlar. Döngü tutarlılığı kaybı, λ (lambda) hiperparametresi ile denetlenir ve genellikle 10 olarak seçilir. Hiperparametre optimizasyonu, modelin performansını maksimize etmek için önemlidir. Grid Search, Random Search ve Bayesyan Optimizasyon gibi yöntemler, hiperparametrelerin optimal değerlerini bulmak için kullanılabilir [40]. GAN modellerinde hiperparametre seçimi, modelin eğitim süreci boyunca performansının sürekli izlenmesi ve gerektiğinde ayarlamalar yapılması ile optimize edilmelidir. Ayrıca, farklı veri setleri ve uygulama alanlarına göre hiperparametrelerin etkisi değişebilir, bu nedenle deneme-yanılma yöntemi ile en iyi sonuçları elde etmek önemlidir.

3.2.4 Performans deęerlendirmesi

Performans deęerlendirmesi, GAN'ların tıbbi grnt iřleme ve tanı srelerindeki etkinlięini ve doęruluęunu belirlemek iin kritik bir adımdır. Bu blmde, tez alıřmasında referans alınan GAN varyantların performansı deęerlendirirken kullanılan nicel metrikler aıklanmıřtır.

3.2.4.1 Karmařıklık matrisi (Confusion matrix)

Karmařıklık matrisi (Confusion matrix), bir sınıflandırma modelinin performansını deęerlendirmek iin kullanılan bir tablodur. Bu matris, modelin gerek ve tahmin edilen sınıf etiketlerini karřılařtırarak oluřturulur [41]. oęunlukla, sınıflandırma problemlerinde ok sınıflı (birden fazla sınıf ieren) veri setlerinde kullanılır. Karmařıklık matrisi, drt farklı terimden oluřur. Doęru Pozitif (True Positive veya TP), modelin doęru bir Őekilde bir pozitif sonu tahmin ettięi durumları, Doęru Negatif (True Negative veya TN) modelin doęru bir Őekilde bir negatif sonu tahmin ettięi durumları, Yanlıř Pozitif (False Positive veya FP) modelin yanlıř bir Őekilde pozitif bir sonu tahmin ettięi durumları, Yanlıř Negatif (False Negative veya FN) modelin yanlıř bir Őekilde negatif bir sonu tahmin ettięi durumları ifade eder. Bu terimler karmařıklık matrisine yerleřtirilir ve modelin performansını anlamak iin kullanılır. Tablo 3.2'de, bir karmařıklık matrisinin genel yapısı verilmiřtir.

Tablo 3.2 Karmařıklık Matrisi (Confusion Matrix)

	Pozitif (Gerek)	Negatif (Gerek)
Pozitif (Tahmin)	Doęru Pozitif (TP)	Yanlıř Pozitif (FP)
Negatif (Tahmin)	Yanlıř Negatif (FN)	Doęru Negatif (TN)

Karmařıklık matrisi terimlerini kullanarak bir sınıflandırma modelinin performansını lmek iin bir dizi metrik hesaplanır. Bunlardan bazıları řunlardır;

“Doęruluk” (Accuracy), modelin doęru tahminlerin toplam tahminlere oranını ifade eder ve modelin ne kadar iyi alıřtıęını genel bir bakıř aısıyla gsterir. GAN'larda,

özellikle ayırt edici ağın doğruluğunu ölçmek için kullanılır. Matematiksel olarak, doğruluk şu şekilde tanımlanır:

$$\text{Doğruluk (Accuracy)} = \frac{\text{Doğru Tahminler (TP + TN)}}{\text{Toplam Tahminler (TP + TN + FP + FN)}} \quad (12)$$

Doğruluk, genel bir performans ölçütü olarak oldukça yaygın kullanılır çünkü modelin genel başarısı hakkında hızlı bir bilgi sağlar. Ancak, doğruluk özellikle dengesiz veri kümelerinde yanıltıcı olabilir. Örneğin, bir veri kümesinde pozitif örnekler çok azsa ve model tüm tahminlerini negatif yaparsa, doğruluk yüksek olabilir ancak bu modelin gerçek performansını yansıtmaz.

“Hassasiyet” (Precision), modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Hassasiyet, doğru pozitif tahminlerin (TP) toplam pozitif tahminlere (doğru pozitif ve yanlış pozitif) oranı olarak hesaplanır. Matematiksel formülü şu şekildedir:

$$\text{Hassasiyet (Precision)} = \frac{\text{Doğru Pozitif (TP)}}{\text{Doğru Pozitif (TP) + Yanlış Pozitif (FP)}} \quad (13)$$

Hassasiyet, tıbbi görüntüleme ve tanı süreçlerinde doğru teşhislerin oranını belirlemek için hayati bir metriktir. Yüksek hassasiyet, modelin pozitif tahminlerinde isabetli olduğunu ve yanlış pozitif oranının düşük olduğunu gösterir. Bu, özellikle tıbbi uygulamalarda doğru ve güvenilir teşhisler yapmak için kritik bir öneme sahiptir.

“Duyarlılık” (Recall), bir modelin doğru pozitif tahminlerin (TP) toplam gerçek pozitif örneklerine (doğru pozitif ve yanlış negatif) oranı olarak hesaplanır. Tıbbi görüntüleme ve tanı süreçlerinde, duyarlılık, modelin hastalıklı vakaları ne kadar başarılı bir şekilde tespit ettiğini gösterir. Matematiksel formülü şu şekildedir:

$$\text{Duyarlılık (Recall)} = \frac{\text{Doğru Pozitif (TP)}}{\text{Doğru Pozitif (TP) + Yanlış Negatif (FN)}} \quad (14)$$

“F1 Skoru”, dengesiz veri kümelerinde, yani pozitif ve negatif sınıfların dağılımının eşit olmadığı durumlarda daha anlamlı bir performans ölçütü sunar. F1 skoru, hassasiyet ve duyarlılığın harmonik ortalaması olarak hesaplanır ve şu şekilde ifade edilir:

$$F1 \text{ Skoru} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (15)$$

F1 skorunun 0 ile 1 arasında bir değer alır. 1 değeri, modelin hem hassasiyet hem de duyarlılık açısından mükemmel olduğunu gösterir. 0 değeri ise modelin başarısız olduğunu gösterir.

3.2.4.2 Frechet Inception Distance (FID)

FID, gerçek görüntülerin ve GAN tarafından üretilen görüntülerin özellik vektörlerinin dağılımlarını karşılaştırır. Bu karşılaştırma, bir görüntü sınıflandırma modeli (genellikle Inception v3 modeli) kullanılarak gerçekleştirilir. Gerçek ve üretilen görüntüler, önceden eğitilmiş bir modeli kullanılarak geçirildiğinde elde edilen ara katman özellik vektörleri çıkarılır. Daha sonra bu görüntülerin özellik vektörlerinin ortalama ve kovaryans matrisleri çıkarılır. Çıkarılan matrisler arasındaki Frechet mesafesi hesaplanır [42]. Matematiksel olarak şu şekilde ifade edilir:

$$FID = \|\mu_{gerçek} - \mu_{üretilen}\|^2 + Tr\left(\Sigma_{gerçek} + \Sigma_{üretilen} - 2(\Sigma_{gerçek}\Sigma_{üretilen})^{1/2}\right) \quad (16)$$

Burada “ $\mu_{gerçek}$ ” gerçek görüntülerin ortalama özellik vektörünü, “ $\mu_{üretilen}$ ” üretilen görüntülerin ortalama özellik vektörünü, “ $\Sigma_{gerçek}$ ” gerçek görüntülerin kovaryans matrisini, “ $\Sigma_{üretilen}$ ” üretilen görüntülerin kovaryans matrisini, “ Tr ” bir matrisin izini (diagonal elemanlarının toplamını) ifade eder.

FID, geleneksel değerlendirme metriklerinden farklı olarak, FID, görüntülerin piksel düzeyindeki benzerliklerini değil, yüksek düzeydeki özellik dağılımlarını karşılaştırır. Bu, insan algısına daha yakın bir kalite değerlendirmesi sağlar. Düşük FID değerleri,

üretileen görüntülerin gerçek görüntülerle daha benzer olduğunu ve daha yüksek bir görsel kaliteye sahip olduğunu gösterir. FID'in diğere metriklerle birlikte kullanılması, modelin performansını daha kapsamlı ve doğru bir şekilde değerlendirilmesini sağlar.

3.2.4.3 Inception Score (IS)

IS, GAN'lar tarafından üretilen görüntülerin kalitesini ve çeşitliliğini değerlendirmek için kullanılan bir metriktir [43]. IS, özellikle üretilen görüntülerin gerçekçi olup olmadığını ve çeşitli sınıfları ne kadar iyi temsil ettiğini ölçer. Daha yüksek IS değerleri, daha yüksek kaliteli ve daha çeşitli görüntüleri gösterir.

IS, üretilen görüntülerin Inception v3 modelinde sınıflandırılmasının ardından hesaplanır. IS, iki ana bileşeni dikkate alır: sınıflandırma doğruluğu ve çeşitlilik. Üretilen görüntüler, önceden eğitilmiş bir Inception v3 modeline verilerek her görüntünün sınıf olasılıkları elde edilir. Daha sonra her görüntü için sınıf olasılıklarının entropisi (belirsizlik ölçüsü) hesaplanır ve tüm görüntüler için ortalama alınır. Ayrıca, tüm görüntülerin marjinal sınıf dağılımı hesaplanarak bu dağılımın entropisi hesaplanır.

Inception Score'ın Hesaplanması: IS, marjinal entropi ile ortalama koşullu entropinin oranı olarak hesaplanır. Matematiksel formülü şu şekildedir:

$$IS = \exp\left(\mathbb{E}_{x \sim p_g}\left[D_{KL}(p(y|x} \parallel p(y))\right]\right) \quad (17)$$

Burada “ $p(y|x)$ ” görüntü x için sınıf olasılıkları dağılımını, “ $p(y)$ ” tüm görüntüler için ortalama sınıf olasılıkları dağılımını, “ D_{KL} ” Kullback-Leibler divergansını (bilgi kaybı ölçüsü), “ $\mathbb{E}_{x \sim p_g}$ ” üretilen görüntüler üzerinden alınan ortalamayı ifade eder.

IS, genellikle diğere değerlendirme metrikleriyle birlikte kullanılır. Frechet Inception Distance (FID) ve Doğruluk (Accuracy) gibi metrikler, görüntülerin piksel düzeyindeki benzerliklerini ve genel performanslarını değerlendirirken, IS, görüntülerin sınıf dağılımlarını ve çeşitliliklerini değerlendirir. Bu kombinasyon, modelin performansını daha kapsamlı ve doğru bir şekilde değerlendirmeyi sağlar.

3.2.4.4 Structural Similarity Index Measure (SSIM)

SSIM, iki görüntü arasındaki algısal farkları değerlendirir ve özellikle tıbbi görüntü kalitesini ölçmek için kullanılır. SSIM, görüntülerin parlaklık, kontrast ve yapısal bilgilerini dikkate alır ve 0 ile 1 arasında bir değer alır. 1 değeri, iki görüntünün tamamen aynı olduğunu gösterir [44]. SSIM, üç ana bileşene dayanarak hesaplanır:

“Parlaklık” (Luminance), iki görüntünün ortalama parlaklık değerlerini karşılaştırır.

$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (18)$$

Burada, μ_x ve μ_y iki görüntünün ortalama parlaklık değerlerini ve C_1 sabit bir değeri ifade eder.

“Kontrast” (Contrast), iki görüntünün kontrast seviyelerini karşılaştırır.

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (19)$$

Burada, σ_x ve σ_y iki görüntünün standart sapma değerlerini ve C_2 sabit bir değeri ifade eder.

“Yapı” (Structure), iki görüntünün yerel yapılarını ve kenar detaylarını karşılaştırır.

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (20)$$

Burada, σ_{xy} iki görüntü arasındaki kovaryans değerini ve C_3 sabit bir değeri ifade eder.

SSIM'in toplam formülü:

$$SSIM(x, y) = [l(x, y)]^\alpha + [c(x, y)]^\beta + [s(x, y)]^\gamma \quad (21)$$

Burada α , β ve γ parametreleri bileşenlerin ağırlıklarını belirler.

Yüksek SSIM değerleri, üretilen görüntülerin orijinal görüntülerle yüksek düzeyde benzer olduğunu ve klinik kullanım için uygun olduğunu gösterir.

4. BULGULAR VE TARTIŞMA

Tezin bu bölümünde GAN modellerinden Cycle-GAN ve (DCGAN-LSGAN-WGAN) modelleri ile elde edilen bulgular açıklanmıştır.

4.1 Kurulum

CT to MR CGAN Dataset (2020) ve Dataset Alzheimer Dataset (2024) Kaggle platformunda paylaşılan toplam veri, eğitim ve test olmak üzere sırasıyla %70 ve %30 olmak üzere bölünmüştür. Modellerin eğitilmesi, test edilmesi, kayıp ve nicel metriklerin hesaplanması ve grafiklerin çizilmesi gibi bütün işlemler Google Colab ortamında gerçekleştirilmiştir [45]. Google Colab, araştırma, eğitim vb. gibi birçok kullanım senaryosu için kullanışlı bir araç olarak araştırmacıların dikkatini üzerine çekmektedir. Deneylerimizde kullandığımız Google Colab sunucu platformu yaklaşık 2-6 saat arası kesintisiz ve ücretsiz olarak 16GB, Intel(R) Xeon(R) CPU @ 2.20GHz işlemci ve 16GB Tesla T4 GPU özelliklerine sahip sanal bir ortam sunmaktadır. Kullanılan derin öğrenme algoritmalarındaki GAN modelleri Python programlama dilinden yararlanılarak, TensorFlow (tensorflow.org) ve PyTorch (pytorchlight.ai) derin öğrenme kütüphaneleri ile düzenlenip geliştirilmiştir.

4.2 Deneysel Sonuçlar


4.2.1 Birinci Uygulama

Bu uygulamada “Cycle-GAN Modeli Kullanılarak Beyin MR-BT Görüntü Sentezi” başlıklı bir çalışma gerçekleştirilmiştir. Bu çalışmada, gerçek MR görüntülerinden sahte BT taramaları oluşturmak için Cycle-GAN modeli referans alınmış ve modelde kullanılmak üzere Kaggle platformunda mevcut bulunan beyin MR + CT veri setinden yararlanılmıştır. Derin öğrenme kütüphanesi olarak TensorFlow kullanılmıştır. Bu veri setleri genellikle anonimleştirilmiş hastaların beyin görüntülerini içerir ve araştırmacılara veya veri bilimcilerine bu görüntüler üzerinde analiz yapma fırsatı sunar. Tablo 4.1’de bu çalışmada model eğitiminde kullanılan hiperparametreler verilmiştir.


Tablo 4.1 Model eğitiminde kullanılan parametreler

Açıklama	Parametreler
Epoch	50 - 500
Öğrenme oranı	0,0002
Optimizasyon algoritması	Adam ($\beta_1=0.5$)
Çözünürlük	256 x 256
Kayıp fonksiyonları	Binary Cross Entropy, Ortalama Mutlak Hata (MAE)
Döngü tutarlılığı kaybı	$\lambda = 10$
Ayırt edici (Discriminator)	PatchGAN Ayırt Edicisi
Üretici (Generator)	U-Net Üreticisi
Aktivasyon fonksiyonları	ReLU, Leaky ReLU, Tanh, Sigmoid
Veri seti	Kaggle veri tabanından alınmış CT-MR görüntü veri seti [15]
Batch boyutu	1
Veri artırma	Çevirme (Yatay ve Dikey), Ölçekleme, Döndürme
Metrik	FID, SSIM

Örnek beyin MR görüntü ve CT taramaları Şekil 4.1 ve Şekil 4.2’de gösterilmiştir.




Şekil 4.1 Eğitimde kullanılan Kaggle örnek beyin MR görüntüleri



Şekil 4.2 Eğitimde kullanılan Kaggle örnek beyin CT taramaları


Colab sunucu platformunda gerçekleştirilen model eğitim süresi yaklaşık 14 saat sürmüştür. Her bir modelde üretilen sahte görüntüler nitel (görsel) ve nicel (metrik) olarak karşılaştırılmıştır. Cycle-GAN modeli kullanılarak eğitilen modelde 50-150-300 ve 500 epochlarda gerçek MR görüntüsünden sentezlenen CT görüntüsü ve bu görüntüden tekrar oluşturulan MR görüntüsü Şekil 4.3’de gösterilmiştir.




Şekil 4.3 MR-CT-MR dönüşümü

Aynı modelde 50-150-300 ve 500 epochlarda CT taramalarından sentezlenen MR görüntüsü ve bu görüntüden tekrar oluşturulan CT görüntüsü Şekil 4.4’te

gösterilmiştir. Ayrıca gerçek MR görüntülerinden Cycle-GAN modeli ile yapılandırılmış MR görüntüleri Şekil 4.5a'da ve gerçek CT taramalarında Cycle-GAN modeli ile yapılandırılmış CT taramaları Şekil 4.5b'de gösterilmiştir.



Şekil 4.4 CT-MR-CT dönüşümü



(a)

(b)

Şekil 4.5 (a) MR-MR dönüşümü (b) CT-CT dönüşümü

Ayrıca modelin eğitim aşamasında gerçekleşen üretici, ayırt edici ve döngüsel kayıp değerleri Tablo 4.2’de verilmiştir. Uygulamasını gerçekleştirdiğimiz Cycle-GAN modelin FID ve SSIM metrik değerleri Tablo 4.3’te verilmiştir.

Tablo 4.2 modelin eğitim aşamasında gerçekleşen üretici, ayırt edici ve döngüsel kayıp değerleri

Epoch	G _{xy}	F _{yx}	D _x	D _y	Cycle-Loss
50	1,5831	1,7752	0,6934	0,6334	0,8193
150	1,4841	1,4577	0,6531	0,6503	0,7938
300	1,6205	2,1262	0,4626	0,5840	0,7520
500	1,7735	2,3573	0,7456	0,6366	0,6053

Tablo 4.3 SSIM ve FID metrikleri

Epoch	SSIM	FID
50	0,733	516
150	0,737	352
300	0,751	275
500	0,77	235

4.2.2 İkinci Uygulama


Bu uygulamada “Beyin MR Görüntülerden Sahte Veri Üretimi için Üretken Rakip Ağ Modellerinin Performans Karşılaştırması” başlıklı bir çalışma gerçekleştirilmiştir. Bu çalışmada, beyin MR görüntülerinden sahte örnek oluşturmak amacıyla yaygın olarak kullanılan GAN tabanlı (DCGAN, LSGAN ve WGAN) mimariler kullanılmıştır. Bu mimariler Kaggle beyin MR veri seti uygulanacak şekilde düzenlenerek eğitimler gerçekleştirilmiştir. Derin öğrenme kütüphanesi olarak PyTorch kullanılmıştır. Tablo 4.4’te bu çalışmada model eğitiminde kullanılan hiperparametreler verilmiştir.

Tablo 4.4 Model eğitiminde kullanılan parametreler

Açıklama	Parametreler		
	WGAN	DCGAN	LSGAN
Epoch	50-500	50-500	50-500
Öğrenme oranı	0,0005	0,0002	0,0002
Optimizasyon algoritması	RMSprop	Adam ($\beta_1=0.5$, $\beta_2=0.999$)	Adam ($\beta_1=0.5$, $\beta_2=0.999$)
Çözünürlük	64 x 64	64 x 64	64 x 64
Kayıp fonksiyonları	Wasserstein loss (W-loss)	Mean Squared Error (MSE)	Binary Cross Entropy (BCE)


Tablo 4.4 (Devam)

Aktivasyon fonksiyonları	ReLU, Leaky ReLU, Tanh	ReLU, Leaky ReLU, Tanh	ReLU, Leaky ReLU, Tanh
Veri seti	Kaggle veri tabanından alınmış MR görüntü veri seti [16]	Kaggle veri tabanından alınmış MR görüntü veri seti [16]	Kaggle veri tabanından alınmış MR görüntü veri seti [16]
Batch boyutu	64	64	64
Veri artırma	Çevirme (Yatay ve Dikey), Ölçekleme, Döndürme	Çevirme (Yatay ve Dikey), Ölçekleme, Döndürme	Çevirme (Yatay ve Dikey), Ölçekleme, Döndürme
Metrik	FID, IS	FID, IS	FID, IS




Şekil 4.6 GAN modelleri için eğitimde kullanılan Kaggle örnek beyin MR görüntüleri

Deneysel çalışma olarak başlangıçta DCGAN modeli kullanılmıştır. Beyin MR veri seti ile eğitilen DCGAN modelinden üretilen sahte beyin MR görüntüleri Şekil 4.7’de gösterilmiştir.




Şekil 4.7 DCGAN modelinin belli epoch'larda sahte MR görüntüleri

Ayrıca DCGAN modelinin eğitim aşamasında gerçekleşen üretici ve ayırt edici kayıp grafiği Şekil 4.8'de gösterilmiştir.



Şekil 4.8 DCGAN modelinin 500 epoch sonrası üretici ve ayırt edici kayıp grafiği

Deneysel çalışmada ikinci GAN modeli olarak LSGAN modeli kullanılmıştır. Beyin MR veri seti ile eğitilen LSGAN modelinden üretilen sahte beyin MR görüntüleri Şekil 4.9'da gösterilmiştir.




Şekil 4.9 LSGAN modelinin belli epoch'larda sahte MR görüntüleri

Ayrıca LSGAN modelinin eğitim aşamasında gerçekleşen üretici ve ayırt edici kayıp grafiği Şekil 4.10'da gösterilmiştir.



Şekil 4.10 LSGAN modelinin 500 epoch sonrası üretici ve ayırt edici kayıp grafiği

Deneysel çalışmada üçüncü GAN modeli olarak WGAN modeli kullanılmıştır. Beyin MR veri seti ile eğitilen WGAN modelinden üretilen sahte beyin MR görüntüleri Şekil 4.11'de gösterilmiştir.



Şekil 4.11 WGAN modelinin belli epoch'larda sahte MR görüntüleri

Ayrıca WGAN modelinin eğitim aşamasında gerçekleşen üretici ve ayırt edici kayıp grafiği Şekil 4.12'de gösterilmiştir.



Şekil 4.12 WGAN modelinin 500 epoch sonrası üretici ve ayırt edici kayıp grafiği

Tablo 4.5’te, DCGAN, LSGAN ve WGAN modellerinin 50-150-300-500 devirdeki (epoch) FID sonuçları verilmiştir.

Tablo 4.5 GAN modellerinin niceliksel FID performans karşılaştırması

Epoch	DCGAN	LSGAN	WGAN
50	0.0418	0.0583	0.0790
150	0.0419	0.0421	0.0794
300	0.0419	0.0415	0.0801
500	0.0421	0.0385	0.0808

Tablo 4.6’da, DCGAN, LSGAN ve WGAN modellerinin 50-150-300-500 devirdeki (epoch) IS sonuçları verilmiştir.

Tablo 4.6 GAN modellerinin niceliksel IS performans karşılaştırması

Epoch	DCGAN	LSGAN	WGAN
50	1.043	1.009	1.037
150	1.043	1.027	1.035
300	1.043	1.037	1.035
500	1.041	1.050	1.036

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Yapılan bu çalışmada, gerçek beyin görüntülerinden sahte beyin görüntüleri elde etmek için farklı GAN modellerinin performansları karşılaştırılmıştır. İlk uygulamada Cycle-GAN modelinden yararlanılarak, Kaggle beyin MR-CT görüntüleri kullanılmış, gerçek MR görüntülerinden sahte CT tarama görüntüleri veya gerçek CT tarama görüntülerinden sahte MR görüntüleri üretmek amaçlanmıştır. Üretilen görüntüler farklı eğitim dönemlerinde (50, 150, 300, 500), görsel ve yapısal benzerlik açısından FID ve SSIM metrikler ile incelenmiştir. Birinci uygulamanın kayıp değerleri incelendiğinde Cycle-GAN modelin eğitim sürecinde kayıpların azaldığı ve stabil hale geldiği görülmektedir. Ancak, bazı kayıp değerlerinde dalgalanmaların olması, modelin belirli aşamalarda zorlandığı anlaşılmaktadır. Bu dalgalanmalar, eğitim sürecinde verilerin veya donanımın yetersiz olduğu yerlerde gerçekleşmiş olabileceği düşünülmektedir.

Ayırt edici kayıpları (D_x ve D_y) ile döngü kaybı (Cycle-loss), modelin belirli epochlar boyunca daha iyi performans göstermeye başladığını ancak üretici kayıplarındaki artışların modelin aşırı öğrenme olasılığını işaret ettiğini gösterir. Epoch 50'den 150'ye kadar olan dönemde, üretici ve döngü kaybı önemli ölçüde düşmüştür, bu da modelin daha iyi öğrenmeye başladığını gösterir. Epoch 300 ve 500'de, özellikle üretici kayıplarının artması modelin aşırı öğrenme (overfitting) yaptığını veya eğitim sürecinde dengesizlik olduğunu gösterir. Döngü kaybının düzenli olarak düşmesi, dönüşümlerin tutarlılığının arttığını gösterir, ancak üretici kayıplarının artması, modelin genel performansını olumsuz etkilemektedir. Modelin aşırı öğrenmesini önlemek için eğitim verisinin artırılması ve çeşitlendirilmesi gerekmektedir. Bu nedenle daha farklı ve daha detaylı veri artırımı (data augmentation) yöntemleri denenmelidir. Kullanılan donanımın iyileştirilerek öğrenme oranının optimize edilmesi, modelin daha dengeli bir şekilde öğrenmesini sağlayabileceği değerlendirilmektedir. Modelin daha dengeli bir eğitim süreci, daha hızlı donanımlar kullanılarak, daha geniş ve daha detaylı bir veri seti ile tekrar edilmesi sonuçların istenilen değerlere geleceği düşünülmektedir.

Bu çalışma kapsamında yapılan ikinci uygulamada, DCGAN, LSGAN ve WGAN modelleri Kaggle beyin MR veri seti üzerinde test edilmiştir. Yapılan deneyler sonucunda, her bir modelin farklı eğitim dönemlerinde (50, 150, 300, 500) ürettiği sahte görüntüleri analiz etmek için görsel ve yapısal benzerlik açısından FID ve IS metrikler kullanılmıştır. FID skoru, üretilen görüntülerin gerçek verilere ne kadar yakın olduğunu hesaplarken, IS skoru üretilen görüntülerin çeşitliliğini ve kalitesini değerlendirmektedir. Ancak, bu metrikler tıbbi görüntüleme verilerinin özelliklerini tam olarak yansıtmayabilir. Örneğin, FID metriği, medikal görüntülerdeki ince detayları ve klinik önemi olan yapıları yakalamada yetersiz kalabilir. Bu durum, medikal görüntüleme alanında değerlendirme yaparken bazı sınırlamalara yol açmaktadır.

DCGAN modelinin üretici ve ayırt edici ağ kayıp grafiğine baktığımızda, eğitimin başlangıcında her iki kayıpta da hızlı bir değişim gözlenir. Ayırt edici kaybı hızla sıfıra yaklaşırken, üretici kaybı hızla yüksek bir değere ulaşır. Ancak ilerleyen iterasyonlarda, ayırt edici kaybı sıfıra yakın sabitlenir. Bu, ayırt edicinin sahte örnekleri gerçeklerden çok iyi ayırt edebildiğini gösterir. Üretici kaybı ise yüksek ve neredeyse sabit kalır, bu da üreticinin sahte örnekler üretmede zorlandığını ve ayırt ediciyi kandıramadığını işaret eder. Eğitim süreci boyunca, üretici kaybının sürekli yüksek kalması ve ayırt edici kaybının sıfıra yakın sabitlenmesi, modelin dengesiz olduğunu ve ayırt edicinin aşırı baskın hale geldiğini gösterebilir. Bu durum, GAN'ların eğitim sürecinde sık karşılaşılan bir durum olan mod çökmesi veya ayırt edicinin aşırı öğrenmesi gibi problemleri işaret edebilir.

LSGAN modelinin üretici ve ayırt edici ağ kayıp grafiği incelendiğinde kayıpların başta yüksek olduğu, ancak eğitim ilerledikçe azaldığı ve stabilize olduğu gözlemlenmektedir. Bu grafikte görülen kayıpların hızlı bir şekilde düşmesi ve sonrasında stabil hale gelmesi, GAN'ların eğitimi sırasında beklenen bir durumdur. Üretici kaybının genellikle daha dalgalı ve zaman zaman ani artışlar gösterdiği, ayırt edici kayıpları genellikle üretici kayıplarına kıyasla daha düşük ve daha az dalgalı olduğu görülmektedir. Eğitim sürecinin başlangıcında yüksek kayıpların hızlı düşmesi, modelin hızla öğrenmeye başladığını gösterir. Sonraki dönemlerde

kayıpların düşük ve stabil seviyelerde kalması, modelin dengeli bir şekilde eğitildiğini ve her iki ağın da iyi performans gösterdiğini gösterir.

WGAN modelinin üretici ve ayırt edici ağ kayıp grafiği analiz edildiğinde eğitim süresince önemli dalgalanmalar olduğu saptanmış. Başlangıçta her iki kaybın da yüksek, ancak zamanla dalgalanmalarla birlikte azalma eğiliminde olduğu, üretici kayıpları belirli bir noktada daha az dalgalanırken, ayırt edici kayıpları daha geniş bir dalgalanma aralığı sergilediği gözlemlenmiştir. Eğitim süresi boyunca her iki kayıp da belirli bir noktada azalma eğiliminde olsa da dalgalanmalar dikkat çekicidir. Bu dalgalanmalar, modelin belirli dönemlerde daha fazla zorlandığını ancak genel olarak ilerleme kaydettiğini göstermektedir.

Tablo 4.5'te sonuçları verilen FID metriği, modellerin kalite ve çeşitlilik açısından performanslarını değerlendirmek için kullanılmıştır. FID metriğindeki düşüş, modelin ürettiği görüntülerin kalitesinin ve çeşitliliğinin arttığını gösterir. Tabloya bakıldığında LSGAN modeli diğer modellere karşı eğitim süreci boyunca performansını sürekli olarak iyileştirmiştir. 500. epoch'ta en düşük FID skoruna ulaşarak en iyi performansı göstermiştir.

Tablo 4.6'da sonuçları verilen IS metriğide, modellerin kalite ve çeşitlilik açısından performanslarını değerlendirmek için kullanılmıştır. DCGAN modelinin IS performansı eğitim süresi boyunca nispeten sabit kalırken, LSGAN ve WGAN modellerinde daha belirgin bir değişim görülmüştür. Özellikle, LSGAN modeli eğitim süresi arttıkça IS performansında artış gösterirken, WGAN modelinde ise IS performansı eğitim süresi boyunca genellikle stabil kalmıştır. Bu sonuçlar, LSGAN modelinin DCGAN ve WGAN'a kıyasla daha iyi çeşitlilik ve gerçekçilik sağladığı söylenebilir.

Bu sonuçlar incelendiğinde;

LSGAN modelinin hem FID hem de IS değerleri açısından en tutarlı ve yüksek performansı gösterdiği görülmüştür. WGAN modelinin FID değerleri açısından LSGAN'a yakın performans gösterdiği, IS değerlerinde başlangıçta yüksek

performans sergilese de eğitim süresince azalma gözlemlenmiştir. DCGAN modeli ise diğer modellere kıyasla daha düşük performans göstermiştir. Ancak, farklı avantajları ve kullanım alanları olabilir ve belirli senaryolarda tercih edilebilir. Bu sonuçlar, GAN modellerinin performansını değerlendirirken hem FID hem de IS metriklerinin dikkate alınması gerektiğini göstermektedir. Eğitim süresince modellerin performansını izlemek ve gerektiğinde model ve hiperparametre seçimlerini gözden geçirmek önemlidir. Modellerin farklı uygulamalardaki performanslarını değerlendirirken, eğitim süresince elde edilen kayıpların ve niceliksel metriklerin dikkatlice incelenmesi gerekmektedir.

5.2 Öneriler

Tıbbi görüntüleme, verilerinin sınırlı olması, derin öğrenme ve makine öğrenmesi gibi ileri teknolojilerin bu alanda uygulanmasını zorlaştırmaktadır. Özellikle etik ve gizlilik kısıtlamaları, araştırmacıların geniş veri setlerine erişimini sınırlamaktadır. Bu nedenle, sahte veri üretimi, tıbbi görüntüleme alanında önemi giderek artmaktadır. GAN gibi yöntemler, sınırlı veri setlerini artırmak ve model performansını iyileştirmek için etkili araçlar sunmaktadır.

Araştırmacılar ve sağlık profesyonelleri, medikal görüntüleme verilerinin artırılması ve değerlendirilmesinde GAN modellerinin kullanımına yönelik olarak daha fazla çalışma yapmalıdır. Özellikle, medikal verilerin farklı inceliklerini dikkate alan GAN modellerinin geliştirilmesi, tıbbi görüntü analizi ve teşhis süreçlerinde önemli katkılar sağlayabilir. Bu bağlamda, alana özgü bilgiye dayanan metriklerin geliştirilmesi ve uygulanması, GAN'ların değerlendirilmesini ve karşılaştırılmasını kolaylaştırabilir.

Bu çalışmada elde edilen bulgular, medikal görüntüleme alanında GAN'ların kullanım potansiyelini ve sınırlamalarını açıkça ortaya koymaktadır. Medikal görüntülerin sınırlı veri setleri ve etik kısıtlamalar nedeniyle sınırlı erişilebilirliği, GAN'ların bu alanda önemli bir araç olabileceğini göstermektedir. Ancak, mevcut metriklerin ve yöntemlerin bazı eksiklikleri göz önüne alındığında, gelecekte yapılacak çalışmalar için birkaç öneri sunulabilir.

Tıbbi görüntülerin değerlendirilmesi için özel olarak tasarlanmış metriklerin geliştirilmesi gerekmektedir. Mevcut FID, IS ve SSIM metrikleri, genel görüntü kalitesini ve çeşitliliğini ölçmekte yeterli olabilir, ancak tıbbi görüntülerin klinik önemini ve detaylarını yansıtmakta yetersiz kalabilir. Bu nedenle, tıbbi görüntülerin yapısal bütünlüğünü ve klinik anlamını daha iyi yansıtan yeni metrikler geliştirilmelidir. Yeni metrikler, tıbbi görüntülerin klinik ayrıntılarını da dikkate almalıdır. Örneğin, tümörlerin boyutunu, konumunu ve morfolojisini doğru bir şekilde yansıtan metrikler, sahte görüntülerin gerçek dünya klinik uygulamalarında kullanılabilirliğini artıracaktır.

Araştırmalarda kullanılan veri setlerinin çeşitliliği artırılmalıdır. Farklı hastalıkların, organların ve görüntüleme modalitelerinin kapsandığı daha büyük ve çeşitli veri setleri, GAN modellerinin genel performansını ve genelleme yeteneğini artıracaktır. Araştırmacılar ve klinik kurumlar arasında veri paylaşımı teşvik edilmelidir. Etik ve gizlilik kısıtlamaları göz önünde bulundurularak, anonimleştirilmiş ve etik kurallara uygun veri setlerinin paylaşılması, araştırma topluluğunun daha geniş ve kapsamlı çalışmalara olanak tanınmasını sağlayacaktır.

Tıbbi görüntüleme için optimize edilmiş yeni GAN varyantlarının geliştirilmesi gerekmektedir. Bu modeller, mevcut GAN'ların karşılaştığı eğitim zorluklarını ve performans sınırlamalarını aşmayı hedeflemelidir. Özellikle, eğitim sürecinde stabiliteyi artıran ve yüksek kaliteli görüntüler üreten modeller üzerinde çalışılmalıdır. Transfer öğrenme teknikleri kullanılarak, büyük genel veri setlerinde eğitilen modellerin medikal görüntüleme veri setlerine uyarlanması sağlanabilir. Bu yaklaşım, küçük veri setlerinde daha iyi performans elde etmeye yardımcı olabilir.

Geliştirilen GAN modelleri, klinik ortamlarda test edilmeli ve onaylanmalıdır. Bu süreç, sahte verilerin gerçek klinik verilerle ne kadar uyumlu olduğunu ve klinik karar verme süreçlerinde kullanılabilirliğini değerlendirmeye yardımcı olacaktır. Sağlık profesyonelleri ve klinik araştırmacılar, GAN modellerinin potansiyeli ve sınırlamaları konusunda eğitilmelidir. Bu farkındalık, yeni teknolojilerin klinik uygulamalara entegrasyonunu hızlandırabilir ve sağlık hizmetlerinin kalitesini artırabilir.

Bu öneriler, medikal görüntüleme alanında GAN'ların daha etkin ve güvenilir bir şekilde kullanılmasına katkı sağlayabileceği düşünülmektedir. Gelecekte yapılacak çalışmalar, bu öneriler doğrultusunda ilerleyerek medikal görüntülerin kalitesini ve klinik anlamını daha iyi yansıtan sahte veriler üretmeye odaklanmalıdır. Bu bağlamda, araştırmacılar ve sağlık profesyonelleri arasında iş birliği ve bilgi paylaşımı, GAN teknolojilerinin sağlık alanındaki potansiyeli en üst düzeye çıkaracaktır.

KAYNAKLAR

- [1] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville and Y. Bengio, "Generative adversarial networks," *Communications of the ACM*, vol. 63, no. 11, pp. 139-144, 2020.
- [2] A. G. Eker and N. Duru, "Medikal görüntü işlemede derin öğrenme uygulamaları," *Acta Infologica*, vol. 5, no. 2, pp. 459-474, 2021.
- [3] Y. Xiao, J. Wu, and Z. Lin, "Cancer diagnosis using generative adversarial networks based on deep learning from imbalanced data," *Computers in Biology and Medicine*, vol. 135, p. 104540, 2021.
- [4] S. Altun and M. F. Talu, "A new approach for Pap-Smear image generation with generative adversarial networks," *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 37, no. 3, pp. 1401-1410, 2022.
- [5] M. E. Doğan and E. M. A. Öztürk, "Oral radyolojide yapay zeka," *HRU International Journal of Dentistry and Oral Research*, vol. 1, no. 3, pp. 78-83, 2022.
- [6] İ. Ataş, "Comparison of deep convolution and least squares GANs for diabetic retinopathy image synthesis," *Neural Computing and Applications*, vol. 35, no. 19, pp. 14431-14448, 2023.
- [7] Frid-Adar, M., Klang, E., Amitai, M., Goldberger, J., Greenspan, H., "Synthetic data augmentation using GAN for improved liver lesion classification," in *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, 2018, pp. 289-293.
- [8] H. C. Shin, N. A. Tenenholtz, J. K. Rogers, C. G. Schwarz, M. L. Senjem, J. L. Gunter, M. Michalski, "Medical image synthesis for data augmentation and anonymization using generative adversarial networks," in *Simulation and Synthesis in Medical Imaging: Third International Workshop, SASHIMI 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Proceedings 3*, Springer International Publishing, 2018, pp. 1-11.
- [9] C. Han, H. Hayashi, L. Rundo, R. Araki, W. Shimoda, S. Muramatsu, Y. Furukawa, G. Mauri, H. Nakayama "GAN-based synthetic brain MR image generation," in *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, 2018, pp. 734-738.
- [10] S. Kazeminia, C. Baur, A. Kuijper, B. Van Ginnekan, N. Navab, S. Albarqouni, A. Mukhopadhyay "GANs for medical image analysis," *Artificial Intelligence in Medicine*, vol. 109, p. 101938, 2020.
- [11] K. Suganthi, "Review of medical image synthesis using GAN techniques," in *ITM Web of Conferences*, EDP Sciences, 2021, p. 01005.
- [12] M. E. Laino, P. Cancian, L.S. Politi, M.G. Della Porta, L. Saba, V. Savevski "Generative adversarial networks in brain imaging: A narrative review," *Journal of Imaging*, vol. 8, no. 4, p. 83, 2022.
- [13] İ. Ataş, "Comparison of deep convolution and least squares GANs for diabetic retinopathy image synthesis," *Neural Computing and Applications*, vol. 35, no. 19, pp. 14431-14448, 2023.

- [14] A. Thakur and G. K. Thakur, "Developing GANs for Synthetic Medical Imaging Data: Enhancing Training and Research," *Int. J. Adv. Multidiscip. Res.*, vol. 11, no. 1, pp. 70-82, 2024.
- [15] D. A. Patel, "CT to MRI CGAN Dataset," Kaggle, 2020. Available: <https://www.kaggle.com/datasets/darren2020/ct-to-mri-cgan>. (Erişim:2024, Mayıs 24)
- [16] Y. Hessein, "Dataset Alzheimer," Kaggle. <https://www.kaggle.com/datasets/yasserhessein/dataset-alzheimer>. (Erişim:2024, Mayıs 24)
- [17] M. F. Collen, "Origins of medical informatics," *Western Journal of Medicine*, vol. 145, no. 6, p. 778, 1986.
- [18] J. M. Prewitt and M. L. Mendelsohn, "The analysis of cell images," *Annals of the New York Academy of Sciences*, vol. 128, no. 3, pp. 1035-1053, 1966.
- [19] M. Sonka, V. Hlavac, and R. Boyle, *Image Processing, Analysis and Machine Vision*, Springer, 2013.
- [20] G. Litjens, T. Kooi, B.E. Bejnordi, A.A.A. Setio, F. Ciompi, M. Ghafoorian, J. A.W.M van der Laak, B. Van Ginneken, C.I Sanchez "A survey on deep learning in medical image analysis," *Medical Image Analysis*, vol. 42, pp. 60-88, 2017.
- [21] J. T. Bushberg and J. M. Boone, *The Essential Physics of Medical Imaging*, Lippincott Williams & Wilkins, 2011.
- [22] W. C. Röntgen, "On a new kind of rays," *Science*, vol. 3, no. 59, pp. 227-231, 1896.
- [23] W. R. Hendee and E. R. Ritenour, *Medical Imaging Physics*, John Wiley & Sons, 2003.
- [24] X-ışınları. <https://www.ceyrekmuhendis.com/x-isinlari-i/> (Erişim:2024, Mayıs 10)
- [25] P. C. Lauterbur, "Image formation by induced local interactions: example employing nuclear magnetic resonance," *Nature*, vol. 242, no. 5394, pp. 190-191, 1973.
- [26] R. W. Brown, Y.C.N. Cheng, E.m. Haacke, M.R. Thompson, R. Venkatesan, *Magnetic Resonance Imaging: Physical Principles and Sequence Design*, John Wiley & Sons, 2014.
- [27] A. Zucco, "Dysprosium-doped carbon dots for magnetic resonance imaging and theranostic applications," Ph.D. dissertation, Politecnico di Torino, 2022.
- [28] "MRI Görüntüleri Üzerinden Beyin Tümörü Tespiti." <https://medium.com/deep-learning-turkiye/mri-goruntuleri-uzerinden-beyin-tumoru-tespiti-ec644a2ff0c9>. (Erişim:2024, Mayıs 24).
- [29] R. B. Buxton, *Introduction to Functional Magnetic Resonance Imaging: Principles and Techniques*, Cambridge University Press, 2009.
- [30] J. Hsieh, "Computed tomography: principles, design, artifacts, and recent advances," 2003.

- [31] M. Prokop, "Multislice CT: technical principles and future trends," *European Radiology*, vol. 13, pp. 3-13, 2003.
- [32] Radiology Key. <https://radiologykey.com/computed-tomography-10>. (Erişim:2024, Mayıs 10) (web dökümanı)
- [33] R. B. Snow, R.D. Zimmerman, S.E. Gandy, M.D. Deck "Comparison of magnetic resonance imaging and computed tomography in the evaluation of head injury," *Neurosurgery*, vol. 18, no. 1, pp. 45-52, 1986.
- [34] Yüzü, Z. Ü., & ATAŞ, İ. BÖLÜM IV. *BİDGE Yayınları*.
- [35] M. Arjovsky, S. Chintala, and L. Bottou, "Wasserstein GAN," in *Proc In Conf. Mach Learn. (ICML)*, 2017, pp. 214-223.
- [36] A. Radford, L. Metz, and S. Chintala, "Unsupervised representation learning with deep convolutional generative adversarial networks," *arXiv preprint arXiv:1511.06434*, 2015.
- [37] X. Mao, Q. Li, H. Xie, R. Y. Lau, Z. Wang, and S. Paul Smolley, "Least squares generative adversarial networks," in *Proc. IEEE Int. Conf. Comput. Vis. (ICCV)*, 2017, pp. 2794-2802.
- [38] Y. Yuan, S. Liu, J. Zhang, Y. Zhang, C. Dong, and L. Lin, "Unsupervised image super-resolution using cycle-in-cycle generative adversarial networks," in *Proc IEEE Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW)*, 2018, pp. 701-710.
- [39] M. B. Ali, I. Y. H. Gu, M. S. Berger, J. Pallud, D. Southwell, G. Widhalm, A. Roux, T.G. Vecchio and A. S. Jakola, "Domain mapping and deep learning from multiple MRI clinical datasets for prediction of molecular subtypes in low grade gliomas," *Brain Sciences*, vol. 10, no. 7, p. 463, Jul. 2020, doi: 10.3390/brainsci10070463
- [40] H. Olğac, and I. Atas, , "Hyperparameter Tuning In Deep Learning Models: Comparative Analysis Of Grid Search And Random Search Methods," presented at the 6th Int. Hasankeyf Scientific Research And Innovation Congress, Batman, Türkiye, Nov. 18-19, 2023.
- [41] M. Sokolova, N. Japkowicz, ve S. Szpakowicz, "Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation," in A. Sattar ve Bh. Kang (Eds.), *AI 2006: Advances in Artificial Intelligence, ser. Lecture Notes in Computer Science*, vol. 4304. Berlin, Heidelberg: Springer, 2006, pp. 1015-1021. doi: 10.1007/11941439_114.
- [42] 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," in *Advances in Neural Information Processing Systems (NeurIPS)*, 2017, pp. 6626-6637.
- [43] T. Salimans, I. Goodfellow, W. Zaremba, V. Cheung, A. Radford, and X. Chen, "Improved Techniques for Training GANs," in *Advances in Neural Information Processing Systems (NeurIPS)*, 2016, pp. 2234-2242.

[44] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image Quality Assessment: From Error Visibility to Structural Similarity," *IEEE Trans. Image Process.*, vol. 13, no. 4, pp. 600-612, Apr. 2004.

[45] Google Colaboratory. <https://colab.research.google.com/> (Eriřim:2024, Mayıs 10) (web dökümanı)

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad

OLĞAÇ, Hamit

Web sayfası

(Research Gate, Academia, vs.)

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Lisans	Gaziantep Üniversitesi	2011
Lise	Mardin Anadolu Lisesi	2003

İş Denevimi

Dönem (Yıl)	Şirket, Kurum	Görev
2012-2014	Mardin İl Özel İdaresi	Elektrik-Elektronik Müh.
2014-2015	Mardin Su ve Kanal İdaresi	Bilgi İşlem Daire Başkanı
2015-2017	Mardin Yatırım İzleme ve Koordinasyon Başkanlığı	Elektrik-Elektronik Müh.
2017-2019	Mardin 112 Acil Çağrı Merkezi	Elektrik-Elektronik Müh.
2019-2020	Mardin Yatırım İzleme ve Koordinasyon Başkanlığı	Elektrik-Elektronik Müh.
2020-2021	Mardin Yatırım İzleme ve Koordinasyon Başkanlığı	Strateji ve Koordinasyon Müdürü
2021-2023	Mardin Yatırım İzleme ve Koordinasyon Başkanlığı	Elektrik-Elektronik Müh.
2023-	Mardin Artuklu Üniversitesi	Elektrik-Elektronik Müh.

Yabancı Dil

İngilizce

Yayınlar

- Hyperparameter Tuning In Deep Learning Models: Comparative Analysis Of Grid Search And Random Search Methods
- Cycle-GAN Modeli Kullanılarak Beyin MR-BT Görüntü Sentezi
-

Özel İlgiler

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Hamit OLĞAÇ		
Öğrenci No	12805003		
Ana Bilim Dalı	Elektrik-Elektronik Mühendisliği		
Program Türü	Proje <input type="checkbox"/>	Yüksek Lisans <input checked="" type="checkbox"/>	Doktora <input type="checkbox"/>
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Dr. Öğr. Üyesi İsa ATAŞ		
Tez Başlığı	Üretken Çekişmeli Ağların (GAN) Tıp Alanındaki Uygulamaları: Görüntü İşleme ve Tanı Süreçlerinde GAN'ların Rolü		
RAPOR BİLGİLERİ			
Raporlama Aşaması	Tez Savunma Sınavı Sonrası		
Sayfa Sayısı	73		
Raporlama Tarihi	02.07.2024		
Benzerlik Oranı (%)	7		

Yukarıda bilgileri verilen tez çalışmamın toplam 73 sayfalık kısmına ilişkin, 02/07/2024 tarihinde şahsım/tez danışmanım tarafından Turnitin isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı %7 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

- Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç
Kaynaklar hariç
Alıntılar hariç/dâhil
Diğer (Açıklayınız)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Tez benzerlik oranı üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Hamit OLĞAÇ

Tarih: 02.07.2024

İmza:

Danışman Adı, Soyadı: Dr. Öğr. Üyesi İsa ATAŞ

İmza:

Tarih: 02.07.2024

Ana Bilim Dalı Başkanı Adı, Soyadı: Doç. Dr. Cafer BUDAK

İmza:

Tarih: 02.07.2024
