



T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü



ÇEKİŞMELİ ÜRETİCİ AĞLAR İLE GERÇEKÇİ SAÇ SENTEZİ

Yüksek Lisans Tezi

Muhammed PEKTAŞ

Bilgisayar Mühendisliği Anabilim Dalı

İzmir

2022

T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

ÇEKİŞMELİ ÜRETİCİ AĞLAR İLE GERÇEKÇİ SAÇ SENTEZİ

Muhammed PEKTAŞ

Danışman: Prof. Dr. Aybars UĞUR

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Yüksek Lisans Programı

İzmir
2022

EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ETİK KURALLARA UYGUNLUK BEYANI

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “**ÇEKİŞMELİ ÜRETİCİ AĞLAR İLE GERÇEKÇİ SAÇ SENTEZİ** ” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

28 / 01 / 2022

Muhammed PEKTAŞ

ÖZET**ÇEKİŞMELİ ÜRETİCİ AĞLAR İLE GERÇEKÇİ SAÇ SENTEZİ**

PEKTAŞ, Muhammed

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Aybars UĞUR

Ocak 2022, 54 sayfa

Üretici modelleme alanında elde edilen son yıllardaki başarılar, bu konudaki çalışmalarını hızlandırmış ve araştırmacıların ilgisini çekmiştir. Bu başarıda en çok payı olan yöntemlerden bir tanesi de çekişmeli üretici ağlar'dır. Çekişmeli üretici ağlar, sanal gerçeklik (VR), artırılmış gerçeklik (AR), süper çözünürlük (super-resolution), görüntü iyileştirme (image enhancement) gibi konularda bir çok uygulama alanına sahiptir.

Saç sentezleme, stil transferi ve şekil düzenleme görevleri, derin öğrenme ve üretici modellemedeki son ilerlemelere rağmen saçın karmaşık doğası nedeniyle hala çözülmeyi bekleyen zorlukları içerisinde barındırmaktadır. Bu problemin çözümü için literatürde önerilen yöntemler genellikle görseller üzerinde yüksek kaliteli saç düzenlemeleri yapmak üzerine odaklanmıştır. Bu tez kapsamında saç sentezi probleminin çözümü için bir çekişmeli üretici ağ yöntemi önerilmiştir. Bu yöntem geliştirilirken, literatürdeki en iyi yöntemler ile yarışır görsel çıktılar elde edebilmenin yanısıra, gerçek zamanlı saç sentezi yapılabilmesi de amaçlanmıştır.

Önerilen yöntem, FFHQ veri kümesi ile eğitilmiş ve devamında ise saç stili transferi ve saç yeniden yapılandırma görevlerindeki sonuçları değerlendirilmiştir. Bu görevlerde elde edilen sonuçlar ve yöntemin işletim süresi literatürdeki en iyi yöntemlerden biri olan MichiGAN ile karşılaştırılmıştır. Karşılaştırma 128x128 çözünürlüğünde gerçekleştirilmiştir. Karşılaştırma sonucunda önerilen yöntemin, gerçekçi saç sentezi açısından MichiGAN ile yarışır sonuçlar elde ettiği, işletim süresi açısından daha iyi performans sergilediği gösterilmiştir.

Anahtar Sözcükler: Saç Sentezi, Saç Stil Transferi, Çekişmeli Üretici Ağlar, Üretici Modelleme, Derin Öğrenme

ABSTRACT**REALISTIC HAIR SYNTHESIS WITH GENERATIVE
ADVERSARIAL NETWORKS**

PEKTAŞ, Muhammed

MSc in Computer Engineering

Supervisor: Prof. Dr. Aybars UĞUR

January 2022, 54 pages

Recent successes in generative modeling have accelerated studies on this subject and attracted the attention of researchers. One of the most important methods used to achieve this success is Generative Adversarial Networks (GANs). It has many application areas such as; virtual reality (VR), augmented reality (AR), super resolution, image enhancement.

Despite the recent advances in hair synthesis and style transfer using deep learning and generative modelling, due to the complex nature of hair still contains unsolved challenges. The methods proposed in the literature to solve this problem generally focus on making high-quality hair edits on images. In this thesis, a generative adversarial network method is proposed to solve the hair synthesis problem. While developing this method, it is aimed to achieve real-time hair synthesis while achieving visual outputs that compete with the best methods in the literature.

The proposed method was trained with the FFHQ dataset and then its results in hair style transfer and hair reconstruction tasks were evaluated. The results obtained in these tasks and the operating time of the method were compared with MichiGAN, one of the best methods in the literature. The comparison was made at a resolution of 128x128. As a result of the comparison, it has been shown that the proposed method achieves competitive results with MichiGAN in terms of realistic hair synthesis, and performs better in terms of operating time.

Keywords: Hair Synthesis, Hair Style Transfer, Generative Adversarial Networks, Generative Modelling, Deep Learning

ÖNSÖZ

Saç sentezi problemi günlük hayat içerisinde birçok uygulama alanına sahiptir ve bir çok yeni uygulama alanı için de gelecek vaad etmektedir. Bu alanların başında sanal gerçeklik ve artırılmış gerçeklik uygulamaları olmakla birlikte çeşitli sosyal medya uygulamaları ve hatta kayıp ve aranan kişilerin muhtemel görünümelerini tahmin etmek gibi problemleri içeren uygulamalar da yer almaktadır.

Bu tezde, görece yeni bir alan olan çekişmeli üretici ağlar ile saç sentezi problemi üzerinde çalışılmıştır. Tez çalışması kapsamında literatürdeki en iyi yöntemler ile yarışır kalitede saç sentezi üretimi yapabilen ve aynı zamanda işletim süresi olarak verimli bir yöntem üzerinde çalışılmıştır. Önerilen yöntem saç yeniden yapılandırma, saç stili transferi görevlerinde test edilmiştir. Testler sonucunda literatürdeki en iyi yöntemler ile yarışır sonuçlar elde edilmiştir.

İZMİR

28 / 01 / 2022

Muhammed PEKTAŞ

İÇİNDEKİLER

	<u>Sayfa</u>
İÇ KAPAK	ii
KABUL ONAY SAYFASI	iii
ETİK KURALLARA UYGUNLUK BEYANI.....	v
ÖZET	vii
ABSTRACT	ix
ÖNSÖZ.....	xi
İÇİNDEKİLER.....	xiii
ŞEKİLLER DİZİNİ	xvii
TABLolar DİZİNİ.....	xix
SİMGELER VE KISALTMALAR DİZİNİ	xx
1. GİRİŞ.....	1
2. DERİN ÖĞRENME	4
2.1 Yapay Sinir Ağları.....	4
2.2 Evrişimsel Sinir Ağları	7
2.3 Eniyileme.....	10
2.3.1 Gradyan iniş.....	11
2.3.2 Yığın gradyan iniş.....	11

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
2.3.3 Stokastik gradyan iniş	12
2.3.4 Mini-yığın gradyan iniş.....	12
2.4 Kayıp Fonksiyonları.....	13
2.4.1 Manhattan mesafesi.....	13
2.4.2 Öklid mesafesi.....	13
2.4.3 Cosine benzerliği.....	14
2.4.4 Algısal kayıp	14
2.4.5 Kimlik kaybı	14
3. ÜRETİCİ MODELLEME	15
3.1 Çekişmeli Üretici Ağlar	15
3.2 Koşullu Çekişmeli Üretici Ağlar.....	17
4. ÖNCEKİ ÇALIŞMALAR.....	19
4.1 İlgili Çalışmalar.....	19
4.2 Veri Kümeleri	20
4.3 Değerlendirme Yöntemleri	21
5. ÇEKİŞMELİ ÜRETİCİ AĞLAR İLE SAÇ SENTEZİ.....	23
5.1 Genel Bakış.....	23

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
5.2 Yöntem	23
5.2.1 Saç üretici ağ.....	24
5.2.2 Ayırıcı ağ	27
5.2.3 Eniyilenen kayıp fonksiyonları.....	28
6. DENEYSEL ÇALIŞMALAR.....	30
6.1 Veri Kümesinin Hazırlanması	30
6.2 Deney Ortamı.....	32
6.3 Deney Sonuçları.....	32
6.3.1 Saç yeniden yapılandırma.....	32
6.3.2 Saç stil transferi	33
6.3.3 Saç şekli düzenleme.....	34
6.3.4 Önerilen yöntemin literatür ile karşılaştırılması	37
7 SONUÇ VE GELECEK ÇALIŞMALAR	43
KAYNAKLAR DİZİNİ.....	44
TEŞEKKÜR	53
ÖZGEÇMİŞ.....	54
EKLER

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1 Biyolojik nöronun matematiksel modellemesi	5
2.2 Bazı klasik aktivasyon fonksiyonlarının girdisi [-5,5] aralığında iken sahip oldukları değerleri	6
2.3 Örnek bir evrişim işleminin bir kaç adımlık gösterimi.....	8
2.4 Katmanlar ve öğrenilen özellik örnekleri	10
2.5 Gradyan iniş yöntemlerinin temsili eniyileme karakteristiği.	13
3.1 Standart GAN yapısı.....	17
3.2 Koşullu GAN temel yapısı	18
5.1 Geliştirilen yönteme genel bakış	24
5.2 AdaINResBlok katmanı.....	26
5.3 Saç karıştırma katmanı	27
6.1 FFHQ veri kümesinden rastgele seçilmiş örneklerin önişleme sonuçları.	31
6.2 FFHQ veri kümesinden rastgele seçilmiş bazı örnekler ve ikili saç maskeleri.....	31
6.3 Önerilen yöntemin saç stili yeniden yapılandırma görevi için elde ettiği bazı sonuçlar. Orjinal görüntü sol, sentezlenen görüntü sağ tarafta yer almaktadır.	33
6.4 Önerilen yöntemin saç stili transferi görevi için elde ettiği bazı sonuçlar. Orjinal görüntü 1. sütun, sentezlenen görüntüler diğer sütunlarda yer almaktadır. Referans saç stili görseli ve hedef saç maskesi çıktı görselinin alt kısmında yer almaktadır.	34

ŞEKİLLER DİZİNİ (devam)ŞekilSayfa

- 6.5 Önerilen yöntemin saç şekli düzenleme görevinde elde ettiği bazı sonuçlar. .36
- 6.6 Önerilen yöntemin saç stil yeniden yapılandırması görevi için elde ettiği bazı sonuçlar. Orjinal görüntü ilk sütun, MichiGAN ikinci sütun ve önerilen yöntem üçüncü sütunda gösterilmektedir.38
- 6.7 Önerilen yöntemin saç stili transferi görevi için elde ettiği bazı sonuçlar. Orjinal örüntü ilk sütun, referans görüntü ikinci sütun, MichiGAN sonuçları üçüncü sütun ve önerilen yöntemin sonuçları dördüncü sütunda gösterilmektedir.40

TABLolar DİZİNİ

<u>Tablo</u>	<u>Sayfa</u>
4.1 Literatür araştırması özeti	22
6.1 Önerilen yöntemin MichiGAN ile FID metriği kullanılarak karşılaştırılması. Sonuçlar FFHQ veri kümesinin test kümesinden rastgele seçilen 5000 adet örnek üzerinde hesaplanılarak elde edilmiştir.	41
6.2 Önerilen yöntemin MichiGAN ile çalışma zamanı hızı, bellek ve görsel çözünürlüğü açısından karşılaştırılması. FPS değeri, 500 adet görsel üzerinden bir görsel üretimi için ortalama süre hesaplanılarak elde edilmiştir. Üretim sürecine model yükleme hariç diğer kaynakların yüklenmesi ve kaydedilmesi dahil edilmiştir.	42

SİMGELER VE KISALTMALAR DİZİNİ**Simgeler** **Açıklama**

b Sabit değer

W Ağırlıklar

f Fonksiyon

K Filtre

M Özellik haritası

X Giriş değişkeni

Y Çıkış değişkeni

s Stil vektörü

 M_L L. katmanın maske girdisi I_{bg} Girdi arkaplanı

F Üretilen görüntü

FM Özellik haritası

 K_n n. evrişim işlemi filtresi η Öğrenme oranı**Kısaltmalar**

AdaIN Adaptive Instance Normalization

ANN Artificial Neural Networks

AR Augmented Reality

SİMGELER VE KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
CNNs	Convolutional Neural Networks
DL	Deep Learning
FFHQ	Flicker Face High Quality Dataset
ML	Machine Learning
VR	Virtual Reality
3D	3-Dimensional

1. GİRİŞ

Tanımlayıcı modelleme (descriptive modelling) ve üretici modelleme (generative modelling) makine öğrenmesinde kullanılan iki temel yaklaşımdır. Tanımlayıcı modellemede model, veri kümesini girdi olarak alır ve veriye dair bir çıkarımda bulunur. Üretici modellemede ise tam tersi bir durum söz konusudur. Bu yaklaşımda çıktılardan verinin kendisi modellenmeye çalışılır. Bu tezin teorik altyapısını oluşturan üretici modellemenin bir çok kullanım alanı söz konusudur. Sanal Gerçeklik (VR) ve Artırılmış Gerçeklik (AR) uygulamalarında, 3D modelleme, görüntü tamamlama, görüntü iyileştirme, sanatsal çıktılar elde etmek gibi bir çok uygulama alanında kullanılmaktadır. Bu tez kapsamında üretici modelleme yaklaşımı ile gerçekçi saç üretimi üzerinde çalışılmıştır. Görece yeni bir alan olmasından dolayı, bu alan dar bir literatüre sahiptir. Bu tez kapsamında üzerinde çalışılan yöntem, literatürdeki en iyi yöntemlerle yarışır sonuçlar vermektedir.

Görüntülerde gerçekçi saç sentezleme işleminin kullanılabileceği bir çok önemli alan vardır. Örneğin bu tez kapsamında yapılan çalışma ile kolluk kuvvetleri, saç rengi ve şeklini değiştirerek kimliği gizlenen kayıp veya suçlu bireylerin olası durumları için farklı görüntüler elde edebilirler ya da saçının görünümünde ve tarzında değişiklik yapmak isteyen kişiler, fiziksel görünümünde uzun süreli değişiklik yapmadan olası durumlarını görüp önceden bir değerlendirme yapabilirler. Bir başka örnek ise çeşitli sosyal medya uygulamalarında kişiler saçları üzerinde değişiklikler yaparak istedikleri görselleri elde edebilirler (Olszewski et al., 2020). Ayrıca farklı saç görünümleri ve tarzları kişinin tanınabilirliği ile ilişkili olduğundan, bu alanlarda değişiklik yapabilme yeteneği, görsel verilerin anonimleştirilmesi süreçlerine de katkı sağlayabilir.

Saç sentezleme problemi tek başına ele alındığında görsel üzerinde sadece saçın değiştiği görsellerin elde edilmesi üzerine çalışılan bir problemdir. Bu problem içerisinde bir çok zorlu alt problem içerir. İnsan yüzünün diğer bölümlerinin aksine kendine özgü geometrisi ve materyali saçın analiz, temsil ve üretim işlemlerini zorlaştırmaktadır. Saç, biraz daha yakından incelenip, şekil ve görünümü ayrı değerlendirildiğinde görsel kalite için birkaç temel husus

tanımlanabilir. Şekil açısından karışık saç maskesi sınırları ve farklı opaklık seviyeleri hassas saç şekli kontrolü ve arkaplan ile saçın kusursuz kesişimi konusunda zorluklara neden olabilir. Görünüm açısından ise, saç liflerinin karmaşık doğası, ipliksi yapıların farklı yön ve görünümündeki farklılıklar ve bunların arasındaki uyumu sağlama gerekliliği, görünüm açısından da saç üretim, temsil ve analizini zorlaştıran faktörlerdir (Tan et al., 2020). Tüm bu zorluklar olmasına karşın, bu problemlerin çözümü için bir çok çalışma yapılmış ve farklı seviyelerde başarılar elde edilmiştir. Bu çalışmada verilen farklı referans saç görünümlerine sahip yeni saç üretimi yapabilen bir çerçeve üzerinde çalışılmıştır.

Bu çalışmada, üzerinde çalışılacak saç sentezi problemi için stil transferi yapılmış gerçek değerler (ground truth) bulunmadığı için tercih edilen eğitim yöntemine uygun olacak şekilde yüz ve saç bölgelerini içeren çok bilinen veri kümeleri kullanılmıştır. Kullanılan veri kümeleri ile geliştirilen yöntemin eğitim ve değerlendirme deneyleri yapılmıştır. Değerlendirmeler için hem niceliksel (quantitative) hemde niteliksel (qualitative) yöntemler kullanılmıştır. Tez çalışması kapsamında, ifade edilen problem için literatürdeki en iyi sonuçlarla yarışır sonuçlar elde edilirken aynı zamanda çalışma süresinin de azaltılması hedeflenmiştir.

Bu çalışmanın literatüre temel katkısı, literatürdeki yüksek başarı elde edebilen yöntemler ile yarışır sonuçlar elde ederken diğer yöntemlerden daha az çalışma zamanı süresine sahip olan yeni bir yöntemin önerilmiş olmasıdır. Geliştirilen yöntem, saç sentezinin videolar üzerinde gerçek zamanlı gerçekleştirilmesinin de önünü açmaktadır.

Tez metninin sonraki bölümleri şu şekilde özetlenebilir:

İkinci bölümde derin öğrenme, yapay sinir ağları (ANN), evrişimli sinir ağları (CNN), eniyileme konuları temel alt başlıklarıyla birlikte açıklanmaktadır.

Tezin üçüncü bölümünde derin öğrenme teknikleri tabanlı Üretici modelleme çalışmaları üzerinde durulmaktadır. Üretici modelleme konusunda sadece tez ile ilgili önemli başlıklara değinilmektedir.

Dördüncü bölümde, saç sentezi problemi hakkında yapılan çalışmalara değinilecektir. Bu çalışmaların yaklaşımları, kullanılan veri kümeleri ve değerlendirme yöntemleri incelenmektedir.

Beşinci bölümde çekişmeli üretici ağlar ile saç sentezi konusunda önerilen yöntem genel çerçevesi ve tüm alt modülleri ile birlikte açıklanmıştır. Yöntemde kullanılan tüm kayıp fonksiyonları kullanım nedenleriyle birlikte paylaşılmıştır ve yöntemin genel kayıp fonksiyonu tanımlanmıştır.

Altıncı bölümde, ilk olarak önerilen yöntemin eğitimi için kullanılan veri kümeleri ve hazırlanışları ifade edilmiştir. Ön hazırlık aşaması tamamlanmış veriler üzerinde, hazırlanan deney ortamında önerilen yöntem kullanılarak saç stil transferi ve saç yeniden yapılandırma görevleri için deneyler yapıp elde edilen sonuçlar paylaşılmıştır ve literatür ile karşılaştırmalar yapılmıştır.

Tezin son bölümünde ise literatüre yapılan katkılar ile birlikte yapılan çalışmanın sonuçlar ve gelecek çalışma önerileri sunulmaktadır.

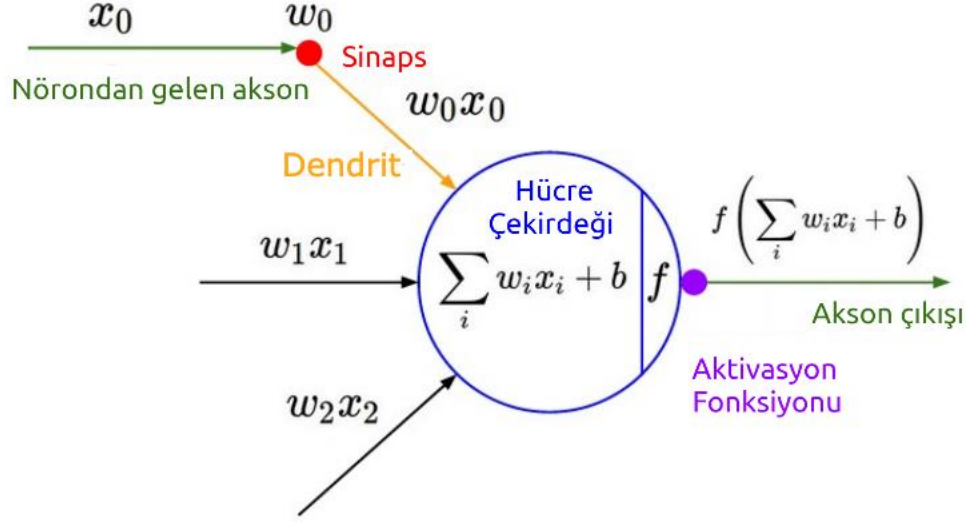
2. DERİN ÖĞRENME

Bu bölümde Derin öğrenmenin temel kavramları kısaca anlatılmaktadır.

2.1 Yapay Sinir Ağları

Derin öğrenme çok geniş bir literatüre sahiptir. Başta bilgisayarlı görü (computer vision) olmak üzere bir çok alanda önemli etkilere sahiptir. Son yılların en popüler ve verimli araştırma alanı olarak görülmektedir. Özellikle derin öğrenme ile gösterimli öğrenme yöntemleri kullanılarak bazı görevlerde insan başarısıyla benzer veya daha başarılı sonuçlar elde edilmiştir (Goh et al., 2020; Stidham et al., 2019).

Derin öğrenme ilhamını beyindeki sinir sisteminden alır. Nöron, sinir sisteminin temel fonksiyonel birimidir. Başlıca görevi bilgi transferini gerçekleştirmesidir. Nöronlar kendilerine gelen bilgiyi (sinyali) toplar, gerekirse aktivasyon seviyesinde değişime sebep olur ve çıktıyı diğer nöronlara aktarırlar. Biyolojik sinir ağlarından esinlenilerek yapay sinir ağları önerilmiştir. Standart bir yapay sinir ağı bir veya birden çok birbirine bağlı temel iş biriminden oluşur. Bu iş birimi yapay nöron olarak adlandırılır. Yapay nöronlar girdi olarak aldığı bilgiyi belirli bir ağırlık ile çarpar ve ek bir girdi ile toplayarak sonuca aktarır. Oluşan bu çıktı, uygulanmak istendiği takdirde nöronun aktiflik durumuna karar verecek bir aktivasyon fonksiyonundan geçirilir. Bu aşamada elde edilen çıktı başka nöronların girdisi veya nihai sonuç olabilir. Her biyolojik nöron, dendrit adı verilen sinyal toplayıcı uçlardan girdi sinyalini alır, hücre çekirdeğinde gerekli işlemlerini yapar ve onu akson boyunca taşıyarak çıktı sinyalini üretir. Biyolojik nöronun esinlenilen bu işlemin matematiksel olarak modellenmesi Şekil 2.1'de gösterilmiştir.



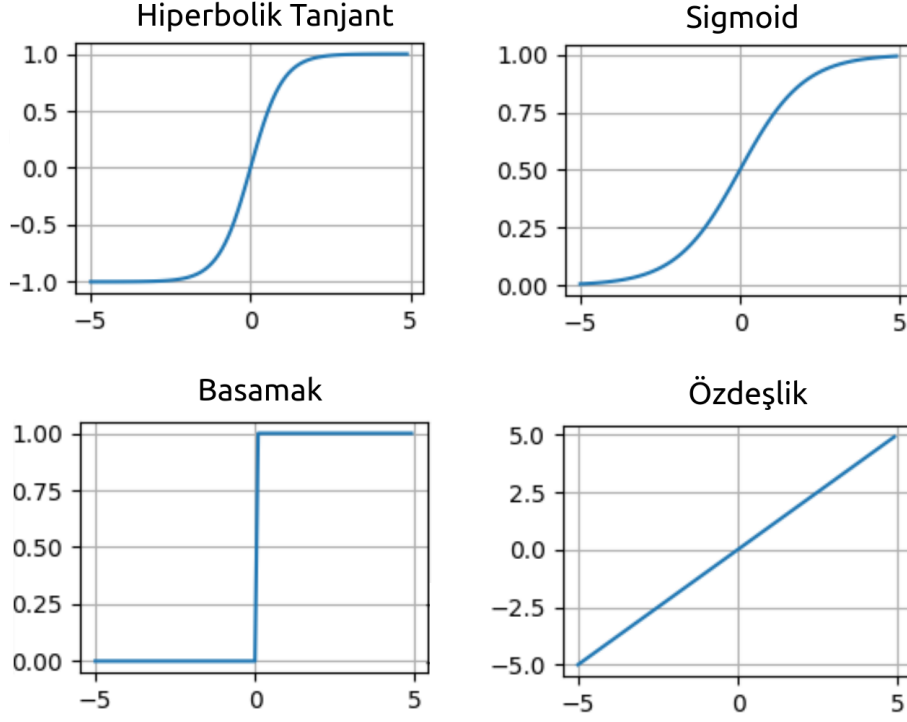
Şekil 2.1. Biyolojik nöronun matematiksel modellemesi (University of Stanford, n.d.)

(x_0) girdi, (w_0) girdinin ağırlığı, (b) ek girdi, (f) aktivasyon fonksiyonu olmak üzere bir yapay nöronun çıktısı, tüm girdiler ağırlıkları ile çarpılarak ek değerle toplanılıp bir aktivasyon fonksiyonundan geçirilerek elde edilir. Bir nöron için bu işlem denklem 2.1 ile ifade edilebilir.

$$y = f\left(\sum (w_i * x_i + b)\right)$$

2.1

Buradaki aktivasyon fonksiyonu, nöronun aktivasyon seviyesini belirler. Aktivasyon fonksiyonu olmadan denklemin kendisi doğrusal bir denklem olduğundan doğrusal olmayan bir problemi modelleyebilmek için genellikle doğrusal olmayan aktivasyon fonksiyonları kullanılır. Şekil 2.2’de bazı örnek klasik aktivasyon fonksiyonları gösterilmiştir.



Şekil 2.2. Bazı klasik aktivasyon fonksiyonlarının girdisi $[-5,5]$ aralığında iken sahip oldukları değerleri (Apicella et al., 2021).

Sigmoid fonksiyonu $[0,1]$ aralığında değerler alır. Değer aldığı aralık sebebiyle ara katmanlarda genellikle aktivasyonları maskeleyici çıktılar oluşturmak veya çıktı tahminlerini olasılık olarak ifade etmek için kullanılır.

Hiperbolik tanjant fonksiyonu $[-1,1]$ aralığında değer alır. Negatif değerlerin ve sifıra yakın değerlerinde kendine uygun şekilde çıktıya aktarılması hiperbolik tanjantın avantajları arasında sayılabilir.

Özdeşlik fonksiyonu girdi olarak aldığı değeri doğrudan çıktıya aktarır. Doğrusal bir fonksiyon olduğundan doğrusal olmayan problemlerin çözümünde kullanılamaz. Güncel yapay sinir ağları modellerinde sık kullanılmayan bir aktivasyon fonksiyonudur.

Basamak fonksiyonu genellikle ikili sınıflandırma problemlerinin çözümünde son katmanlarda kullanılır. Türev öğrenbilme yeteneği olmadığından ara katmanlarda kullanımı tavsiye edilmez.

Belirtilen girdiler, ağırlıklar, ek girdiler ve aktivasyon fonksiyonları ışığında bir yapay nöronun çıktısı başka bir yapay nöronun girdisi olabilir böylece bir sinir ağı oluştururlar. Oluşturulan sinir ağının kapasitesi arttıkça daha büyük bir hipotez uzayına sahip olur ve daha zorlu problemlerin modellenmesine imkan verir. Hipotez uzayı bir modelin ifade edebileceği çözüm kümesidir (Goodfellow et al., 2016).

2.2 Evrimsel Sinir Ağları

Geleneksel makine öğrenmesi algoritmalarında problemin çözümü için gerekli özellik çıkarımı araştırmacılar tarafından yapılmaktadır. Bu özellik çıkarma işlemi ayrıca alanda uzmanlık bilgisi de gerektirmektedir ancak CNN (LeCun et al., 1989) uygulamalarında özellik çıkarımı öğrenme sırasında ara katmanlarda elde edilebilmektedir. Bu durum daha az uzman bilgisi gerektirmesi, özellik çıkarımı sırasındaki zaman kazanılması anlamında önemli bir kazançtır. Bu nedenle CNN, örüntü tanıma ile ilgili alanlarda son yıllarda önemli bir etkiye sahiptir.

Görüntü verileri uzamsal ilişkileri olan görsellerdir ve CNN bu özelliği kullanır. CNN de filtreler kümesi öğrenilir. $[K_1 \dots K_n]$ filtreler kümesi, (n) filtre indeksi olmak üzere filtreler, (X) girdi görüntüsü ile evrişim işleminden geçirilir ve sonucunda (FM) özellik haritaları oluşturulur. Bu işlem denklem 2.2 ile ifade edilebilir.

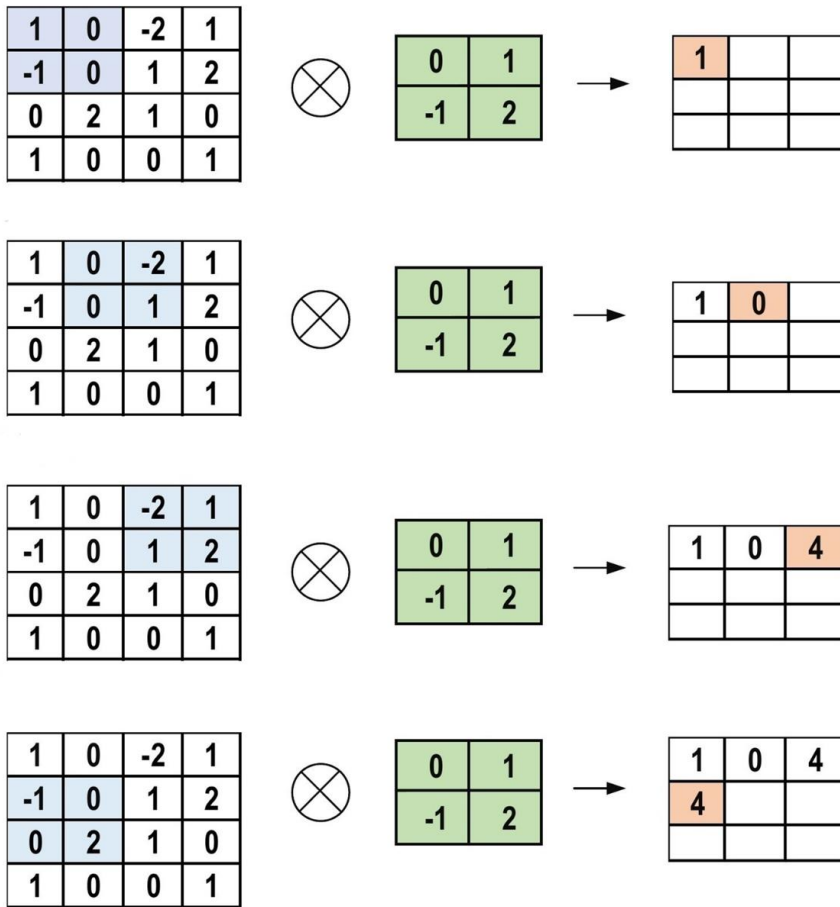
$$FM_n = K_n \otimes X \quad 2.2$$

Evrışim işleminde kullanılan filtre uygulandığı görüntüyle uyumluysa güçlü, uyumsuz ise zayıf çıktılar üretir. Her bir filtrelerin ağırlık değerleri paylaşıldığından tam bağlı yapay sinir ağlarına göre daha az parametre içerirler. Evrişim işlemi için filtrelerin boyutu (kernel size), adım sayısı (stride), doldurma (padding) işlemi gibi özelliklerin ayarlanması gerekir. Elde edilmek istenilen özellik haritasının içeriği ve büyüklüğünü bu değerle ile ayarlanabilir. Girdi büyüklüğü (n), çıktının büyüklüğü (n'), doldurma değeri (p), uygulanan filtre

büyüklüğü (f), adım değeri (s) olmak üzere evrişimi işlemi sonucunda oluşan çıktının boyutları denklem 2.3 ile ifade edilebilir.

$$n' = \frac{(n + 2p - f)}{s} - 1 \quad 2.3$$


Evrişim işlemi sırasında kullanılan filtre büyüklüğü, adım sayısı gibi değişkenler çıktıyı etkilemektedir. Örneğin, büyük filtreler özellik çıkarırken daha çok sayıda komşu piksel'i değerlendirir, adım sayısı büyüklüğü filtrelerin resme uygulanma sayısını değiştirebilir. Bu ve benzeri parametreler evrişim işlemi sonucunda elde edilecek özellik haritasını etkilemektedir. Örnek bir evrişim işlemi şekil 2.3 te gösterilmektedir.



Şekil 2.3. Örnek bir evrişim işleminin bir kaç adımlık gösterimi (Alzubaidi et al., 2021)

CNN'in bir başka özelliđi ise yapay sinir ađlarındaki parametre sayısını azaltmasıdır. Bu sayede arařtırmacıların daha karmařık problemleri çözebilmek için daha büyük modeller geliřtirmesinin önü açılmıştır. CNN'in bir diđer önemli yönü ise katmanlar ilerledikçe daha soyut özellikler öğrenebilmesidir. Örneđin görsel girdilerle çalışılan bir problemde, ilk katmanda kenar ve köşe özellikleri ikinci katmanda ise basit şekiller olacak şekilde öğrenmeye etki eden özellikler öğrenilir (Albawi et al., 2017). Şekil 2.4 te öğrenilen özelliklerin temsili gösterilmiştir.





Şekil 2.4. Katmanlar ve öğrenilen özellik örnekleri (Zeiler et al., 2014)

2.3 Eniyileme

Yapay sinir ağlarında öğrenme işlemi temelde, ağırlıklar ve ek birim değerlerinin bir veri kümesi üzerinde en az hatayı verecek şekilde değiştirilmesi işlemidir. Bu işlem aslında bir en iyileme (optimization) problemidir. Çoğu en

iyileme yöntemi girdileri değiştirerek ilgili fonksiyonunun değerini en küçültmeyi (minimization) amaçlar. Eniyileme işlemi uygulamak istediğimiz fonksiyon genellikle amaç yada kayıp fonksiyonu olarak adlandırılır. Yapay sinir ağlarında en sık kullanılan eniyileme yöntemi gradyan inişi yöntemidir (Ruder et al., 2016).

2.3.1 Gradyan iniş

Gradyan iniş algoritması yapay sinir ağlarını optimize etmede kullanılan en bilinen algoritmadır ve son yıllarda da bilinirliğini giderek artmaktadır. Keras (Chollet et al., 2015), Pytorch (Paszke et al., 2019) gibi birçok iyi bilinen derin öğrenme kütüphanelerinde birçok farklı versiyonunun uygulamaları bulunmaktadır. Bu algoritma genellikle kara kutu bir eniyileme yöntemi olarak kullanılır.

Gradyan iniş algoritması, ($\theta \in \mathbb{R}^d$) model parametreleri olmak üzere $J(\theta)$ amaç fonksiyonunu (örneğin bölüm 2.4 deki fonksiyonlar) optimize eder. Optimizasyon sürecinde amaç fonksiyonunun parametrelere göre gradyanı ($\Delta J(\theta)$) hesaplanır. Gradyan, fonksiyonun türevini ifade etmektedir. Parametreler gradyanların tam tersi yönde güncellenir. Böylelikle iç bükey olarak modellenmiş problem uzayında minimum değere yaklaşılmış olur. Çözüm uzayının morfolojik gösteriminde aşağıya doğru ilerlendiğinden gradyan iniş algoritması olarak adlandırılır. Gradyan iniş algoritması bazı parametrelere sahiptir. Bunlardan birisi öğrenme oranı (η) olarak bilinir. Bu oran yerel minimuma yaklaşıırken atılacak adım büyüklüğünü etkiler. Diğer bir deyişle amaç fonksiyonunun oluşturduğu uzayda bir iniş karakteristiği gösterilir (Ruder et al., 2016). Bu algoritmanın yığın gradyan inişi, Stokastik gradyan inişi, Mini-yığın gradyan inişi olmak üzere temelde 3 farklı çeşidi vardır.

2.3.2 Yığın gradyan iniş

Yığın gradyan iniş vanilya gradyan iniş olarak bilinir. Bu versiyonda veri kümesindeki tüm elemanların amaç fonksiyonu çıktısı ile yapay sinir ağının parametreleri arasındaki gradyan hesaplanır ve denklem 2.4 ile güncellenir.

$$\theta = \theta - \eta \cdot \Delta \theta J(\theta) \quad 2.4$$

Bu yöntemde tek bir güncelleme işlemi için tüm datasetin gradyanları hesaplandığından diğer versiyonlara göre yavaştır ve daha çok bellek ihtiyacına sahiptir.

2.3.3 Stokastik gradyan iniş

Stokastik gradyan inişte yığın gradyan inişinin aksine güncelleme işlemi tüm veri seti için bir kere değil, seçilmiş her rastgele örnek için gerçekleştirilir. (X_i) veri kümesinde bir eleman, (y_i) çıktısı olmak üzere güncelleme işlemi denklem 2.5 ile hesaplanır.

$$\theta = \theta - \eta \cdot \nabla \theta J(\theta; X_i; y_i) \quad 2.5$$

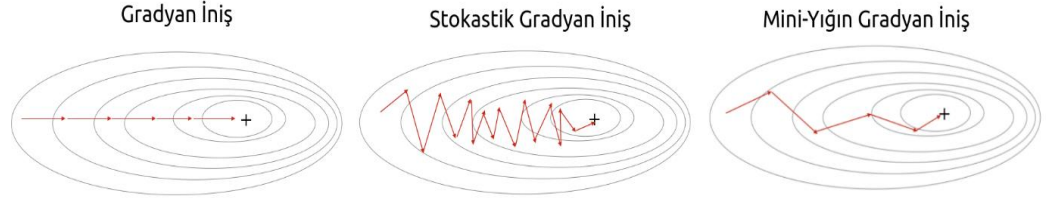
Bu işlemde güncelleme için tüm datasetteki gradyanları hesaplamak gerekmediğinden bellek ve hız olarak yığın gradyan iniş yöntemine göre daha verimli bir yoldur ancak en iyileme süresince varyansı yüksek bir yol izleyebilir.

2.3.4 Mini-yığın gradyan iniş

Mini-yığın gradyan inişi yönteminde ise eniyileme yolunda düşük varyans ve aynı zamanda hızlı bir optimizasyon yapabilmek adına veri kümesinden küçük bir alt küme seçilir ve bu kümedeki örnekler için gradyanlar hesaplanarak parametreler güncellenir. (n) mini-yığındaki eleman sayısı olmak üzere güncelleme işlemi denklem 2.6 ile hesaplanır.

$$\theta = \theta - \eta \cdot \nabla \theta J(\theta; X_{i+n}; y_{i+n}) \quad 2.6$$

Gradyan iniş algoritması ve 3 farklı varyasyonunun en iyileme süreci şekil 2.5 de temsili olarak gösterilmiştir.



Şekil 2.5. Gradyan iniş yöntemlerinin temsili eniyileme karakteristiği. (Jacques M., 2020)

2.4 Kayıp Fonksiyonları

Kayıp fonksiyonları, tasarlanan modelin eğitimi sırasında problemin çözümüne yaklaştırmaya teşvik etmek ve modelin başarısını değerlendirmek için kullanılır. Eğitim sırasında modelin eğitim kümesi üzerindeki veya test veri kümesindeki başarısını değerlendirerek eğitim sürecinin başarılı devam edip etmediği ve modelin genelleştirme yeteneği hakkında bilgi edinilmesine olanak tanır. Ayrıca öğrenme sürecinde modelin yaptığı hatanın hesaplanması, modelin kendi hatalarını düzeltmesi için en önemli adımlardan bir tanesidir. Bu bölümde görüntü verileri ile ilgili birkaç örnek kayıp fonksiyonundan söz edilecektir.

2.4.1 Manhattan mesafesi

L1 mesafesi Manhattan mesafesi olarak da bilinmektedir. Beklenen çıktı ile gerçek çıktı birbirinden çıkarılır ve sonucun mutlak değeri alınarak toplanır. L1 mesafesi denklem 2.7'de gösterilmektedir.

$$L(X_1, X_2) = \|X_1 - X_2\| \quad 2.7$$

2.4.2 Öklid mesafesi

L2 mesafesi öklid uzaklığı olarak da bilinir. Beklenen çıktı ile gerçek çıktının farklarının karesi alınıp toplanır ve sonuca karekök işlemi uygulanır. Bu kayıp fonksiyonunun girdi görüntülerini yeniden elde etme (reconstruction) görevi sırasında bulanık çıktılara neden olur (Pathak et al., 2016; Zhang et al., 2016). Öklid mesafesi denklem (2.8) ile ifade edilebilir.

$$L(X_1, X_2) = \|X_1 - X_2\|_2 \quad 2.8$$

2.4.3 Cosine benzerliđi

Cosine benzerliđi iki vektörün arasındaki açıyı ölçerek vektörler arasındaki benzerliđi veya mesafeyi ölçmeyi amaçlar. Denklem 2.9'da gösterilmiştir.

$$L(X_1, X_2) = \frac{X_1 \cdot X_2}{(\|X_1\|^2 * \|X_2\|^2)} \quad 2.9$$

2.4.4 Algısal kayıp

Algısal kayıp fonksiyonu genellikle iki farklı girdininin VGG (Simonyan and Zisserman, 2014) ağının ara katman çıktıları arasında ağırlıklı kayıpların toplamı şeklinde hesaplanır. Bu yöntem genellikle görseldeki yerel özelliklerin korunabilmesi için kullanılır. Algısal kayıp fonksiyonu denklem 2.10 ile ifade edilebilir.

$$L(X_1, X_2) = L_1(Vgg(X_1), Vgg(X_2)) \quad 2.10$$

2.4.5 Kimlik kaybı

Kimlik kayıp fonksiyonu görseldeki kimlik bilgisi üzerinden bir kayıp değeri hesaplama durumlarında kullanılır. Örneđin üretilen görüntüdeki kimlik bilgisi ile girdideki kimlik bilgisinin aynı olmasının istediđi durum için örnek bir kimlik kayıp fonksiyonu, (ID) kimlik bilgisi üreten bir model olmak üzere denklem 2.11 ile gösterilebilir.

$$L(X_1, X_2) = L_1(ID(X_1), ID(X_2)) \quad 2.11$$

3. ÜRETİCİ MODELLEME

Bu bölümde, üretici modellemenin temel amacı ve kullanılan yöntemlere kısaca değinilmektedir. Tez ile ilgili olarak çekişmeli üretici ağlar ile üretici modelleme yöntemleri detaylıca ele alınmaktadır.

Makine öğrenmesinde kullanılan en önemli paradigmalardan birisi tanımlayıcı modellemedir. Tanımlayıcı modellemeye örnek olarak sınıflandırma problemi verilebilir. Sınıflandırma probleminde bir örnek girdi olarak alınır ve model onun hangi sınıfa ait olduğunu tahmin etmeye çalışır. Örneklerden sınıfların öğrenildiği bu süreç bir tanımlayıcı modelleme örneğidir. Üretici modellemede ise bu örneğin tam tersi bir durum söz konusudur. Sınıfı girdi olarak verilen sınıfa ait bir sentetik örnek üretilmeye çalışılır. Üretici modellemede girdi örneklerinin hangi dağılımdan olduğu değil, dağılımın kendisinin öğrenilmesi amaçlanır.

Üretici modelleme için Enerji tabanlı yöntemler (LeCun, Y. et al., 2006; Du, Y. et al., 2019; Ho, J. et al., 2020), Varyasyonel otomatik kodlayıcılar (VAE) (Child, R., 2020; Kongma, D. P. et al., 2013), Çekişmeli üretici ağlar (GANs) (Goodfellow, I. et al., 2014; Radford, A. et al., 2015; Karras, T. et al., 2017, Karras, T. et al., 2021) ve daha birçok yöntem (Fahlman et al., 1983; Ackley et al., 1985; Hinton et al., 1984; Hinton ve Sejnowski, 1986; Hinton et al., 2006; Kingma et al., 2013; Rezende et al; 2014;) söz konusudur. Bu bölümde, son zamanlardaki en başarılı yöntemlerden kabul edilen ve bu tez kapsamında yapılan çalışmanın temelini oluşturan çekişmeli üretici ağlardan bahsedilecektir.

3.1 Çekişmeli Üretici Ağlar

Çekişmeli Üretici Ağlar (GANs), 2014 yılında I. Goodfellow tarafından tanıtılmıştır (Goodfellow et al., 2014). Tanıtıldıktan bugüne araştırmacıların ilgisini üzerine çekmeyi başarmıştır. Böylece kendisine bilgisayarlı görü (Ma, L. et al., 2017; Yu, J. et al., 2018) ve doğal dil işleme (Patashnik, O. et al., 2021; Zhang, H. et al., 2017, Yang, Z. et al., 2017) gibi birçok alanda kullanım alanı bulmuştur.

GAN'lar diğer üretici modeller ile karşılaştırıldığında dağılımları öğrenilebilir, istenilen örnekleri verimli bir şekilde üretebilir gibi bir çok yönden avantajlara sahiptir. Bu avantajları özellikle bilgisayarlı görü alanındaki süper çözünürlük (super resolution), görselden görsele geçiş (image-to-image translation) ve görüntü tamamlama (image completion) gibi önemli problemlerde yüksek başarı elde edebilmesinde yardımcı olmuştur (Wang, X. et al., 2021; Wang, T. C. et al., 2018; Yeh, R. A. et al., 2017). Ancak GAN'lar da kendi problemlerine sahiptir. En önemli iki probleminden bir tanesi zor eğitilmesi diğer problem ise değerlendirmesinin zor olmasıdır. (Wang, Z. et al., 2020).

Çekişmeli üretici ağlarda, temelde iki farklı ağ birbiriyle mücadele ederken, gerçekçi sentetik veri üretmeyi öğrenirler. Bu ağlardan bir tanesi üretici (generator) olarak adlandırılır ve gerçekçi sentetik veriyi üretir. Diğer ağ ise ayırıcı (discriminator) olarak adlandırılır. Bu ağın görevi üretici ağın ürettiği çıktılarının gerçekçiliğini denetlemektir. Verimli bir öğrenme süreci gerçekleştirebilmek için iki ağ arasında bir denge yakalanması gerekmektedir. Dengeli bir eğitim geçirilmeyen durumlarda mod çökmesi (mode collapse) adı verilen bir problem ile sıkça karşılaşılır. Bu problem üretilen sentetik verilerin genel dağılımının sadece dar bir alt kümesinin üretilmediği yani üretilen örneklerdeki varyansın düşük olduğu duruma verilen addır. Üretici modellemede yüksek çeşitlilikte sentetik verilerin üretilmesi hala üzerinde çalışılan önemli araştırma konusudur (Pan, Z. et al., 2019).


G, üretici, D ayırıcı z normal dağılımdan örneklenmiş bir vektör olmak üzere çekişmeli üretici ağların en genel amaç fonksiyonu denklem 3.1'de gösterilmiştir.

$$\begin{aligned} \min_G \max_D V(D, G) & \quad 3.1 \\ &= E_{x \sim p_{data}(X)} [\log D(X)] \\ &+ E_{z \sim p_Z(z)} [\log (1 - D(G(z)))] \end{aligned}$$

Öğrenme süreci çekişmeli (adversarial) olacak şekilde ilerler. Bu çekişme süreci bir sıfır toplamlı oyun şeklindedir. Üretici ağ başarılı sonuçlar ürettiğinde ayırıcı ağ gerçek ve sahteyi ayıramaz ve maliyet fonksiyonun değeri yükselir. Bu durumda ayırıcı ağ, ayırma işlemini daha iyi öğrenmesi yönünde teşvik edilmiş

olur. Ayırıcı ağ sentetik ve gerçek verileri yeterli doğrulukta ayırt edebildiğinde üretici ağ, ayırıcı ağı yanıltamaz. Bu durumda da üretici ağın maliyeti yükselir. Bu durumda da üretici ağ daha gerçekçi çıktılar üretebilmesi konusunda teşvik edilmiş olur. Böylece iki ağ, çekişmeli bir şekilde birbirlerini eğiterek gerçekçi sentetik çıktıyı üretmeyi öğrenirler. Üretici ve Ayırıcı ağ arasındaki bu ilişki, GAN eğitimini zorlaştırmaktadır. İki ağın kapasitelerinin dengeli olmadığı, öğrenme hızlarının farklı olduğu ya da en iyilemeye uygun bir noktadan başlamadıkları gibi nedenlerle arasındaki denge bozulabilmektedir. Bu durumda stabil bir eğitim sürecini elde edilemediğinden optimal kalitede çıktılara ulaşılamamaktadır.

GANs tanıtıldığı günden bu yanada üzerinde sıkça çalışılmış ve birçok versiyonu geliştirilmiştir. Genel olarak çalışmalar daha stabil ve başarılı eğitim süreçleri elde etmek (Arjovski et al., 2017; Gulrajani et al., 2017; Keras et al., 2017) ve ilgili göreve uygun özel mimariler (Keras et al., 2019; Gecer et al., 2019; Choi et al., 2020, Kupyn et al.2018, Wu et al., 2019) tasarlamak şeklinde iki ana kategoriye ayrılabilir (Gui et al., 2020). Şekil 3.1’de standart bir GAN yapısı gösterilmektedir.



Şekil 3.1. Standart GAN yapısı

3.2 Koşullu Çekişmeli Üretici Ağlar

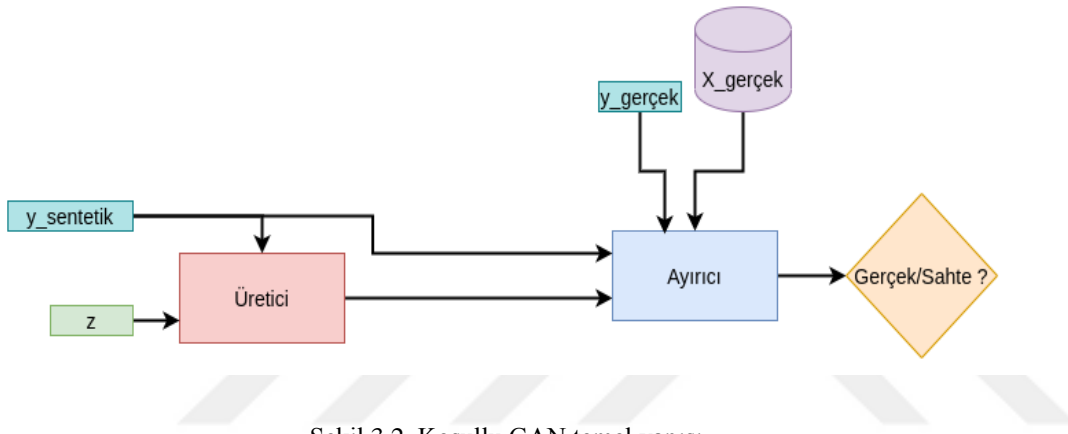
Koşullu üretici ağlar (Mirza et al., 2014) genellikle üretim sürecini kontrol edebilmek için kullanılır. Üretici ağ’ın ilgili girdisine ek olarak üretilen çıktılarını kontrol edebilecek ek girdiler sağlanarak üretici ağın üretme süreci bu girdiğe bağımlı hale getirilir. Böylelikle kontrol girdisi veya girdileri ile birlikte istenilen

çıktı elde edilebilir. Koşullu çekişmeli ağlar için genel amaç fonksiyonu denklem 3.2’de verilmiştir.

3.2

$$\begin{aligned} \min_G \max_G V(D, G) \\ = E_{x \sim p_{data}(X)} [\log D(X|y)] \\ + E_{z \sim p_Z(z)} [\log (1 - D(G(z|y)))] \end{aligned}$$

Koşullu çekişmeli ağların temel yapısı Şekil 3.2’de gösterilmektedir.



Şekil 3.2. Koşullu GAN temel yapısı

4. ÖNCEKİ ÇALIŞMALAR

Bu bölümde çekişmeli üretici ağlar ile saç sentezi literatürü incelenecektir. İlgili çalışmalar, problemin çözümü için kullanılan veri kümeleri ve sonuçların değerlendirilme yöntemleri üzerinde durulacaktır.

4.1 İlgili Çalışmalar

Saç sentezi problemi farklı amaçlar ile birçok farklı yönden ele alınabilir. Yüz görüntülerinde görüntü düzenleme (image editing) problemi üzerinde yapılan bazı çalışmalarda görüntünün farklı yerleri çeşitli şekillerde değiştirilir. Örneğin saç ve yüzün belli bölgeleri eskizler ile değiştirilerek modele girdi olarak verilir. Elde edilen çıktıda gerçekçi bölgeler korunurken eskiz ile değiştirilen bölgeler için eskize uygun şekilde gerçekçi çıktılar üretilir. Daha sonra önerilen çözüm ile değiştirilen bölgeye uygun gerçekçi çıktı tahmin edilmeye çalışılır. Bu ve benzeri şekillerde yüz üzerinde duran saçlar uygun bir şekilde kaldırılabilir yada saç bölgesi farklı saç şekilleri ile değiştirilebilir. (Yang et al., 2020; Portenier et al., 2018, Jo et al., 2019)

Saç sentezleme problemi üzerinde hali hazırda, içinde saç'a ait bölgeler de barındıran gerçekçi çıktılar üreten bir çekişmeli üretici ağı, vektör uzayında düzenlemeler yapılarak da çalışabilir. Zhu ve arkadaşlarının Barbershop adlı çalışması ile Saha ve arkadaşlarının LOHO adlı çalışmasında, vektör uzayında yapılan iteratif optimizasyon yöntemleri ile saç stil transferi ve saç sentezi problemi üzerinde çalışılmıştır. (Zhu et al., 2021; Saha et al., 2021).

Koşullu üretici ağlar ile farklı koşullar için uygun, kontrollü bir şekilde saç üretebilmek üzerine yapılan çalışmalar da bulunmaktadır. Tan ve arkadaşları, sözde denetimli öğrenme (pseudo supervised learning) stratejisini kullanarak, geliştirdikleri koşullu çekişmeli üretici ağ yöntemi ile saç sentezleme işleminde şekil, yapı, görünüm ve arkaplan özelliklerinin birbirinden bağımsız bir şekilde kontrol edilebilmesi üzerinde çalışmışlardır. (Tan et al., 2020). Fan ve arkadaşlarının yaptığı çalışmada geliştirilen koşullu üretici ağ yönteminde ise saçın rengi, yapısı ve şekli kontrol edilebilmektedir (Fan et al., 2021).

Çekişmeli ağlar ile saç üretme problemi Olszewski ve arkadaşlarının çalışmalarında iki faz olarak ele alınmıştır. İlk fazda sentetik verilerden oluşan bir veri kümesi kullanarak saçın üretilmesi ve ikinci fazda ise gerçek saç görüntülerinden oluşmuş bir veri kümesi ile çıktılarını iyileştirilerek gerçek görüntüye yerleştirilmesi şeklinde ele alınmıştır. (Olszewski et al., 2020).

Metinler kullanılarak belirtilen ifadeye uygun saçlı görseller üretmek için hem metin hem görsel verilerin kullanıldığı çalışmalar da mevcuttur. Bu çalışmalarda amaç yazılan metne uygun renk ve görünüme sahip saç görsellerinin üretilmesidir (Wei et al., 2021).

4.2 Veri Kümeleri

Çekişmeli üretici ağlar ile saç sentezi literatürü oldukça yeni ve dar bir alandır. Saçın dinamik yapısı, dokusu gibi kendine has özelliklerinin yanı sıra bir kişinin farklı saç stillerinde bulunmasının zor bulunan bir durum olması, bu alana özel bir veri kümesi oluşturulmasının önünde önemli bir engeldir. Bildiğimiz kadarıyla bu problem için hazırlanmış, kullanıma açık bir veri kümesi bulunmamaktadır. Bu nedenle saç sentezi problemi çözümü için araştırmacılar farklı yollar izlemektedirler.

Bazı araştırmacılar online uygulamaları (Laticis Imagery., 2017; Daz Productions., 2017) kullanarak sentetik veri kümesi oluşturmuş ve bu sentetik veri kümesinde aldığı sonuçları daha küçük ama gerçek verilerden oluşmuş bir veri kümesi ile iyileştirmeyi hedeflemişlerdir. (Olszewski et al., 2020) Bazıları ise yüksek kaliteli az sayıda görüntü üzerinde çalışmalarını gerçekleştirmişleridir. (Zhu et al., 2021)

Bazı araştırmacılar (Tan et al., 2020; Jo et al., 2019) ise yüz'ü odağına alan problemlerinin çözümü için kullanılan FFHQ (Kerras et al., 2019), CelebA-HQ (Kerras et al., 2018) gibi bazı iyi bilinen veri kümelerinden faydalanmışlardır.

4.3 Değerlendirme Yöntemleri

Bu bölümde, saç sentezi probleminin çözümü için sunulan yöntemlerin başarılarının karşılaştırılması ve kullanılan yöntemlerin sonuçlarının değerlendirilmesi için kullanılan nitel ve nicel yöntemler üzerinde durulacaktır.

Nicel yöntemler, matematiksel bir metrik ile sonuçların değerlendirildiği yöntemlerdir. Bu yöntemler ile açıkça sonuçların başarısı değerlendirilebilir. Bu sayede çıktı olarak elde edilen nicel değerleri kullanarak hassas bir şekilde farklı çözümleri karşılaştırmak mümkün hale gelir. Saç sentezleme probleminin çözümünde elde edilen veri, görüntü olduğu için genellikle bu problemin başarısında görüntü değerlendirme metrikleri kullanılır. Bu metrikler, doğrudan tahmin edilen görüntüyle gerçek görüntünün arasındaki farkı hesaplayabildiği gibi bazıları da dağılımlarını karşılaştırabilir. Bu metriklere RMSE, PSNR, SSIM (Wang, Z. et al., 2004), LPIPS(Zhang et al., 2018), FID (Heusel et al., 2017), L1, L2 örnek olarak verilebilir.

Gerçekçi saç sentezi problemi, görsel çıktılar üretilen bir problem olduğu için nitel değerlendirme de çoğunlukla kullanılır. Bu değerlendirme şeklinde önerilen yöntem ve diğer yöntemlerin aynı girdiler için aynı amaca yönelik çıktıları istenir ve elde edilen çıktılar kişisel gözlemler ile değerlendirilir. Bu gözlemler özellikle nicel olarak yeterince değerlendirilemeyen problemlerin tespitinde sıklıkla kullanılır. Örneğin çıktılardaki yapay hatalar (artifact) gözlenir, ışık gibi görsel durumlar incelenebilir.

Bu bölümde belirtilen doğrudan saç sentezi problemine odaklanan yöntemler, kullandıkları temel yaklaşımlar ve sonuçlarını değerlendirme yöntemleri Tablo 4.1'de sunulmuştur.

Tablo 4.1. Literatür araştırması özeti

Çalışma	Yöntem	Veri Kümesi	Değerlendirme Yöntemi
(Zhu et al., 2021)	StyleGANv2 vektör uzayını görsel özelliklerin daha verimli taşınabildiği bir vektör uzayına dönüştürülerek bu uzayda saç stili probleminin çözümü üzerinde çalışılmıştır. Çalışma zamanında iteratif çalışan bir yöntemdir.	120 adet 1024x1024 çözünürlükte görseller kullanılmıştır. (Zhu et al., 2020)	Nitel gözlemler ve PSNR, RMSE, SSIM, VGG, LPIPS, FID gibi nicel metrikler.
(Saha et al., 2021)	Saç stil transferi yaparken aynı zamanda vektör uzayında saç'a ait detayları doldurabilir. Saçın algısal yapısı, görünümü ve stil bilgisini bir birinden ayırır ve her bir özellik için belirlenen kayıp fonksiyonları ile çalışma zamanında optimizasyon işlemi yapılır.	70.000 adet yüksek kaliteli görüntüden oluşan FFHQ veri kümesi kullanılmıştır.	FID, PSNR, SSIM gibi nicel metriklerin yanında görsel değerlendirmelerde bulunulmuştur.
(Tan et al., 2020)	Saçın görünümü, arkaplanı, şekli ve yapısının bir birbirini etkilemeden değişebildiği bir koşullu çekişmeli üretici ağ yöntemidir. Ayrıca düzenleme yapabilmek için bir arayüz uygulaması da geliştirmiştir.	70.000 adet yüksek kaliteli görüntüden oluşan FFHQ veri kümesi kullanılmıştır.	Nitel değerlendirmelerin yanı sıra nicel bir metrik olarak FID'den faydalanılmıştır.
(Wei et al., 2021)	Verilen referans görsel veya metin kullanılarak orjinal görüntüdeki saç bölgesinin düzenlenebildiği bir yöntem sunulmaktadır.	30.000 adet yüksek kaliteli görüntüden oluşan CelebA-HQ veri kümesi kullanılmıştır.	IDS, PSNR ve FID gibi metriklerle birlikte nitel değerlendirmeler de kullanılmıştır.
(Fan et al., 2021)	Saçın renk, yapı ve şeklinde düzenlemeler yapmaya izin veren bir koşullu çekişmeli üretici ağ yöntemidir.	70.000 adet yüksek kaliteli görüntüden oluşan FFHQ veri kümesi kullanılmıştır.	IDS, PSNR, ACD ve SSIM gibi nicel metriklerin yanında nitel değerlendirmeler de yapılmıştır.

5. ÇEKİŞMELİ ÜRETİCİ AĞLAR İLE SAÇ SENTEZİ

Bu bölümde saç sentezi için önerilen, çekişmeli üretici ağlar temelli yöntemimizin genel yapısı, alt modülleri ve eğitimi için kullanılan kayıp fonksiyonları hakkında bilgi verilecektir.

Bu çalışma kapsamında önerilen yöntemin gerçekleşmesi için Python programlama dili ve yapay zeka araştırmalarında sıkça kullanılan Pytorch kullanılmıştır.

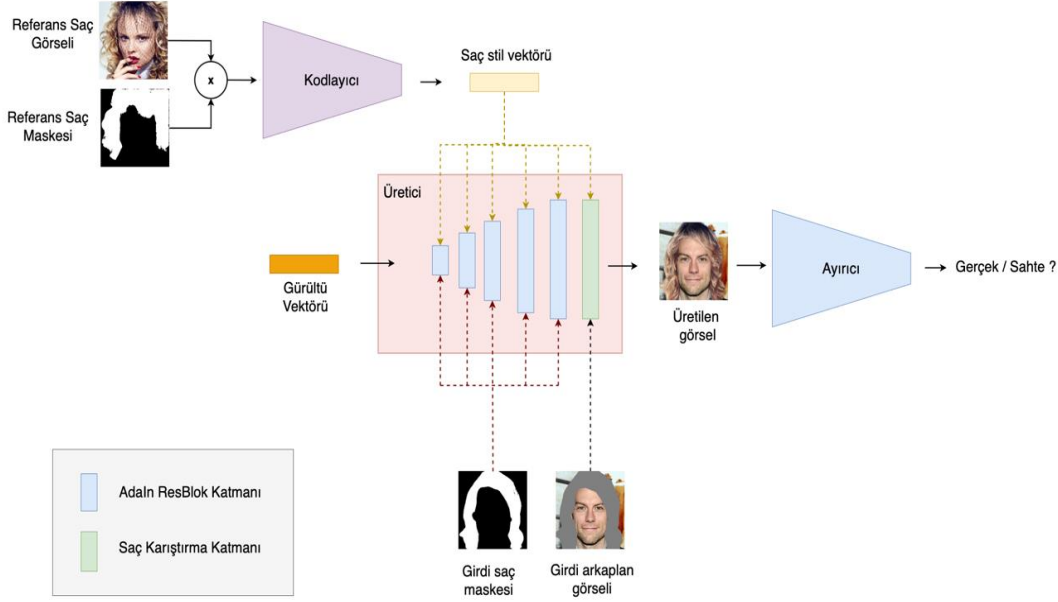
5.1 Genel Bakış

Günümüzde görüntülerde gerçekçi saç sentezleme işlemi önemli alanlarda kullanılabilir. Bu işlem, saç rengi ve şeklini değiştirerek kimliği gizlenen kayıp veya suçlu bireylerin olası durumlarının tahmininde yada gelecekte görsel verilerde anonimliğin sağlanması için yapılan veri işlemlerinde destekleyici etken olarak kullanılabilir. Ayrıca kişisel görünümünde değişiklik yapmak isteyen kişiler, uzun süreli fiziksel değişime maruz kalmadan olası durumlarını görüp, önceden bir değerlendirme yapabilirler. Tüm bu ve benzeri kullanım alanlarının yanı sıra gerçekçi saç sentezleme problemi, saçın doğası itibariyle zorlu bir problemdir. Bu problem içerisinde bir çok zorlu alt problem içerir. İnsan yüzünün diğer bölümlerinin aksine kendine özgü geometrisi ve materyali saçın analiz, temsil ve üretimini zorlaştırmaktadır. Daha detaylı incelendiğinde zorlu saç maskesi sınırları, hassas saç şekli kontrolü ihtiyacı, arka plan ile saçın kusursuz kesişimi, bu problemin temel zorluklarından bazıları olarak gösterilebilir. Çekişmeli üretici ağlar ile saç sentezi probleminin görece yeni bir alan olmasından dolayı, oldukça dar bir literatüre sahiptir. Biz de, bu tez kapsamında çekişmeli ağlar ile gerçekçi saç sentezinde literatürdeki en iyi yöntemler ile yarışır sonuçlar veren bir yöntem sunuyoruz.

5.2 Yöntem

Önerilen yöntem bir çekişmeli üretici ağ mimarisidir (Şekil 5.1). Yöntem, bir kodlayıcı ağ, bir üretici ağ ve bir ayırıcı ağdan oluşmaktadır. Üretici ağ iki kısımdan

oluşur. İlk kısım saç üretim katmanlarından ikinci kısım ile saç karıştırma katmanından oluşmaktadır. Üretici ağın ilk kısmı, gerçekçi saçların üretilmesinden sorumludur ikinci kısmı ise üretilen saç'ın arka plan ile kusursuz bir şekilde karıştırılması ve son düzenlemelerinin yapılması görevini üstlenir.



Şekil 5.1. Geliştirilen yönteme genel bakış

Kodlayıcı ağ, çekişmeli üretici ağ'ın koşul girdisini üretmektedir. Bu girdi üretilmek istenilen saçı temsil eden referans saçtan elde edilmiş bir vektördür. Referans saç'a sahip görsel, saç maskesi ile maskelendikten sonra referans saç bölgesi elde edilir. Referans saç bölgesini girdi olarak alan kodlayıcı ağ, çıktı olarak saç bölgesinin vektör uzayda bir temsilini üretir. Bu temsil ve rasgele örneklenmiş gürültü vektörü üretici ağ'ın girdisidir. Ayrıcı ağ ise üretici ağ'ın çıktılarının gerçekliğini değerlendirmekle yükümlüdür. Geliştirilen yöntem şekil 5.1 de gösterilmiştir.

5.2.1 Saç üretici ağ

Üretici ağ (G), iki kısımdan oluşmaktadır. İlk kısım, girdi olarak aldığı gürültü vektörü ile referans saç'tan elde edilen stil vektörünü kullanarak saç sentezi işlemini gerçekleştirmektedir. İkinci kısım ise, sentezlenen saç ve arkaplan görüntüsünün karıştırılmasından ve son düzenlemelerinin yapılmasından

sorumludur. Gürültü vektörü, normal dağılımdan örneklenir ve $p_z(x)$ şeklinde ifade edilebilir. Stil vektörü ise s ile ifade edilebilir. Sonuç olarak gürültü vektörü ve kontrol değişkenini gerçekçi saç sentezine dönüştüren üretici ağ, denklem 5.1 ile ifade edilebilir.

$$X = G(z|s) \quad 5.1$$

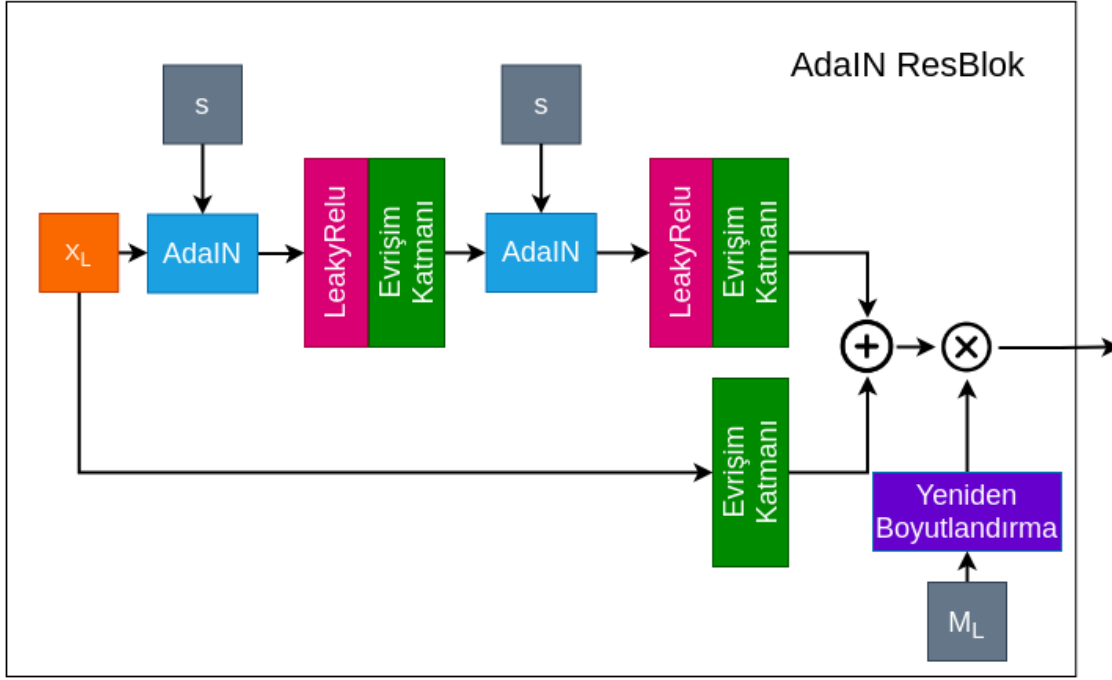
Üretici ağın ilk kısmı, AdaInResBlok katmanlarından oluşmaktadır.

5.2.1.1 AdaINResBlok katmanı

Adaptif Örnek Normalizasyonu (AdaIN) (Kerras et al.,2019; Dumoulin et al., 2016; Dumoulin et al., 2018; Ghiasi et al., 2017) , bir önceki katmandan gelen içerik girdisini ve stil vektörünü girdi olarak alır ve içerik girdisini istatistiksel olarak stil vektörüne hizalar. Hizalama işlemi basitce ortalama(μ) ve standart sapma(σ) değeri ile normalize edilmiş içerik girdisinin, stil vektörünün standart sapmasıyla ölçeklenerek, yine kontrol değişkeninin ortalaması kadar ötelenmesidir. AdaIN işlemi denklem 5.2 ile ifade edilebilir.

$$AdaIN(X, y) = \sigma(y) \left(\frac{X - \mu(X)}{\sigma(X)} \right) + \mu(y) \quad 5.2$$

AdaInResBlok katmanı (Choi et al., 2020), RestBlok katmanına AdaIN normalizasyonunun entegre edilmiş versiyonudur. Bu katmanda kontrol değişkeni, AdaIN vasıtasıyla ağ'a enjekte edilir. Böylelikle üretici ağın katmanlarında kontrol değişkenine istatistiksel olarak bir yaklaşma söz konusu olur. AdaINRestBlok katmanı, girdisini iki kez, adaptif örnek normalleştirme, aktivasyon fonksiyonu ve evrişim katmanı üçlüsünden geçirir. Elde edilen çıktı, girdinin başka bir evrişim katmanı çıktısı ile toplanarak sonuca aktarır. Şekil 5.2'de yöntemimizde kullanılan AdaINResBlok gösterilmektedir.



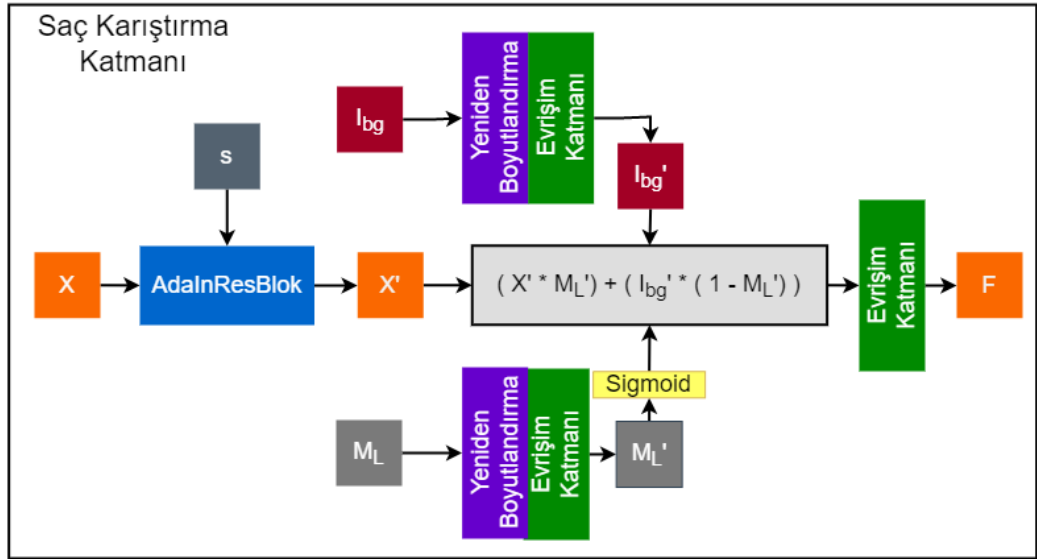
Şekil 5.2. AdaINResBlok katmanı

AdaINResBlok'lardan oluşan üretici ağ'ın ikinci kısmı saç karıştırma katmanıdır. Bu iki kısım birlikte üretici ağ'ı oluşturmaktadır.

5.2.1.2 Saç karıştırma katmanı

Gerçekçi saç sentezleme probleminin en önemli alt problemlerinden birisi üretilen saç ile arkaplan görüntüsünün kusursuz bir şekilde karıştırılmasının sağlanmasıdır. Bu problemin çözümü için, alfa ve poisson karıştırma yöntemi gibi yöntemler kullanılabileceği gibi üretici ağ'ın tamamı veya ek bir ağ ile de karıştırma problemini çözümü üzerinde çalışmak mümkündür (Pérez, P. et al., 2003; Zhang, L. et al. 2020; Wu, H. et al., 2019). Bu tez kapsamında önerilen yöntem, gerçekçi saç sentezi yapılırken aynı zamanda verimli bir yöntem olması da beklendiğinden önerilen yöntemde ek bir ağ kullanılması tercih edilmemiştir. Onun yerine üretici ağ'ın son katmanını oluşturan saç karıştırma katmanı öneriyoruz. Bu katmanda içerik girdisi AdaIN ResBlok'tan geçirdikten sonra saç maskesi ile çarpılır ve orjinal görüntüdeki arkaplan bölgesiyle toplanır. Elde edilen çıktı bir evrişim katmanından geçirilerek üretici ağ'ın nihai çıktısı elde edilmiş olur. Bu karıştırma işleminin üretici ağ'ın sonunda gerçekleştirilmesi, ayırıcı ağ'ın karıştırılacak

alanların gerçekçi bir şekilde düzenlemesini denetleyebilmesini sağlar. Saç karıştırma katmanı Şekil 5.3’de gösterilmektedir.



Şekil 5.3. Saç karıştırma katmanı

5.2.2 Ayırıcı ağ

L2 ve L1 kayıp fonksiyonları tek başına gerçekçi çıktılar üretmekte yeterli olamamakta, fotoğraf üretme probleminde bulanık çıktılara sebep olmaktadır (Larsen, A. et al., 2016). Bu kayıp fonksiyonları, yinede düşük frekans özellikleri yakalamada başarılılardır. (Isola, P. et al., 2017). Bu çalışmada kullanılan ayırıcı ağ evrişim katmanlarından oluşan bir kodlayıcı ağıdır. Bu ağ üretici ağ tarafından sentezlenen görüntülerin gerçekliğini değerlendirmek ve değerlendirme sonuçlarıyla üretici ağı daha gerçekçi çıktılar üretmeye teşvik etmekle yükümlüdür. Aldığı görüntü girdisini tek kanallı $N \times N$ 'lik bir çıktıya eşleyerek, yerel özniteliklerin istatistiksel özelliklerini yakalamayı amaçlamaktadır. (Li and Wand., 2016; Isola et al., 2017). Ayırıcı ağ'ın aldığı görüntünün gerçekliğini değerlendirmesi, denklem 5.3’de ifade edilmektedir.

$$p = D(X)$$

5.2.3 Eniyilenen kayıp fonksiyonları

$X \in R^{H \times W \times C}$, $s \in R^{512}$, $z \in R^{512}$ olmak üzere, önerilen yöntem aşağıdaki anlatılan kayıp fonksiyonlarını optimize etmektedir.

5.2.3.1 Algısal kayıp fonksiyonu

Saç bölgesine ait yüksek seviyeli özneliklerin korunabilmesi için önceden ImageNet (Deng et al., 2009) üzerinde eğitilmiş bir VGG19 (Simonyan and Zisserman., 2014) modelini kullanarak, algısal kayıp (Johnson et al., 2016; Gatys et al., 2016) değerini hesaplıyoruz. Bu kayıp fonksiyonunda sentetik ve gerçek görüntünün VGG19 ağının ara katmanlarındaki aktivasyonlarının birbirinden uzaklığı hesaplanır. Böylece üretici ağı gerçek saç ile daha uyumlu çıktılar üretmesi için teşvik etmektedir. Algısal kayıp fonksiyonu denklem 5.4'te gösterilmektedir.

$$L_{algısal} = L_1(Vgg(X) - Vgg(G(X))) \quad 5.4$$

5.2.3.2 Stil kayıp fonksiyonu

Verilen saç bölgesine ait özelliklerin, vektör uzayda başarılı bir şekilde temsil edilebilmesi, üretilen çıktılarda istenilen seviyede elde edilebilmesi açısından kritik öneme sahiptir. Stil kayıp fonksiyonu, saç bölgesini vektör uzayda bir temsile dönüştüren kodlayıcı ağı en iyi temsili üretecek şekilde teşvik etmektedir. Stil kayıp değeri, gerçek saç bölgesinden elde edilen stil vektörü temsili ile üretilen saç bölgesinden elde edilen stil vektörü arasında L1 mesafesi hesaplanarak elde edilir. Stil kayıp fonksiyonu denklem 5.5 ile gösterilebilir. (Huang et al., 2018; Zhu et al., 2017).

$$L_{stil} = L_1(E(X_{saç}), E(X'_{saç})) \quad 5.5$$

5.2.3.3 Piksel kayıp fonksiyonu

Algısal kayıp fonksiyonuyla yüksek frekanslı bölgeler yakalanabilse de, çıktının doğru renkte ve doğru ışıkta olması gibi düşük frekanslı özelliklerin

yakalanabilmesi için piksel kayıp fonksiyonu kullanılmaktadır. Bu kayıp fonksiyonunda girdi ve çıktı resimlerinin pixel tabanlı farklı alınarak hesaplanır ve üretici ağı düşük seviyeli öznetelikleri yakalayabilecek şekilde üretim yapmaya teşvik eder. Piksel kayıp fonksiyonu, denklem 5.6'da gösterilmektedir.

$$L_{piksel} = L_1(X, X') \quad 5.6$$

5.2.3.4 Çekişmeli kayıp fonksiyonu

Çekişmeli kayıp fonksiyonu çekişmeli üretici ağlar tabanlı yöntemimizin stabil bir şekilde eğitilmesi amacıyla kullanılan kayıp fonksiyonudur. Gerçek ve üretilen görsellerin ayırıcı ağ çıktılarına göre üretici ve ayırıcı ağ arasındaki çekişmeli eğitimin gerçekleşmesini sağlar.

$$L_{çekişmeli} = E_x [\log D(X)] + E_{z,s,M} [\log (1 - D(G(z, s, M)))] \quad 5.7$$

5.2.3.5 Genel amaç fonksiyonu

Algısal kayıp, Stil kayıp ve Piksel kayıp fonksiyonundan oluşan önerilen yöntem için kullanılan genel amaç fonksiyonu denklem 5.8 ile gösterilmektedir.

$$\min_G \max_D (\lambda_{piksel} * L_{piksel} + \lambda_{stil} * L_{stil} + \lambda_{algısal} * L_{algısal} + \lambda_{çekişmeli} * L_{çekişmeli}) \quad 5.8$$

6. DENEYSEL ÇALIŞMALAR

Bu bölümde, bu tez kapsamında Çekişmeli üretici ağlar ile gerçekçi saç problemi için önerilen yöntemi ve onun farklı konfigürasyonlarını değerlendirebilmek için hazırlanan deney ortamlarından ve elde edilen deney sonuçlarından bahsedilecektir.

6.1 Veri Kümesinin Hazırlanması

Deneysel çalışmalarda FFHQ veri kümesi kullanılmıştır. FFHQ veri kümesi 70000 adet yüksek kaliteli (1024x1024) görselden oluşur. Celeb-HQ veri kümesinden yaş, etnik köken ve arka plan açısından çok daha fazla varyasyona sahip olmakla birlikte şapka, güneş gözlüğü gibi birçok aksesuar da içermektedir. Flickr web sitesinden çekilen görüntüler otomatik olarak hizalanmış ve kırılmıştır (Kerras et al., 2019).

MichiGAN ile adil bir karşılaştırma yapabilmek adına, yöntemimizin eğitiminde MichiGAN ön işleme adımları izlenerek eğitime hazırlanmış veri kümesi kullanılmıştır. Kullanılan ön işleme adımları sonucunda elde edilen veri kümesi 56000 eğitim ve 14000 test olacak şekilde iki farklı kümeden oluşmaktadır. Görseller 512x512 çözünürlüğe indirilmiş ve saç'a ait bölgelerin ikili maskeleri çıkarılmıştır. Önerilen yöntem, 128x128'lik çözünürlükteki girdiler için tasarlandığından MichiGAN ön işleme prosedürüne ek olarak 128x128'e yeniden boyutlandırma işlemi uygulanmıştır. Belirlenen ön işlemeler sonucunda elde edilen görüntülerden rastgele seçilmiş örnek şekil 6.1 de gösterilmiştir.



Şekil 6.1. FFHQ veri kümesinden rastgele seçilmiş örneklerin önışleme sonuçları.

Önerilen yöntemde saç bölgesini temsilen ikili saç maskesine ihtiyaç duyulmaktadır. Bahsedilen önışleme sonucunda saç olan bölgeler 1, olmayan bölgelerin 0 değerini aldığı ikili maskeler de elde edilmiştir. Bazı örnekler ve ikili maskeleri şekil 6.2’de gösterilmiştir.



Şekil 6.2. FFHQ veri kümesinden rastgele seçilmiş bazı örnekler ve ikili saç maskeleri

6.2 Deney Ortamı

Tez kapsamında yapılan çalışmalarda 8GB belleğe sahip NVIDIA RTX2080 ekran kartı, intel core i9 9900K @ 3.6GHz 16 çekirdekli işlemci, 32 GB RAM ve Ubuntu 18.04 işletim sistemi ve CUDA 10.2 ye sahip bir bilgisayar kullanılmıştır.

Yöntemlerin gerçekleşmesi için Python programlama dilinin 3.6.7 sürümü ve Pytorch kütüphanesinin 1.8.1 sürümü kullanılmıştır.

6.3 Deney Sonuçları

Bu bölümde, önerilen yöntem ile Bölüm 6.1’de eğitim için hazırlanma süreci anlatılan veri kümesi kullanılarak deneyler yapılmıştır. Yapılan deneyler hem nicel hemde nitel olarak değerlendirilmiştir. Nitel ve nicel testlerin yapılması ve sonuçların değerlendirilmesi için bölüm 6.1 de belirtilen test kümelerindeki görseller kullanılmıştır. Önerilen yöntemin eğitimi sırasında, eniyileme yöntemi olarak Adam (Kingma et al., 2014) eniyileme algoritması kullanılmıştır. Üretici ağ ve ayırıcı ağ için öğrenme oranı 0.0001, B1 ve B2 parametreleri için sırasıyla 0.5 ve 0.999 değerleri kullanılmıştır. Eğitim süresi 55 dönem (epoch), yığın büyüklüğü (batch size) 8 olarak uygulanmıştır. Tüm kayıp fonksiyonu lambda değerleri 1 olarak belirlenmiştir.

6.3.1 Saç yeniden yapılandırma

Saç stili yeniden yapılandırma görevi, ilgili girdiler sağlandığına orijinal saç görüntüsünü elde etmenin hedeflendiği bir görevdir. Saç stili yeniden yapılandırma görevinde girdi ve referans görüntü için aynı görsel seçilir. Önerilen yöntemin çalışması için gerekli girdiler saç maskesi, arka planı, saç bölgesi hazırlanır. Bu girdiler sonucunda orijinal görüntü model tarafından oluşturulmaya çalışılır. Bu işlem denklem 6.1 ile formülize edilebilir.

$$G(z, X_{maske}, X_{arkaplan}, E(X_{saç})) = X' \quad 6.1$$

Geliştirilen yöntemin stil yeniden yapılandırma görevindeki bazı sonuçları Şekil 6.3'te gösterilmektedir.



Şekil 6.3. Önerilen yöntemin saç stili yeniden yapılandırma görevi için elde ettiği bazı sonuçlar. Orjinal görüntü sol, sentezlenen görüntü sağ tarafta yer almaktadır.

6.3.2 Saç stil transferi

Saç stil transferi görevinde, seçilen bir girdi görseli için farklı bir referans görseli seçilir. Girdi ve referans görselden elde edilen ilgili materyaller yönteme girdi olarak verilir ve sonuç olarak orijinal görüntünün, referans saç stili ile üretilmesi amaçlanır. Saç stili transfer işlemi denklem 6.2 ile formülize edilebilir.

$$G(z, X_{maske}, X_{arkaplan}, E(R_{saç})) = X' \quad 6.2$$

Önerilen yöntem ile elde edilen saç stili transferi sonuçları Şekil 6.4'te gösterilmektedir.



Şekil 6.4. Önerilen yöntemin saç stili transferi görevi için elde ettiği bazı sonuçlar. Orijinal görüntü 1. sütun, sentezlenen görüntüler diğer sütunlarda yer lmaktadır. Referans saç stili görseli ve hedef saç maskesi çıktı görselinin alt kısmında yer almaktadır.

6.3.3 Saç şekli düzenleme


Saç şekli düzenleme görevi, görseldeki saç bölgesinin düzenlenerek farklı şekillere sahip saç üretimini içermektedir. Saçın stilini değiştirmenin yanı sıra, saç şeklinde yapılabilen değişimler daha ileri bir saç sentezme seçeneği sunmaktadır. Bu görev kapsamında, orijinal görsel, referans görsel ve bu görsellere karşılık gelen saç maskeleri elde edildikten sonra orijinal görselin saç maskesi üzerinde bazı düzenlemeler yapılır. Bu düzenlemeler sonucunda elde edilen yeni saç

maskesindeki saç bölgelerinde görsele uygun bir şekilde saç üretilmesi hedeflenir. Saç şekli düzenleme görevi denklem 6.3 ile ifade edilebilir.

$$G(z, X_{\text{düzenlenmiş maske}}, X_{\text{arkaplan}}, E(R_{\text{saç}})) = X' \quad 6.3$$

Önerilen yöntemin saç şekli düzenleme görevindeki sonuçları Şekil 6.5'te gösterilmektedir.





Şekil 6.5 Önerilen yöntemin saç şekli düzenleme görevinde elde ettiği bazı sonuçlar.

Şekil 6.5'te görüldüğü üzere önerilen yöntem, stil transferi görevi ile birlikte şekilde düzenleme görevinde de başarılı sonuçlar elde etmiştir.

6.3.4 Önerilen yöntemin literatür ile karşılaştırılması

Bu bölümde önerilen yöntem, literatürdeki en başarılı sonuçlar seviyesinde sonuçlar elde edebilen MichiGAN yöntemi ile hem üretilen görsellerin kalitesi hem de çalışma zamanı verimliliği açısından değerlendirilmiştir. Önerilen yöntemin ve MichiGAN yönteminin FFHQ veri kümesinden rastgele seçilmiş görseller üzerinde saç yeniden yapılandırma ve saç stil transferi görevleri gerçekleştirilmiş buradan elde edilen çıktılar üzerinden görsel kalitelerinin nicel ve nitel değerlendirilmeleri yapılmıştır.

Saç stil yeniden yapılandırılması görevinde ilgili girdilerden orjinal görselin kendisi sentezlenmesi amaçlanır. Şekil 6.6 incelendiğinde önerilen yöntemin stil yeniden yapılandırma görevinde nitel açıdan başarılı çıktılar elde ettiği görülmektedir.




Şekil 6.6. Önerilen yöntemin saç stil yeniden yapılandırması görevi için elde ettiği bazı sonuçlar. Orjinal görüntü ilk sütun, MichiGAN ikinci sütun ve önerilen yöntem üçüncü sütunda gösterilmektedir.

Şekil 6.6 incelendiğinde saç dışındaki bölgenin tamamen korunduğu ve sadece ilgili saç bölgesinin sentezlendiği görülmektedir. Elde edilen sentezlenmiş görüntülerin orjinal görüntüler ile arasındaki farkın az olması, saç stili yeniden

yapılandırma görevi için iki yöntemin de yüksek başarılarla sahip olduğunu göstermektedir.

Saç stil transferi görevinde, girdi resmine ek olarak farklı bir referans resim seçilir. Seçilen referans resimdeki saç'ın stil özellikleri girdi resmine aktarılması hedeflenir. Bu görevin sonucunda saç dışında bir bölgenin değişmemesi ve saç bölgesi ile arka plan görseli arasındaki geçişin gerçekçi yapılması beklenir. Şekil 6.7'da, önerilen yöntemin literatürdeki en başarılı sonuçlar seviyesinde çıktılar elde edebilen MichiGAN ile karşılaştırması gösterilmektedir.





Şekil 6.7. Önerilen yöntemin saç stili transferi görevi için elde ettiği bazı sonuçlar. Orjinal örüntü ilk sütun, referans görüntü ikinci sütun, MichiGAN sonuçları üçüncü sütun ve önerilen yöntemin sonuçları dördüncü sütunda gösterilmektedir.

Yöntemlerin çıktılarının başarısı görsel olarak araştırmacılar tarafından değerlendirilmekle birlikte görsel veri üretiminde bu değerlendirme için sıkça kullanılan metrikler bulunmaktadır. Bu metriklerden en yaygın kullanılanı Frechet Inception Distance (FID)'dir. Önerilen yöntemin MichiGAN ile FID, PSNR ve SSIM metrikleri kullanılarak karşılaştırılması Tablo 6.1'de gösterilmektedir.

Tablo 6.1. Önerilen yöntemin MichiGAN ile FID metriği kullanılarak karşılaştırılması. FID değeri küçüldükçe daha iyi, PSNR ve SSIM metriklerinde ise değer yükseldikçe daha iyi anlamına gelmektedir.

Yöntemler	Saç Stil Yeniden Yapılandırma			Saç Stil Transferi		
	FID	PSNR	SSIM	FID	PSNR	SSIM
MichiGAN	26.607	32.993	0.872	31.160	32.361	0.791
Önerilen Yöntem	26.171	35.881	0.907	33.111	34.283	0.819

Her iki yöntemin sonuçları, FFHQ test veri kümesinden rastgele seçilen 5000 adet orijinal ve referans görsel çiftinden oluşturulan veri kümesi üzerinde değerlendirilmiştir. MichiGAN sonuçları 512x512 çözünürlüğüne sahip olduğundan bilinear interpolasyon yöntemi ile 128x128'e yeniden boyutlandırılmıştır. Sentezlenecek veya stil vektörü ile temsil edilecek bölge saç bölgesi olduğundan, görseller en az %3 saç bölgesi içeren görseller arasından seçilmiştir. Tablo 6.1'de görüldüğü üzere, önerilen yöntem saç yeniden yapılandırma görevinde MichiGAN'dan daha yüksek performans sergilemekle birlikte saç stil transferi görevinde gerisinde kalmıştır. Bu değerlendirmeden de görüldüğü üzere, önerilen yöntem literatürdeki en iyi yöntemler ile yarışır seviyede başarılı görsel çıktılar üretebilmektedir.

Önerilen yöntem görsel başarı olarak literatürdeki en iyi yöntemler başarısında çıktıları üretmeyi hedeflemekle birlikte en önemli hedeflerinden birisi de gerçek zamana yakın hızlarda bu saç sentezi yapabilmektir. Bu bağlamda önerilen yöntemin çalışma hızı ve bellek verimliliği önem kazanmaktadır. Önerilen yöntemin verimlilik açısından başarılı olabilmek için 128x128 çözünürlüğünde görseller üzerinde eğitimi yapılmıştır. Bu durum yüksek çözünürlüklü görseller üretme açısından rakiplerine karşı doğal bir dezavantaja sahip olması anlamına gelirken bellek ve çalışma hızı açısından kendisine avantaj sağlamaktadır. Tablo

6.2’de, önerilen yöntem ile MichiGAN yöntemi çalışma zamanı hızı, parametre sayısı ve görsel çözünürlüğü açısından karşılaştırılmaktadır.

Tablo 6.2. Önerilen yöntemin MichiGAN ile çalışma zamanı hızı, bellek ve görsel çözünürlüğü açısından karşılaştırılması. FPS değeri, 500 adet görsel üzerinden hesaplanmıştır.

Yöntemler	Görsel / Saniye (FPS)	Parametre Sayısı (M)	Çözünürlük (Piksel)
MichiGAN	2.46	109.5	512x512
Önerilen Yöntem	31.25	33.12	128x128

Tablo 6.2’deki sonuçlar bir görsel üretimi için ortalama süre hesaplanılarak elde edilmiştir. Üretim sürecine model yükleme hariç diğer kaynakların yüklenmesi ve kaydedilmesi dahil edilmiştir. Geliştirilen yöntem çıktı çözünürlüğü açısından MichiGAN’dan 4 kat daha düşük bir çözünürlüğe sahip olmasının hız avantajına sahip olduğu da göz önünde bulundurularak MichiGAN’dan yaklaşık 12 kat ($31.25/2.46 \sim 12$) daha yüksek çalışma hızına ve yaklaşık 3 kat ($109.5/33.12 \sim 3$) daha düşük bellek alanına sahiptir. Çalışma zamanı hızını ölçebilmek için saniye başına işlenen görüntü sayısı dikkate alınmıştır. Parametre sayıları iki yöntemin de üretici ağırları üzerinden hesaplanmıştır.

7 SONUÇ VE GELECEK ÇALIŞMALAR

Bu tez çalışmasında saç sentezi probleminin çözümü için bir Çekişmeli üretici ağ mimarisi önerilmiştir. Önerilen yöntemin başarısı saç stil transferi, saç yeniden yapılandırma ve saç şekli düzenleme görevleri için test edilmiştir. Saç stil transferi ve saç yeniden yapılandırma görevlerinde literatürdeki en iyi yöntemlerden birisi olan MichiGAN ile hem nitel hemde nicel karşılaştırmalar yapılmıştır.

Önerilen yöntem bir üretici, bir kodlayıcı ve bir üretici ağ'dan oluşmaktadır. Üretilen saç bölgesinin orjinal görüntü ile başarılı bir şekilde karıştırılması için Saç Karıştırma Katmanı tasarlanmıştır. Bir kodlayıcı ağ vasıtasıyla referans saç'a ait stil vektörü elde edilmiş ve bu stil vektörü AdaIN vasıtasıyla üretici ağ'a enjekte edilmiştir. Bu işlemler sonucunda uçtan uca saç sentezi yapabilen bir yöntem önerilmiştir. Önerilen yöntem, FFHQ veri kümesi ile sözde-denetimli bir şekilde eğitilmiştir.

Eğitim sonucunda elde edilen modelin gerçekçi saç üretimi başarısı FID, PSNR ve SSIM metriği kullanılarak MichiGAN yöntemi ile karşılaştırılmış ve iki yöntem benzer seviyelerde başarılar elde etmişlerdir. Önerilen yöntem, gerçekçi sentezleme yeteneği ile birlikte çalışma zamanı bellek açısından da verimli olmayı da amaçlamaktadır. MichiGAN ile yapılan çalışma zamanı hızı karşılaştırmasında yaklaşık 12 kat daha hızlı ve yaklaşık 3 kat daha az bellek alanına sahip olduğu gösterilmiştir. Bu hız değerlendirilirken MichiGAN'ın 512x512 çözünürlükte görseller ürettiği ancak önerilen yöntemin 128x128 çözünürlüğe sahip görseller ürettiği göz önünde bulundurulmalıdır.

Sonuç olarak önerilen yöntem literatürdeki en iyi yöntemlerle yarışır kalitede saç sentezi yapabilirken, gerçek zamanlı bir işletim hızına da sahiptir. Yapılan çalışmanın yakın gelecekte, araştırmacılar için gerçek zamanlı saç sentezi çalışmalarına katkı sağlayacağını ön görülmektedir.

KAYNAKLAR DİZİNİ

- Ackley, D. H., Hinton, G. E. and Sejnowski, T. J.**, 1985, A learning algorithm for Boltzmann machines. *Cognitive science*, 9(1), 147-169 pp.
- Albawi, S., Mohammed, T. A and Al-Zawi, S.**, 2017, Understanding of a convolutional neural network. In *2017 International Conference on Engineering and Technology (ICET)*, 1-6 pp.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... and Farhan, L.**, 2021, Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8(1), 1-74pp.
- Apicella, A., Donnarumma, F., Isgrò, F. and Prevete, R.**, 2021, A survey on modern trainable activation functions. *Neural Networks*.
- Arjovsky, M., Chintala, S. and Bottou, L.**, 2017, Wasserstein generative adversarial networks. In *International conference on machine learning*, 214-223pp.
- Child, R.**, 2020, Very deep vaes generalize autoregressive models and can outperform them on images. *arXiv preprint arXiv:2011.10650*.
- Choi, Y., Uh, Y., Yoo, J. and Ha, J. W.**, 2020, Stargan v2: Diverse image synthesis for multiple domains. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 8188-8197pp.
- Chollet, F. and others.**, 2015, Keras, <https://keras.io/> (Erişim tarihi: 3 Aralık 2021)
- Daz Productions**, 2017, <https://www.daz3d.com/> (Erişim tarihi: 11 Kasım 2021)
- Deng, J., Guo, J., Xue, N. and Zafeiriou, S.**, 2019, Arcface: Additive angular margin loss for deep face recognition. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4690-4699pp.
- Deng, Jia, Wei Dong, Richard Socher, Li-Jia Li, Kai Li and Li Fei-Fei.**, 2009, Imagenet: A large-scale hierarchical image database, *IEEE conference on computer vision and pattern recognition*, 248-255pp.

KAYNAKLAR DİZİNİ (devam)

- Du, Y. and Mordatch, I.**, 2019, Implicit generation and generalization in energy-based models. *arXiv preprint arXiv:1903.08689*.
- Fahlman, S. E., Hinton, G. E. and Sejnowski, T. J.**, 1983, Massively parallel architectures for AI: NETL, Thistle, and Boltzmann machines. In *National Conference on Artificial Intelligence, AAAI*.
- Fan, W., Fan, J., Yu, G., Fu, B. and Chen, T.**, 2021, HSEGAN: Hair Synthesis and Editing Using Structure-Adaptive Normalization on Generative Adversarial Network, *IEEE International Conference on Image Processing (ICIP)*, 1324-1328pp.
- Gatys, L. A., Ecker, A. S. and Bethge, M.**, 2016, Image style transfer using convolutional neural networks. In Proc. CVPR, 2414–2423pp.
- Gecer, B., Ploumpis, S., Kotsia, I. and Zafeiriou, S.**, 2019, Ganfit: Generative adversarial network fitting for high fidelity 3d face reconstruction. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 1155-1164pp.
- Ghiasi, G., Lee, H., Kudlur, M., Dumoulin, V. and Shlens, J.**, 2017, Exploring the structure of a real-time, arbitrary neural artistic stylization network. *arXiv preprint arXiv:1705.06830*.
- Goh, Y. C., Cai, X. Q., Theseira, W., Ko, G. and Khor, K. A.**, 2020, Evaluating human versus machine learning performance in classifying research abstracts. *Scientometrics*, 125(2), 1197-1212pp.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... and Bengio, Y.**, 2014, Generative adversarial networks. *arXiv preprint arXiv:1406.2661*.
- Goodfellow, I., Bengio, Y., Courville, A. and Bengio, Y.**, 2016, *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press, 108-109pp.
- Gui, J., Sun, Z., Wen, Y., Tao, D. and Ye, J.**, 2020, A review on generative adversarial networks: Algorithms, theory, and applications. *arXiv preprint arXiv:2001.06937*.

KAYNAKLAR DİZİNİ (devam)

- Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V. and Courville, A.,** 2017, Improved training of wasserstein gans. *arXiv preprint arXiv:1704.00028*.
- Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B. and Hochreiter, S.,** 2017, Gans trained by a two time-scale update rule converge to a local nash equilibrium, In *Advances in neural information processing systems*, 6626–6637.
- Hinton, G. E., Osindero, S. and Teh, Y. W.,** 2006, A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554pp.
- Hinton, G. E. and Sejnowski, T. J.,** 1986, Learning and relearning in Boltzmann machines. *Parallel distributed processing: Explorations in the microstructure of cognition*, 282-317pp.
- Hinton, G. E., Sejnowski, T. J. and Ackley, D. H.,** 1984, *Boltzmann machines: Constraint satisfaction networks that learn*. Pittsburgh, PA: Carnegie-Mellon University, Department of Computer Science.
- Ho, J., Jain, A. and Abbeel, P.,** 2020, Denoising diffusion probabilistic models. *arXiv preprint arXiv:2006.11239*.
- Isola, P., Zhu, J. Y., Zhou, T. and Efros, A. A.,** 2017, Image-to-image translation with conditional adversarial networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1125-1134pp.
- Jacques, M.,** 2020, Batch vs Mini-batch vs Stochastic Gradient Descent with CodeExamples. <https://edgeaiguru.com/Batch-vs-Mini-batch-vs-StochasticGradient-Descent> (Erişim tarihi: 28 Nisan 2021)
- Jo, Y. and Park, J.,** 2019, Sc-fegan: Face editing generative adversarial network with user's sketch and color. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 1745-1753pp.
- Justin Johnson, Alexandre Alahi, and Fei-Fei Li.,** 2016, Perceptual losses for real-time style transfer and super-resolution. CoRR, abs/1603.08155.
- Karen Simonyan and Andrew Zisserman.,** 2014. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.

KAYNAKLAR DİZİNİ (devam)

- Karras, T., Aittala, M., Laine, S., Härkönen, E., Hellsten, J., Lehtinen, J. and Aila, T.**, 2021, Alias-free generative adversarial networks. In *Thirty-Fifth Conference on Neural Information Processing Systems*.
- Karras, T., Aila, T., Laine, S. and Lehtinen, J.**, 2017, Progressive growing of GANs for improved quality, stability, and variation. *arXiv preprint arXiv:1710.10196*.
- Karras, T., Laine, S. and Aila, T.**, 2019, A style-based generator architecture for generative adversarial networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4401-4410pp.
- Kingma, D. P. and Welling, M.**, 2013i, Auto-encoding variational bayes. *arXiv preprint arXiv:1312.6114*.
- Kingma, D. P.**, 2013, Fast gradient-based inference with continuous latent variable models in auxiliary form. *arXiv preprint arXiv:1306.0733*.
- Kupyn, O., Budzan, V., Mykhailych, M., Mishkin, D. and Matas, J.**, 2018, Deblurgan: Blind motion deblurring using conditional adversarial networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 8183-8192pp.
- Larsen, A. B. L., Sønderby, S. K., Larochelle, H. and Winther, O.**, 2016, Autoencoding beyond pixels using a learned similarity metric. In *International conference on machine learning*, 1558-1566pp.
- Laticis Imagery**, 2017, <https://www.daz3d.com/whiskers-for-genesis-3-male-s> (Erişim tarihi: 11 Kasım 2021)
- LeCun, Y., Chopra, S., Hadsell, R., Ranzato, M. and Huang, F.**, 2006, A tutorial on energy based learning. *Predicting structured data*.
- LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R., Hubbard, W. and Jackel, L.**, 1989, Handwritten digit recognition with a back-propagation network. *Advances in neural information processing systems*.

KAYNAKLAR DİZİNİ (devam)

- Li, C. and Wand, M.**, 2016, Precomputed real-time texture synthesis with markovian generative adversarial networks, In *European conference on computer vision*, 702-716pp.
- Ma, L., Jia, X., Sun, Q., Schiele, B., Tuytelaars, T. and Van Gool, L.**, 2017, Pose guided person image generation, *arXiv preprint arXiv:1705.09368*.
- Mirza, M. and Osindero, S.**, 2014, Conditional generative adversarial nets. *arXiv preprint arXiv:1411.1784*.
- Olszewski, K., Ceylan, D., Xing, J., Echevarria, J., Chen, Z., Chen, W. and Li, H.**, 2020, Intuitive, Interactive Beard and Hair Synthesis with Generative Models, In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 7446-7456pp.
- Pan, Z., Yu, W., Yi, X., Khan, A., Yuan, F. and Zheng, Y.**, 2019, Recent progress on generative adversarial networks (GANs): A survey, *IEEE Access*, 36322-36333pp.
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... and Chintala, S.**, 2019, PyTorch: An Imperative Style, High-Performance Deep Learning Library, In *Advances in Neural Information Processing Systems*, 8024–8035pp.
- Patashnik, O., Wu, Z., Shechtman, E., Cohen-Or, D. and Lischinski, D.**, 2021, Styleclip: Text-driven manipulation of stylegan imagery, In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2085-2094pp.
- Pathak, D., Krahenbuhl, P., Donahue, J., Darrell, T. and Efros, A. A.**, 2016, Context encoders: Feature learning by inpainting, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2536-2544pp.
- Pérez, P., Gangnet, M. and Blake, A.**, 2003, Poisson image editing. In *ACM SIGGRAPH*, 313-318pp.
- Portenier, T., Hu, Q., Szabo, A., Bigdeli, S. A., Favaro, P. and Zwicker, M.**, 2018, Faceshop: Deep sketch-based face image editing, *arXiv preprint arXiv:1804.08972*.

KAYNAKLAR DİZİNİ (devam)

- Radford, A., Metz, L. and Chintala, S.**, 2015, Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- Rezende, D. J., Mohamed, S. and Wierstra, D.**, 2014, Stochastic backpropagation and approximate inference in deep generative models, In *International conference on machine learning*, 1278-1286pp.
- Ronneberger, O., Fischer P., Brox, T.** U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer, 2015
- Ruder, S.** (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Saha, R., Duke, B., Shkurti, F., Taylor, G. W. and Aarabi, P.**, 2021, LOHO: Latent Optimization of Hairstyles via Orthogonalization, In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 1984-1993pp.
- Stidham, R. W., Liu, W., Bishu, S., Rice, M. D., Higgins, P. D., Zhu, J., ... and Waljee, A. K.**, 2019, Performance of a deep learning model vs human reviewers in grading endoscopic disease severity of patients with ulcerative colitis, *JAMA network open*, 2(5), e193963-e193963.
- Tan, Z., Chai, M., Chen, D., Liao, J., Chu, Q., Yuan, L., ... and Yu, N.**, 2020, MichiGAN: multi-input-conditioned hair image generation for portrait editing, *arXiv preprint arXiv:2010.16417*.
- University of Stanford. (n.d.)**, CS231n Convolutional Neural Networks For Visual Recognition, <https://cs231n.github.io/neural-networks-1/> (Erişim Tarihi : 11 Kasım 2021)
- V. Dumoulin., E. Perez., N. Schucher., F. Strub., H. d. Vries., A. Courville. and Y. Bengio.** , 2018, Feature-wise transformations, *Distill*, e11p.

KAYNAKLAR DİZİNİ (devam)

- V. Dumoulin., J. Shlens. and M. Kudlur.,** 2016, A learned representation for artistic style. CoRR, abs/1610.07629.
- Wang, Z., She, Q. and Ward, T. E.,** 2021, Generative adversarial networks in computer vision: A survey and taxonomy, *ACM Computing Surveys*, 54(2), 1-38pp.
- Wang, X., Xie, L., Dong, C. and Shan, Y.,** 2021, Real-ESRGAN: Training real-world blind super resolution with pure synthetic data, In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 1905-1914pp.
- Wang, T. C., Liu, M. Y., Zhu, J. Y., Tao, A., Kautz, J. and Catanzaro, B.,** 2018, High resolution image synthesis and semantic manipulation with conditional gans, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 8798-8807pp.
- Wang, Z., Bovik, A. C., Sheikh, H. R. and Simoncelli, E. P.,** 2004, Image quality assessment: from error visibility to structural similarity, *IEEE transactions on image processing*, 13(4), 600-612pp.
- Wei, T., Chen, D., Zhou, W., Liao, J., Tan, Z., Yuan, L., ... and Yu, N.,** 2021, Hairclip: Design your hair by text and reference image, *arXiv preprint arXiv:2112.05142*.
- Wu, H., Zheng, S., Zhang, J. and Huang, K.,** 2019, GP-GAN: Towards realistic high resolution image blending, In *Proceedings of the 27th ACM international conference on multimedia*, 2487-2495pp.
- Huang, X., Liu, M. Y., Belongie, S. and Kautz J.,** 2018, Multimodal unsupervised image-to-image translation, ECCV.
- Huang, X. and Belongie, S.,** 2017. Arbitrary style transfer in real-time with adaptive instance normalization, In *Proceedings of the IEEE international conference on computer vision*, 1501-1510pp.
- Yang, Z., Hu, J., Salakhutdinov, R. and Cohen, W. W.,** 2017, Semi-supervised QA with generative domain-adaptive nets, arXiv preprint arXiv:1702.02206.

KAYNAKLAR DİZİNİ (devam)

- Yang, S., Wang, Z., Liu, J. and Guo, Z.,** 2020, Deep plastic surgery: Robust and controllable image editing with human-drawn sketches, In *European Conference on Computer Vision*, 601-617pp.
- Yeh, R. A., Chen, C., Yian Lim, T., Schwing, A. G., Hasegawa-Johnson, M. and Do, M. N.,** 2017, Semantic image inpainting with deep generative models, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 5485-5493pp.
- Yu, J., Lin, Z., Yang, J., Shen, X., Lu, X. and Huang, T. S.,** 2018, Generative image inpainting with contextual attention, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 5505-5514pp.
- Zhang, R., Isola, P., Efros, A. A., Shechtman, E. and Wang, O.,** 2018, The unreasonable effectiveness of deep features as a perceptual metric, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 586–595pp.
- Zeiler, M. D. and Fergus, R.,** 2014, Visualizing and understanding convolutional networks, In *European conference on computer vision*, 818-833pp.
- Zhang, L., Wen, T. and Shi, J.,** 2020, Deep image blending, In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 231-240pp.
- Zhang, R., Isola, P. and Efros, A. A.,** 2016, Colorful image colorization, In *European conference on computer vision*, 649-666pp.
- Zhu, P., Abdal, R., Femiani, J. and Wonka, P.,** 2021, Barbershop: GAN-based Image Compositing using Segmentation Masks, *arXiv preprint arXiv:2106.01505*.
- Zhu, P., Abdal, R., Qin, Y., Femiani, J. and Wonka, P.,** 2020, Improved StyleGAN Embedding: Where are the Good Latents?, *arXiv preprint arXiv:2012.09036*.

KAYNAKLAR DİZİNİ (devam)

Zhu, J. Y., Zhang, R., Pathak, D., Darrell, T., Efros, A. A., Wang, O. and Shechtman, E., 2017, Multimodal Image-to-Image Translation by Enforcing Bi-Cycle Consistency, In *Advances in neural information processing systems*, 465-476pp.



TEŞEKKÜR

Tez çalışmam boyunca desteğini eksik etmeyen nişanlım Cevher SÖYLEMEZ'e, çalışma boyunca bana özgür bir çalışma ortamı sağlayan ve destekleyen danışmanım Prof. Dr. Aybars UĞUR'a ve hem donanım ihtiyaçlarım hemde bünyesinde çalışırken yüksek lisans eğitimime devam edebilmem konusunda gerekli desteği sağlayan Syntonym A.Ş.'ye çok teşekkür ederim.

Tabiki eğitimimin en başından beri beni destekleyen başta babam Cemil PEKTAŞ ve annem Muteber PEKTAŞ olmak üzere tüm aileme minnet ve teşekkürlerimi sunarım.

28 / 01 / 2022

Muhammed PEKTAŞ

ÖZGEÇMİŞ**Kişisel Bilgiler**

Soyadı, adı : PEKTAŞ, Muhammed

Uyruğu : Türkiye

Eğitim

<u>Derece</u>	<u>Eğitim Birimi</u>	<u>Mezuniyet tarihi</u>
Yüksek Lisans	Ege Üni./ Bilgisayar Mühendisliği	2022
Lisans	Konya Teknik Üni./Bilgisayar Mühendisliği	2019

İş Deneyimi

<u>Yıl</u>	<u>Yer</u>	<u>Görev</u>
2019	Syntonym A.Ş	Bilgisayarlı Görü Mühendisi
2018	IBTECH	Stajyer
2017	Microsoft Türkiye	Stajyer

EKLER

Ek 1. İngilizce-Türkçe Sözlük



Ek 1. İngilizce-Türkçe Sözlük

İngilizce

Türkçe

Machine Learning

Makine Öğrenmesi

Deep Learning

Derin Öğrenme

Virtual Reality

Sanal Gerçeklik

Augmented Reality

Artırılmış Gerçeklik

Bias

Yanlılık

Classification

Sınıflandırma

Dataset

Veri seti

Noise

Gürültü

Generative Adversarial Networks

Çekişmeli Üretici Ağlar

Loss Function

Kayıp Fonksiyonu

Gradient Descent

Gradyan İniş

Ground Truth

Gerçek Değer

Adaptive Instance Normalization

Adaptif Örnek Normalleştirme

Pseudo Supervised Training

Sözde Denetimli Öğrenme