

Üretken Yapay Zekâ

Türkçe Özet – Bir makine, insan yapımı eserlerden ayırt edilemeyecek, benzersiz içerikler oluşturabilir mi? Bunu, karmaşık gerçek dünya veri örneklerinin yapısını öğrenerek ve aynı yapıya bağlı benzer sentetik örnekler üreterek, üretken çekişmeli ağların (GAN'lar) yardımıyla yapmak mümkün müdür? Üretken modellerin gelişmesindeki ilerlemelere göre, cevap en azından bir dereceye kadar evet gibi görünüyor. Üretken modellerde hedef, mevcut veri setine yakın sentetik örnekler üretmektir; diğer bir deyişle, verilen bir veri setindeki örneklerin türetildiği dağılımı öğrenip bu dağılımdan yeni örnekler üretmektir. Genel olarak veri setleri sınırlı sayıda örnekler içerdiğinden, her zaman veri seti dağılımını tam olarak öğrenmek mümkün olmamaktadır. Bu nedenle gerçek veri dağılımına mümkün olduğunca benzer bir dağılım modellenmeye çalışılmaktadır. Üretilen verilerin kalitesini ölçmek için kapsamlı ve kapsayıcı bir metriğe ihtiyaç duyulmaktadır. Bu çalışmada, GAN'ların değerlendirme puanlarını önemli ölçüde etkileyebilecek gerçek veri kümelerindeki küçük değişikliklerin ve ince farklılıkların etkilerini hafifletmeye yardımcı olabilecek yeni bir yöntemden bahsedilmiş olup çeşitli uygulamalar yapılmıştır. Ayrıca GAN'lar ile ilgili etik ve hukuki problemlere değinilmiştir.

Anahtar Kelimeler – Üretken Çekişmeli Ağlar, Üretken Çekişmeli Ağların Uygulamaları, Etik, Yapay Zekâ, Derin Öğrenme

Atf: Gözet, M., Filiz, U. ve Yılmaz, A. E. (2023). Üretken Yapay Zekâ. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 32-40.

Generative Artificial Intelligence

Extended Abstract

Can a machine attempt to approach the task of creating unique content that would be indistinguishable from human-produced artefacts? Is it possible to do this with the help of generative adversarial networks (GANs) by learning the structure of the complex real-world data examples and generating similar synthetic examples that are bound by the same structure? According to the recent advances in the development of generative models, the answer seems to be yes, at least to an extent. In generative models, the goal is to generate synthetic samples close to the existing dataset; In other words, it is to learn the distribution from which the samples in a given data set are derived and to generate new samples from this distribution. In general, since the datasets contain a limited number of samples, it is not always possible to learn the dataset distribution exactly. For this reason, it is tried to model a distribution as similar as possible to the actual data distribution. A comprehensive and inclusive metric is needed to measure the quality of the data produced. In this study, a new method that can help mitigate the effects of small changes and subtle differences in real datasets that can significantly affect the evaluation scores of GANs is mentioned and various applications are made. In addition, ethical and legal problems related to GANs are mentioned.

Keywords – Generative Adversarial Networks, GANs Applications, Ethic, Artificial Intelligence, Deep Learning

Citation: Gozet, M., Filiz, U. and Yılmaz, A. E. (2023). Generative Artificial Intelligence. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 32-40.

I. GİRİŞ

Makine öğrenmesi algoritmaları, veri setinin etiketlenip etiketlenmemesine göre denetimli ve denimsiz öğrenme olmak üzere iki kategoriye ayrılabilir. Denetimli öğrenme için farklı özelliklere sahip bir veri seti gereklidir ve veri setindeki her örnek etiketlenmelidir. Denetimli öğrenmenin temsilcileri sınıflandırma, regresyon ve yapılandırılmış çıktı problemleridir. Ancak denimsiz öğrenme, etiketli veri içermez diğer bir deyişle bağımlı değişken yoktur. Veriler bir dizi örnek x 'ten oluşur ve amaç, x 'in istatistiksel yapısını öğrenmektir. Genel olarak yoğunluk tahmini, kümeleme, sentez ve gürlüğü giderme denimsiz öğrenme olarak kabul

edilir. Denetimli öğrenme durumunda, etiketleri otomatik olarak toplamak veya not eklemek zordur. Bu nedenle, araştırmacılar denimsiz öğrenmeye daha fazla önem vermektedir. Denimsiz öğrenme görevinde, üretken modeller en umut verici teknolojilerden biridir. Tipik üretken modeller genellikle Markov zincirlerine, maksimum olasılığa ve yaklaşık çıkarıma dayalıdır. Üretken modeller, bir süredir farklı alanlardaki araştırmacıların ilgisini çekmektedir. Makine öğrenimi ve daha spesifik olarak derin öğrenme alanlarındaki son gelişmelerle birlikte, üretken modellemenin araştırma çalışmalarının sayısında ve farklı alanlardaki uygulamalarında muazzam bir artış görülmektedir. Üretken modelleme sanat eseri ve müzik bestelerinden,

sentetik ve tıbbi veri kümelerine kadar, hem hayal gücünün hem de zekanın sınırlarını zorlamaktadır [5].

Üretken modellerin girdi değişkenleri genellikle gerçek dünya değerleriyle hiç ilgili olmayan ve hatta çoğu zaman rastgele oluşturulmuş sayı vektörleridir. Üretken modeller, görüntü üretimindeki başarısının yanı sıra rastgele gürültüden metin, müzik veya video üretme gibi birçok farklı alanda çalışmalar yapılmaktadır [39, 40].

Gerçek görüntülere benzer sentetik görüntülerin üretiminde Üretken Çekişmeli Ağların (Generative Adversarial Networks-GAN) oldukça başarılı bir performans sergilediği görülmektedir [1].

II. MATERYAL VE YÖNTEM

2.1. Üretken Modeller ve Üretken Çekişmeli Ağlar

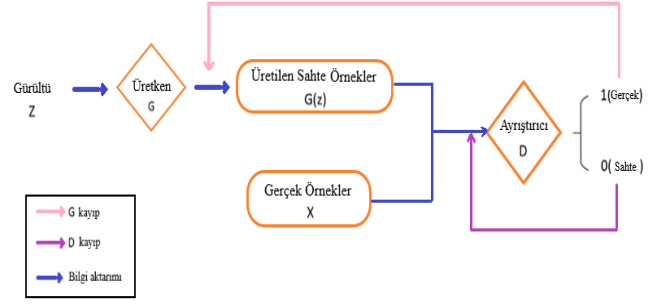
Büyük ölçüde oyun teorisi kavramlarından ilham alan üretken çekişmeli ağlar, ilk olarak Goodfellow ve arkadaşları tarafından önerilmiştir [1]. Üretken çekişmeli ağlar, yapay zekâ alanındaki en önemli araştırma yollarından biridir ve olağanüstü veri üretme kapasitesi geniş ilgi görmüştür [18]. Bu ağların amacı, veri kümesindeki örnek görsellere benzer sentetik görüntüler üretmektir. Klasik derin ağ mimarilerinden farkı, üretici ve ayırıcı olmak üzere iki derin ağ mimarisinin eğitimini çekişmeli ve eşzamanlı bir şekilde gerçekleştirebilmesidir.

Üretken modeller yeni veri örnekleri oluşturabiliyorken ayırıcı modeller, farklı veri örnekleri türleri arasında ayırım yapmaktadır. Üretken bir model, gerçek hayvanlara benzeyen yeni hayvan fotoğrafları oluşturabilirken, ayırt edici bir model bir köpeği bir kediden ayırt edebilmektedir. Bir dizi X veri örneği ve bir dizi Y etiketi verildiğinde: üretken modeller ortak olasılık $p(X, Y)$ veya etiket yoksa yalnızca $p(X)$ 'i yakalarken ayırıcı modeller koşullu olasılığı $p(Y | X)$ yakalar.

Üretken bir model, verilerin dağılımını içerir ve belirli bir örneğin ne kadar olası olduğunu söyler. Örneğin, bir dizideki bir sonraki kelimeyi tahmin eden modeller tipik olarak üretken modeldir, çünkü bunlar bir kelime dizisine bir olasılık atayabilirler. Ayırıcı bir model, belirli bir örneğin muhtemel olup olmadığı sorusunu yok sayar ve yalnızca bir etiketin örneğe uygulanma olasılığının ne kadar olduğunu söyler [7].

2.2. Klasik Üretken Çekişmeli Ağ Mimarisi

Klasik üretken çekişmeli ağ mimarisi araştırmacılar tarafından geleneksel üretken modellerin performansını artırmak için geliştirilmiş, denetimsiz öğrenme için kullanılan bir sinir ağı mimarisidir. Şekil 1'de gösterildiği gibi bir üretken (generative, G) ve bir ayırıcı (discriminator, D) olmak üzere iki farklı derin ağ mimarisine sahiptir. Bu yapı ile bilinen derin ağ mimarilerinden farklılık gösterir ve öğrenme işlemi bu iki ağın rekabetçi bir şekilde çalışmasıyla gerçekleşir. Üretken çekişmeli ağlar hem üretken hem de ayırıcı bir model içerirken, üretken ve ayırıcı modeller ayrı ayrı var olabilmekte ve farklı görevler için kullanılabilir. Sadece üretken modeller hedef dağıtımdan yeni veri örnekleri oluşturabilmektedir.



Şekil 1. Klasik GAN mimarisi [41]

Şekil 1. de G derin ağı, giriş olarak aldığı bir gürültü vektöründen gerçek görüntülere benzer görüntüler üretmeye çalışırken; D derin ağı, üretici tarafından üretilen sentetik görüntüler sahte (0) ile gerçek (1) görüntüleri ayırt etmeye çalışır. Bu şekilde her iki ağ da paralel, çekişmeli bir şekilde eğitilir ve bu eğitim aşamasında G kademeli olarak gerçek görüntüler ile ayırt edilemeyecek yeni görüntüler üretir [9]. Bu çekişmeli eğitim, üretken ve ayırt edici kayıpların değer fonksiyonu ile minimax oyunu olarak adlandırılır. Kayıp fonksiyonu denklem 1'de formüle edilmiştir.

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

Burada x , gerçek veri dağılımı $p_{data(x)}$ 'den örneklenir, z , önceki dağıtım $p_z(z)$ 'den örneklenmiştir. Üretici gerçek verilerle aynı verileri üretebildiğinde ve ayırıcı artık sahte verileri gerçek verilerden doğru bir şekilde ayırt edemediğinde, iki ağ Nash dengesine ulaşmak için eş zamanlı olarak eğitilir.

Klasik üretken çekişmeli ağ mimarisinin geleneksel üretken modellere göre çeşitli avantajları vardır. Gerçek veri noktalarına benzer yüksek kaliteli veri noktaları üretebilmek, çeşitli uygulamalar için çeşitli veri noktaları üretebilmek ve etiketli verilere olan ihtiyacı azaltan denetimsiz öğrenme modelleri kullanılarak eğitilebilmektedir. Bununla birlikte, klasik üretken çekişmeli ağ mimarisinin de bazı sınırlamaları vardır. Ana sınırlamalardan biri, özellikle büyük veri kümelerinin eğitilmesinin hesaplama açısından pahalı olmasıdır. Ek olarak, optimum performans elde etmek için kullanılan hiperparametreleri ayarlamının çok kolay bir iş olmamasıdır. Fakat yine de gerçek veri noktalarına benzer yüksek kaliteli veri noktaları üretebilen denetimsiz öğrenme için güçlü bir araçtır. Bazı sınırlamaları olmakla birlikte, üretken modelleme alanında devrim yaratma ve gerçekçi veri noktaları üretebilen yapay zekâ sistemlerinin oluşturulması için yeni olasılıklar açma potansiyeline sahiptir.

Üretken çekişmeli ağlar Goodfellow tarafından önerildiğinden beri, çok fazla üretken çekişmeli ağ varyantı yayınlanmıştır [22].

Tablo 1. Üretken çekişmeli ağ taksonomisi mimariler

GAN Taksonomisi		
Mimariler		
Ağ Mimarileri	Gizli Alan Mimarileri	Uygulamaya Odaklı Mimariler
LAPGAN, 2015 / DCGAN, 2016 / BEGAN, 2017 / PROGAN, 2017; AutoGAN, 2019 / SAGAN, 2018; BigGAN, 2019; YLG, 2020	CGAN, 2014; AC-GAN, 2017; InfoGAN, 2016 / BiGAN, 2016 / SGAN, 2016	CycleGAN, 2017; DiscoGAN, 2017; DualGAN, 2017 / SRGAN, 2016 / StyleGAN, 2019 / Face Completion GAN, 2017 / AlphaGAN, 2018 / MocoGAN, 2018; DVD-GAN, 2019 / SinGAN, 2019

GAN taksonomisi, GAN mimarileri ve kayıp değişkenleri olmak üzere iki ana kategoriye ayrılmıştır. Tablo 1 GAN mimarilerini içermektedir. Mimariler: ağ mimarisi, gizli alan mimarileri ve uygulama odaklı mimariler olmak üzere üç alt kategoriye ayrılmıştır.

Tablo 2. Üretken çekişmeli ağ taksonomisi kayıp değişkenler

GAN Taksonomisi		
Kayıp		
Kayıp Tipleri	Düzenleştirme	
IPM Tabanlı	IPM Tabanlı Olmayan	WGAN-GP, 2017 / WGAN-CT, 2018 / WGAN-LP, 2017 / MRGAN, 2016 / SN-GAN, 2018 / SS-GAN, 2019
RGAN, 2018 / WGAN, 2017 / Geometric GAN, 2017; Sphere GAN, 2019	FCGAN, 2014; LSGAN, 2016; f-GAN, 2016 / UGAN, 2016 / LS-GAN, 2017	

Tablo 2. de kayıp değişkenler, kayıp tipleri ve düzenleme olarak iki alt kategoriye ayrılmıştır. Yazarlar, bu taksonomiye 323 üretken çekişmeli ağ makalesini inceleyerek hazırlamışlardır [22].

2.3. Değerlendirme Metrikleri

Son zamanlarda, üretken çekişmeli ağların teorik

başarılarına rağmen, üretilen verilerin kalitesini ölçmek için kapsamlı ve kapsayıcı bir metriğe ihtiyaç duyulmaktadır. Bu nedenle üretken modelleri karşılaştırmak için IS, MS, FID, MS-SSIM, vb. gibi farklı metrikler kullanılmaktadır. Son yıllarda alanda yapılan çalışmalardan bazıları FID metriğinin temel sorunları olan taraflılık (bias) ve küçük ayrıntılara hassaslık problemlerine bir çözüm bulmak amacıyla geliştirilmiştir. Bu başlık altında ek olarak Filiz tarafından önerilmiş, değerlendirme puanlarını önemli ölçüde etkileyebilecek gerçek veri kümelerindeki küçük değişikliklerin ve ince farklılıkların etkilerini hafifletmeye yardımcı olabilecek yeni bir yöntemden de bahsedilmiştir.

2.3.1. Başlangıç Puanı (IS)

Bu metrik, üretken çekişmeli ağlarda yaygın olarak kullanılmaktadır ve Salimans vd. tarafından [36] önerilmiştir. IS'nin yüksek olması, oluşturulan modelin yüksek kaliteli örnekler üretebildiğini, aynı zamanda örneklerin de çeşitli olduğunu göstermektedir.

$$IS(G) = e^{(\mathbb{E}_{x \sim P_g} D_{KL}(p(y|x)||p(y)))} \quad (2)$$

Burada x , P_g den örneklenir ve $D_{KL}(p(y|x)||p(y))$ x ve y dağılımları arasındaki Kullback-Leibler sapması, $p(y|x)$ koşullu sınıf dağılımı ve $p(y) = \int_x p(y|x)p_g(x)$ marjinal sınıf dağılımıdır.

İyi sonuçlar için karşılanması gereken 2 koşul önerilmiştir:

- 1) $p(y|x)$ düşük entropiye sahip olmalıdır, yani görüntüde tek bir nesne olmalıdır.
- 2) $p(y)$ yüksek entropiye sahip olmalıdır.

Bu varsayımlar karşılandıktan sonra, daha yüksek IS puanı, daha iyi bir üretim performansını göstermektedir. Bununla birlikte, IS'nin de sınırlamaları vardır, eğer üretici model, çöküş moduna girerse, IS puanı yüksek olsa da doğru bir başarı değerlendirme yöntemi olmayacaktır. GAN, bir görüntü veri kümesindeki tüm sınıfları algılamada başarısız olduğunda, başlangıç puanı değişmez, bu nedenle, GAN'ın performansını göstermez. Bunun için başka metriklere ihtiyaç duyulmaktadır.

2.3.2. Mod Puanı (MS)

IS'ye dayanarak, oluşturulan örneklerin çeşitliliğini ve görsel kalitesini aynı anda yansıtabilen MS adlı başka bir değerlendirme ölçütü önermiştir. Bu değerlendirme metriği, yer gerçeği etiketleri üzerindeki önceki dağılımlara duyarlı olmayan IS sorununu ele alır.

2.3.3. Frechet Başlangıç Mesafesi (FID)

FID, Heusel ve diğerleri tarafından önerilmiştir [37] ve sınıf içi modun düşmesini tespit etmek için kullanılır. Bu yaklaşımda, üretilen örnekler, başlangıç ağının belirli katmanı tarafından sağlanan özellik uzayına gömülür. Üretilen örneklerin çok boyutlu bir Gauss'u takip ettiği varsayımına dayanarak, oluşturulan örnekler ile gerçek veriler arasındaki

ortalama ve kovaryans hesaplanır. FID'in, resim kalitesi ile arasına negatif bir ilişki vardır. Düşük FID puanı, modelin daha iyi performans gösterdiğini gösterir. Aktivasyonların kovaryans matrislerinin ortalamaları ve izleri arasındaki Öklid mesafesinin karesi olarak hesaplanır:

$$FID = \|\mu_t - \mu_g\|_2^2 + Tr(\Sigma_t + \Sigma_g - 2\sqrt{\Sigma_t \Sigma_g}) \quad (3)$$

IS ile karşılaştırıldığında, gürültüye karşı daha dayanıklıdır. Yetersiz örnek olması durumunda bile (yalnızca bir tür resim üretilir), yüksek bir FID değeri oluşmaktadır [41]. FID, pratik açıdan oldukça popüler olmasına rağmen, "görüntünün birden fazla anı üzerinde çalışma" [2] ve görüntüdeki küçük değişikliklerin yüksek etkisi gibi pek çok dezavantajlı davranışa sahiptir [44].

2.3.4. Görüntü Kalitesi için Çok Ölçekli Yapısal Benzerlik (MS-SSIM)

İki görüntü arasındaki benzerliği ölçmek için kullanılan tek ölçekli SSIM metriğinden farklı olarak, Wang ve ark. [22] ilk olarak çoklu ölçekli görüntü kalitesi değerlendirmesi için MS-SSIM'i önermiştir. İnsan algısı benzerlik yargısını tahmin ederek görüntülerin benzerliğini nicel olarak değerlendirir.

İyi bir değerlendirme metriği, oluşturulan örnekleri gerçek olandan ayırmalı, mod çöküşünü doğrulamalı ve aşırı ezberlemeyi tespit etmelidir.

2.3.5. Çekirdek Başlangıç Mesafesi (KID)

Çekirdek başlangıç puanı, rastgele seçilen örneklerle gerçek bir görüntü dağılımı P_r ile oluşturulan görüntü dağılımı P_g arasındaki farklılık miktarını ölçen bir metriktir. [45]. Teorik olarak MMD, bir polinom Gauss çekirdeği ile karelenmiş maksimum ortalama tutarsızlık olarak hesaplanır (Fortet ve diğerleri 1953):

$$M_k(P_r, P_g) = \mathbb{E}_{x, x' \sim P_r} [k(x, x')] - 2\mathbb{E}_{x \sim P_r, y \sim P_g} [k(x, y)] + \mathbb{E}_{y, y' \sim P_g} [k(y, y')] \quad (4)$$

Burada k Gauss çekirdeğidir. $k(x, x') = e^{-\|x-x'\|^2}$ dır. Uygulamada, yapılacak bu hesaplama için bir tahmin yapılması gerekir, bu nedenle hem üretici hem de gerçek görüntü dağılımlarından sonlu örneklerle tahmin ediciler burada $P_r = \{x_1, x_2, \dots, x_n\}$ ve $P_g = \{y_1, y_2, \dots, y_n\}$ dir.

$$\hat{M}_k(P_r, P_g) = \frac{1}{\binom{n}{2}} \sum_{i \neq i'} k(x_i, x_{i'}) - \frac{2}{\binom{n}{2}} \sum_{j \neq j'} k(x_j, y_j) + \frac{1}{\binom{n}{2}} \sum_{j \neq j'} k(y_j, y_{j'}) \quad (5)$$

Tıpkı Fréchet Başlangıç Mesafesi gibi, Çekirdek Başlangıç Mesafesi de Inception-V3 ağının tahmininde normal dağılım varsayar ve daha düşük Çekirdek Başlangıç puanı daha iyi bir performansı gösterir.

2.3.6. Önerilen yöntem

Yığılma yöntemi, Üretken Çekişmeli Ağların (GAN'lar) değerlendirmesini iyileştirmenin bir yolu olarak önerilmiştir. Toplu işlemede, orijinal görüntü birden çok daha küçük görüntüye veya "görüntü parçalarına" bölünür. Metrik daha sonra her yığın için hesaplanır ve her yığının puanları toplanarak nihai puan elde edilir. Bu işlem matematiksel olarak aşağıdaki formülle temsil edilir:

$$\Phi_{Total} = \sum_{b=0}^{\alpha*\beta} \Phi_b \quad (6)$$

Burada Φ süreçte kullanılan metriği temsil eder ve b yığının indeksini gösterir. α ve β değerleri, yığınların sırasıyla satırını ve sütununu kontrol eden parametrelerdir.

Bu yöntemin amacı, her seferinde yalnızca bir görüntü yerine mevzubahis görüntünün içindeki birden çok görüntü grubunu dikkate alarak GAN'ların daha kapsamlı bir değerlendirme yapmasını sağlamaktır. Bu yaklaşım, Parmar vd. [44] tarafından tartışıldığı gibi değerlendirme puanlarını önemli ölçüde etkileyebilecek gerçek veri kümelerindeki küçük değişikliklerin ve ince farklılıkların etkilerini hafifletmeye yardımcı olabilir.

2.4. Üretken Çekişmeli Ağların Uygulamaları

Bir tür üretken model olan, GAN'ların doğrudan uygulama alanı veri üretimidir. Bu, gerçek örneklerin dağılımından öğrenmektedir ve dağılımla tutarlı örnekler oluşturmaktadır. Şu anda GAN'ların en başarılı uygulamaları; görüntü çevirisi, görüntü süper çözünürlüğü, görüntü sentezi ve video üretimi vb. dahil olmak üzere bilgisayarla görme alanlarında kullanılmaktadır. Bu uygulamaların detayları aşağıda tanıtılmaktadır. Sadece görüntü değil, diğer medya türleri de (ses, metin) bu şekilde üretilebilir [10-13].

Görüntü içi boyama, görüntülerin eksik kısımları doldurulabilmektedir. Bir görüntüdeki boşlukları doldurma görevi olan görüntü içi boyama birçok uygulamada kullanılmaktadır. Ortaya çıkan alanı uygun görüntülerle doldururken istenmeyen görüntü içeriğini kaldırmak için de kullanılmaktadır [14].

Görüntü süper çözünürlüğü, düşük çözünürlüklü görüntüleri, gözle görülür yükseltme kusurları olmaksızın yüksek çözünürlüğe yükseltir [15]. Süper çözünürlük, yakalanan görüntüleri iyileştirir ve gürültüyü oldukça iyi bir şekilde ortadan kaldırabilir, ancak güvenlik endişeleri nedeniyle birçok deney ve deneme yapılması gerektiğinden, tıbbi alanda GAN'ların benimsenmesi oldukça yavaştır. Sağlık hizmetiyle uğraşırken, modelleri değerlendirmek ve gürültü gidermenin görüntünün gerçek içeriğini yanlış bir teşhise yol açabilecek bir şekilde bozmamasını sağlamak için bir dizi alan ile ilgili uzmanın dahil edilmesi zorunlu hale gelmektedir.

Etki alanı uyarlaması, bir alandan gelen verileri diğer alandan gelen verilere benzetmektedir (ör. orijinal olarak tasvir edilen içeriği korurken normal bir fotoğrafı yağlı boya tablo gibi göstermek) [16]. Şekil 2. de at içeriği bulunan bir fotoğrafın CycleGAN modeli ile Zebralara dönüştürüldüğü bir örnek verilmiştir.

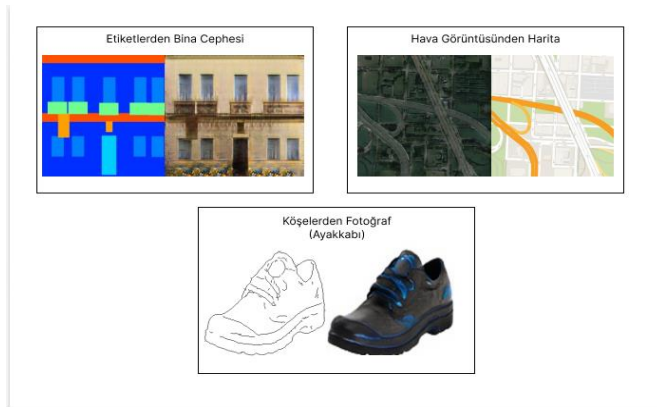


Şekil 2. Herhangi iki sırasız görüntü koleksiyonu X ve Y verildiğinde, algoritma bir görüntüyü otomatik olarak birinden diğerine "çevirmeyi" öğrenir ve bunun tersi de geçerlidir: ImageNet veri setinden alınan at görseli (solda) ve stil dönüşümü sonucunda oluşturulan zebra görseli (sağda).

Çizgi film karakteri üretmek, insan yüzleri girdi olarak alınıp yüksek yoğunluklu bir çokgen elde etmek için işleyerek GAN ile karakterler oluşturulabilir, bu da sıfırdan çizgi film karakterleri geliştirirken zaman kazandırabilir [48].

Sahte haberler ve sohbet robotları, insanlar her zaman makinelerle konuşmak istemişlerdir; ilk sohbet robotu ELIZA [6], 1960'larda MIT'de yazılmıştır ve bir kullanıcının girdisini dönüştürmek ve bir yanıt oluşturmak için basit bir program kullanılmıştır. BERT modeli daha sonra dönüştürücü birimleri, doğal dil kalıplarının ve bağlamsal önemin güçlü birçok boyutlu kodlamasında birleştirir. Bu yaklaşım, doğal dil işleme (NLP) görevleri veya chatbot diyalog sistemleri için belge oluşturmada kullanılabilir.

Üretken yapay zekâ görüntü dönüşümleri için de sıkça kullanılmaktadır. Etiket girişlerinden bina cephesi üretimi, siyah beyaz görüntülerin renklendirilmesi, uydu/hava haritası giriş görüntülerini Google Haritalar benzeri çıktılara dönüştürme, etiketleri segmentlere ayırmak için sokak görünümü gibi anlamsal segmentasyon görevleri eskizden fotoğrafa, eskizden portreye, eskizden kediye, eskizden renkli Pokémon'a ve hatta ayakkabılar, çantalar vb. arka plan kaldırma boyama sırasında veya görüntü tamamlama, termalden RGB görüntüye çeviri, gündüzdüzen geceye manzara ve yazdan kışa manzara dönüşümü gibi birçok farklı uygulaması bulunmaktadır. Şekil 3'te pix2pix algoritması ile oluşturulmuş farklı uygulamalar verilmiştir.



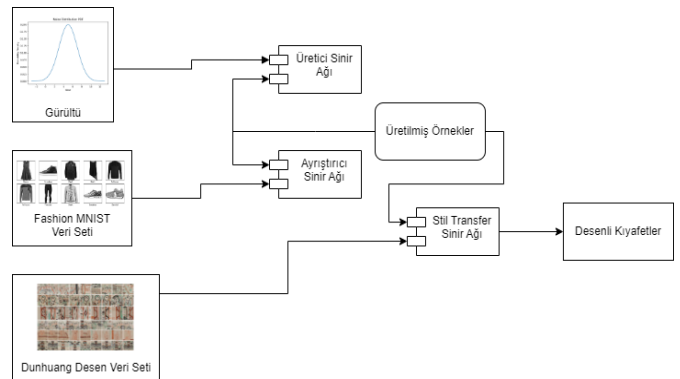
Şekil 3. Pix2pix algoritmasıyla görüntü çevirisi örnekleri [16, 49, 50]

Derin sahtecilik (Deepfake), çoklu girdilerden öğrenen ve çıktı üreten en iyi tekniklerden biridir. Yüz değiştirmek, görüntü oluşturmak için de kullanılabilir. Şekil 4'te farklı metinler verildiğinde Deepfake modeli ile oluşturulan farklı görseller verilmiştir.



Şekil 4. Deepfake ile oluşturulan görüntü örnekleri. Görüntüler DALL-E modeli ile oluşturulmuştur.

Moda endüstrisinde tasarım ve desenler çok önemli bir rol oynamaktadır ve zaman geçtikçe tasarımcılar yeni giysiler için yeni tasarım ve desenler bulmaları gerekmektedir. Bu teknik, moda tasarımcısının kumaş ayakkabı, çanta ve cüzdanlar için yeni bir tasarım oluşturmasına yardımcı olan eski tasarım ve desenlerin kombinasyonundan desen ve tasarım oluşturmada kullanılabilir [8, 42]. Şekil 5'te Dunhuang desen veri seti içindeki farklı desenler, Fashion MNIST veri seti içindeki kıyafetlerle birleştirilerek farklı kıyafet tasarımlarının nasıl elde edileceğini gösteren diyagram verilmiştir.



Şekil 5. Dunhuang desen veri seti ve Fashion MNIST veri seti kullanılarak farklı desenlerden kıyafet elde edilmesi [42]

Bu teknoloji eğlence amaçlı yaratılmıştır, ancak şimdi derin sahtecilik popülerlik kazandıkça, kullanımı artmaya başlamıştır. Bu teknik artık ünlülerin ve yüksek profilli politikacıların yüzünü başka biriyle değiştirerek karakter karalaması için kullanılmaktadır. Bu teknik, gelecek yıllarda etik olmayan şekillerde kullanılırsa problem teşkil edeceği öngörülmektedir [38].

Kendisine birçok farklı kullanım alanı bulmasına rağmen,

GAN'ların hala çözülmesi gereken problemleri vardır. GAN'ları eğitmek herkesin bildiği gibi zordur ve bazen bu ağlar, gerçek hayatta belirli şeylerin nasıl çalıştığını anlamak için eğitim verilerinde yeterli bilgiye sahip olmadığı için, beklenmedik görüntüler üretebilmektedir. Örneğin, portre görüntülerinden oluşan bir veri kümesi verildiğinde, ağ insan yüzlerinin nasıl modelleneceğini biliyor olabilir, ancak belirli giysi öğelerinin nasıl görünmesi gerektiği fikrini kavramada başarısız olabilir. Bu nedenle, beklenen sonuçla ilgili olacak verilerin dikkatli bir şekilde seçilmesi zorunludur.

2.5. Zorlukları ve Sınırlılıkları

Temel üretken çekişmeli ağ mimarisi ile düşük çözünürlüğe sahip veri setleri kullanılarak nispeten iyi sonuçlar üretilmektedir. Fakat yüksek çözünürlüklü veri setleri kullanıldığında genel olarak iki ana problem meydana gelmektedir. İlk problem, üretken çekişmeli ağın kararsızlık durumuna düşmesidir. Bu problem ayrıştırıcı ağı, üretici ağına üstünlük sağlaması sonucu ortaya çıkmaktadır; diğer bir deyişle ayrıştırıcı ağ, üretici ağı için yüksek gradyan değerleri üretmekte ve üretici ağını istikrarsız hale getirmektedir. Yakın zamanda bu problemle başa çıkmak için, kayıp fonksiyonları [24-27], düzenleme teknikleri [28-31], üretken çekişmeli ağ mimarileri [32-35] önerilmektedir.

Üretken çekişmeli ağlardaki ikinci temel sorun, her zaman çökme moduna girmesidir. Mod çöküşü; üretici ağına çok boyutlu uzayda benzer özelliklere sahip çok fazla örnek ürettiği veya üretilen örnekler arasında minimum çeşitlilik olduğu durumu göstermektedir. Çoğu zaman, GAN'lar gerçek dengeye yaklaşamaz ve optimal olmayan çözümler üretir. Bu problemin üstesinden gelmek için ise ayrıştırıcı ağına girdi olarak her bir yığındaki imgelerin birbiriyle olan benzerlik istatistikleri verilmektedir.

GAN'ların eğitilmesinin zor olduğu bilinmektedir ve bu da genellikle anlamsız çıktılar üreten üreticilere neden olmaktadır. GAN'ların öğrendiklerini ve çok katmanlı GAN'ların ara temsillerini anlamaya ve görselleştirmeye çalışan çok sınırlı yayınlanmış araştırma vardır [17].

2.6. Problemlere Yönelik Oluşturulan Çözüm Önerileri

Umut verici başarılarla rağmen, gradyan kaybolması, mod çökmesi ve ıraksak veya salınımlı davranış gibi birkaç yaygın sorunlu kararsız eğitim ve yakınsama davranışı nedeniyle GAN'ları eğitmek hala zordur. Üretken çekişmeli ağların eğitimindeki bu sorunlar genellikle bu alanda daha fazla araştırma ve uygulanabilirliği engellemektedir. Son zamanlarda, yukarıda belirtilen sorunları hafifletmek için mevcut çalışmalar, daha kararlı ağ mimarileri tasarlamak, öğrenme hedeflerini değiştirmek, hedefleri düzenli hale getirmek, eğitim stratejileri, hiperparametreleri ayarlamak vb. gibi çeşitli çözümler önerilmiştir.

Mevcut çalışmaların çoğu ya görüntü kalitesine ya da görüntü çeşitliliğine odaklanmıştır. Olası bir araştırma yönü,

düşük görüntü çeşitliliğinden zarar görmeyen görüntü kalitesi üzerinde çalışmak olabilir. Ayrıca, GAN'ların eğitim istikrarsızlığı sorununu ele almak için mevcut yöntemler, değişikliklere karşı çok hassas olan buluşsal yöntemlere hala bağlıdır. Bu yaklaşımların yeni alanlarda uygulanabilirliğini kısıtlayan temel sebeplerden biri de budur. Öte yandan, mevcut çalışmaların çoğunun bir seferde yalnızca bir eğitim sorununu çözmeyi önerdiğini ve çoğu zaman teorik analiz içermediği gözlemlenmiştir. Diğer bir önemli araştırma yönü, daha izlenebilir formülasyonları keşfetmek ve eğitimi istikrarlı ve anlaşılır kılmak amacıyla GAN'ların eğitim sürecindeki sorunları ele almak için teorik bir çerçeveye/analizlere sahip olmaktır.

Ayrıca, önerilen çözümler eğitim iyileştirme ölçeğinde farklılık göstermektedir. Modellerin çoğu, hiperparametre ayarlarını ve hesaplama kaynaklarını iyileştirerek benzer sonuçlara ulaşabilir. Bu nedenle, ilgili çalışmaların büyük çoğunluğunun en son teknoloji verimlilik yerine en yüksek doğruluk elde etmeye odaklandığını söylenebilir. Mevcut işlerin üzerinde algoritmik iyileştirmelere sahip çözümler geliştirmek, geleceğe yönelik bir yön olabilir.

Uygun mimari seçiminin, amaç fonksiyonlarının ve optimizasyon tekniklerinin GAN eğitim kararlılığını geliştirdiği GAN tasarım ve optimizasyon çözümü önerilmiştir. Ek olarak, amaç fonksiyonları, farklı GAN'lar için gelecekteki araştırmalarda keşfedilebilecek olan optimizasyon stratejilerinin kullanımına, hiperparametre seçimine ve eğitim adımlarının sayısına duyarlıdır. Öte yandan, GAN eğitimini geliştirmek için çevrimiçi öğrenme, oyun teorisi varyantları vb. gibi diğer teknolojilerin kullanılmasına yönelik araştırmalar henüz başlangıç aşamasındadır. Uygun mimari, kayıp fonksiyonu ve optimizasyon tekniklerinin bir kombinasyonu, üstün sonuçlar verebilir ve gelecekte keşfedilecek bir araştırma yönü olabilir.

2.7. Etik

Dünyanın nasıl modellendiği ve bu modelleri kullanmanın diğerlerinin dünyayı algılama biçimini nasıl etkileyebileceği önemli bir konudur. GAN'ların öğrendiği semantik kavramlar, verilere dayalıdır ve dünyanın nasıl çalıştığına dair gerçeği tam olarak temsil etmemektedir. Örneğin, çoğu insan verisi erkek veya kadın olarak tanımlanmaktadır. Bu nedenle bir GAN, tek tip bir spektrum olarak erkek ve kadın arasında bir şekilde doğrusal bir ilişki öğrenmektedir. Ancak bu, sadece erkek ya da kadından oluşan birçok insan için gerçekle uyuşmamaktadır. GAN'lar kullanılarak bir görüntüde cinsiyetin manipüle edilmesi, bu nedenle, onu herhangi bir sistemin parçası olarak açıklamadan önce düşünülmesi gerekmektedir. Oluşturulan herhangi bir sistem (makine öğrenimi veya başka türlü) için bazı basit sorular sorulmalıdır: Sistemden faydalanan veya zarar gören insanlar var mı ve bu insanlar bu faydayı veya zararı görmeli mi? İnsanların davranışlarını olumlu veya olumsuz yönde değiştirebilir veya

iyi niyetli kullanıcılar tarafından bile kötüye kullanılabilir mi? Genel olarak, mikro ve makro ölçekte neyin yanlış gidebileceği düşünülmelidir. Etik çok karmaşık bir konudur. Ancak derin öğrenmeyle birlikte birçok farklı şeyi otomatikleştirme yeteneği vardır. Bu, toplum için bir nimet olabilir ve insanları zahmetli ve yorucu işlerden kurtarabilir, ancak aynı zamanda istenmeyen eşitsizlikleri bir ölçekte büyütebilir ve çoğaltabilir.

GAN'lar, güvenlik tehdidi oluşturabilecek sahte belgeler veya diğer hassas materyaller oluşturmak için kullanılabilir. Örneğin, birine ait olan ağız hareketlerini başka bir sesle eşleştirebilir ve videoları değiştirmek için kullanılabilir. Ayrıca başkalarını yanıltmak için güçlü bir araçtır. Kodu çevrimiçi yayınlarsanız, başkalarına zarar vermek için kolayca kötüye kullanılabilir. Bu kodu halka yerleştirmenin faydaları nelerdir ve zararlarından ağır basar mı? Eğer kötüye kullanılabilir bir üretken oluşturursanız, belki de modelinizden/yaklaşımınızdan bir görüntünün gelip gelmediğini anlayan ve böylece herhangi bir kötü amaçlı kullanımı tespit etmeye yardımcı olan bir detektör üzerinde çalışılabilir. Bunlar soyut problemler gibi görünebilir, ancak işin içindeyken bazı endişeler olacaktır. Örneğin, yakın tarihli bir rapor, derin sahtekarlık olarak bilinen deepfakelerin insanları yüzbinlerce doları dolandırmak için kullanıldığını göstermiştir [43]. Etik kolay cevapları olan siyah beyaz bir mesele değildir. Yapay zekanın sosyal adalet, demokrasi ve insan onuru üzerindeki etkisi gibi daha geniş toplumsal ve kültürel konuları kapsar. Bir iş yaparken etraflıca düşünülmesi gerektiği unutulmamalıdır.

2.8. Hukuki Hususlar

Makine öğrenimi, veri bilimi ve üretken çekişmeli ağlar alanlarındaki hızlı gelişmeler, derin sahtekarlık (deepfake) olarak bilinen yeni bir içerik oluşturma teknolojisi oluşmuştur. Tıpkı önceki birçok teknoloji gibi (Sony Betamax kaydedici, sanal gerçeklik veya Bitcoin), derin sahtekarlıklar başlangıçta bazı yasa dışı veya ahlaksız faaliyetlere uygulanmıştır [47]. Medyanın yaratılmasından ve kullanılmasından kaynaklanan ve yasal yelpazeyi kapsayan, seçim yasası, ceza hukuku, kanıt ve fikri mülkiyet alanlarındaki sonuçlar da dahil olmak üzere potansiyel sonuçlar vardır [46].

Hukuki açıdan, mahremiyete yönelik saldırının yanı sıra, yaratıcı derin sahtekarlıkların yasallığıyla ilgili anlaşmazlıklarda sözleşme, haksız fiil veya mülkiyet hukukundan kaynaklanan bir dizi başka temel yasa doktrin geçerli olabilir. Ek olarak, yaratıcı derin sahteler, IP ile ilgili belirli tartışmalara yol açabilir. Daha spesifik olarak, telif hakkı yasası açısından, bir derin sahte yaratıcının yeni oluşturulan derin sahtecilik için telif hakkı sahibi olduğunu iddia edip edemeyeceği veya orijinal içeriğin kullanımının (bir veya daha fazla telif hakkıyla korunan çalışma) ihlal teşkil edip etmediği sorgulanabilir. Ayrıca telif hakkı ve/veya görüntü hakları derin sahtekarlığın yaratıcısının sorumluluktan muaf

olacak belirli bir doktrine güvenip güvenemeyeceği sorgulanabilir. Örneğin, telif hakkı ihlali durumunda, derin bir sahtekarlığın yaratıcısı, parodi veya hiciv gibi yasal muafiyetlere başvurabilir.

Ortak hukuk mahkemeleri önünde bir telif hakkı ihlali iddiası söz konusu olduğunda, derin sahtekarlığın yaratıcısı sorumluluktan kaçmak için adil kullanım doktrinine güvenebilir. Daha spesifik olarak, derin sahtekarlığın yaratıcısı ABD mahkemelerinde dava edilirse, davalı, adil kullanımı olumlu bir savunma olarak, yani davacı bir telif hakkı ihlali tespit etmeyi başardıktan sonra ileri sürebilir. Derin sahtekarlığın yaratıcısının sorumluluktan kaçıp kaçamayacağı sorusu, davanın olgusal koşullarına ve ihlalde bulunduğu iddia edilen kişinin mahkemeyi adil analiz için dört faktörünün kendi lehine olduğuna ikna edip edemeyeceğine bağlı olacaktır. İlk olarak, sanık yeni yaratılan derin sahtekarlığın doğası gereği dönüştürücü olduğunu ve derin sahtekarlığın ahlaki açıdan iyi amaçlar için "kullanılmasının" amaçlandığını göstermelidir. Ancak derin sahtecilik ticari amaçlarla kullanılırsa davalı adil kullanım göstermekte zorluk yaşayabilir. İkincisi, adil kullanım doktrini, orijinal çalışmanın doğasının ne olduğuna bakmayı gerektirir: yayımlanmış mı, yayımlanmamış mı? Derin sahtecilik söz konusu olduğunda, özellikle derin sahteciliğin çok sayıda girdi dosyasına dayandığı durumlarda, adil kullanım doktrininin bu ikinci şartının belirli bir durumda nasıl sonuçlanacağını görmek zor olabilir. Üçüncüsü, bir derin sahte davadaki sanık, derin sahte oluşturmak için kullanımın önemsiz olduğunu göstermede başarılı olabilir ve tüm anlaşmazlık, derin sahte oluşturmak için kullanılan orijinal çalışmanın (veya eserlerin) kalitesi ve miktarı etrafında dönecektir. İhlal ettiği iddia edilen kişi, bir filmin yalnızca kısa bir parçası kullanılmışsa daha fazla şansa sahip olabilir; ancak bu kısa parça bir filmin en kötü şöhretli sahnesiyse, davalı bu noktada başarılı olamayabilir. Son olarak ve dördüncü olarak, adil kullanım analizi, orijinal ürünün potansiyel pazarı üzerindeki etkisinin değerlendirilmesini gerektirir. Yine, bu, davanın verili olgusal koşullarına bağlı olacaktır [47].

Gelişmekte olan birçok teknoloji için, yasanın ortaya çıkardıkları benzersiz sorunlara acil bir çözümü yoktur. Sonuç olarak, mahkemeler ve avukatlar, kendi davalarında ve masalarında karşılaştıkları bu sorunlara çözüm üretmelidir. Bu sürecin etkinliği, hukuk alanına, teknolojinin türüne, davayı gören mahkemeye ve bir dizi başka faktöre bağlı olarak önemli ölçüde değişmektedir [46]. Bu nedenle, derin sahtelerin kaderinin, derin sahte tespit teknolojilerinin geliştirilmesine ve içerik dağıtım platformlarının kötü niyetli içeriği belirlemeye yönelik etik taahhütlerine bağlı kalması önerilmektedir [47]. Bireylerin ve kuruluşların GAN'ları herhangi bir amaçla kullanmadan önce en son yasal gelişmelerden haberdar olmaları ve yasal riskleri azaltmak için stratejiler geliştirmeye yardımcı olabilecek hukuk uzmanlarından danışmanlık almaları önem arz etmektedir.

III.SONUÇ

Üretken modellerin ağ ve algoritmalarının mimarisini iyileştirerek, insanların ayırt etmesi zor olan görüntüler, sesler, videolar ve metinler üretebilen daha güçlü bir üretken model tasarlamak mümkün görünmektedir. Görüntülerden metinlere ve hatta melodilere kadar veri oluşturmak, buzdağının sadece görünen kısmını temsil etmektedir. Yapay zekânın sürekli gelişmesiyle birlikte siber güvenlik ve hatta yapay zekâ güvenliği araştırmacılar tarafından giderek daha fazla ilgi görmektedir. Özel yeni üretken çekişmeli ağlar uygulamalarının ortaya çıkışı, artırılmış gerçeklik, eğitim verisi oluşturmak, güvenlik alanından tıp alanına kadar üretken çekişmeli ağların büyük fayda sağlayacağı öngörülmektedir. Üretken çekişmeli ağ modellerinin hem ele alınan problemlerde daha iyi sonuçlar almasını sağlamak hem de benzer birçok problemde kullanışlı hale getirmek için değerlendirme metrikleri geliştirilerek performansını arttırmaya yönelik çalışmalar yapılmaya devam etmektedir. Diğer taraftan GAN'lar, kimlik hırsızlığı, var olmayan kişilerin sentetik görüntülerini oluşturmak, birinin yapmadığı bir şeyi söylemiş veya yapmış gibi görünmesi için değiştirilmiş videolar veya resimler olan deepfake'ler oluşturmak için de kötü amaçlar için kullanılabilir. GAN'lar, mevcut telif haklarını veya ticari markaları ihlal edebilecek ve potansiyel yasal anlaşmazlıklara yol açabilecek içerikler üretebilir. GAN tarafından oluşturulan içeriğin kötü amaçlarla kullanılma potansiyeli veya GAN'ların insan yaratıcılığının ve özgünlüğünün yerini alma potansiyeli gibi bir dizi etik kaygı gündeme getirmektedir. Bu kaygıları önüne geçmek için GAN'ları kullanırken yasal ihlalleri önlemek, etik yönergeleri kullanmak\geliştirmek, yetkili eğitim verileri kullanmak, gizliliğe saygı duymak, derin sahtekarlıkları tespit etmek için önlemler almak ve hukuk uzmanlarına danışmak gerekmektedir. GAN'ların potansiyel risklerini ve faydalarını anlamak için daha fazla araştırmaya ihtiyaç vardır.

KAYNAKÇA

- [1] Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). *Generative Adversarial Networks*, In Proceedings of the 27th International Conference on Neural Information Processing Systems - (NIPS'14), 2, (pp.2672–2680). Montreal, Canada, December.
- [2] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.
- [3] Xu, L., Zeng, X., Li, W., & Huang, Z. (2020). Multi-granularity generative adversarial nets with reconstructive sampling for image inpainting. *Neurocomputing*, 402, 220–234. <https://doi.org/10.1016/j.neucom.2020.04.011>
- [4] Hedjazi, M. A., & Genc, Y. (2021). Efficient texture-aware multi-GAN for image inpainting. *Knowledge-Based Systems*, 217, 106789. <https://doi.org/10.1016/j.knsys.2021.106789>
- [5] Babcock, J., & Bali, R. (2021). *Generative AI with Python and TensorFlow 2*. Birmingham, UK: Packt Publishing.
- [6] Available:<http://blogs.evergreen.edu/cpat/files/2013/05/Computer-Power-and-Human-Reason.pdf> (Erişim tarihi: 02.01.2023)
- [7] Available:<https://developers.google.com/machine-learning/gan/generative> (Erişim tarihi: 29.12.2022)
- [8] Gatys, L. A., Ecker, A. S., & Bethge, M. (2016). Image style transfer using convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2414-2423).
- [9] Çelik, G. *Üretken Ağlar ve Uygulamaları*. Türkçe Doktora Tezi. İnönü Üniversitesi Fen Bilimleri Enstitüsü, İnönü, Haziran, 2021.
- [10] Available: <https://github.com/NVLabs/stylegan2> (Erişim tarihi: 10.01.2023)
- [11] Wu, Y., Donahue, J., Balduzzi, D., Simonyan, K., & Lillcrap, T. (2019). Logan: Latent optimisation for generative adversarial networks. *arXiv preprint arXiv:1912.00953*.
- [12] Available: <https://github.com/robbiebarrat/art-DCGAN> (Erişim tarihi: 12.01.2023)
- [13] Available:<https://news.mit.edu/2020/rewriting-rules-machine-generated-art-0818> (Erişim tarihi: 13.01.2023)
- [14] Liu, G., Reda, F. A., Shih, K. J., Wang, T. C., Tao, A., & Catanzaro, B. (2018). Image inpainting for irregular holes using partial convolutions. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 85-100).
- [15] Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2017). Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4681-4690).
- [16] Zhu, J. Y., Park, T., Isola, P., & Efros, A. A. (2017). Unpaired image-to-image translation using cycle-consistent adversarial networks. In *Proceedings of the IEEE international conference on computer vision* (pp. 2223-2232).
- [17] Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- [18] Pan, Z., Yu, W., Yi, X., Khan, A., Yuan, F., & Zheng, Y. (2019). Recent progress on generative adversarial networks (GANs): A survey. *IEEE Access*, 7, 36322-36333.
- [19] Cai, Y., Wang, X., Yu, Z., Li, F., Xu, P., Li, Y., & Li, L. (2019). Dualattn-GAN: Text to image synthesis with dual attentional generative adversarial network. *IEEE Access*, 7, 183706-183716.
- [20] Karras, T., Laine, S., & 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* (pp. 4401-4410).
- [21] Figueira, A., & Vaz, B. (2022). Survey on synthetic data generation, evaluation methods and GANs. *Mathematics*, 10(15), 2733.
- [22] Wang, Z., She, Q., & Ward, T. E. (2021). Generative adversarial networks in computer vision: A survey and taxonomy. *ACM Computing Surveys (CSUR)*, 54(2), 1-38.
- [23] Saxena, D., & Cao, J. (2021). Generative adversarial networks (GANs) challenges, solutions, and future directions. *ACM Computing Surveys (CSUR)*, 54(3), 1-42.
- [24] Zhao, J., Mathieu, M., & LeCun, Y. (2016). Energy-based generative adversarial network. *arXiv preprint arXiv:1609.03126*.
- [25] Arjovsky, M., Chintala, S., & Bottou, L. (2017, July). Wasserstein generative adversarial networks. In *International conference on machine learning* (pp. 214-223). PMLR.
- [26] Park, S. W., & Kwon, J. (2019). Sphere generative adversarial network based on geometric moment matching. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4292-4301).
- [27] Jolicœur-Martineau, A. (2018). The relativistic discriminator: a key element missing from standard GAN. *arXiv preprint arXiv:1807.00734*.
- [28] Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. C. (2017). Improved training of wasserstein gans. *Advances in neural information processing systems*, 30.
- [29] Miyato, T., Kataoka, T., Koyama, M., & Yoshida, Y. (2018). Spectral normalization for generative adversarial networks. *arXiv preprint arXiv:1802.05957*.
- [30] Wei, X., Gong, B., Liu, Z., Lu, W., & Wang, L. (2018). Improving the improved training of wasserstein gans: A consistency term and its dual effect. *arXiv preprint arXiv:1803.01541*.
- [31] Chen, T., Zhai, X., Ritter, M., Lucic, M., & Houlsby, N. (2019). Self-supervised gans via auxiliary rotation loss. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 12154-12163).
- [32] Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- [33] Berthelot, D., Schumm, T., & Metz, L. (2017). Began: Boundary equilibrium generative adversarial networks. *arXiv preprint arXiv:1703.10717*.

- [34] Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2017). Progressive growing of gans for improved quality, stability, and variation. *arXiv preprint arXiv:1710.10196*.
- [35] Gong, X., Chang, S., Jiang, Y., & Wang, Z. (2019). Autogan: Neural architecture search for generative adversarial networks. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 3224-3234).
- [36] Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., & Chen, X. (2016). Improved techniques for training gans. *Advances in neural information processing systems*, 29.
- [37] Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S. (2017). Gans trained by a two time-scale update rule converge to a local nash equilibrium. *Advances in neural information processing systems*, 30.
- [38] Yadav, D., & Salmani, S. (2019, May). Deepfake: A survey on facial forgery technique using generative adversarial network. In *2019 International conference on intelligent computing and control systems (ICCS)* (pp. 852-857). IEEE.
- [39] Shahriar, S., & Al Roken, N. (2022). How can generative adversarial networks impact computer generated art? Insights from poetry to melody conversion. *International Journal of Information Management Data Insights*, 2(1), 100066.
- [40] Aldausari, N., Sowmya, A., Marcus, N., & Mohammadi, G. (2022). Video generative adversarial networks: a review. *ACM Computing Surveys (CSUR)*, 55(2), 1-25.
- [41] Cheng, J., Yang, Y., Tang, X., Xiong, N., Zhang, Y., & Lei, F. (2020). Generative adversarial networks: a literature review. *KSII Transactions on Internet and Information Systems (TIIS)*, 14(12), 4625-4647.
- [42] Wu, Q., Zhu, B., Yong, B., Wei, Y., Jiang, X., Zhou, R., & Zhou, Q. (2021). ClothGAN: generation of fashionable Dunhuang clothes using generative adversarial networks. *Connection Science*, 33(2), 341-358.
- [43] Raff, E. (2022). *Inside deep learning: Math, algorithms, models*. Manning Publications.
- [44] Parmar, G., Zhang, R., & Zhu, J. Y. (2022). On aliased resizing and surprising subtleties in gan evaluation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11410-11420).
- [45] Bińkowski, M., Sutherland, D. J., Arbel, M., & Gretton, A. (2018). Demystifying mmd gans. *arXiv preprint arXiv:1801.01401*.
- [46] Gerstner, E. (2020). Face/off: "DeepFake" face swaps and privacy laws. *Def. Counsel J.*, 87, 1.
- [47] Li, Y., Chang, M. C., & Lyu, S. (2018). In ictu oculi: Exposing ai generated fake face videos by detecting eye blinking. *arXiv preprint arXiv:1806.02877*.
- [48] Kataoka, Y., Matsubara, T., & Uehara, K. (2016, June). Image generation using generative adversarial networks and attention mechanism. In *2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS)* (pp. 1-6). IEEE.
- [49] Isola, P., Zhu, J.-Y., Zhou, T., & Efros, A. A. (2017). "Image-to-Image Translation with Conditional Adversarial Networks" *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 5967 - 5976), IEEE.
- [50] Zhu, J. Y., Zhang, R., Pathak, D., Darrell, T., Efros, A. A., Wang, O., & Shechtman, E. (2017). Toward multimodal image-to-image translation. *Advances in neural information processing systems*, 30.