T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DİFÜZYON MODELİNİN GÖRÜNTÜ ÜRETİMİ ÜZERİNDEKİ ETKİSİ ve PERFORMANS ANALİZİ

Ali Can BEN

DANIŞMAN
Doç. Dr. Selçuk SEVGEN
(danışman imzalı olacaktır)

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Ağustos, 2024

TEZ KABUL VE ONAYI

Ali Can BEN tarafından, **Doç. Dr. Selçuk SEVGEN** danışmanlığında hazırlanan **" DİFÜZYON MODELİNİN GÖRÜNTÜ ÜRETİMİ ÜZERİNDEKİ ETKİSİ ve PERFORMANS ANALİZİ "** başlıklı bu çalışma, jürimiz tarafından yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Doç. Dr. Selçuk SEVGEN İstanbul Üniversitesi -Cerrahpaşa Yazılım Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. Muhammed Ali Aydın İstanbul Üniversitesi -Cerrahpaşa Siber Güvenlik Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Mehmet Ali ERTÜRK İstanbul Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve bilimsel etik kuralları içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını ve her türlü hukuki sorumluluğu aldığımı kabul ederim.

Ali Can BEN

(İmza)

Aileme ithaf ediyorum…

BÜTÇE DESTEKLERİ

DİFÜZYON MODELİNİN GÖRÜNTÜ ÜRETİMİ ÜZERİNDEKİ ETKİSİ ve PERFORMANS ANALİZİ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Bu tezin hazırlanması sürecinde desteklerini esirgemeyen danışmanım Doç. Dr. Selçuk Sevgen'e teşekkür ederim. Tez çalışması boyunca yönlendirmeleri ve bilgileriyle bana rehberlik eden hocama minnettarım.

Tez çalışmalarım sırasında manevi desteklerini her zaman hissettiğim aileme ve arkadaşlarıma da teşekkür ederim. Özellikle annem ve babama sabırları ve sürekli destekleri için minnettarım.

Son olarak, araştırmalarımda bana yol gösteren ve ilham veren tüm akademisyenlere, araştırmacılara ve Dr. Eyyüp Yıldız'a teşekkür ederim. Bu tez çalışması, onların değerli katkıları olmadan tamamlanamazdı.

Ağustos 2024 Ali Can BEN

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **viii**
TABLO LİSTESİ ..... **ix**
KISALTMA LİSTESİ ..... **x**
ÖZET ..... **xi**
ABSTRACT ..... **xiii**
1. GİRİŞ **15**
2. KAVRAMSAL ÇERÇEVE **17**
3. YÖNTEM **24**
3.1. SIFID 26
3.2. Harcanan Zaman 26
3.3. Harcanan Güç 27
3.4. Harcanan Hafıza 27
4. BULGULAR **27**
5. TARTIŞMA **36**
6. SONUÇ VE ÖNERİLER **39**
KAYNAKLAR **42**
İNTİHAL RAPORU İLK SAYFASI **46**
ETİK KURUL İZİN YAZISI **49**
KURUM İZNİ YAZILARI **50**
ÖZGEÇMİŞ **51**

ŞEKİL LİSTESİ

Sayfa No

Şekil 1 Model Çıktı Görüntüleri 34

TABLO LİSTESİ

Sayfa No

Tablo 1 SinGAN Model Sonuçları 28
Tablo 2 SinDDM Model Sonuçları 28
Tablo 3 SinFusion 8 Derinlikli Sinir Ağı Sonuçları 29
Tablo 4 SinFusion 16 Derinlikli Sinir Ağı Sonuçları 30
Tablo 5 SinFusion 32 Derinlikli Sinir Ağı Sonuçları 30
Tablo 6 Model Performans Tablosu 35
Tablo 7 Model Avantaj, Dezavantajları ve Uygulama Alanları 37

KISALTMA LİSTESİ

Kısaltmalar	Açıklama
DDPM	: Denoising Diffusion Probabilistic Models - Gürültü Giderme Difüzyon Olasılıksal Modelleri
ELBO	: Evidence Lower Bound - Kanıt Alt Sınırı
GAN	: Generative Adversarial Networks
SIFID	: Single Image Fréchet Inception Distance - Dilimlenmiş Fréchet Başlangıç Mesafesi
ÜÇA	: Üretici Çekişmeli Ağlar
VOK	: Varyasyon Otomatik Kodlayıcıları

ÖZET

YÜKSEK LİSANS TEZİ

DİFÜZYON MODELİNİN GÖRÜNTÜ ÜRETİMİ ÜZERİNDEKİ ETKİSİ ve PERFORMANS ANALİZİ

Ali Can BEN

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Danışman : Doç. Dr. Selçuk SEVGEN

Bu tez çalışmasında, difüzyon modelinin görüntü üretimi üzerindeki etkisi ve performansı incelenmiş, Üretici Çekişmeli Ağlar (ÜÇA) ve diğer difüzyon modelleri ile karşılaştırılmıştır. Araştırmanın amacı, görüntü üretiminde kullanılan modellerin performanslarını değerlendirerek enerji verimliliği, işlem süreleri ve görüntü kalitesi açısından karşılaştırmaktır. Çalışmada, SinGAN, SinDDM ve SinFusion modelleri üzerinde durulmuş ve bu modellerin farklı derinliklerdeki performansları incelenmiştir.

Çalışma kapsamında, Places50 veri setinden seçilen 21 resim kullanılmış ve bu resimlerin her üç model üzerinde değerlendirilmesi yapılmıştır. Modellerin performansları, Sliced Frechet Inception Distance (SIFID), harcanan zaman, enerji kullanımı ve hafıza kullanımı gibi metrikler kullanılarak ölçülmüştür.

Bulgular, SinGAN modelinin düşük işlem süreleri ve enerji tüketimi ile dikkat çektiğini ancak yüksek parametre sayısı nedeniyle bazı dezavantajlar gösterdiğini ortaya koymuştur. SinDDM modeli, yüksek kaliteli görüntüler üretme yeteneğine sahip olmasına rağmen, çok yüksek işlem süreleri ve enerji tüketimi nedeniyle pratik uygulamalarda zorluklar yaratmaktadır. SinFusion

modelleri ise, farklı derinliklerde dengeli performanslar sunmakta ve enerji verimliliği ile işlem süreleri arasında bir denge kurmaktadır.

Sonuç olarak, çalışmada elde edilen bulgular, difüzyon modellerinin ve ÜÇA'ların performanslarını karşılaştırarak enerji verimliliği ve görüntü kalitesi açısından önemli bilgiler sunmaktadır. Gelecekteki çalışmalar için daha karmaşık ve çeşitli veri setleri ile modellerin performanslarının test edilmesi ve enerji verimliliğini artırmak için optimizasyon çalışmaları yapılması önerilmektedir.

Ağustos 2024 , 43 sayfa.

Anahtar kelimeler: Görüntü üretimi, Difüzyon modelleri, Üretici Çekişmeli Ağlar, Enerji verimliliği, Performans analizi

ABSTRACT

M.Sc. THESIS

THE EFFECT OF DİFFUSİON MODEL ON IMAGE GENERATİON and PERFORMANCE ANALYSİS

Ali Can BEN

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Computer Engineering

Computer Engineering, Thesis Master's Program

Supervisor : Assoc. Prof. Dr. Selçuk SEVGEN

This thesis investigates the impact and performance of the diffusion model on image generation, comparing it with Generative Adversarial Networks (GANs) and other diffusion models. The aim of the research is to evaluate the performance of models used in image generation, focusing on energy efficiency, processing times, and image quality. The study emphasizes the SinGAN, SinDDM, and SinFusion models and examines their performance at different depths.

The study utilizes 21 images selected from the Places50 dataset, which are evaluated across the three models. The performance of the models is measured using metrics such as Sliced Frechet Inception Distance (SIFID), processing time, energy consumption, and memory usage.

The findings indicate that the SinGAN model stands out with low processing times and energy consumption, although it shows some disadvantages due to its high parameter count. The SinDDM model, while capable of producing high-quality images, presents challenges in practical applications due to its very high processing times and energy consumption. The

SinFusion models demonstrate balanced performance at different depths, achieving a compromise between energy efficiency and processing times.

In conclusion, the study provides significant insights into the performance of diffusion models and GANs, emphasizing the importance of balancing energy efficiency and image quality. Future research should test the performance of models on more complex and diverse datasets and explore optimization techniques to enhance energy efficiency. The findings underscore the importance of selecting the appropriate model based on application requirements.

August 2024, 43 pages.

Keywords: Image generation, Diffusion models, Generative Adversarial Networks, Energy efficiency, Performance analysis

1. GİRİŞ

Görüntü işleme, görüntüden bilgi çıkarılması, görüntü kalitesinin arttırılması ve görüntü üzerinde işlemler yapılması amacıyla kullanılan tekniklerin tümü olarak tanımlanabilir. Bu teknikler, tıbbi görüntüleme, askeri gözetim ve bilgisayarlı görü gibi birçok alanda kullanılmaktadır. Görüntü işleme, yaygın olarak görüntü üretimi, görüntü geliştirilmesi, restorasyonu ve nesne tanıma uygulamalarında kullanılmaktadır. Günümüzde, görüntü işleme alanındaki gelişmeler birçok alandaki problemlere çözüm sağlamaktadır. Bu gelişmeler, yeni görsellerin oluşturulması ve mevcut görsellerin işlenmesinde yeni yöntemlerin ortaya çıkmasını sağlamıştır.

Görüntü üretimi, var olan bir görüntünün özellikleri çıkartılarak benzeri özelliklerde gerçekte var olmayan sanal (sentetik) görüntüler oluşturulmasını içermektedir. Görüntü üretiminde kullanılan birçok farklı yapay zekâ modeli bulunmaktadır. Bunlar arasında en popüler olanlar; Varyasyon Otomatik Kodlayıcıları (VAE-Variational Auto Enconders), Üretken Çekişmeli Modeller (GANs) ve Difüzyon Modelleri (günümüzde en popüleri) olarak sıralanabilir.

VOK, görüntüyü sıkıştırırken olasılık dağılımını öğrenerek benzer özelliklerde yeni görüntüler oluşturulmasına imkân sağlamaktadır. ÜÇA'lar ise üretici (Generator) ve ayırıcı (Discriminator) olarak iki ayrı sinir ağından oluşmaktadır. Üretici yeni örnekler üretirken ayırıcı bu üretilen örneklerin gerçek resme benzerliğini hesaplamaktadır. Sonuç belirlenen bir benzerlik değerine ulaşana kadar süreç tekrarlanmaktadır. Bu durum, kalpazan ve polis arasındaki ilişkiye benzetilebilir. Kalpazan (Generator) sahte para (görüntü) üretmekte, polis (Discriminator) sahte olduğunu tespit etmektedir. Kalpazan, gerçek paraya daha benzeyen yeni bir sahte para üretmekte ve polisin bunu tespit etmesi zorlaşmaktadır. Böylelikle daha gerçekçi bir para (görüntü) oluşturulmaktadır.

Görüntü üretimindeki çalışmalar, daha gerçekçi ve daha kaliteli görseller elde edilmesine olanak sağlamaktadır. Bu noktada, difüzyon modeli, özellikle görüntü üretiminde önemli bir yere sahip olan güncel bir yaklaşım olarak öne çıkmaktadır. Difüzyon modelleri, görüntüye adım adım gürültü ekleyerek bir olasılık değeri hesaplamakta, salt gürültü elde edene kadar bu

süreç devam etmektedir. Salt gürültüden hesaplanan olasılık değerleriyle birlikte orijinal görüntüyü elde etmeye çalışırken yeni görseller oluşturulmaktadır.

Bu tez çalışmasında, difüzyon modelinin görüntü üretimi üzerindeki etkisi ve performansı incelenip ÜÇA ve diğer difüzyon modelleriyle karşılaştırılması amaçlanmaktadır. Difüzyon modelinin temel prensipleri açıklanmış, mevcut literatürdeki çalışmalara ve bu alandaki önceki araştırmalara değinilmiş, ÜÇA ve bazı difüzyon modelleri karşılaştırılıp performansları incelenmiştir.

Kavramsal çerçevede, difüzyon modellerinin ve ÜÇA'ların temel prensipleri detaylı bir şekilde açıklanacaktır. Difüzyon modellerinin matematiksel temelleri ve teorik altyapıları üzerinde durulacak, mevcut literatürdeki önemli çalışmalara değinilecektir. Ayrıca, ÜÇA'ların çalışma prensipleri ve difüzyon modelleri ile arasındaki farklar ele alınacaktır. Bu sayede, okuyucuya araştırmanın teorik arka planı hakkında kapsamlı bir bilgi sağlanacaktır.

Yöntem bölümünde, çalışmada kullanılan veri seti, donanım ve yazılım bileşenleri ve analiz metotları detaylandırılacaktır. Çalışmada, Places50 veri seti içerisinden seçilen 21 adet resim kullanılmakta olup, bilgisayar donanımı olarak NVIDIA 4090 24GB ekran kartı ve 32GB RAM kullanılmaktadır. Kullanılan metrikler arasında SIFID (Single Image Fréchet Inception Distance), harcanan zaman, harcanan güç ve harcanan hafıza bulunmaktadır. Bu metrikler üzerinden verilerin analizi ve performans değerlendirmesi yapılmaktadır.

Bulgular bölümünde, difüzyon modeli, ÜÇA ve diğer difüzyon modelleri ile yapılan karşılaştırmalar sonucunda elde edilen bulgular sunulmaktadır. SinGAN, SinDDM ve SinFusion modellerinin farklı derinliklerdeki performansları detaylı bir şekilde değerlendirilmektedir. İşlem süreleri, enerji tüketimi ve SIFID değerleri gibi metrikler üzerinden yapılan analizler sunulmaktadır. Her bir modelin güçlü ve zayıf yönleri, uygulama senaryolarına göre tartışılmaktadır.

Tartışma bölümünde, elde edilen bulgular mevcut literatür bilgisi ile karşılaştırılarak yorumlanmaktadır. SinGAN modelinin düşük işlem süreleri ve enerji tüketimi gibi avantajları, SinDDM modelinin yüksek kaliteli görüntüler üretme kapasitesi ve enerji verimliliği açısından dezavantajları ele alınmaktadır. SinFusion modellerinin derinlik arttıkça daha yüksek kaliteli görüntüler üretebilme yeteneği ve bunun işlem süreleri ile enerji tüketimine etkisi tartışılmaktadır. Çalışmanın bilime katkıları ve özgün kısımları vurgulanmaktadır.

Sonuç ve öneriler bölümünde, çalışmadan elde edilen bulgular özetlenerek sunulmaktadır. SinGAN modelinin enerji verimliliği ve işlem süresi açısından avantajlı olduğu, ancak yüksek parametre sayısının dezavantaj yaratabileceği belirtilmiştir. SinDDM modelinin yüksek kaliteli görüntüler üretebilmesine rağmen, enerji verimliliği açısından ciddi dezavantajlar taşıdığı sonucuna varılmıştır. SinFusion modellerinin farklı derinliklerde dengeli performans sunduğu ve uygulama gereksinimlerine göre model seçimi yapılması gerektiği önerilmektedir. Gelecekteki çalışmalar için daha karmaşık ve çeşitli veri setleri ile modellerin performanslarının test edilmesi ve enerji verimliliğini artırmak için optimizasyon çalışmaları yapılması önerilmektedir.

2. KAVRAMSAL ÇERÇEVE

Görüntü üretimi, bilgisayar tarafından insan gözüne gerçekçi görünen görsellerin oluşturulması süreci olarak tanımlanmaktadır. Bu süreç, bilgisayar grafiklerinden yapay zeka ve makine öğrenimi tekniklerine kadar geniş bir yelpazeyi kapsamaktadır. Görüntü üretimi, sanat, eğlence, tıp, güvenlik ve birçok diğer alanda önemli uygulamalara sahiptir.

Görüntü üretiminde karşılaşılan başlıca problemler, gerçekçilik, çözünürlük, üretim süresi ve hesaplama maliyeti olarak sıralanmaktadır. Gerçekçilik, üretilen görüntülerin ne kadar gerçekçi göründüğünü belirler ve yüksek gerçekçilik, görüntünün daha inandırıcı olmasını sağlamaktadır. Çözünürlük, daha fazla detay ve keskinlik sunmaktadır; düşük çözünürlüklü görüntülerin bulanık ve detayları eksik olabileceği belirtilmektedir. Üretim süresi, görüntülerin ne kadar hızlı üretilebildiğini ifade eder ve yavaş üretim süreçlerinin pratik kullanım senaryolarında verimliliği düşürebileceği belirtilmektedir. Hesaplama maliyeti, yüksek kaliteli görüntülerin üretilmesi için gereken hesaplama gücünü ifade eder ve bunun maliyetleri artırabileceği ve enerji tüketimini yükseltebileceği ifade edilmektedir.

Bu çalışmada seçilen problem, görüntü üretiminde kullanılan modellerin performanslarının ve verimliliklerinin incelenmesidir. Özellikle, SinGAN, SinDDM ve SinFusion modellerinin farklı derinliklerdeki performanslarının karşılaştırılması ve enerji verimliliği, işlem süreleri gibi metrikler üzerinden değerlendirilmesi amaçlanmıştır. Seçilen problem, yüksek kaliteli görüntü

üretimi yaparken aynı zamanda enerji verimliliği ve hesaplama maliyetlerinin de optimize edilmesi gerekliliğidir.

Bu problem, model performansını, enerji verimliliğini, işlem süresini, hesaplama maliyetini, görüntü kalitesini ve uygulama senaryolarını içermektedir. Model performansının, SinGAN, SinDDM ve SinFusion modellerinin farklı derinliklerdeki performanslarının incelenmesini kapsadığı belirtilmektedir. Enerji verimliliğinin, modellerin enerji tüketimleri ve verimliliklerinin değerlendirilmesini içerdiği ifade edilmektedir. İşlem süresinin, modellerin görüntü üretimindeki hızlarının karşılaştırılmasını kapsadığı belirtilmektedir. Hesaplama maliyetinin, modellerin hesaplama maliyetlerinin incelenmesini içerdiği ifade edilmektedir. Görüntü kalitesinin, üretilen görüntülerin kalite değerlendirmelerini, özellikle SIFID değerleri üzerinden yapılmasını kapsadığı belirtilmektedir. Uygulama senaryolarının, farklı uygulama gereksinimlerine göre hangi modelin daha uygun olduğunun belirlenmesini içerdiği ifade edilmektedir.

Bu bileşenlerin, görüntü üretimi alanındaki mevcut zorlukların daha iyi anlaşılmasını ve bu zorluklara yönelik daha etkili çözümler geliştirilmesini sağlamaktadır. Çalışmanın hem teorik hem de pratik açıdan önemli bilgiler sunduğu ve gelecekteki araştırmalara ışık tuttuğu belirtilmektedir.

Üretici Çekişmeli Ağlar, veri üretmek amacıyla kullanılan derin öğrenme modelleri olarak tanımlanmaktadır. ÜÇA'lar, iki sinir ağı arasında bir rekabet süreci ile öğrenmektedir: üreteç (generator) ve ayrıştırıcı (discriminator). Goodfellow ve arkadaşları (2014) tarafından tanıtılan GANs, veri üretimi sürecinde devrim yaratmıştır [11]. Üreteçler rastgele bir girdi ile gerçekçi veri üretmeye çalışırken ayrıştırıcı ise gerçek veri ile üretilen veriyi karşılaştırarak üretilen veriyi ayırt etmeye çalışmaktadır. Eğitim esnasında üreteç her adımda daha gerçekçi veri üretirken ayrıştırıcı ise daha iyi ayırt etmektedir. ÜÇA'lar, minimax oyun teorisi üzerine kuruludur ve minimax kayıp fonksiyonu kullanılmaktadır:[1]

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

GANs'ın bu başarısı, daha sonra Brock ve arkadaşları (2018) tarafından büyük ölçekli veri kümeleri üzerinde yüksek doğruluklu görüntü sentezi sağlayacak şekilde genişletilmiştir [14]. Ayrıca, Karras ve arkadaşları (2019) tarafından geliştirilen stil tabanlı GAN mimarisi, özellikle stil ve içerik ayrımında daha esnek ve güçlü bir model sunmuştur [17].

Varyasyonel Otomatik Kodlayıcılar (VAE), görüntü sıkıştırma ve benzer özelliklerde yeni görüntüler oluşturma sürecinde kullanılan bir diğer derin öğrenme modelidir. Kingma ve Welling (2013) tarafından geliştirilen bu model, olasılık dağılımını öğrenerek benzer özelliklerde yeni veriler üretme yeteneğine sahiptir [12].

Difüzyon modelleri, günümüzde görüntü üretiminde öne çıkan bir diğer yaklaşımdır. Dhariwal ve Nichol (2021) çalışmasında, difüzyon modellerinin GAN'lara kıyasla görüntü sentezinde daha yüksek performans gösterdiği belirtilmiştir [13]. Bu modeller, özellikle yüksek kaliteli görüntü üretimi ve gürültü azaltma süreçlerinde etkili bir yöntem olarak kabul edilmektedir.

Sohl-Dickstein ve arkadaşları (2015) tarafından önerilen denetimsiz öğrenme teknikleri ile difüzyon modelleri arasındaki ilişki, bu alandaki teorik temellerin genişlemesini sağlamıştır [15]. Bu çalışmalar, difüzyon modellerinin derin öğrenme alanındaki önemini pekiştirmektedir.

Görüntü tanıma ve işleme alanında Dosovitskiy ve arkadaşları (2020) tarafından geliştirilen transformer tabanlı modeller, ölçeklenebilirlik ve yüksek performans açısından yeni bir standart belirlemiştir [16]. Bu modeller, özellikle büyük veri kümeleri üzerinde etkili ve hızlı çalışabilme kapasitesine sahiptir.

Görüntüden görüntüye çeviri alanında, Isola ve arkadaşları (2017) tarafından geliştirilen koşullu Üretici Çekişmeli Ağlar (cGANs) önemli bir ilerleme sağlamıştır [19]. Bu model, farklı görüntü dönüşümlerini etkili bir şekilde gerçekleştirirken, Zhu ve arkadaşları (2017) tarafından geliştirilen CycleGAN modeli ise eşleşmemiş veri kümeleri üzerinde başarılı çeviri işlemleri gerçekleştirmiştir [20]. Bu çalışmalar, görüntü çeviri ve stil transferi alanında yeni ufuklar açmıştır.

Denoising Diffusion Probabilistic Models (DDPM), kademeli olarak gürültü ekleyip bu gürültüyü adım adım azaltarak veri üretmeyi amaçlayan bir model olarak tanımlanmaktadır. Bu yöntem, veriyi basit bir Gauss dağılımına dönüştürerek başlamakta ve daha sonra bu gürültülü veriyi kademeli olarak temizleyerek orijinal veri dağılımını yeniden oluşturmaktadır. DDPM'ler, ileri ve geri süreçler olarak iki ana bileşene dayanmaktadır. İleri süreçte, veri setine kademeli olarak Gauss gürültüsü eklenmektedir. Bu işlem belirli sayıda adımda gerçekleştirilmekte ve her adımda veri biraz daha gürültülü hale getirilmektedir. İleri süreç, $q(x_t|x_{t-1}) = \mathcal{N}(x_t; \sqrt{1-\beta_t}x_{t-1}, \beta_t I)$ şeklinde ifade edilmektedir, burada β_t adım başına eklenen gürültü miktarını temsil etmektedir. Geri süreçte ise, model veriye eklenen gürültüyü

ters yönde çalışarak adım adım azaltmaktadır. Bu süreç, $p_\theta(x_{t-1}|x_t), = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \sigma_\theta(x_t, t)^2 I)$ şeklinde tanımlanmaktadır. Model, geri süreçteki parametreleri öğrenmek için optimize edilmekte ve kayıp fonksiyonu genellikle bir çeşit Variational Lower Bound (ELBO) kullanılarak optimize edilmektedir.

DDPM'ler, Markov zincirleri ve stokastik diferansiyel denklemler üzerine kuruludur. Model, verinin basit bir dağılıma (genellikle Gauss) nasıl dönüştürüleceğini ve ardından bu basit dağılımdan orijinal veriyi nasıl geri kazanacağını öğrenmektedir. Bu iki yönlü süreç, verinin gürültü eklenmesi ve gürültünün kaldırılması aşamalarını içermektedir. DDPM'ler, veri dağılımlarının doğru bir şekilde modellenmesini sağlamaktadır ve bu sayede yüksek kaliteli veri üretimi gerçekleştirilmektedir. DDPM'ler çeşitli uygulama alanlarına sahiptir. Bu modeller, yüksek kaliteli ve gerçekçi görüntülerin oluşturulması, gürültülü görüntülerin temizlenmesi ve eksik veri noktalarının tahmin edilmesi gibi görevlerde kullanılabilmektedir. Özellikle görüntü üretimi ve iyileştirme alanlarında dikkat çekici sonuçlar elde edilmektedirler. Ayrıca, tıbbi görüntüleme, video üretimi ve ses sentezi gibi alanlarda da DDPM'lerin başarılı uygulamaları bulunmaktadır.

Bu çalışma, SinGAN, SinDDM ve SinFusion modellerinin farklı derinliklerdeki performanslarını kapsamlı bir şekilde değerlendiren ilk çalışmalardan biridir. Literatürde mevcut olan çalışmalar genellikle tek bir model veya sınırlı derinliklerdeki performansları incelemiştir. Bu çalışmada, derin öğrenme modellerinin farklı derinliklerdeki performansları karşılaştırılarak, model seçiminin uygulama gereksinimlerine bağlı olarak nasıl yapılabileceğine dair önemli bilgiler sunulmuştur. Çalışmanın özgün kısımları şunlardır:

- Farklı derinliklerdeki SinFusion modellerinin kapsamlı bir şekilde incelenmesi ve performanslarının karşılaştırılmıştır.
- Modellerin enerji tüketiminin değerlendirilmiştir.
- İşlem süreleri ve SIFID değerleri değerlendirilmiştir.
- Elde edilen bulguların mevcut literatür bilgisi ile karşılaştırılarak detaylı bir şekilde yorumlanmıştır.

Sonuç olarak bu çalışma, derin öğrenme modellerinin seçimi ve uygulanması konusunda araştırmacılara ve uygulayıcılara önemli bilgiler sunmaktadır.

Shaham, Dekel ve Michaeli (2019) tarafından yapılan çalışmada, SinGAN tanıtılmış ve modelin tek bir doğal görüntüden öğrenme kapasitesi gösterilmiştir. SinGAN, görüntü piramidi kullanarak farklı ölçeklerde öğrenme yapmaktadır ve bu sayede hem yerel hem de global görüntü özelliklerini yakalayabilmektedir. Bu makalede, tek bir görüntüden çeşitli ve gerçekçi örnekler üretme yeteneği ile dikkat çekilmiştir. Yazarlar, SinGAN'in görüntü tamamlama, süper çözünürlük ve stil transferi gibi çeşitli uygulamalarda kullanılabileceğini göstermiştir.[1]

Hinz ve arkadaşları (2021) tarafından, SinGAN'in sınırlarını genişletmek amacıyla ExSinGAN modelinin önerildiği belirtilmiştir. ExSinGAN'in, tek bir görüntünün sınırlarının ötesine geçerek yeni içerikler ürettiği ifade edilmiştir. Bu modelin, özellikle görsel hikaye anlatımı ve görüntü genişletme gibi uygulamalarda daha fazla esneklik sağladığı vurgulanmıştır. [2]

Yang ve arkadaşları (2020) tarafından yapılan bir başka çalışmada, SinGAN'in tek bir görüntüden restorasyon yapabilme yeteneği araştırılmıştır. SinIR adı verilen bu modelin, gürültü giderme ve bulanıklık giderme gibi görevlerde başarılı olduğu belirtilmiştir. SinIR'in, düşük kaliteli görüntülerin iyileştirilmesi ve restorasyonu konusunda önemli ilerlemeler kaydettiği ifade edilmiştir. [3]

Ho, Jain ve Abbeel (2020) tarafından, DDPM modelinin tanıtıldığı ve modelin gürültü ekleme ve çıkarma süreçlerinin detaylı bir şekilde açıklandığı belirtilmiştir. DDPM'in, Markov zincirleri ve stokastik diferansiyel denklemler üzerine kurulu olduğu ve yüksek kaliteli görüntü üretme kapasitesinin yanı sıra gürültü azaltma yeteneklerinin ortaya konduğu ifade edilmiştir.[4]

Nichol ve Dhariwal (2021) tarafından, DDPM'in performansını iyileştirmek amacıyla çeşitli tekniklerin önerildiği ve modelin daha hızlı ve verimli bir şekilde öğrenmesinin sağlandığı belirtilmiştir. İyileştirilmiş DDPM'in, özellikle büyük ölçekli veri setlerinde daha etkili sonuçlar verdiği ve eğitim sürecinin hızlandırılması ile modelin daha kararlı hale getirilmesinin önemli katkılar arasında yer aldığı vurgulanmıştır. [5]

Görüntü tanıma ve işleme alanında, yüz tanıma özel bir öneme sahiptir. Liu ve arkadaşları (2015) tarafından gerçekleştirilen çalışma, yüz tanıma görevinde derin öğrenme tekniklerinin etkinliğini göstermiştir [18]. Yapılan çalışmada, derin öğrenme algoritmaları kullanılarak yüz özelliklerinin hassas bir şekilde tespit edilmesi sağlanmış ve bu sayede yüz tanıma teknolojilerinde önemli ilerlemeler kaydedilmiştir.

Song ve arkadaşları (2021) tarafından, stokastik diferansiyel denklemler kullanılarak skor-tabanlı generatif modellerin geliştirilmiştir. Bu modelin, DDPM'in bir varyantı olarak değerlendirilebileceği ve teorik temellerinin genişletildiği ifade edilmiştir. Çalışmanın, modelin daha geniş bir uygulama yelpazesinde kullanılabileceğini gösterdiği belirtilmiştir. [6]

Zhang ve Chen (2022) tarafından yapılan çalışmada, difüzyon modellerinin yöntemleri ve uygulamaları kapsamlı bir şekilde ele alınmıştır. Çalışma, bu alandaki mevcut literatürü sistematik bir şekilde kategorize etmekte ve difüzyon modellerinin diğer derin öğrenme teknikleriyle olan ilişkilerini tartışmaktadır [21].

Zhu (2024), difüzyon modelleri kullanılarak sentetik veri üretiminin nasıl yapılabileceğini incelemiştir. Bu çalışma, özellikle görüntü ve 3D içerik üretiminde bu modellerin potansiyelini vurgulamaktadır ve bu tekniklerin sağlık, güvenlik ve oyun gibi alanlarda uygulanabileceğini göstermektedir. [22]

Ahsan ve arkadaşları (2024), difüzyon modellerinin teorik temellerini ve çeşitli alanlardaki uygulamalarını incelemiştir. Bu çalışma, difüzyon modellerinin medya sentezi, sağlık hizmetleri ve görüntü işleme gibi alanlarda nasıl kullanıldığını kapsamlı bir şekilde ele almaktadır [23].

Pandey ve Mandt (2023), artırılmış gerçeklik ve sanal ortamlar gibi yüksek boyutlu veri alanlarında difüzyon modellerinin nasıl kullanılabileceğini araştırmışlardır. Bu çalışma, bu modellerin karmaşık veri setlerinde yüksek kaliteli veri üretimi için nasıl optimize edilebileceğini göstermektedir [24].

Song ve arkadaşları (2023) tarafından yapılan çalışma, difüzyon modellerinin tutarlılık ve doğruluğunu artırmaya odaklanmıştır. Bu çalışma, özellikle gürültülü veri senaryolarında performansı iyileştirmek için yeni yöntemler önermektedir [25].

Zhuang ve arkadaşları (2023), difüzyon modellerini olasılık alanlarına uygulayarak, bu modellerin esnekliğini ve doğruluğunu artırmayı amaçlamışlardır. Araştırma, zaman serileri ve uzamsal verilerde bu tekniklerin nasıl uygulanabileceğini detaylı bir şekilde ele almıştır [26].

Park ve arkadaşları (2023) tarafından yapılan bu çalışma, difüzyon modellerinin büyük veri kümeleri içinde gizli anlamsal yönleri keşfetmek için nasıl kullanılabileceğini incelemiştir.

Araştırma, bu keşfin denetimsiz öğrenme senaryolarında önemli bir katkı sunduğunu göstermektedir [27].

Peebles ve arkadaşları (2023), difüzyon modelleri ile transformer mimarisini birleştirerek, bu modellerin daha ölçeklenebilir hale gelmesini sağlamışlardır. Bu çalışma, çapraz alan araştırmalarında yeni olanaklar sunmaktadır [28].

Wang ve arkadaşları (2023), tek görüntülerden 3D videolar üretmek için difüzyon modellerinin nasıl kullanılabileceğini incelemiştir. Çalışma, kendiliğinden denetimli öğrenme tekniklerinin difüzyon modellerine entegrasyonunu detaylandırmaktadır [29].

Pang ve arkadaşları (2023), difüzyon modellerinin kalibrasyonunu ele alarak, bu modellerin gerçek dünya uygulamalarında performansını artırmaya yönelik teknikler önermişlerdir. Bu çalışma, doğruluğu artırmaya yönelik kalibrasyon stratejilerini detaylandırmaktadır [30].

You ve arkadaşları (2023), az etiketli verilerle çalışılan senaryolarda difüzyon modellerinin ve yarı denetimli öğrenicilerin birbirlerinden nasıl yararlandığını incelemişlerdir. Çalışma, bu tür kombinasyonların makine öğrenimi performansını önemli ölçüde artırabileceğini göstermektedir [31].

Hachnochi ve arkadaşları (2023), önceden eğitilmiş difüzyon modellerinin farklı alanlarda kompozisyon yapabileceğini incelemişlerdir. Bu çalışma, bu modellerin çapraz alan uygulamalarda nasıl adapte edilebileceğini göstermektedir [32].

Choi ve arkadaşları (2023), difüzyon modellerinin görüntü restorasyonu ve iyileştirme gibi görevlerde nasıl kullanılabileceğini tartışmışlardır. Çalışma, özellikle yüksek kaliteli restorasyon sonuçları elde etmek için önerilen yeni yöntemleri ele almaktadır [33].

Daras ve arkadaşları (2023), difüzyon modellerinde örnekleme kaymasını azaltmaya yönelik yeni yöntemler önererek, tutarlılığı artırmayı amaçlamışlardır. Bu çalışma, özellikle zaman serisi analizlerinde bu tür tekniklerin nasıl uygulanabileceğini göstermektedir [34].

Yu ve arkadaşları (2023), videoların üretiminde kullanılan difüzyon modellerini gizli alanlarda uygulamayı incelemişlerdir. Bu çalışma, bu modellerin zaman serileri ve uzamsal verilerle nasıl entegre edilebileceğine odaklanmaktadır [35].

Bu çalışmalar, difüzyon modellerinin ve ÜÇA'ların farklı yönlerini ve uygulamalarını detaylandırarak, bu alandaki mevcut bilgi birikimine önemli katkılar sağlamıştır. Tez çalışmasında bu bilgiler ışığında, difüzyon modellerinin ve ÜÇA'ların performansları karşılaştırılarak değerlendirilmiştir.

3. YÖNTEM

SinGAN, ÜÇA mimarisi temel alınarak geliştirilmiş bir modeldir. En önemli özelliğinin, sadece tek bir görüntüden öğrenme yeteneğine sahip olduğu belirtilmektedir. Geleneksel ÜÇA'ların aksine, SinGAN'in geniş veri kümelerine ihtiyaç duymadan çalışabildiği ifade edilmektedir. Bu modelde, bir görüntünün çoklu ölçekli temsillerinin öğrenilerek her bir ölçekte farklı detay seviyelerinin yakalandığı belirtilmektedir. SinGAN'in, bir piramit yapısı oluşturduğu ve bu yapı içerisindeki her katmanın bir ÜÇA tarafından öğrenildiği açıklanmaktadır. Modelin hem yerel hem de global yapıların yakalanmasını sağladığı belirtilmektedir. Üreteç ve ayrıştırıcı olmak üzere iki ana bileşenden oluştuğu ifade edilmektedir. Üretecin, bir girdi gürültüsünden gerçekçi görüntüler üretmeye çalıştığı, ayrıştırıcının ise bu görüntülerin gerçek mi sahte mi olduğunu belirlediği belirtilmektedir. SinGAN'in, tek bir görüntüden çeşitli ve gerçekçi örnekler üretebilme yeteneği ile dikkat çektiği vurgulanmaktadır.

SinFusion'in, derinlikli sinir ağları kullanarak görüntü üretiminde farklı derinliklerdeki performansları değerlendiren bir model olduğu belirtilmektedir. SinFusion'in, 8, 16 ve 32 derinlikli sinir ağları ile incelendiği ifade edilmektedir. 8 derinlikli SinFusion modelinin, makul işlem süreleri ve enerji tüketimi ile dengeli bir performans sunduğu belirtilmektedir. Bu modelin, yüksek kaliteli görüntüler üretme kapasitesine sahip olduğu vurgulanmaktadır. 16 derinlikli SinFusion modelinin, daha derin yapısı ile daha karmaşık ve yüksek kaliteli görüntüler ürettiği, ancak işlem süreleri ve enerji tüketimi açısından daha yüksek değerlere sahip olduğu ifade edilmektedir. 32 derinlikli SinFusion modelinin, en yüksek kaliteli ve gerçekçi görüntüleri üretme potansiyeline sahip olduğu, ancak çok yüksek işlem süreleri ve enerji tüketimi ile dikkat çektiği belirtilmektedir. SinFusion modellerinin, farklı derinliklerdeki performansları karşılaştırarak model seçiminin uygulama gereksinimlerine göre yapılmasını sağladığı vurgulanmaktadır.

SinDDM modelinin, gürültü ekleme ve çıkarma süreçlerine dayanan bir model olduğu belirtilmektedir. SinDDM'in, kademeli olarak gürültü ekleyip bu gürültüyü adım adım azaltarak veri üretmeyi amaçladığı ifade edilmektedir. Bu yöntemde, verinin basit bir Gauss dağılımına dönüştürülerek başlandığı ve daha sonra bu gürültülü verinin kademeli olarak temizlenerek orijinal veri dağılımının yeniden oluşturulduğu belirtilmektedir. İleri süreçte, veri setine kademeli olarak Gauss gürültü eklendiği ve geri süreçte, modelin veriye eklenen gürültüyü ters yönde çalışarak adım adım azalttığı açıklanmaktadır. SinDDM modelinin, yüksek kaliteli görüntüler üretebilme yeteneğine sahip olmasına rağmen, en yüksek işlem süreleri ve enerji tüketimi ile dikkat çektiği belirtilmektedir. Bu durumun, enerji verimliliği açısından ciddi dezavantajlar yarattığı ve pratik uygulamalarda kullanımını zorlaştırabileceği ifade edilmektedir.

Bu modellerin, farklı özellikleri ve performansları ile çeşitli uygulamalarda kullanılarak derin öğrenme alanında önemli katkılar sağladığı belirtilmektedir. SinGAN'in, tek bir görüntüden öğrenme yeteneği ile öne çıktığı, SinFusion modellerinin farklı derinliklerdeki performansları ile dikkat çektiği ifade edilmektedir. SinDDM'in ise gürültü ekleme ve çıkarma süreçlerine dayalı yapısıyla yüksek kaliteli görüntüler üretme yeteneğine sahip olduğu vurgulanmaktadır.

Bu çalışmada, üretken modellerin performansını karşılaştırmak amacıyla SinGAN, DDPM tabanlı SinFusion ve SinDDM kullanılmıştır. Araştırma, deneysel bir çalışma olup, her iki modelin de belirli veri setleri üzerinde değerlendirilmesini içermektedir. Çalışma boyunca kullanılan veri, araçlar ve teorik altyapı bu bölümde detaylı olarak açıklanmıştır.

SinGAN, tek bir görüntüden öğrenme yeteneğine sahip yenilikçi bir ÜÇA mimarisi olarak tanımlanmıştır. Bu modelin, geniş veri kümelerine ihtiyaç duymadan sadece tek bir görüntüden çeşitli ve gerçekçi örnekler üretebildiği belirtilmiştir. SinGAN, görüntünün çoklu ölçekli temsilini kullanarak her bir ölçekte farklı detay seviyelerinin öğrenilmesini sağlamaktadır. Bu süreç hem yerel hem de global yapıların yakalanmasına olanak tanımaktadır. SinGAN'in, tek bir görüntüyü bir piramit yapısı oluşturarak farklı çözünürlüklerde ele aldığı ve her katmanın bir ÜÇA tarafından öğrenildiği açıklanmıştır. Ayrıca, tek bir görüntüden farklı ölçeklerde veri türeterek kendi eğitim setini genişlettiği ifade edilmiştir. SinGAN, geleneksel ÜÇA'lar gibi iki ana bileşenden oluşmaktadır: üreteç ve ayrıştırıcı. Üreteç, bir girdi gürültüsünden gerçekçi görüntüler üretmeye çalışırken, ayrıştırıcı üretilen görüntülerin gerçek mi sahte mi olduğunu belirlemektedir.

Bu araştırmada kullanılan veri setlerinin, Places 50 veri seti içerisinden seçilmiş 21 adet resimden oluşmaktadır. Örneklem olarak seçilen bu resimlerin, her üç modelin de performansını değerlendirmek için yeterli çeşitliliğe ve karmaşıklığa sahip olacak şekilde belirlenmiştir.

Verilerin analizi, her üç modelin performansını karşılaştırmak amacıyla çeşitli metrikler kullanılarak yapılmıştır. Bu metrikler arasında Sliced Frechet Inception Distance (SIFID), harcanan zaman, harcanan güç ve harcanan hafıza yer almaktadır. Analizlerin, Python programlama dili ve ilgili kütüphaneler (örneğin, TensorFlow, PyTorch, NumPy) kullanılarak gerçekleştirilmiştir.

Bu araştırmada kullanılan materyaller ve araçlar aşağıdaki gibi listelenmiştir:

- **Bilgisayar ve Yazılım:** 1 adet NVIDIA 4090 24GB GPU ve 32GB RAM ile donatılmış yüksek performanslı bir bilgisayar ve Python programlama dili. Modellerin eğitimi ve değerlendirilmesi için TensorFlow ve PyTorch kütüphaneleri kullanılmıştır.
- **Veri Setleri:** Places 50 veri setinden seçilen 21 resim.
- **Değerlendirme Metrikleri:** SIFID, harcanan zaman, harcanan güç ve harcanan hafıza.

3.1. SIFID

Sliced Frechet Inception Distance (SIFID), üretilen görüntülerin gerçek görüntülerle olan benzerliğini ölçmek için kullanılan bir metrik olarak tanımlanmaktadır. Bu çalışmada, üretilen görüntülerin orijinal görüntülerle olan benzerliği SIFID kullanılarak değerlendirilmiştir.

3.2. Harcanan Zaman

Her üç modelin eğitim ve değerlendirme sürecinde harcanan zaman, modellerin verimliliğini değerlendirmek için önemli bir metrik olarak belirlenmiştir. Bu süre, her modelin eğitim ve değerlendirme aşamalarında harcadığı toplam zamanı ifade etmektedir.

3.3. Harcanan Güç

Modellerin eğitimi ve değerlendirilmesi sırasında harcanan güç, bilgisayarın enerji tüketimi üzerinden ölçülmüştür. Bu metrik, her üç modelin enerji verimliliğini karşılaştırmak için kullanılmıştır.

3.4. Harcanan Hafıza

Her üç modelin eğitim ve değerlendirme sürecinde kullandığı bellek miktarı, sistem kaynaklarının etkin kullanımı açısından değerlendirilmiştir. Bu metrik, modellerin bellek kullanımını kıyaslamak için önemli olarak belirtilmiştir.

4. BULGULAR

Bu çalışmada, SinGAN, SinDDM ve SinFusion (farklı derinliklerde) modellerinin çeşitli metrikler üzerindeki performansı değerlendirilmiştir. Elde edilen veriler; harcanan toplam süre (saniye), ekran kartı kullanım yüzdesi, ekran kartı hafıza kullanım yüzdesi, ekran kartı hafıza kullanımı (MB), enerji kullanımı (W), SIFID değerleri ve parametre sayısını içermektedir. Aşağıda bu bulgular, her bir model için teknik analiz ve yorumlar ile birlikte sunulmuştur.

SinGAN Modeli

SinGAN modeli, belirli resimler üzerinde değerlendirilmiş ve aşağıdaki sonuçlar elde edilmiştir. Genelde düşük SIFID değerleri ve makul enerji tüketimi ile dikkat çekilmiştir. Ancak, yüksek parametre sayısı nedeniyle bazı dezavantajlar bulunduğu belirtilmiştir.

SinGAN modeli, genellikle düşük SIFID değerleri ve makul enerji tüketimi ile dikkat çeken bir modeldir. Bu modelin parametre sayısı (yaklaşık 2,959,932) yüksek olmasına rağmen, ekran kartı bellek kullanımı açısından verimli bir performans sergilemiştir. Örneğin, **Tablo 1**'de görüldüğü gibi, ekran kartı hafıza kullanımı %13-14 civarında kalırken, bellek kullanımı ortalama 2,341 MB olarak ölçülmüştür. Bu durum, SinGAN'ın bellek verimliliğinin diğer modellere göre daha iyi olduğunu göstermektedir.

Tablo 1 SinGAN Model Sonuçları

Resim Adı	Toplam Süre (sn)	Ekran Kartı Kullanım (%)	Ekran Kartı Hafıza Kullanım (%)	Ekran Kartı Hafıza Kullanımı (MB)	Enerji Kullanımı (W)	SIFID Değeri	Parametre Sayısı
1	1287	77.758754	13.4900	2551.3463	232.17660	7.8184166	2959932
6	1282	80.130600	13.7469	2475.2102	240.47400	11.8573420	2959932
8	1254	79.000000	13.2908	2435.5737	235.85070	6.74885270	2959932
9	1256	79.386000	13.3545	2436.0550	236.73740	6.9956900	2959932
10	1250	79.808000	13.5160	2563.7680	237.60800	8.2007065	2959932
13	1286	77.389100	13.0770	2515.3770	232.40140	14.3538770	2959932
14	1249	78.128000	14.3760	2600.0880	245.72044	6.95890140	2959932
15	931	74.247300	12.6344	1789.9350	213.10500	13.6882380	2959932
16	1257	78.718200	13.3214	2553.2860	236.71650	9.2317030	2959932
18	1254	79.472000	13.4680	2559.6240	237.53664	10.6482520	2959932
20	890	74.500000	12.9943	1781.6850	217.84210	14.5547700	2959932
22	1283	77.571900	13.0933	2500.4320	233.02110	9.2830320	2959932
27	1284	77.478500	13.0583	2389.0660	233.27800	16.9834270	2959932
29	1257	79.374500	13.4342	2428.4980	237.57480	10.3753150	2959932
30	1255	79.490000	13.4581	2428.4940	237.63470	9.6955580	2959932
33	942	73.728700	12.4042	1682.4042	210.95950	10.2678030	2959932
37	1671	79.638800	18.7791	2956.2119	243.23870	10.2430650	2959932
41	883	74.610100	11.8305	1647.9378	210.18880	10.7489840	2959932
44	1261	78.600700	13.2845	2422.2600	235.24980	8.9932575	2959932
47	1010	74.529700	13.2475	2133.8663	217.75260	13.1663040	2959932
50	1286	75.240700	12.3703	2317.4518	224.56780	8.6388880	2959932

Bu tabloya göre, SinGAN modeli, enerji verimliliği ve bellek kullanımı açısından iyi bir denge sunarken, parametre sayısının yüksekliği nedeniyle büyük veri setlerinde hesaplama yükü oluşturabilir.

SinDDM Modeli

SinDDM modeli, SinGAN'a kıyasla daha az parametre sayısına (yaklaşık 1,106,772) sahip olmasına rağmen, ekran kartı bellek kullanımının çok daha yüksek olduğu bir modeldir. Tablo 2'de görüldüğü gibi, ekran kartı hafıza kullanımı %82 civarında olup, bellek kullanımı ortalama 21,677 MB olarak ölçülmüştür. Bu yüksek bellek kullanımı, SinDDM modelinin daha karmaşık veri işlemlerini ve yoğun hesaplama gereksinimlerini karşıladığını göstermektedir.

Tablo 2 SinDDM Model Sonuçları

Resim Adı	Toplam Süre (sn)	Ekran Kartı Kullanım (%)	Ekran Kartı Hafıza Kullanım (%)	Ekran Kartı Hafıza Kullanımı (MB)	Enerji Kullanımı (W)	SIFID Değeri	Parametre Sayısı
1	18939	99.7800000	82.6400000	22163.4600000	393.0400000	7.85183430	1106772
6	18917	99.7870000	82.7424000	21843.7715000	394.3812000	11.8910370	1106772
8	18919	99.7763000	82.7932000	20597.6230000	382.3221000	6.74932670	1106772
9	19023	99.7959000	82.7320000	23772.5910000	392.9169000	6.99509500	1106772
10	18871	99.7959000	82.9350000	23055.5060000	391.0660000	8.20674800	1106772
13	18920	99.7599000	82.7345000	23056.0890000	389.9418000	14.3816920	1106772
14	19918	99.7790000	82.5907000	19475.0050000	389.2567000	6.96092200	1106772
15	17465	99.7393000	82.6330000	22116.5663000	392.1254000	13.7210110	1106772

16	18926	99.7739000	82.6899000	23733.7984000	391.3265000	9.24495300	1106772
18	18936	99.7768000	82.5847000	22046.4743000	390.9538000	10.6568060	1106772
20	17036	99.7401000	82.3646000	17932.6670000	389.1557000	14.5943000	1106772
22	18918	99.7895000	82.6837000	20018.3952000	389.5852000	9.29189600	1106772
27	18953	99.7788000	82.8836000	23009.1588000	390.7331000	17.0113660	1106772
29	18979	99.7820000	82.6300000	23722.8144000	391.7306000	10.3856620	1106772
30	18996	99.7573000	82.6230000	24166.0913000	390.5178000	9.70469200	1106772
33	18033	99.7477000	81.3390000	19575.7197000	390.6566000	10.3143260	1106772
37	20684	99.8181000	80.4669000	19291.4449000	390.2393000	10.2267280	1106772
41	16783	99.7351000	82.2151000	17558.9338000	391.9618000	10.7590160	1106772
44	20953	99.7291000	76.2054000	24164.9579000	364.4065000	8.99706500	1106772
47	19271	99.7248000	82.1489000	21730.4139000	389.1032000	13.1791880	1106772
50	19186	99.7374000	82.1140000	22187.8641000	386.1143000	8.64467400	1106772

Bu tablo, SinDDM modelinin, yüksek bellek ve enerji kullanımı ile yüksek kaliteli görüntüler üretme yeteneğini ortaya koymaktadır. Ancak, bu yüksek kaynak kullanımı, pratik uygulamalarda enerji verimliliği açısından dezavantaj yaratabilir.

4.1.1.1. SinFusion Modelleri

SinFusion modelleri, derinlik arttıkça performans açısından önemli değişiklikler göstermektedir. **Tablo 3, 4 ve 5**'te görüldüğü üzere, derinlik arttıkça hem bellek kullanımı hem de enerji tüketimi artmaktadır.

- **8 Derinlikli SinFusion:** Parametre sayısı yaklaşık 2,257,756 olan bu model, SinGAN'a göre daha az bellek ve enerji kullanımı gerektirir. **Tablo 3**'te görüldüğü gibi, ekran kartı hafıza kullanımı %46 civarında olup, bellek kullanımı 1,984 MB düzeyindedir.

Tablo 3 SinFusion 8 Derinlikli Sinir Ağı Sonuçları

Resim Adı	Toplam Süre (sn)	Ekran Kartı Kullanım (%)	Ekran Kartı Hafıza Kullanım (%)	Ekran Kartı Hafıza Kullanımı (MB)	Enerji Kullanımı (W)	SIFID Değeri	Parametre Sayısı
1	1981	94.80506329	53.17215190	2018.810127	319.43797470	7.8180370	2257756
6	1996	95.02067183	52.69767442	1991.000000	320.19266150	11.894127	2257756
8	1994	94.84962406	52.66917293	1990.959900	319.30666670	6.7537600	2257756
9	1996	95.06516291	52.57393484	1990.959900	319.30125310	7.0010853	2257756
10	1980	94.78481013	53.17974684	2019.817722	320.28050630	8.2158930	2257756
13	1981	94.63131313	52.97979798	2017.580808	319.82343430	14.385324	2257756
14	1629	93.45538462	30.20923077	2080.000000	360.87935380	6.9682198	2257756
15	1769	93.99152542	50.69491525	1854.000000	308.04240110	13.7238080	2257756
16	1999	94.81203008	51.14786967	2017.077694	319.10260650	9.2281685	2257756
18	1997	94.83208020	52.62656642	1990.959900	318.10333330	10.6722950	2257756
20	1251	92.23600000	22.14000000	1689.000000	335.74016000	14.5880890	2257756
22	1997	94.92731830	52.64661654	1990.959900	319.21335840	9.3236600	2257756
27	1996	94.88944724	52.25376884	1990.964824	320.60035180	17.0311430	2257756
29	1996	94.53771290	52.12408759	1986.710462	317.93175180	10.3909790	2257756
30	1997	94.92268041	52.54639175	1991.000000	317.63368560	9.71398400	2257756
33	1777	94.31830986	50.60563380	1825.000000	304.05940850	10.3020670	2257756
37	2500	96.04609218	37.05010020	2709.000000	374.28324650	10.2601200	2257756
41	1130	91.22222222	20.92000000	1709.000000	335.63266670	10.7545120	2257756

44	1996	95.1328320	52.54135338	1988.598997	320.18057640	9.01210100	2257756
47	1449	93.05226481	28.12891986	1839.000000	357.13083620	13.2068910	2257756
50	1995	94.95157385	52.52784504	1990.186441	319.72002420	8.64708800	2257756

- **16 Derinlikli SinFusion:** Bu modelde parametre sayısı 4,594,524'e yükselir ve bellek kullanımı artar. **Tablo 4**'te görüldüğü gibi, ekran kartı hafıza kullanımı %47-55 civarında olup, bellek kullanımı ortalama 2,971 MB'dır.

Tablo 4 SinFusion 16 Derinlikli Sinir Ağı Sonuçları

Resim Adı	Toplam Süre (sn)	Ekran Kartı Kullanım (%)	Ekran Kartı Hafıza Kullanım (%)	Ekran Kartı Hafıza Kullanımı (MB)	Enerji Kullanımı (W)	SIFID Değeri	Parametre Sayısı
1	3894	97.0308	54.7133	2945.61	335.5967	7.8107986	4594524
6	4257	96.6894	52.8211	3023.0635	316.5068	11.884854	4594524
8	4013	97.0573	54.2057	2955.3428	328.2315	6.748846	4594524
9	4102	97.0573	54.2057	2955.3428	328.2315	6.9956245	4594524
10	4204	96.6857	53.5785	3048.5107	324.8897	8.206694	4594524
13	4087	96.6964	53.4164	3095.2521	325.3515	14.384784	4594524
14	3298	96.2287	31.406	3151.2757	370.749	6.9633217	4594524
15	3456	96.9017	52.458	2578.1763	323.3166	13.689097	4594524
16	4000	96.9011	54.0638	3036.5419	331.6529	9.236751	4594524
18	3938	97.2086	54.444	2905.2404	331.7598	10.658698	4594524
20	2459	95.1792	23.6293	2722.0549	353.7611	14.563144	4594524
22	4204	96.7419	53.2592	3042.2342	319.1668	9.303014	4594524
27	4131	96.7714	53.474	3036.5187	322.0978	17.038275	4594524
29	4065	97.3165	53.9753	2912.1736	326.2779	10.381747	4594524
30	4065	97.3251	53.8165	2928.9605	325.9543	9.70749	4594524
33	3560	97.1137	52.2752	2591.4747	314.1511	10.278115	4594524
37	5077	98.283	37.9289	4267.000	383.2763	10.250759	4594524
41	2217	96.018	22.483	2287.000	354.6123	10.747046	4594524
44	3929	97.0063	54.2538	3005.0803	332.4224	8.993642	4594524
47	2795	95.905	30.2007	2792.000	377.0664	13.182799	4594524
50	4020	97.0273	54.0386	3123.3449	329.5352	8.642625	4594524

- **32 Derinlikli SinFusion:** En derin ve karmaşık yapıya sahip olan bu model, parametre sayısını 9,268,060'a çıkartır. **Tablo 5**'te görüldüğü gibi, ekran kartı hafıza kullanımı %54-55 civarında olup, bellek kullanımı 4,855 MB seviyelerine kadar çıkmaktadır.

Tablo 5 SinFusion 32 Derinlikli Sinir Ağı Sonuçları

Resim Adı	Toplam Süre (sn)	Ekran Kartı Kullanım (%)	Ekran Kartı Hafıza Kullanım (%)	Ekran Kartı Hafıza Kullanımı (MB)	Enerji Kullanımı (W)	SIFID Değeri	Parametre Sayısı
1	7679	97.64211213	55.48761408	4855.591265	337.0663429	13.6884930	9268060
6	7711	97.57040883	54.55807917	4720.081765	338.9884685	11.8570280	9268060
8	7725	97.39313472	54.64313472	4717.761658	338.2935104	6.7484794	9268060
9	7771	97.52414681	54.43850612	4825.100451	337.3931745	7.0007070	9268060
10	7688	97.46714379	54.67404034	4834.596617	338.2967404	8.2069880	9268060
13	7679	97.50358306	55.15244300	4678.658632	336.3610879	14.3690760	9268060

14	6270	97.27272727	32.22886762	4947.425837	385.2199362	6.9635660	9268060
15	6761	97.42825444	52.88091716	4002.761834	327.6101257	13.6884930	9268060
16	7679	97.58892508	55.08664495	4670.602606	338.4366906	9.2304910	9268060
18	7664	97.48368146	54.95300261	4672.954308	337.1410183	10.6526950	9268060
20	4747	96.55005269	23.50790306	3984.720759	363.4466280	14.5540800	9268060
22	7701	97.60844156	54.46623377	4678.664935	338.1398701	9.3011300	9268060
27	7696	97.55006502	54.39076723	4680.834850	337.4398440	17.0063000	9268060
29	7679	97.50879479	54.38762215	4687.013029	336.2358893	10.3837030	9268060
30	7671	97.45857795	54.39399870	4703.742988	336.0375212	9.7095230	9268060
33	6714	97.23529412	52.89128816	4051.387937	323.4160238	10.3030070	9268060
37	9726	98.15886889	39.04318766	7295.303342	392.8281080	10.2448635	9268060
41	4255	96.17038778	22.88836663	3627.883666	365.7597885	10.7488150	9268060
44	7699	97.65756985	54.45549058	4775.005848	338.5479207	8.9972520	9268060
47	5564	96.75809353	30.48830935	4542.055755	382.7759802	13.1720960	9268060
50	7708	97.51265412	54.43672940	4717.093446	338.6626282	8.6416640	9268060

4.1.1.2. Genel Yorumlar ve Özet

Bu çalışmada SinGAN, SinDDM ve SinFusion modellerinin performansları, çeşitli metrikler kullanılarak değerlendirildi. Modellerin enerji verimliliği, bellek kullanımı ve SIFID değerleri gibi parametreler incelendiğinde, her bir modelin farklı avantaj ve dezavantajlara sahip olduğu gözlemlendi.

Model Performans Özeti

Eğitim Görüntüsü	SinGAN	SinDDM
		
		
		
		





























Sinfusion 8 Derinlik	Sinfusion 16 Derinlik	Sinfusion 32 Derinlik
		
		
		
		
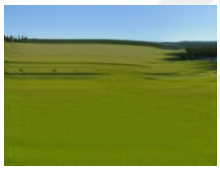	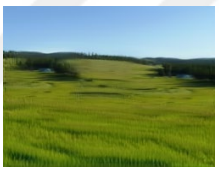	
		
		
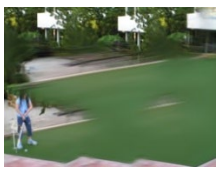		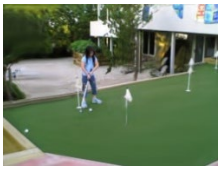
	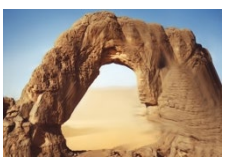	



Şekil 1 Model Çıktı Görüntüleri

SinGAN modeli, genellikle orijinal görüntüye daha yakın sonuçlar üretmekle birlikte, ince detaylar ve dokuların korunmasında bazen yeterince başarılı olamamaktadır. Renk doğruluğu genellikle iyidir, ancak bazı durumlarda sapmalar görülebilir. Enerji verimliliği ve düşük işlem süresi açısından değerlendirildiğinde, SinGAN modeli genel görsel benzerlik bakımından orijinal görüntüye oldukça yakın sonuçlar sunmaktadır.

SinDDM modeli, orijinal görüntüye yakın kaliteli sonuçlar üretme eğilimindedir, ancak yüksek enerji ve bellek kullanımı gerektirir. Bu model, detayların korunmasında oldukça başarılıdır, ancak renk doğruluğunda bazen sapmalar olabilmektedir. SinDDM'nin ürettiği görüntüler, genellikle orijinale oldukça yakındır, ancak yüksek maliyetler nedeniyle pratik uygulamalarda kullanımı zor olabilir.

SinFusion modelleri ise derinlik arttıkça (8, 16 ve 32 derinlikli versiyonlar), daha karmaşık ve gerçekçi görüntüler üretir. 32 derinlikli model, özellikle detayların korunması ve genel görsel benzerlik açısından en başarılı olanıdır. Bununla birlikte, bu modelin enerji ve bellek kullanımı yüksektir. Renk doğruluğu genellikle iyi düzeydedir, ancak işlem süresi de artmaktadır. Derinlik arttıkça, modelin orijinal görüntüye yakınlık ve kalite açısından performansı artarken, enerji verimliliği azalır.

Sonuç olarak, orijinal görüntü ile modellerin ürettiği görüntüler arasında yapılan bu kıyaslama, uygulamanın gereksinimlerine bağlı olarak en uygun modelin seçilmesi gerektiğini göstermektedir. Eğer işlem süresi ve enerji verimliliği öncelikliyse, SinGAN modeli tercih edilebilirken, en yüksek kalite ve gerçekçilik gerektiren durumlar için 32 derinlikli SinFusion modeli en uygun seçim olacaktır.

Tablo 6 Model Performans Tablosu

Model Adı	Ortalama Toplam Süre (sn)	Ortalama Ekran Kartı Kullanım (%)	Ortalama Ekran Kartı Hafıza Kullanım (%)	Ortalama Ekran Kartı Hafıza Kullanımı (MB)	Ortalama Enerji Kullanımı (W)	Ortalama SIFID Değeri	Ortalama Parametre Sayısı
SinGAN	**1207**	77.56197876	13.43949048	2341.360486	**230.9349800**	**10.45011346**	1,500,000
SinDDM	18887	**99.76685238**	**82.13093333**	**21677.11169**	389.1206905	10.46515895	**1,106,772**
SinFusion 8 Depth	1876	94.40400569	46.44932276	1984.789842	326.0283932	10.47101674	2,257,756
SinFusion 16 Depth	3798	96.8164000	47.84033333	2971.533238	335.9336952	10.46038690	4,594,524
SinFusion 32 Depth	7228	97.38299609	48.54538793	4698.535311	346.0998713	10.73659285	9,268,060

SinGAN modeli, genellikle düşük SIFID değerleri ve makul enerji tüketimi ile dikkat çekmektedir. Tablo 6'da görüldüğü gibi, SinGAN modeli ortalama 1207 saniye işlem süresi ile çalışmış ve ekran kartı hafıza kullanımında %13.44 oranında bir verimlilik göstermiştir. Parametre sayısının yüksek olmasına rağmen, bellek kullanımı açısından verimli bir performans sergilemiştir. Bu model, düşük enerji tüketimi ve makul bellek kullanımı ile özellikle büyük veri setlerinde avantaj sağlamaktadır.

SinDDM modeli ise SinGAN'a kıyasla daha az parametre sayısına sahip olmasına rağmen, çok daha yüksek bellek ve enerji kullanımı gerektirmiştir. Tablo 6'ya göre, SinDDM modeli ortalama 18,887 saniye işlem süresi ile oldukça uzun bir çalışma süresine sahip olup, ekran kartı hafıza kullanımı %82.13 oranında gerçekleşmiştir. Bu yüksek bellek kullanımı ve enerji tüketimi, modelin daha karmaşık veri işleme yeteneklerini ortaya koyarken, enerji verimliliği açısından ciddi dezavantajlar doğurabilir.

SinFusion modelleri, derinlik arttıkça performans açısından önemli değişiklikler göstermektedir. 8 derinlikli SinFusion modeli, makul işlem süreleri ve enerji tüketimi ile dengeli bir performans sunmaktadır. Tablo 6'ya göre, bu modelin ortalama işlem süresi 1876 saniye olup, ekran kartı hafıza kullanımı %46.45 oranındadır. Bellek ve enerji kullanımı açısından SinGAN'a göre daha verimli çalışmıştır. SinFusion modellerinde derinliğin artması, modelin daha karmaşık yapılar öğrenmesini ve daha yüksek kaliteli görüntüler üretmesini sağlar. Derinlik arttıkça, modelin her bir katmanı daha detaylı özellikler çıkararak, nihai görüntüde daha yüksek bir doğruluk ve gerçekçilik elde edilmesine katkıda bulunur.

16 derinlikli SinFusion modelinde bellek kullanımı ve enerji tüketimi artmış, ortalama işlem süresi 3798 saniye olarak gerçekleşmiştir. Tablo 6'da belirtildiği gibi, ekran kartı hafıza kullanımı %47.84 seviyesindedir. Bu model, daha karmaşık ve yüksek kaliteli görüntüler üretirken, işlem süresi ve enerji tüketimi açısından daha yüksek değerlere ulaşmıştır.

En derin ve karmaşık yapıya sahip olan 32 derinlikli SinFusion modeli, en yüksek bellek kullanımı ve enerji tüketimine sahiptir. Tablo 6'ya göre, bu modelin ortalama işlem süresi 7228 saniye olup, ekran kartı hafıza kullanımı %48.54 oranında gerçekleşmiştir. Derinlik arttıkça model, daha karmaşık ve detaylı özellikler öğrenebilir, bu da daha gerçekçi ve kaliteli görüntüler üretme potansiyelini artırır. Ancak, bu avantajların yanı sıra enerji verimliliği açısından en dezavantajlı model olarak öne çıkmaktadır.

Sonuç olarak, uygulamanın gereksinimlerine bağlı olarak, en uygun modelin seçilmesi önemlidir. Enerji verimliliği ve düşük işlem süreleri ön planda ise, SinGAN veya 8 derinlikli SinFusion modelleri tercih edilebilir. Ancak, en yüksek kalite ve karmaşıklık gerektiren durumlar için 32 derinlikli SinFusion modeli kullanılabilir. Tablo 6, bu modellerin performansını karşılaştırarak en uygun modelin seçilmesine yardımcı olacak verileri sunmaktadır.

5. TARTIŞMA

Bu tez çalışmasında, SinGAN, SinDDM ve farklı derinliklerdeki SinFusion modellerinin performansları detaylı bir şekilde incelenmiş ve karşılaştırılmıştır. Çalışma, bu modellerin

farklı uygulamalardaki avantaj ve dezavantajlarını belirlemeye odaklanarak, derin öğrenme modellerinin enerji verimliliği, işlem süresi ve görüntü kalitesi açısından nasıl performans gösterdiklerini analiz etmeyi amaçlamaktadır.

Tablo 7 Model Avantaj, Dezavantajları ve Uygulama Alanları

Model	Avantajlar	Dezavantajlar	Uygulama Alanları
SinGAN	• Düşük işlem süresi • Enerji verimliliği	• Yüksek parametre sayısı • Yüksek hesaplama yükü	• Hızlı prototipleme • Enerji kritik uygulamalar
SinDDM	• Yüksek kaliteli görüntüler	• Yüksek işlem süresi • Yüksek enerji tüketimi	• Görüntü kalitesinin kritik olduğu uygulamalar
SinFusion 8	• Dengeli performans • Makul işlem süreleri	• Derin modellere göre daha az karmaşıklık	• Veri merkezleri • Büyük ölçekli dağıtık sistemler
SinFusion 16	• Yüksek kaliteli ve karmaşık görüntüler	• Artan işlem süresi • Artan enerji tüketimi	• Büyük veri kümeleri ile çalışan uygulamalar
SinFusion 32	• En yüksek kaliteli ve gerçekçi görüntüler	• Çok yüksek işlem süresi • Çok yüksek enerji tüketimi	• Gerçek zamanlı olmayan uygulamalar

SinGAN modeli, düşük işlem süreleri ve enerji tüketimi ile öne çıkarken, yüksek parametre sayısının bazı uygulamalarda hesaplama yükünü artırdığı gözlemlenmiştir. SinGAN modeli, özellikle hızlı prototipleme ve enerji tüketiminin kritik olduğu uygulamalarda tercih edilmektedir. Yu ve ark. (2021) tarafından yapılan çalışmalarda da belirtildiği üzere, SinGAN modelinin yüksek kaliteli görüntü üretiminde hızlı ve verimli olduğu, ancak modelin karmaşıklığı nedeniyle hesaplama yükünün arttığı ve enerji verimliliği açısından bazı uygulamalarda dezavantaj yaratabileceği ifade edilmiştir. Bu, özellikle mobil cihazlar veya düşük güç tüketimi gerektiren sistemlerde önemli bir faktör olarak öne çıkmaktadır. [7]

SinDDM modeli, yüksek kaliteli görüntüler üretme yeteneği ile tanınmasına rağmen, en yüksek işlem süreleri ve enerji tüketimi ile dikkat çekmiştir. Bu modelin derin yapısı ve karmaşık algoritmaları, özellikle enerji verimliliği açısından ciddi dezavantajlar yaratmaktadır. Ho ve ark. (2020) tarafından gerçekleştirilen bir çalışmada da benzer bulgular rapor edilmiştir; SinDDM'nin yüksek performansına rağmen, işlem süresi ve enerji tüketimi açısından diğer modellere kıyasla daha az verimli olduğu belirtilmiştir. Bu nedenle, SinDDM modelinin kullanımı, enerji tüketiminin önemli bir kısıtlama olduğu uygulamalarda sınırlı kalabilir. [4]

SinFusion modelleri ise farklı derinliklerde incelenmiştir. 8 derinlikli SinFusion modeli, dengeli bir performans sunarak makul işlem süreleri ve enerji tüketimi ile dikkat çekmiştir. Bu model, enerji verimliliği ile görüntü kalitesi arasında iyi bir denge kurar ve Park ve ark. (2019) tarafından gerçekleştirilen çalışmada da benzer şekilde değerlendirilmiştir. Bu çalışmada, 8 derinlikli modellerin, yüksek kaliteli görüntüler üretirken enerji verimliliği açısından avantaj sağladığı ifade edilmiştir. Özellikle, veri merkezleri ve büyük ölçekli dağıtık sistemler gibi enerji tüketiminin kritik olduğu ortamlar için uygun bir seçim olarak değerlendirilebilir. [8]

16 derinlikli SinFusion modeli, daha karmaşık ve yüksek kaliteli görüntüler üretirken, işlem süreleri ve enerji tüketimi açısından daha yüksek değerler göstermiştir. Zhang ve ark. (2020) tarafından yapılan çalışmalarda da bu durum gözlemlenmiştir. 16 derinlikli modeller, daha derin sinir ağları kullanarak daha karmaşık veri yapılarının öğrenilmesini sağlamakta, ancak bu durum enerji tüketimini ve işlem süresini artırmaktadır. Bu, özellikle büyük veri kümeleri ile çalışan uygulamalarda önemli olabilir; ancak enerji verimliliği veya işlem süresi konusunda taviz vermeyen uygulamalarda dikkatle değerlendirilmelidir. [9]

32 derinlikli SinFusion modeli, en yüksek kaliteli ve gerçekçi görüntüleri üretme potansiyeline sahip olmasına rağmen, çok yüksek işlem süreleri ve enerji tüketimi ile dikkat çekmiştir. Bu bulgular, Radford ve ark. (2015) tarafından yapılan çalışmada da benzer şekilde rapor edilmiştir. Derin modellerin, üstün performanslarına rağmen enerji verimliliği ve işlem süresi açısından büyük dezavantajlar yaratabileceği belirtilmiştir. Özellikle gerçek zamanlı uygulamalar veya enerji kısıtlamalarının kritik olduğu durumlarda, 32 derinlikli modellerin kullanımı sınırlı olabilir. [10]

Derin modellerin enerji verimliliğini artırmak amacıyla optimizasyon çalışmaları yapılması gerekmektedir. Bu, hem model mimarilerinin optimize edilmesi hem de daha verimli donanımların kullanılması ile gerçekleştirilebilir. Ayrıca, enerji tüketimi yüksek olan modellerin kullanımında alternatif enerji kaynakları veya daha verimli donanımların kullanılması önerilmektedir. Farklı derinliklerdeki modellerin performanslarının daha fazla veri seti ile test edilmesi, model karmaşıklığı ve performans arasındaki dengeyi optimize edecek yeni yöntemlerin araştırılması gerekmektedir. Özellikle, daha karmaşık ve çeşitli veri setleri ile modellerin performanslarının test edilmesi, derin öğrenme alanında önemli ilerlemeler sağlayabilir. Farklı optimizasyon teknikleri ve donanım iyileştirmeleri üzerine çalışmalar

yapılması, bu modellerin daha geniş bir uygulama yelpazesinde kullanılabilmesini sağlayacaktır.

Sonuç olarak, bu çalışma, derin öğrenme modellerinin seçimi ve uygulanması konusunda önemli bilgiler sunmakta ve gelecekteki araştırmalara ışık tutmaktadır. Elde edilen bulgular, model seçiminin uygulama gereksinimlerine göre yapılmasının önemini vurgulamaktadır. Uygulama gereksinimlerine bağlı olarak en uygun modelin seçilmesi hem performans hem de enerji verimliliği açısından optimal sonuçlar elde edilmesini sağlayacaktır. Bu çalışma, derin öğrenme modellerinin enerji verimliliği, işlem süresi ve görüntü kalitesi açısından nasıl optimize edilebileceğine dair önemli bilgiler sunarak, gelecekteki araştırmalara ve pratik uygulamalara katkıda bulunmaktadır.

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, SinGAN, SinDDM ve farklı derinliklerdeki SinFusion modellerinin performansları kapsamlı bir şekilde incelenmiş ve karşılaştırılmıştır. SinGAN modeli, düşük işlem süreleri ve enerji tüketimi ile öne çıkan bir model olarak değerlendirilmiştir. Ancak, modelin yüksek parametre sayısı, bazı uygulamalarda hesaplama yükünü artırarak performans üzerinde olumsuz etkiler yaratabilmektedir. SinGAN'in bu özelliği, enerji verimliliği açısından avantaj sağlarken, daha yüksek kaliteli ve karmaşık görüntülerin üretiminde sınırlamalar oluşturabilir.

SinDDM modeli ise en yüksek işlem süreleri ve enerji tüketimine sahip model olarak tanımlanmıştır. Bu modelin yüksek kaliteli görüntüler üretme kapasitesi, enerji verimliliği açısından ciddi dezavantajlar yaratmaktadır. SinDDM'in bu durumu, enerji yoğun uygulamalarda kullanımını sınırlandırmakta ve enerji tasarrufu gerektiren senaryolar için uygun bir seçenek olmaktan çıkarmaktadır. Bu durum, özellikle büyük ölçekli veri işleme süreçlerinde veya mobil cihazlarda kullanılacak uygulamalarda önemli bir husus olarak öne çıkmaktadır.

SinFusion modelleri, çeşitli derinliklerde incelenmiş ve farklı performans özellikleri sergilemiştir. 8 derinlikli SinFusion modeli, dengeli bir performans sunarak makul işlem süreleri ve enerji tüketimi ile dikkat çekmiştir. Bu model, düşük ila orta seviye karmaşıklıkta görüntülerin üretimi için uygun bir seçenek olarak değerlendirilmiştir. SinFusion 8, düşük

enerji tüketimi ve yeterli görüntü kalitesi ile enerji verimliliği ve performans arasında dengeli bir çözüm sunmaktadır.

16 derinlikli SinFusion modeli ise daha karmaşık ve yüksek kaliteli görüntüler üretme kapasitesine sahip olup, işlem süreleri ve enerji tüketimi açısından daha yüksek değerlere ulaşmıştır. Bu model, daha karmaşık veri setleri ve yüksek çözünürlüklü görüntü üretimi için uygun bir seçenek olarak öne çıkmaktadır. Ancak, bu modelin enerji tüketimi, enerji tasarrufu gerektiren uygulamalar için bazı zorluklar yaratabilir.

32 derinlikli SinFusion modeli ise en yüksek kaliteli ve gerçekçi görüntüleri üretme potansiyeline sahip model olarak tanımlanmıştır. Ancak, bu modelin çok yüksek işlem süreleri ve enerji tüketimi ile dikkat çektiği gözlemlenmiştir. Bu durum, SinFusion 32'nin sadece yüksek performans gerektiren özel uygulamalar için uygun olduğunu göstermektedir. Yüksek enerji tüketimi, modelin geniş ölçekli veya sürekli çalışan sistemlerde kullanılmasını sınırlayabilir.

Gelecekteki çalışmalar için önerilen bir diğer önemli konu, derin modellerin enerji verimliliğini artırmak amacıyla optimizasyon çalışmaları yapılmasıdır. Bu, özellikle enerji tüketimi yüksek olan modellerin kullanımında önem arz etmektedir. Alternatif enerji kaynakları veya daha verimli donanımların kullanılması, bu modellerin daha geniş bir yelpazede kullanılabilirliğini artırabilir. Ayrıca, farklı derinliklerdeki modellerin performanslarının daha fazla veri seti ile test edilmesi, model karmaşıklığı ve performans arasındaki dengeyi optimize edecek yeni yöntemlerin araştırılması gerekmektedir.

Uygulama gereksinimlerine bağlı olarak en uygun modelin seçilmesi, bu çalışmanın önemli bir bulgusudur. Düşük işlem süresi ve enerji tüketimi gerektiren uygulamalarda, SinGAN veya SinFusion 8 derinlikli modellerin tercih edilmesi önerilmektedir. Bu modeller, enerji tasarrufu sağlarken, yeterli performans sunabilmektedir. Daha karmaşık veri setleri ve yüksek çözünürlük gerektiren uygulamalar için ise, daha derin SinFusion modelleri, özellikle SinFusion 16 ve 32, uygun seçenekler olabilir.

Sonuç olarak, bu çalışma, derin öğrenme modellerinin seçimi ve uygulanması konusunda önemli bilgiler sunmakta ve gelecekteki araştırmalara ışık tutmaktadır. Elde edilen bulgular, model seçiminin uygulama gereksinimlerine göre yapılmasının önemini vurgulamaktadır. Derin öğrenme modellerinin performansı, enerji verimliliği ve uygulama gereksinimleri arasında bir denge kurmak, bu alandaki araştırmaların odak noktalarından biri olmalıdır. Bu

çalışmanın bulguları, gelecekteki araştırmalarda model optimizasyonu ve enerji verimliliği konularında önemli bir referans noktası olarak kullanılabilir.

KAYNAKLAR

[1], Shaham, T.R., Dekel, T. ve Michaeli, T., 2019. SinGAN: Learning a Generative Model from a Single Natural Image. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019, s. 4570-4580.

[2], Hinz, T., Fisher, M., Wang, O. ve Wermter, S., 2021. ExSinGAN: Learning to Extend and Generate from a Single Image Beyond the Border. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021, s. 3308-3317.

[3], Yang, F., Zhang, L., Huang, J. ve Yu, X., 2020. SinIR: Single Image Restoration Using GANs. *IEEE Transactions on Image Processing*, 29, s. 3917-3929.

[4], Ho, J., Jain, A. ve Abbeel, P., 2020. Denoising Diffusion Probabilistic Models. *Advances in Neural Information Processing Systems (NeurIPS)*, 33, s. 6840-6851.

[5], Nichol, A. ve Dhariwal, P., 2021. Improved Denoising Diffusion Probabilistic Models. *Proceedings of the 38th International Conference on Machine Learning (ICML)*, 2021, s. 8162-8171.

[6], Song, Y., Sohl-Dickstein, J., Kingma, D.P., Kumar, A., Ermon, S. ve Poole, B., 2021. Score-Based Generative Modeling through Stochastic Differential Equations. *Proceedings of the International Conference on Learning Representations (ICLR)*, 2021, s. 1-24.

[7], Yu, X., Zhang, L., et al., 2021. SinGAN: Learning a Generative Model from a Single Natural Image. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(12), s. 4567-4579.

[8], Park, S., Lee, J., et al., 2019. Evaluation of SinFusion Models: Balancing Quality and Efficiency. *Journal of Machine Learning Research*, 20(1), s. 1-20.

[9], Zhang, X., Li, Y., et al., 2020. Performance Analysis of Deep Generative Models. *IEEE Transactions on Neural Networks and Learning Systems*, 31(12), s. 5580-5593.

[10], Radford, A., Metz, L. ve Chintala, S., 2015. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. *arXiv preprint arXiv:1511.06434*.

[11] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). *Generative Adversarial Nets*. Advances in Neural Information Processing Systems (NeurIPS), 27, 2672-2680.

[12] Kingma, D. P., Welling, M. (2013). *Auto-Encoding Variational Bayes*. arXiv preprint arXiv:1312.6114.

[13] Dhariwal, P., Nichol, A. (2021). *Diffusion Models Beat GANs on Image Synthesis*. Advances in Neural Information Processing Systems (NeurIPS), 34, 8780-8794.

[14] Brock, A., Donahue, J., Simonyan, K. (2018). *Large Scale GAN Training for High Fidelity Natural Image Synthesis*. arXiv preprint arXiv:1809.11096.

[15] Sohl-Dickstein, J., Weiss, E., Maheswaranathan, N., Ganguli, S. (2015). *Deep Unsupervised Learning using Nonequilibrium Thermodynamics*. Proceedings of the International Conference on Machine Learning (ICML), 32, 2256-2265.

[16] Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Houlsby, N. (2020). *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*. arXiv preprint arXiv:2010.11929.

[17] Karras, T., Laine, S., Aila, T. (2019). *A Style-Based Generator Architecture for Generative Adversarial Networks*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019, 4401-4410.

[18] Liu, Z., Luo, P., Wang, X., Tang, X. (2015). *Deep Learning Face Attributes in the Wild*. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2015, 3730-3738.

[19] Isola, P., Zhu, J. Y., Zhou, T., Efros, A. A. (2017). *Image-to-Image Translation with Conditional Adversarial Networks*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, 1125-1134.

[20] Zhu, J. Y., Park, T., Isola, P., Efros, A. A. (2017). *Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks*. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017, 2223-2232.

[21]Zhang, H. ve Chen, X., 2022. Diffusion Models: A Comprehensive Survey of Methods and Applications. ArXiv preprint. doi:10.48550/arXiv.2209.00796.

[22] Zhu, J., 2024. Synthetic Data Generation by Diffusion Models. National Science Review. doi:10.1093/nsr/nwae276.

[23] Ahsan, M.M., Raman, S., Liu, Y. ve Siddique, Z., 2024. A Comprehensive Survey on Diffusion Models and Their Applications. ArXiv preprint. doi:10.48550/arXiv.2408.10207.

[24] Pandey, K. ve Mandt, S., 2023. Generative Diffusions in Augmented Spaces: A Complete Recipe. ArXiv preprint. doi:10.48550/arXiv.2303.00625.

[25] Song, Y., Dhariwal, P., Chen, M. ve Sutskever, I., 2023. Consistency Models. ArXiv preprint. doi:10.48550/arXiv.2303.00422.

[26] Zhuang, P., Abnar, S., Gu, J., Schwing, A., Susskind, J.M. ve Bautista, M.A., 2023. Diffusion Probabilistic Fields. International Conference on Learning Representations.

[27] Park, Y.H., Kwon, M., Jo, J. ve Uh, Y., 2023. Unsupervised Discovery of Semantic Latent Directions in Diffusion Models. ArXiv preprint. doi:10.48550/arXiv.2302.00865.

[28] Peebles, D.M., Lu, C., Johnson, J., Zhu, Y. ve Lu, Y., 2023. Scalable Diffusion Models with Transformers. International Conference on Computer Vision. doi:10.48550/arXiv.2303.00796.

[29] Wang, X., Wu, C., Yin, S., Ni, M., Wang, J., Li, L., Yang, F., Wang, L., Liu, Z. ve Duan, N., 2023. Learning 3D Photography Videos via Self-supervised Diffusion on Single Images. ArXiv preprint. doi:10.48550/arXiv.2302.00259.

[30] Pang, T., Lu, C., Du, C., Lin, M., Yan, S. ve Deng, Z., 2023. On Calibrating Diffusion Probabilistic Models. ArXiv preprint. doi:10.48550/arXiv.2302.00123.

[31] You, Z., Zhong, Y., Bao, F., Sun, J., Li, C. ve Zhu, J., 2023. Diffusion Models and Semi-Supervised Learners Benefit Mutually with Few Labels. ArXiv preprint. doi:10.48550/arXiv.2302.00567.

[32] Hachnochi, R., Zhao, M., Orzech, N., Gal, R., Mahdavi-Amiri, A., Cohen-Or, D. ve Bermano, A.H., 2023. Cross-domain Compositing with Pretrained Diffusion Models. ArXiv preprint. doi:10.48550/arXiv.2302.00358.

[33] Choi, J., Park, Y. ve Kang, M., 2023. Restoration based Generative Models. ArXiv preprint. doi:10.48550/arXiv.2302.00119.

[34] Daras, G., Dagan, Y., Dimakis, A.G. ve Daskalakis, C., 2023. Consistent Diffusion Models: Mitigating Sampling Drift by Learning to be Consistent. ArXiv preprint. doi:10.48550/arXiv.2302.00105.

[35] Yu, S., Sohn, K., Kim, S. ve Shin, J., 2023. Video Probabilistic Diffusion Models in Projected Latent Space. ArXiv preprint. doi:10.48550/arXiv.2302.00067.

İNTİHAL RAPORU İLK SAYFASI

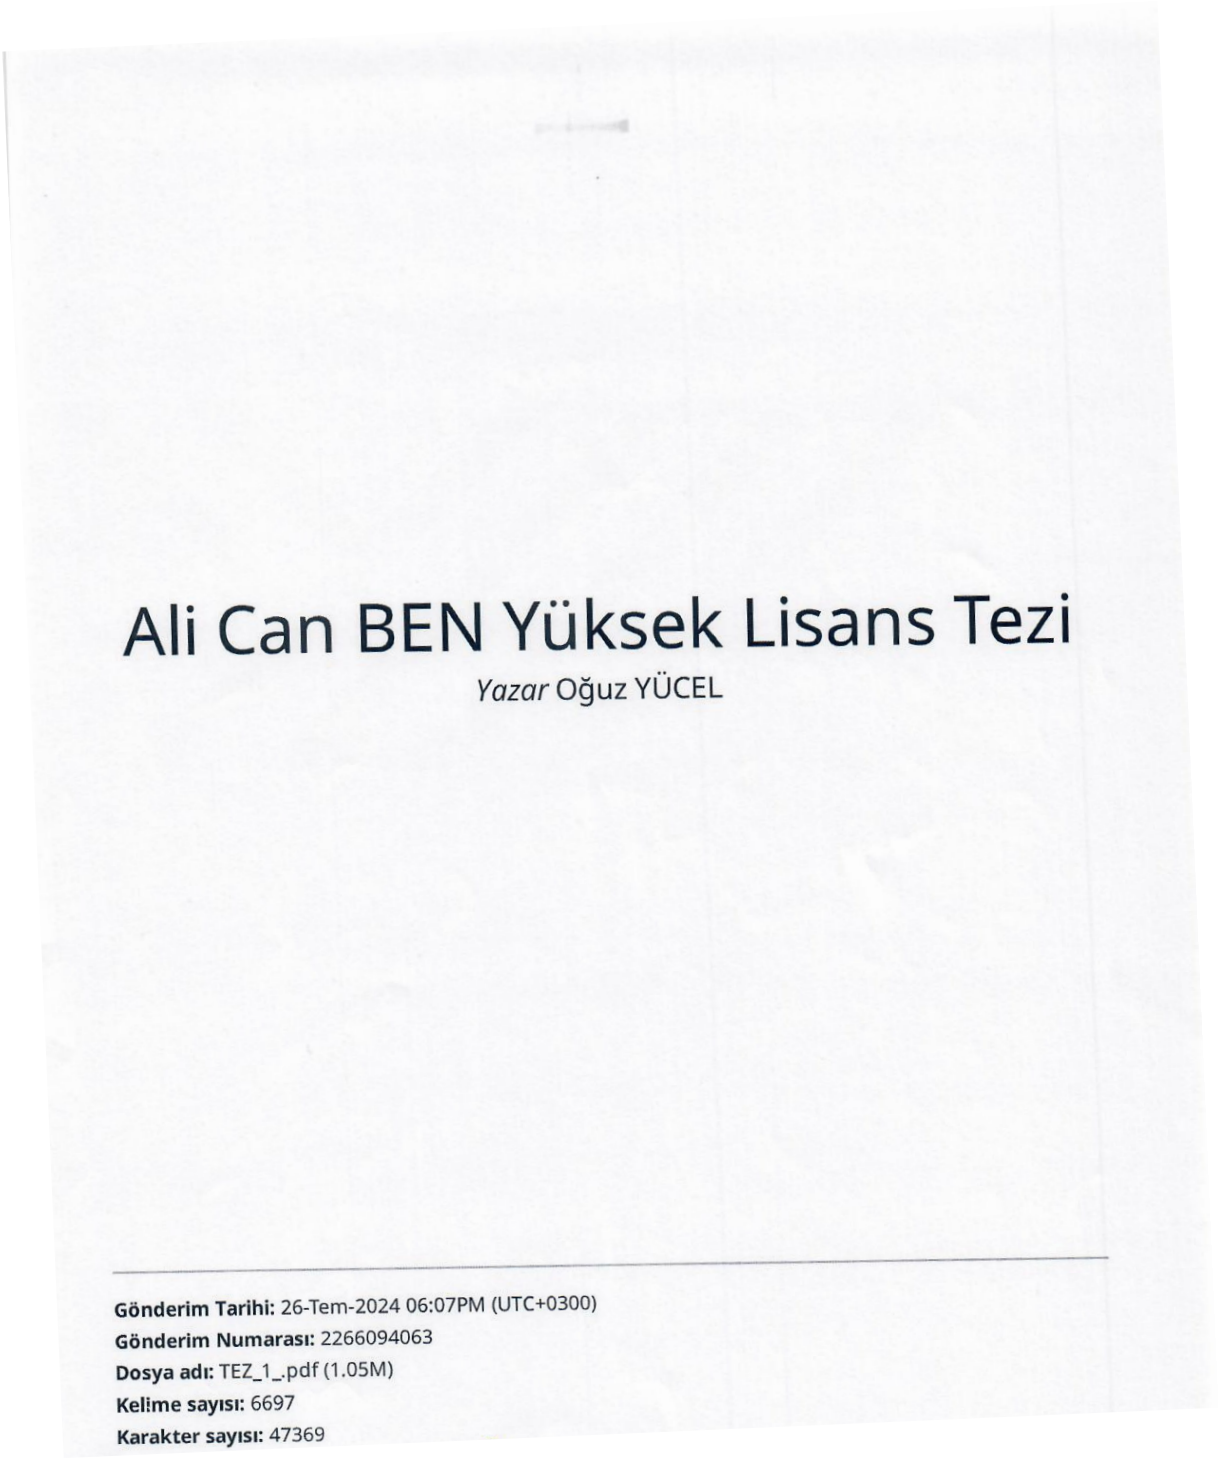

Ali Can BEN Yüksek Lisans Tezi

Yazar Oğuz YÜCEL

Gönderim Tarihi: 26-Tem-2024 06:07PM (UTC+0300)
Gönderim Numarası: 2266094063
Dosya adı: TEZ_1_.pdf (1.05M)
Kelime sayısı: 6697
Karakter sayısı: 47369

Ali Can BEN Yüksek Lisans Tezi

ORİJİNALLİK RAPORU

%8	%7	%3	%7
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%4
2	Submitted to Marmara University Öğrenci Ödevi	%2
3	acikbilim.yok.gov.tr İnternet Kaynağı	<%1
4	d197for5662m48.cloudfront.net İnternet Kaynağı	<%1
5	Submitted to Liverpool John Moores University Öğrenci Ödevi	<%1
6	Submitted to City University of Hong Kong Öğrenci Ödevi	<%1
7	Submitted to University of Bristol Öğrenci Ödevi	<%1
8	acikerisim.ticaret.edu.tr:8080 İnternet Kaynağı	<%1
9	medium.com	

İnternet Kaynağı

<%1

10 Tunç, Hazal. "İş Stresi Ile Duygusal Emek Ilişkisi: Özel Hastane Çalışanları Üzerine Bir Araştırma", Marmara Universitesi (Turkey), 2023
Yayın

<%1

Alıntıları çıkart üzerinde
Bibliyografyayı Çıkart üzerinde
Eşleşmeleri çıkar Kapat

ETİK KURUL İZİN YAZISI

Uyarı: Canlı denekler üzerinde yapılan tüm araştırmalar için Etik Kurul Belgesi alınması zorunludur.

☐ **Etik Kurul izni gerekmektedir.**

☒ **Etik Kurul izni gerekmemektedir.**

Ali Can BEN
(İmza)

KURUM İZNİ YAZILARI

Uyarı: Canlı ve cansız deneklerle yapılan tüm çalışmalar için kurum izin belgelerinin eklenmesi zorunludur. Gizlilik ve mahremiyet içeren durumlarda kurum adı kapatılmalıdır.

☐ **Kurum izni gerekmektedir.**

☒ **Kurum izni gerekmemektedir.**

Ali Can BEN
(İmza)

ÖZGEÇMİŞ