



**ÜRETKEN ÇEKİŞMELİ AĞLAR İLE FONKSİYONEL 3B TASARIM
VARYANTLARI ÜRETİLMESİ**

Nurullah YÜKSEL

DOKTORA TEZİ

ENDÜSTRİYEL TASARIM MÜHENDİSLİĞİ ANA BİLİM DALI

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ARALIK 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Nurullah YÜKSEL

12/12/2023

ÜRETKEN ÇEKİŞMELİ AĞLAR İLE FONKSİYONEL 3B TASARIM VARYANTLARI ÜRETİLMESİ

(Doktora Tezi)

Nurullah YÜKSEL

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Aralık 2023

ÖZET

Bu doktora tezi tasarım otomasyonu amaçlı yürütülen yapay zekâ destekli yeni ve özgün bir araştırmayı içermektedir. Bu bağlamda Üretken Çekişmeli Ağların (GAN) tasarım yeteneği ile sonlu elemanlar analizi (FEA) yöntemi birlikte kullanılarak 3B konsept tasarımların mekanik özellikleri geliştirilmiştir. GAN mimarilerinin, mekanik özellikleri öğrenme zorluklarını aşmak için yeni bir tasarım ve değerlendirme metodolojisi geliştirilmiştir. Bu metodoloji, birbirini izleyen ve tamamlayan, veri seti oluşturma, GAN eğitimi ve FEA içeren bir süreci kapsamaktadır. İlk olarak, önerilen yöntemin mekanik özellikleri geliştirme potansiyeli 2B kafes tasarımları üzerinde yapılan bir ön çalışma ile gösterilmiştir. Bu ön çalışma hafif ve yüksek mukavemetli kafes yapıları tasarlama konusunda karşılaşılan zorlukların GAN ile çözülebileceğini göstermiştir. Elde edilen bulgular ile yüksek mekanik performanslı 3B tasarım varyantları geliştirmek için bir yol haritası oluşturulmuştur. Ayrıca, 3B nesne tanıma ve üretken tasarım model eğitimi için, parametrik tasarım ve Voronoi diyagramlarını birleştiren yeni bir veri üretme yöntemi de geliştirilmiştir. Bu yöntem, çeşitliliği yüksek ve geniş ölçekli veri kümeleri üreterek derin öğrenme eğitimi için özgün ve önemli bir veri kaynağı oluşturmaktadır. Son aşamada ise GAN eğitimi ve FEA süreçlerini içeren fonksiyonel üretken tasarım modeli sunulmuştur. Bu model, tasarım özelliklerini ve otomasyonu iyileştirirken, üretken modellerin hedef odaklı tasarımlar üretmesi için özgün bir yol sunmaktadır. Önerilen yöntemin geçerliliği, rotora hareket serbestliği sağlayarak helikopterin yönlenmesine yardımcı olan iki yapısal bileşen üzerinde gerçekleştirilen örnek uygulamalarla gösterilmiştir. İki uygulamada GAN ile üretilen yapısal bileşenlerin ortalama emniyet faktörlerinde sırasıyla %6,8 ve %16,9'luk bir iyileşme görülmüştür. Elde edilen bulgular, yapısal bileşenlerin üretken modellerle doğrudan tasarlanmasında derin öğrenmenin önemli ve büyük bir potansiyele sahip olabileceğini göstermektedir. Bu tez aynı zamanda yapay zekâ uygulamalarının mühendislik tasarımında nasıl etkili sonuçlar üretebileceğini göstermekte ve bu alanda yapılacak yeni araştırmalara da ışık tutmaktadır.

Bilim Kodu : 91406

Anahtar Kelimeler : Üretken çekişmeli ağlar, parametrik tasarım, mekanik özellikler, mühendislik tasarımı

Sayfa Adedi : 218

Danışman : Prof. Dr. H. Rıza BÖRKLÜ

GENERATION OF FUNCTIONAL 3D DESIGN VARIANTS WITH GENERATIVE ADVERSARIAL NETWORKS

(Ph. D. Thesis)

Nurullah YÜKSEL

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

December 2023

ABSTRACT

This PhD thesis includes a new and original research conducted for design automation purposes, supported by artificial intelligence. In this context, the mechanical properties of 3D concept designs were improved by using the design capability of Generative Adversarial Networks (GAN) together with the finite element analysis (FEA) method. A new design and evaluation methodology has been developed to overcome the difficulties in learning the mechanical properties of GAN architectures. This methodology covers a process that includes dataset creation, GAN training, and FEA. Initially, the potential of the proposed method to improve mechanical properties was demonstrated through a preliminary study on 2D lattice designs. This preliminary study has shown that the challenges encountered in designing light and high-strength lattice structures can be resolved using GANs. Findings have provided a roadmap for developing high mechanical performance 3D design variants. Moreover, a new data generation method combining parametric design and Voronoi diagrams for 3D object recognition and generative design model training has also been developed. This method constitutes a unique and significant data source for deep learning training by generating diverse and large-scale datasets. In the final phase, a functional generative design model involving GAN training and FEA processes has been presented. This model offers an innovative path for producing target-oriented designs with generative models while improving design features and automation. The validity of the proposed method is demonstrated through case studies on two structural components that help steer the helicopter by providing freedom of movement to the rotor. In both applications, the average safety factor of structural components generated with GANs showed an improvement of 6.8% and 16.9%, respectively. The findings show that deep learning may have significant and great potential in directly designing structural components with generative models. This thesis also demonstrates how artificial intelligence applications can generate effective results in engineering design and sheds light on future research in this field.

Science Code : 91406

Key Words : Generative adversarial networks, parametric design, mechanical properties, engineering design

Page Number : 218

Supervisor : Prof. Dr. H. Rıza BÖRKLÜ

TEŞEKKÜR

Doktora sürecimde bilgisi ve tecrübesiyle yardımlarını esirgemeyen kıymetli danışman hocam Prof. Dr. Hüseyin Rıza BÖRKLÜ'ye en içten teşekkürlerimi sunarım. Çalışmalarım boyunca değerli katkılarıyla destek olan Prof. Dr. İsmail ŞAHİN ve Doç. Dr. Harun GÖKÇE hocalarıma şükranlarımı ifade etmek isterim. Tez sürecimde her zaman yanımda olan Dr. Öğr. Üyesi Oğulcan EREN ve Dr. Neslihan TOP'a teşekkür ederim.

Eğitim hayatım boyunca bana inanılmaz bir destek ve motivasyon kaynağı olan, her zaman yanımda olan aileme ve arkadaşlarıma sonsuz sevgi ve minnettarlık duygularımı sunarım.

Tezimin gerçekleşmesinde 122E411 numaralı proje ile maddi destek sağlayan TÜBİTAK'a teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	xii
ŞEKİLLERİN LİSTESİ	xiv
RESİMLERİN LİSTESİ	xviii
SİMGELER VE KISALTMALAR.....	xix
1. GİRİŞ.....	1
2. MÜHENDİSLİK TASARIMI PERSPEKTİFİNDEN YAPAY ZEKÂ UYGULAMALARI.....	7
2.1. Tasarımda Yapay Zekâ	7
2.2. Sistematik Literatür Araştırması	9
2.3. Yapay Zekâ Yöntemlerine Genel Bir Bakış.....	11
2.4. Yapay Zekâ Yöntemleri	13
2.4.1. Makine öğrenmesi	13
2.4.2. Genetik algoritma	19
2.4.3. Bulanık mantık	20
2.5. Tasarımda Yapay Zekâ Uygulamaları	21
2.5.1. İlham alma.....	21
2.5.2. Fikir ve konsept oluşturma.....	25
2.5.3. Fikir ve konsept değerlendirme.....	30
2.5.4. Tasarım optimizasyonu	34
2.5.5. Tasarım destek sistemleri.....	40
2.5.6. Modelleme ve geri çağırma.....	42

	Sayfa
2.6. Tartışma.....	44
2.7. Sonuçlar.....	52
3. ÜRETKEN ÇEKİŞMELİ AĞLAR (GAN) İLE TASARLANAN EKLEMELİ OLARAK ÜRETİLMİŞ KAFES YAPILARIN MEKANİK ÖZELLİKLERİNİN ARAŞTIRILMASI	53
3.1. Eklemeli İmalat İçin Tasarımda Derin Öğrenme	53
3.2. Metodoloji	56
3.2.1. Parametrik tasarım	56
3.2.2. Üretken Çekişmeli Ağlar (GAN) ile kafes tasarımı	59
3.2.3. Hücresel yapı tasarım süreci	61
3.2.4. Mekanik tepki tahmini	64
3.2.5. Kafes yapıların malzeme püskürtme ile üretilmesi	65
3.2.6. Mekanik testler ve sayısal analiz.....	68
3.3. Bulgular.....	69
3.3.1. Boyutsal doğruluk ve kalite kontrol.....	69
3.3.2. Basma testi ve sonlu elemanlar analizi	72
3.3.3. Darbe testi	81
3.3.4. Elastik modülün belirlenmesi ve karşılaştırılması	82
3.4. Tartışma.....	85
3.5. Sonuçlar.....	87
4. VORONOI DİYAGRAMLARI VE PARAMETRİK TASARIM ENTEGRASYONU İLE SENTETİK 3B VERİLER OLUŞTURMA	89
4.1. Derin Öğrenme Eğitiminde Veri Kümeleri.....	89
4.2. Metodoloji	92
4.2.1. 3B model temsil yöntemleri	92
4.2.2. Parametrik tasarım	96
4.2.3. Voronoi diyagramı	98

Sayfa

4.2.4. Voronoi diyagramının parametrik tasarıma entegre edilmesi.....	100
4.3. 3B Veri Kümesi Oluşturma.....	103
4.3.1. Parametrik tasarım	103
4.3.2. Voronoi diyagramının parametrik tasarıma entegre edilmesi.....	106
4.3.3. Veri kümesi oluşturulması ve veri ön işleme	107
4.3.4. Oluşturulan Tasarımların Değerlendirmesi.....	109
4.5. Bulgular ve Tartışma.....	112
4.5.1. Derin öğrenmede parametrik tasarımın rolü	113
4.6. Sonuçlar.....	114
5. ÜRETKEN ÇEKİŞMELİ AĞLAR.....	117
5.1. Üretken Tasarım.....	117
5.1. Üretken Çekişmeli Ağların Temelleri	118
5.1.1. Derin sinir ağları	119
5.1.2. Evrişimli sinir ağları.....	121
5.2. 3DGAN Geliştirme Motivasyonu	122
5.3. 3DGAN Teorisi	123
5.3.1. 3B evrişim katmanı	123
5.3.2. 3B tersine evrişim katmanı.....	125
5.3.3. Toplu normalleştirme katmanı	125
5.3.4. Aktivasyon katmanları	126
5.3.5. Rastgele gürültü vektörü	126
5.4. 3DGAN Eğitimi	127
5.5. Uygulama	130
5.5.1. Eğitim veri kümesi	130
5.5.2. Model eğitimi	131
5.5.3. Model testi.....	135

Sayfa

5.6. Sonuçlar.....	138
6. 3DGAN VE SONLU ELEMANLAR ANALİZİ İLE MEKANİK PERFORMANSIN GELİŞTİRİLMESİ	139
6.1. Fonksiyonel Üretken Tasarım Modeli	139
6.2. Derin Öğrenme Tabanlı Üretken Tasarım.....	141
6.2.1. Üretken tasarım ile konsept üretme.....	141
6.2.2. Üretken tasarım ile konsept değerlendirme.....	142
6.2.3. Üretken tasarım ile optimizasyon.....	143
6.3. Metodoloji	144
6.3.1. Veri üretimi ve ön hazırlık	145
6.3.2. Üretken model eğitimi.....	147
6.3.3. Tasarım değerlendirme.....	148
6.3.4. Eklemeli imalat	149
6.4. Uygulama 1	151
6.4.1. Veri ön hazırlık	152
6.4.2. Derin öğrenme eğitimi	153
6.4.3. Tasarım değerlendirme.....	155
6.5. Uygulama 2	160
6.5.1. Veri üretimi ve ön hazırlık	160
6.5.2. Üretken model eğitimi.....	162
6.5.3. Veri (model) üretimi	164
6.5.4. Tasarım değerlendirme.....	165
6.5.5. Eklemeli imalat ile parça üretimi	172
6.6. Bulgular.....	174
6.7. Sonuç.....	177
7. SONUÇLAR VE ÖNERİLER.....	179

Sayfa

KAYNAKLAR	185
EKLER.....	211
EK 1. İdeal 3DGAN mimarisini belirleme denemeleri	212
EK-2. GAN model eğitimi için veri boyutlandırma	216
ÖZGEÇMİŞ	217



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. 3B model üreten GAN araştırma çalışmalarının genel bir karşılaştırması .	3
Çizelge 2.1. Bilimsel veri tabanlarında kullanılan notasyonlar, formüller ve kelime dizileri	10
Çizelge 2.2. Yapay zekâ yöntemlerinin tasarım süreçlerindeki uygulama alanlarının avantaj ve dezavantajları	49
Çizelge 3.1. Parametrik modelde bazı parametreler ve oluşturulan bir dizi tasarımı, temel blokları, birim hücreleri ve bunlara karşılık gelen 3B modelleri gösteren parametrik BDT modeli formülasyonuna genel bakış	57
Çizelge 3.2. Birim hücre tipleri, boyutları ve fiziksel özelliklerinin karşılaştırılması....	62
Çizelge 3.3. Kafes yapıların mekanik tepkilerinin Maxwell stabilite kriteri ile belirlenmesi. 's' ve 'j' sırasıyla dikiş ve düğüm sayılarını temsil etmektedir. 'M' değeri yapısal sertliği göstermektedir.....	64
Çizelge 3.4. RGD 720'nin mekanik özelliklerine genel bir bakış ürün veri sayfasında verilmiştir	66
Çizelge 3.5. Kafes test numuneleri için kullanılan malzeme, baskı süresi ve üretim maliyetlerinin karşılaştırılması	67
Çizelge 3.6. BDT verilerinin ve basılı özelliklerin kritik bölümlerindeki boyutsal farklılıklar. Sapmalar, basılı özelliklerin BDT verilerinden daha küçük olduğu durumlarda negatif olarak ifade edilir. Tüm boyutlar mm cinsindendir.....	71
Çizelge 3.7. Hücre yapılarının yapısal ve mekanik özellikleri	74
Çizelge 3.8. Kafes yapıların Kafes yapıların Charpy darbe testi sonuçları	83
Çizelge 3.9. Gibson-Ashby elastisite modülünü hesaplamak için kullanılan korelasyon katsayıları.	84
Çizelge 4.1. Parametre değer aralıkları	104
Çizelge 4.2. Sonlu Elemanlar Analizi sonuçları	110
Çizelge 5.1. Eğitim veri kümesini oluşturan veri kaynakları.....	132
Çizelge 5.2. Eğitim hiper-parametreleri.....	132
Çizelge 5.3. 3DGAN model mimarisi ve öğrenilebilir parametre sayısı	133

Çizelge	Sayfa
Çizelge 6.1. Altıncı iterasyon sonunda 3DGAN modeli tarafından üretilen mafsal örnekleri ve fiziksel özellikleri (uygulama-1)	156
Çizelge 6.2. Altıncı iterasyon sonunda 3DGAN modeli tarafından üretilen mafsal örnekleri ve fiziksel özellikleri (uygulama-2)	169
Çizelge 6.3. SLA ve FDM yöntemleriyle üretim karşılaştırması	174



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. 2006 ve 2021 yılları arasında tasarımda yapay zekâ konulu yayınlanan makale sayısı	14
Şekil 2.2. Yaygın kullanılan YZ yöntemleri ve birbirleri ile ilişkileri.....	15
Şekil 2.3. Yaygın kullanılan makine öğrenmesi algoritmaları	16
Şekil 2.4. TechNet ile oluşturulan “uçan araba” konsept ağı	23
Şekil 2.5. Kaşık ve yaprak görüntüleri (a) ile eğitilmiş GAN modeli tarafından üretilen görüntüler (b)	25
Şekil 2.6. Yapay sinir ağı ve genetik algoritma iş birliği ile üretilen konsept tasarımlar: Mikser (M), kahve makinesi (C) ve çamaşır makinesi (W)	27
Şekil 2.7. (a) Şişe ve armuttan esinlenilen tasarım konseptleri (b) Çaydanlık ve balıktan esinlenilen tasarım konseptleri (c) Üretilen konseptlerin 3B modelleri.....	28
Şekil 2.8. BeGAN modeli ile üretilen 2 boyutlu jant konseptleri.....	29
Şekil 2.9. (a) DCGAN modeli ile üretilen 2B yay görüntüleri (b) CNN modeli tarafından tahmin edilen geometrik parametrelerle oluşturulan bir 3B yay modeli.....	30
Şekil 2.10. Akıllı saat tasarımı için oluşturulmuştur Ağ modeli.....	32
Şekil 2.11. Shu vd.’nin işlevsel üretken tasarım modeli; (a) Tasarım veri kümesi (b) GAN modeli ile üretilen yeni kavramlar (c) Üretilen kavramların CFD analizi (d) Yüksek performanslı kavramlar, eğitim veri kümesine dahil edilen CFD ile doğrulanır ve süreç tekrarlanır	34
Şekil 2.12. Tavlama benzetimi kullanılarak kanat morfolojisi optimizasyonu için farklı yarasa kanat topolojileri.....	36
Şekil 2.13. CFD analizi ve RENN yöntemi ile aerofoil şekil optimizasyonu sonuçları.	38
Şekil 2.14. BeGAN ile üretilen jant konseptlerinin uyumluluk, yenilikçilik ve maliyet açısından analizi	39
Şekil 2.15. Sıralı tasarım görselleri ile eğitilen derin öğrenme modelinin önerilen tasarım adımları yeşil olan basit kafes sistemleri. Soldan sağa; tasarımın mevcut durumu, derin öğrenme modelinin önerisi ve bir sonraki gerçek tasarım adımı	42
Şekil 2.16. PrGAN modeli ile üretilen 3B sandalye modelleri.....	44

Şekil	Sayfa
Şekil 2.17. 2006 ve 2021 yılları arasında YZ yöntemlerini içeren makale sayısı (Scopus veri tabanı).....	45
Şekil 2.18. 2006 ve 2021 yılları arasında YZ yöntemlerine dayalı tasarımı içeren yayınların dağılımı, (ES: Uzman Sistemler, FL: Bulanık Mantık, GA: Genetik Algoritma, YSA: Yapay Sinir Ağları, ML: Makine Öğrenmesi, DL: Derin Öğrenme)	46
Şekil 2.19. 2006 ve 2021 yılları arasında YZ yöntemlerine dayalı tasarım konusunu içeren yayınların dağılımı (In: İlham, Id: Fikir üretimi, E: Değerlendirme, O: Optimizasyon, DM: Karar verme, M: Modelleme).....	46
Şekil 2.20. Tasarım uygulamaları için uygun YZ yönteminin seçilmesine ilişkin akış şeması	51
Şekil 3.1. Kafes yapıların tasarım (hesaplamalı tasarım, Derin öğrenme ile kafes üretimi), üretim (3B Baskı) ve doğrulama (Kalite kontrol, Basma testi, Darbe testi) adımlarını gösteren akış şeması.	56
Şekil 3.2. Yüksek yapısal performanslı kafes yapıların üretilmesi ve test edilmesi için yinelemeli parametrik tasarım süreci	58
Şekil 3.3. Üretici ve Ayırıcı ağlar arasındaki ilişkiyi gösteren standart DCGAN mimarisi. Şekil, tipik bir DCGAN mimarisinde veri oluşturma, değerlendirme ve geri yayılım sürecini özetlemektedir	59
Şekil 3.4. DCGAN tarafından oluşturulan kafes tasarımı çeşitleri, kırmızı kare 3B baskı için kullanılan tasarımları gösterir	61
Şekil 3.5. Malzeme püskürtmeli Eİ yönteminin süreç şeması	65
Şekil 3.6. BDT verileri ile 3B baskılı modeller arasında boyutsal karşılaştırma. Tüm boyutlar mm cinsindendir.....	70
Şekil 3.7. Eklemeli olarak imal edilen kafes yapılar için basma testlerinden elde edilen gerilme-gerinim diyagramı: (a) Standart kafes yapılar, (b) MG-1, MG-2, MG-3, (c) MG-4, MG-5, MG-6.....	76
Şekil 3.8. Tek eksenli sıkıştırma altındaki kafes test numuneleri için ANSYS statik yapısal modülü aracılığıyla elde edilen Sonlu Elemanlar Analizi (FEA) sonuçları: (a) Standart kafes yapılar, (b) MG-1, MG-2, MG-3, MG-4, (c) MG-5, MG-6	77
Şekil 3.9. Tüm kafes tasarımları için maksimum gerilime karşı maksimum gerinim haritası.	81
Şekil 3.10. Hooke ve Gibson-Ashby denklemleri ile hesaplanan elastik modülün karşılaştırılması.....	85
Şekil 4.1. Sentetik veri kümesi oluşturma akış şeması	92

Şekil	Sayfa
Şekil 4.2. 3B model temsil yöntemleri: Nokta bulutu, Voksel ve Poligon mesh.....	93
Şekil 4.3. Nokta bulutunun mesh ve Voksel temsiline dönüştürülmesi	95
Şekil 4.4. Temel bir Voronoi grafiği.....	99
Şekil 4.5. Helikopter rotoru montajının bir bölümü ve orijinal mafsallı gösteren BDT modeli.....	103
Şekil 4.6. Parametrik olarak modellenmiş iş parçası ve kullanılan parametreler	104
Şekil 4.7. Parametrik tasarımla üretilmiş konsept tasarımların bazıları	105
Şekil 4.8. Voronoi diyagramlarının iş parçasına entegrasyon adımları	107
Şekil 4.9. Oluşturulan modellerin bir dizine kaydedilmesi için algoritma	108
Şekil 4.10. Voronoi diyagramlarının parametrik tasarıma entegre edilmesi elde edilen veriler.....	108
Şekil 4.11. Mesh yapısının voksel formatına dönüştürme süreci	109
Şekil 4.12. Model ağırlıklarına göre emniyet faktörlerinin karşılaştırılması.....	111
Şekil 5.1. Temel GAN mimarisini ifade eden akış şeması	117
Şekil 5.2. Yapay sinir hücresinin temsili gösterimi	120
Şekil 5.3. Derin sinir ağı mimarisi	120
Şekil 5.4. Temel CNN mimarisi	121
Şekil 5.5. Havuzlama işlemi için yaklaşımlar.....	122
Şekil 5.6. 3B evrişim işleminin sembolik gösterimi	124
Şekil 5.7. 3B tersine evrişim işleminin sembolik gösterimi	125
Şekil 5.8. Temel üretici ağı mimarisi.....	128
Şekil 5.9. Temel ayırıcı ağı mimarisi.....	129
Şekil 5.10. Veri kümesinden 3B sandalye veri örnekleri.....	131
Şekil 5.11. Eğitim aşamalarında üretilen yeni sandalye modelleri.....	136
Şekil 5.12. Eğitim sürecinde üretici ve ayırıcı ağı kayıp değerleri	138
Şekil 6.1. Fonksiyonel tasarım seçenekleri oluşturma sürecini ifade eden akış şeması .	145

Şekil	Sayfa
Şekil 6.2. Ele alınan bileşen ve rotor montajındaki konumu (uygulama-1)	152
Şekil 6.3. Kullanılan sentetik veri kümesinden bazı örnekler	153
Şekil 6.4. 3DGAN modeli tarafından oluşturulan yeni iş parçası örnekleri	154
Şekil 6.5. Üretken çekişmeli ağ eğitim sürecinde kayıp değerleri (uygulama-1).....	155
Şekil 6.6. Veri hazırlık ve yapısal analiz süreci.....	155
Şekil 6.7. Eğitim ve değerlendirme iterasyonu için ortalama güvenlik faktörleri.....	157
Şekil 6.8. Süreç boyunca üretilen tasarımların hacim ve güvenlik faktörlerini.....	158
Şekil 6.9. Sonlu elemanlar analiz otomasyonunun doğrulanması. a) orijinal model, b) GAN ile üretilmiş model, c) düzenlenmiş model.....	159
Şekil 6.10. Uygulama-2’de ele alınan bileşenin helikopter rotor montajındaki konumu ve parametrik model.....	161
Şekil 6.11. Voronoi diyagramlarının parametrik tasarıma dâhil edilmesi ile oluşturulan veri kümesi	162
Şekil 6.12. 3DGAN modeli tarafından oluşturulan yeni iş parçası örnekleri	164
Şekil 6.13. Üretken çekişmeli ağ eğitim sürecinde kayıp değerleri (uygulama-2).....	165
Şekil 6.14. Voksel’den mesh’e dönüşüm ve mesh iyileştirme süreci.....	165
Şekil 6.15. Veri hazırlık ve yapısal analiz süreci.....	166
Şekil 6.16. Veri düzenleme otomasyonu: Mesh modelin BDT ortamına alınması	166
Şekil 6.17. Veri düzenleme otomasyonu: Mesh yapının katı modele dönüştürülmesi...	167
Şekil 6.18. Veri düzenleme otomasyonu: Deliklerin oluşturulması ve malzeme ataması.....	168
Şekil 6.19. Veri düzenleme otomasyonu: Sonlu elemanlar analizi	168
Şekil 6.20. Üretilen tasarımların hacim ve güvenlik faktörlerini.....	170
Şekil 6.21. Eğitim iterasyonları için ortalama güvenlik faktörleri.....	171
Şekil 6.22. Sonlu elemanlar analiz otomasyonunun doğrulanması. a) orijinal model, b) GAN ile üretilmiş model, c) düzenlenmiş model.....	172
Şekil 6.23. GAN modeli tarafından üretilen hatalı geometrilerden örnekler.....	176

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3.1. Minimum destek yapısı kullanımı ve en hızlı baskı süresi için yapı plakası üzerinde yönlendirilmiş kafes yapı örnekleri	66
Resim 3.2. Hücresel numunelerin basma testi sırasındaki deformasyon adımları.	72
Resim 3.3. Basma testinin ardından çeşitli hücresel numunelerde çatlakların oluşması ve yayılması.....	74



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

E	Elastikiyet modülü
GPa	Giga paskal
J	Jul
kJ	Kilo jul
MPa	Mega paskal
Mg	Magnezyum
ms	Milisaniye
µm	Mikrometre
σ	Gerilme
ε	Gerinim
δ	Deformasyon
Ø	Çap
°C	Santigrat derece

Kısaltmalar

Açıklamalar

3B / 3D	3 Boyutlu (İng. 3 Dimensional)
AYZ	Açıklanabilir Yapay Zekâ
AlSi10Mg	Alüminyum silisyum on magnezyum
BDT	Bilgisayar Destekli Tasarım
BDM / CAE	Bilgisayar Destekli Mühendislik (İng. Computer Aided Engineering)
CFD	Hesaplamalı Akışkanlar Dinamiği (İng. Computational Fluid Dynamics)
CNN	Evrişimli Sinir Ağları (İng. Convolutional Neural Networks)

Kısaltmalar**Açıklamalar**

DfAM	Eklemeli İmalat için Tasarım (İng. Design for Additive Manufacturing)
Eİ	Eklemeli İmalat
FDM	Eriyik Biriktirme Tekniği (İng. Fused Deposition Modelling)
FEA	Sonlu Elemanlar Analizi (İng. Finite Element Technique)
GAN	Üretken Çekişmeli Ağlar (İng. Generative Adversarial Networks)
GA	Genetik Algoritma
MJ	Malzeme püskürtme (İng. Material Jetting)
NURBS	Düzgün Olmayan Rasyonel Temelli Eğri
OBJ	Ön Dalga Nesnesi (İng. Wavefront Object)
SA	Tavlama Benzetimi (İng. Simulated Annealing)
TO	Topoloji Optimizasyonu
UV	Mor Ötesi (İng. Ultraviyole)
YZ	Yapay Zekâ
YSA	Yapay Sinir Ağları

1. GİRİŞ

Bilimsel ve teknolojik alanda son bir asırlık süreçte yaşanan hızlı gelişmeler sosyal hayat ve düzeni derinden etkilemiştir. 1960'ların başlarında MIT'de Ivan Sutherland tarafından geliştirilen 'Sketchpad' adlı sistem Bilgisayar Destekli Tasarım (BDT) alanında ilk ve önemli bir çalışma olmuştur [1]. Bu teknoloji, 1980'lerde kişisel bilgisayarların yaygınlaşmasıyla herkes için erişilebilir hale gelmiştir. Kısa süre içerisinde hem bilgisayarlar hem de BDT yazılım performanslarında önemli artışlar olmuştur. Bu ilerlemeye paralel olarak, Yapay Zekâ (YZ) tasarım süreçlerinde önemli bir araç haline gelmiştir. Öğrenme, anlama ve yorumlama gibi yetenekleriyle YZ, tasarım çözümlerini optimize etme ve süreçleri hızlandırmada kilit bir rol oynamaktadır.

Araştırma konusu

Yapay Zekâ (YZ); öğrenme, anlama, tahmin, yorumlama, üretme kabiliyetleri ile tasarım problem çözümlerine büyük katkı sağlar [2]. Tasarımda YZ kullanılması; süreçleri kısaltma, maliyetleri azaltma, hassas sonuçlar elde etme, kaliteyi artırma, yaratıcılığı geliştirme ve tasarımda otomasyon gibi faydalar sağlayabilir. Ancak tek bir YZ tekniğinin tüm tasarım sürecinde ve/veya her tür problem çözümünde kullanılması olası değildir. Klasik YZ yöntemleri (kural tabanlı sistemler, bulanık mantık gibi) tasarım seçenek değerlendirme, optimizasyon ve karar verme işlemlerinde kullanırken; makine öğrenmesi ve derin öğrenme gibi modern YZ yöntemleri ise ilham ve tasarım konsepti üretme amaçlı kullanılabilir [3].

Bu tez yazım sürecinde tasarımda kullanılan güncel YZ çalışmaları hakkında kapsamlı bir kaynak araştırması yapılmıştır. Bu kaynak araştırması, 2015 ve sonrası YZ çalışmalarındaki bariz artışı ortaya koymuştur. Bu artış genelde makine öğrenmesi / derin öğrenme gibi veri bağımlı yöntemlerin etkisi ile olmuştur. Bilgisayar teknolojisinde hızlı gelişme ve veri depolarına daha kolay erişim bu yöntemlerin tercih ve kullanımını artırmıştır. Buna karşılık klasik YZ yöntemlerin tasarımda kullanımı ise giderek azalma eğilimindedir.

Veriye dayalı tahmin ve çıkarım yapabilen YZ yöntemlerine Makine öğrenmesi denir [4]. Bu algoritmalar veri kümesine ait örüntü ve kalıpları tespit ederek yeni veri yorumlarında kullanır [5]. Klasik programlama ile yapılması zor olan doğal dil işleme, örüntü tanıma, tahmin ve çıkarım görevlerinde kullanılabilir [6, 7]. Derin öğrenme ise makine öğrenmesinin

bir alt dalıdır. Derin öğrenme algoritmaları ile nesne ve yüz tanıma, hareket tahmini, görüntü onarımı ve yeni görüntü oluşturma iş/işlemleri yapılabilir. Büyük veriye ulaşımın kolaylaşması ve veri miktarının artması (sosyal medya, online alışveriş siteleri, nesnelerin interneti, fotoğraf ve 3 Boyutlu (3B) model depoları vb. kaynaklardan) sonucu derin öğrenme çalışmaları yoğunlaşmıştır. Ayrıca bilgisayarın performans artışları ve büyük veriye uygun algoritmalar geliştirilmesi ile tahmin ve yorumlama başarısını da geliştirmiştir.

Varyasyonel Otomatik Kodlayıcı (İng. Variational Autoencoder, VAE), Evrişimli Sinir Ağı (İng. Convolutional Neural Network, CNN), Yinelemeli Sinir Ağı (İng. Recurrent Neural Network, RNN), Üretken Çekişmeli Ağlar (İng. Generative Adversarial Networks, GANs) popüler derin öğrenme yöntemleridir [8]. GAN, görüntü, ses, video, 3B model gibi verileri üretme ve düzenlemede kullanılan çok yeni bir derin öğrenme mimarisidir [9]. Standart bir GAN mimarisi Üretici ve Ayırmacı olmak üzere iki farklı derin sinir ağı içerir. Üretici ağ gerçek görsel olasılık dağılımları ile eğitilerek yeni (sahte) görseller oluşturur. Tipik bir CNN mimarisine sahip ayırmacı ağ ise üretilen görselleri gerçek görsellerden ayırmaya çalışır. Bu iki ağın eğitim amacı sırasıyla üretme ve ayırt etme becerilerini geliştirmektir [10]. Böylece yeni ve gerçekçi veriler üretilebilir. GAN ile bir görüntünün çözünürlüğünü artırma, metini görüntüye dönüştürme, eskizleri renkli görsellere dönüştürme, siyah beyaz fotoğrafları renklendirme, 2B görüntülerden 3B modeller oluşturma gibi işlemler yapılabilir [11]. Tasarım sürecinde ise ilham oluşturma, fikir/konsept üretme, işlemsel (hesaplamalı) tasarım topoloji optimizasyonu, bilgisayar destekli mühendislik / tasarım görevleri GAN yardımıyla kolayca yapılabilir [12].

Erken tasarım aşamasında problemi belirledikten sonra konsept oluşturma süreci yürütülür. Yaratıcı ve yeni fikir oluşturmak için bu süreç oldukça zor, yıpratıcı ve zihinsel faaliyetler gerektirir. Ayrıca sistematik bir yaklaşım ve tecrübe de çok önemlidir. Bu süreçte üretilen konseptlerin sayısı, çeşit ve kaliteleri ise tüm tasarım sürecini ve geliştirilecek ürünü etkiler. Ancak tasarımcı yaratıcılığı her zaman yüksek düzeyde olamayabilir. Derin öğrenme bu tür problemlerin üstesinden gelmek için kullanılan yöntemlerden biridir. Güncel 3B model üreten veri bağımlı tasarım araştırma çalışmaları Çizelge 1.1'de karşılaştırılmıştır. Bu çalışmaların ilki 2016 yılında yapılmıştır. Çalışmalar, kullanılan veri formatına göre sınıflandırılabilir. Bu çalışmalarda genelde voksel ve nokta bulutu formatlar kullanılmıştır. 3B cGAN, IG-GAN ve Shu ve arkadaşlarına ait GAN modeli ile form koşullandırma yapılabilir. Yani GAN ile üretilen modellerin bazı form özellikleri geliştirilirken bir kısmı

sabit tutulabilir. Yalnızca bunlardan Shu ve arkadaşlarına ait çalışmada üretilen konseptlerin fonksiyonel özellik iyileştirmeleri yapılmıştır.

Çizelge 1.1. 3B model üreten GAN araştırma çalışmalarının genel bir karşılaştırması

	3D GAN	Point Cloud GAN	Shu et al. GAN	Ben-Hamu et al. GAN	3D cGAN	IG-GAN
<i>Yıl</i>	2016	2018	2020	2018	2019	2020
<i>Veri formatı</i>	Voksel	Nokta bulutu	Nokta bulutu	Mesh	Voksel	Voksel
<i>İmalat için ek işlem</i>	Hayır	Mesh oluşturma	Mesh oluşturma	Hayır	Hayır	Hayır
<i>Form koşullandırma</i>	Yok	Yok	Var	Yok	Var	Var
<i>Fonksiyonel koşullandırma</i>	Yok	Yok	Var	Yok	Yok	Yok

İyi bir tasarım için biçim (form), fonksiyon ve davranış bir bütün olarak ele alınmalıdır. Biçim, ürünün geometrik ve topolojik özelliklerini içerir. Fonksiyon ürünün tasarım amacını ifade ederken, davranış ise ürünün kullanıcı ve çevreyle ilişkisini gösterir. Veri bağımlı üretken tasarım çalışmaları genelde yeni formlar üretmeyi amaçlar. Burada üretilen konseptler fonksiyonel/yapısal iş parçaları olmaktan hayli uzak olup, ancak ek düzenleme ve iyileştirme ile kullanılabilirler.

Bu tez, üretken derin öğrenme modeli ile sonlu elemanlar analizi (İng. Finite Element Analysis, FEA) birlikte kullanılarak / uygulanarak tasarımların form ve fonksiyon özelliklerinin iyileştirilmesi amaçlamaktadır. 3DGAN kullanılarak oluşturulan tasarımlar, sonlu elemanlar analizi yardımıyla mekanik açıdan test edilirken, yinelemeli bir süreçle mekanik özellikler geliştirilmektedir.

Araştırmanın amaç ve hedefleri

Bu tez çalışmasının ana amacı mühendislik tasarımında 3B fonksiyonel konseptler oluşturabilen veri bağımlı bir üretken tasarım modeli geliştirmektir. Derin öğrenme ve sonlu elemanlar analizi birleşimi ile mekanik özellikleri gelişmiş bileşenler tasarlanabilir. Bu yöntem ayrıca normal tasarım sürecinde yürütülen; fikir ve konsept üretme, modelleme, değerlendirme ve yeniden tasarım adımlarında otomasyon da sağlayacaktır. Tez kapsamında gerçekleştirilmesi hedeflenen alt amaçlar ise şu şekildedir:

- Tasarım süreçlerinde en sık kullanılan yapay zekâ yöntemlerini ve bu yöntemlerin uygulama alanlarını tanımlamak.
- GAN ve 3DGAN model teorisini ve bu teoriyle ilgili kriterleri (model mimarisi, eğitim parametreleri, eğitim hataları ve çözüm yöntemleri gibi) anlamak ve açıklamak.
- 3DGAN eğitiminde kullanılan veri yapılarını sınıflandırmak ve uygulama türüne göre veri temsil yöntemini belirlemek.
- Bu projeye uygun 3B model formatını seçmek, GAN eğitimi için bir veri kümesi üretmek ve düzenlemek. Bu veri kümesi, tez çalışması tamamlandığında diğer derin öğrenme projelerinde kullanılmak üzere genel kullanıma sunulacaktır.
- Özgün 3B modeller üretebilmek için standart GAN mimarisini yeniden düzenlemek ve ideal GAN mimarisini ve eğitim parametrelerini belirlemek. Böylece mühendislik tasarımı için en uygun GAN mimarisini elde etmek.
- Fonksiyonel tasarım konseptlerini üretebilmek için bir sonlu elemanlar analizi yazılımı kullanmak ve bu analizi minimum insan müdahalesi ile gerçekleştirmek.
- Derin öğrenme destekli üretken tasarım yöntemleriyle oluşturulan 3B modellerin üretilebilirlik ve uygulanabilirliğini test etmek. Oluşturulan 3B modelleri eklemeli imalat yöntemleri kullanılarak üretmek.
- Tasarım süreçlerini otomatikleştirmek ve insan müdahalesini en aza indirgeyerek hata riskini ve tasarım geliştirme sürelerini azaltmak.
- Mühendislik tasarım çalışmalarında derin öğrenme algoritmalarının kullanımını yaygınlaştırmak.

Bu hedefler doğrultusunda bu tez çalışması, otonom bir tasarım yaklaşımı geliştirme yolunda önemli bir adım atmayı hedeflemektedir.

Araştırmanın özgün yönü

Bir ürün tasarımına ait inovatif özellikler genelde kavramsal tasarım sürecinde oluşur. Bu aşama yaratıcılık ve tecrübe gerektiren sezgisel bir süreçtir. Çevresel (gürültü, ortam vb.) ve duygusal (üzüntü, sevinç, öfke vb.) faktörler sezgisel süreç başarılarını etkileyebilir. Ayrıca konsept üretme süresi de problem boyutuna göre değişebilir. Bu nedenlerle yeni ve yaratıcı konsept oluşturmada insan müdahalesi azaltılmadığıdır. Bu tezin temel amacı derin öğrenme destekli üretken tasarım yöntemiyle oluşturulan 3B modellerin fonksiyonel özelliklerini

geliştiren otonom bir yaklaşım ve sistem geliştirmektir. Bir ürünün (iş parçasının) fonksiyonelliği, kullanım sırasında karşılaşılabileceği kuvvet, yük ve titreşim gibi fiziksel etkenlere verdiği tepkiler ile ölçülebilir. Bu bağlamda tasarlanan sisteme ait yük, kuvvet veya güç aktaran tüm bileşenler FEA ile değerlendirilir ve gerekirse yeniden tasarlanır. Bu araştırma kapsamında ilk defa veri bağımlı üretken tasarım ile FEA yöntemleri birleştirilmektedir. Böylece uzun / zahmetli analiz-tekrar tasarım işlemleri daha kısa sürede ve insan müdahalesi olmadan gerçekleştirilebilir. Ayrıca fikir üretme, 2B konsept geliştirme, 3B model üretme ve değerlendirme süreçleri önerilen yöntemle otomatik olarak yapılmaktadır. Fonksiyonel 3B konsept tasarımlar üretilmesi ile tasarım sürecinin otomasyon seviyesi de artırılmıştır. Literatürdeki mevcut çalışmalardan farklı olarak üretilen konseptler gerçek iş parçalarıdır. Bu çalışmayla elde edilen diğer önemli ve özgün kazanımlar şöyle özetlenebilir:

- Tasarım süreçleri önemli oranda insan müdahalesi olmadan otomatik yapılmaktadır. Böylece insan kaynaklı hatalar önlenir, süreç kısalabilir / hızlanabilir ve nitelikli iş gücü tasarrufu da sağlanabilir.
- Kısmen sınırlı sayıda veri ile eğitilen üretken derin öğrenme modeli sınırsız sayıda fonksiyonel 3B (tasarım) modelleri üretebilmektedir.
- Üretilen modeller veri sayısının yetersiz ve/veya gizlilik gereği veriye ulaşmanın zor olduğu başta savunma ve otomotiv endüstrilerinde derin öğrenme çalışmaları için gerekli eğitim verilerini oluşturabilir.
- Parametrik tasarım ve Voronoi diyagramlarının birleştirilmesi 3B modeller için büyük veri oluşturmanın hızlı ve yenilikçi bir yolunu sunmaktadır.
- Az sayıda personel ile çok sayıda tasarım konsepti üretilebilir ve ideale en yakın seçenekler belirlenebilir.
- Öğrenilen bilgiler unutulmayacağı için sürekli yüksek seviyede yaratıcılık elde edilebilir.
- Klasik tasarım işlemine göre maliyet daha az (ve makul) düzeydedir.
- Ön yargılardan uzak, duygusal ve çevresel etkilerden bağımsız olduğu için maksimum verimle çalışır.

Araştırma planı

Tez sistematik olarak hazırlanmış 6 bölümden oluşmaktadır. Bölüm 2’de kapsamlı bir literatür taraması yapılarak mühendislik ve ürün tasarımında kullanılan YZ teknikleri ve uygulamaları incelendi. Bu bölüm, kavramsal ürün tasarımında hem klasik hem de modern

YZ tekniklerini eleştirel bir şekilde ele almaktadır. Son 15 yılda YZ'nın mühendislik tasarımındaki artan kullanımını dikkate alınarak bu yöntemler tasarım süreçleri (fikir oluşturma, konsept oluşturma, değerlendirme vb.) bazında sınıflandırılmıştır. Bu bölümde mevcut uygulama sınırları belirlenerek tasarımın YZ ile nasıl destekleneceği konusunda mühendislere genel bir bakış sunulması amaçlanmaktadır.

Bölüm 3'te önerilen yöntemin uygulanabilirliğini görmek amacıyla GAN modeliyle tasarlanan 2B kafes yapıların mekanik özelliklerini incelemek için bir ön çalışma yapılmıştır. Geleneksel kafes yapıları ve YZ ile oluşturulan kafesler Malzeme Püskürtme (İng. Material Jetting, MJ) eklemeli imalat yöntemiyle üretilmiş, boyutsal ve mekanik özellikleri değerlendirilmiştir. Bu ön araştırma, GAN modellerinin yapısal elemanları tasarlama görevlerinde üstün ve zayıf yönleri hakkında önemli bilgiler sunmaktadır.

Bölüm 4 tez kapsamında gerçekleştirilen yaklaşım için Voronoi diyagramlarını parametrik tasarıma entegre ederek, derin öğrenme eğitimi için 3B BDT verisi üretme sürecini tanıtmaktadır. Bu entegrasyon, karmaşık geometrilerin oluşturulmasını ve çeşitliliği yüksek veri kümelerinin hızla üretilmesini kolaylaştırmaktadır. Bu, aynı zamanda derin öğrenme modellerin daha doğru ve güvenilir sonuçlar üretmesine, veri eksikliği sorunlarıyla başa çıkmasına ve inovatif tasarım süreçlerine katkıda bulunmasına yardımcı olabilir.

Bölüm 5'te GAN ve 3DGAN modelleri hakkında kapsamlı bir teorik alt yapı sunulmuştur. GAN modellerinin tarihçesi ve alternatif GAN modelleri tanıtılmıştır. 3DGAN mimarisi tanıtılarak eğitim süreci açıklanmıştır. Son olarak tez çalışmasında kullanılan 3DGAN model mimarisi ve hiper-parametreler belirlenmiştir.

Bölüm 6'da 3B konsept tasarımlarının mekanik özelliklerini geliştirmek 3DGAN ve FEA temelli çerçeve tanıtılmaktadır. Sunulan çerçevenin geçerliliği havacılıkta kullanılan iki ayrı yapısal bileşen üzerinde gösterilmiştir. Bu parçalar / bileşenler ile yapılan uygulamalar hem seçilen 3DGAN mimarisi hem de FEA ile ilişkili çalışmaların etkinlik ve geçerliliğini açık bir şekilde ortaya koymaktadır.

Son bölümde ise tezden elde edilen sonuçlar detaylı bir şekilde ele alınmıştır. Ayrıca Tezin sınırlamaları ve potansiyel eksikleri tartışılarak yapılacak yeni araştırmalar hakkında kapsamlı önerilerde bulunulmuştur.

2. MÜHENDİSLİK TASARIMI PERSPEKTİFİNDEN YAPAY ZEKÂ UYGULAMALARI

Geleneksel ürün ve mühendislik tasarım süreçleri insan merkezlidir ve bilimsel, sezgisel, deneyimsel ve yaratıcı yöntemleri içeren uzman bilgisi gerektirir [13]. Son yıllarda bu geleneksel yaklaşım, diğer tüm mühendislik disiplinlerinde olduğu gibi YZ'nın ürün ve mühendislik tasarımında kullanılmasıyla değişmektedir. YZ, zihinsel süreçleri veya etkinlikleri taklit eden bilgisayar algoritmalarının genel adıdır [14, 15]. Mühendislik tasarım süreci de dahil olmak üzere çeşitli disiplinlerde öğrenme, anlama, tahmin etme, problem çözme, öneride bulunma ve karar verme gibi görevlerde kullanılabilmektedir [2]. YZ destekli tasarım teknikleri, karşılaştırma, değerlendirme ve tahmin gibi karmaşık tasarım işlemlerini yöneterek tasarımcının yenilik ve yaratıcılık gerektiren konulara odaklanmasını sağlar. Bu şekilde YZ yöntemleri tasarım süreçlerini kısaltır, kesin sonuçlar elde eder ve genel tasarım maliyetlerini düşürür. Ayrıca, yüksek hesaplama, büyük veri işleme ve nesnel karar verme yetenekleri nedeniyle bu tür görevleri yerine getirmede insanlara kıyasla üstündür [16, 17].

2.1. Tasarımda Yapay Zekâ

Birçok yapay zekâ tekniği arasında uzman sistemler, bulanık mantık, yapay sinir ağları ve genetik algoritmalar çok uzun bir süredir tasarım değerlendirme ve optimizasyon süreçlerinde çok kullanılan klasik yöntemlerdir [18]. Ancak, makine öğrenmesi ve derin öğrenme gibi veri odaklı modern yöntemlerin tasarım sürecinde uygulanması son yıllarda artmıştır. Fikir esinlenme, konsept oluşturma, değerlendirme, optimizasyon ve karar verme gibi tasarım sürecinin bir veya daha fazla aşamasında çeşitli diğer yapay zeka teknikleri kullanılabilmektedir [17]. Saridakis ve Dentsoras tarafından yapılan yeni bir çalışmada, mühendislik tasarımında klasik YZ tekniklerinin (bulanık mantık, genetik algoritma ve yapay sinir ağı) kullanımı incelemiştir [19]. Araştırma sonuçları, bu yöntemlerin tasarım problemlerinde verimli olduğunu göstermektedir. Benzer şekilde, Youssef ve diğerleri (vd.) fotovoltaiik hücre tasarımı ve geliştirilmesinde bu tür geleneksel YZ tekniklerini karşılaştırmıştır [20]. Chang vd. ise makine öğrenmesi ve derin öğrenme tekniklerini kullanarak mekanik parçaların kusur tespiti ve tasarımına ait uygulanan öğrenme yöntemlerini sınıflandırmıştır [21]. Abualigah ve Diabat, mühendislik tasarım problemlerinde meta sezgisel bir optimizasyon algoritması olan Grasshopper optimizasyon algoritmasının kullanımını incelemiştir [22]. Optimizasyon algoritmasının uygulama

türlerini ve tasarımıda hibrit kullanımıyla ilgili bir rehber hazırlamışlardır. Giri vd., moda ve giyim endüstrisinde yapay zekâ tekniklerinin kullanımı üzerine sistematik ve kapsamlı bir literatür taraması yapmışlardır [23]. Bu özel alana özgü uygulanabilir makine öğrenimi, derin öğrenme, uzman sistemler, karar destek sistemleri ve optimizasyon algoritmalarının önemini ve kapsamını belirlemişlerdir. Özellikle, tedarik, tasarım, üretim ve dağıtım süreçlerinde YZ tekniklerinin kullanılmasının olumlu ve olumsuz yönleri gösterilmiştir. Verganti vd., deneyim ve yaratıcılık gerektiren zihinsel bir süreç olan inovasyon ve tasarım süreçlerinde YZ'nin rolünü incelemiştir [24]. Bir başka çalışmada Nasiri ve Khosravani, eklemeli imalat alanında makine öğrenme uygulamalarını gözden geçirmiş ve mekanik özellikler üzerinde büyük etkisi olan baskı parametreleri, gözeneklilik ve kusur tespitini optimize etmişlerdir [25]. Makine öğrenmesinin 3B baskı teknolojilerindeki yeri, önemi ve geleceği de tartışılmış, araştırmacılara ve uygulayıcılara faydalı önerilerde bulunulmuştur. Le, ürün tasarımıda YZ kullanımının etkisini sosyal ve ekonomik sürdürülebilirlik perspektifinden incelemiş ve ürün tasarım sürecini ürün yaşam döngüsüne entegre ederek YZ tekniklerinin bu konudaki gelişimini tanıtmıştır [26]

Benzer YZ kapsamlı çalışmalar, mühendislik ürün tasarımıda yanı sıra mimari tasarım ve inşaat mühendisliği alanlarında da yayınlanmıştır [2]. Lu vd., inşaat mühendisliğinde uygulanan YZ teknikleri üzerine kapsamlı bir literatür taraması yapmıştır [18]. Bu çalışmada evrimsel hesaplama, bulanık mantık, uzman sistemler, sinir ağları ve kollektif zekâ gibi YZ yöntemlerine ait mevcut uygulamalar gözden geçirilmiştir. Salehi ve Burgueño örüntü tanıma, makine öğrenmesi ve derin öğrenme yöntemlerinin yapı mühendisliği uygulamalarını incelemiştir [5]. Bu güncel YZ yöntemlerinin yukarıda bahsedilen daha geleneksel yöntemlere göre avantajları tartışılmıştır. Pan ve Zhang, inşaat mühendisliği ve inşaat yönetiminde kullanılan YZ teknikleri ve bunların mevcut uygulamaları hakkında 1997-2020 dönemini kapsayan ayrıntılı bir literatür taraması yapmıştır [27]. İlgili çalışma robotik, sanal gerçeklik, artırılmış gerçeklik, blok zincirleri ve 4 boyutlu yazıcılar gibi konuların YZ ile birleşiminin gelecek yıllarda potansiyel araştırma alanları olacağını belirtmektedir.

Değerli katkılara rağmen, mühendislik ve ürün tasarımı ile ilgili önceki inceleme çalışmalar sınırlı ve dar bir alanda gerçekleştirilmiştir. Bunlar genellikle bazı tasarım problemlerindeki klasik YZ teknikleri veya son yıllarda ürün ve mühendislik tasarımıda uygulanan makine öğrenmesi ve derin öğrenmedeki önemli gelişmeleri kapsamaktadır. Bununla birlikte, açık

literatürdeki derleme çalışmalarının neredeyse tamamı yalnızca belirli uygulamalar için klasik veya modern YZ yöntemlerini ele almaktadır. Yani, önceki inceleme makaleleri yapay zekanın mühendislik ve ürün tasarımındaki uygulamaları hakkında önemli bilgiler sağlamış olsa da geleneksel kural tabanlı ve modern veriye bağlı yöntemleri birlikte ele almamışlardır. Bu bölüm, kavramsal ürün tasarımı kapsamında hem klasik (yani genetik algoritma, bulanık mantık, yapay sinir ağları) hem de modern YZ tekniklerinin (yani makine öğrenmesi ve derin öğrenme) kullanımını eleştirel bir şekilde incelemektedir. Böylece mühendislik tasarımı alanında klasik ve modern yapay zekâ tekniklerini birleştiren daha kapsamlı olarak mevcut literatürü tamamlamaktadır. Bu şekilde, bu yöntemlerin birlikte ele alınması tasarım uygulamalarında daha verimli ve kapsamlı YZ çözümleri keşfetmeye yardımcı olabilir. Ayrıca, özellikle son 5 yılda mühendislik tasarımı yapay zekâ kullanımındaki muazzam artış bu incelemeyi gerekli kılmıştır. Bu bölümün bir diğer amacı, YZ yöntemlerini mühendislik tasarım süreçlerindeki (fikir oluşturma, konsept oluşturma, değerlendirme, optimizasyon, tasarım desteği, modelleme vb.) kullanımlarına göre sınıflandırmaktır. Genel olarak bu bölümün nihai hedefi, sonraki bölümlerde ana hatları çizilen çerçeve bağlamında, YZ destekli tasarımın uygulama alanlarını bir bütün olarak mühendislik tasarımcılarının dikkatine sunmaktır. Mevcut inceleme kapsamında son 15 yılın önemli çalışmaları sınıflandırmış ve değerlendirmiştir. Ayrıca her bir YZ yönteminin tasarım çalışmalarındaki güçlü ve zayıf yönleri de ele alınmıştır.

2.2. Sistematik Literatür Araştırması

Bu bölüm, yapay zekânın mühendislik tasarım süreçlerinde kullanımını ele almaktadır. YZ'nın tasarımda geniş bir kullanım yelpazesi olduğundan, eksiksiz, rasyonel ve tekrarlanabilir bir literatür taraması yapmak için sistematik bir arama yönteminin uygulanması gerekir. Buradaki gözden geçirme süreci, arama, seçme ve bilgi edinme adımlarını içermiştir. Bilimsel veri tabanlarından elde edilen makaleler, içerik ve kapsamlarına göre değerlendirilmiş ve kapsam dışı kalanlar ise elenmiştir. Derlenen makaleler daha sonra içeriklerine göre sınıflandırılmıştır.

Yayınlanmış makaleleri tarama

Yayınlanan araştırma makalelerine en çok kullanılan şu iki farklı bilimsel veri tabanından erişilmiştir: “Scopus” ve “Web of Science”. Veri tabanlarında arama yapmak için kullanılan

notasyonlar, formüller ve kelime dizileri ve bulunan makale sayıları Çizelge 1'de gösterilmiştir. 2006-2022 yılları arasında akademik veri tabanlarında bulunan YZ ve tasarım ile ilgili tüm dergi ve konferans makaleleri literatür araştırmasına dahil edilmiştir. İngilizce makaleler herhangi bir ülke kısıtlaması olmadan incelenmiştir.

Çizelge 2.1. Bilimsel veri tabanlarında kullanılan notasyonlar, formüller ve kelime dizileri

Veri Tabanı	Arama kelimeleri	Makale Sayısı
Scopus	TITLE-ABS-KEY (("artificial intelligence" OR "decision support system" OR "data-driven design " OR "design automation" OR "machine learning" OR "design intelligence") AND ("conceptual design" OR "engineering design" OR "mechanical design" OR "product design" OR "design development" OR "design optimization" OR "design assessment" OR "design evaluation" OR "design creativity" OR "idea generation"))	1221
Web of Science	(TS= (("artificial intelligence" OR "decision support system" OR "data-driven design " OR "design automation" OR "machine learning" OR "design intelligence") AND ("conceptual design" OR "engineering design" OR "mechanical design" OR "product design" OR "design development" OR "design optimization" OR "design assessment" OR "design evaluation" OR "design creativity" OR "idea generation")) AND LANGUAGE: (English)	680

İlgili makalelerin seçimi

Çizelge 2.1'de elde edilen yaklaşık 2.000 yayın arasından hangi yayınların kullanılacağı dört aşamalı bir eleme ve seçim süreci ile belirlenmiştir. Bu kapsamda: (1) Öncelikle aynı yayınlar ortak bildiri havuzundan çıkarılmıştır. (2) Bir sonraki adımda makale başlığı ve anahtar kelimeler incelenmiş, çalışma kapsamı dışında kalan yayınlar da elenmiştir. Bir sonraki aşamada özet içeriğine göre bazı makaleler elenmiştir. (4) Tüm bu eleme işlemlerinden sonra 132 dergi ve 52 konferans bildirisi olmak üzere toplam 184 yayın belirlenerek çalışmaya dahil edilmiştir.

Bilginin elde edilmesi

Önemsiz ayrıntılarla ve keşifsel literatürle vakit kaybetmeden makalenin konusunu ve kapsamını belirlemek için bir inceleme yöntemi kullanılmıştır [28]. Bu aşamada öncelikle bildirilerin özeti incelenmiş, giriş ve sonuç bölümleri ancak özeti ilgili ve ilgi çekici bulunması halinde incelenmiştir. Bu bölümler, araştırma konusu ile ilgili ise bulgular/tartışma bölümleri analiz edilmiştir. İnceleme havuzuna dahil edilen yayınlar,

bulgular/tartışma bölümleri de dahil olmak üzere her yönüyle araştırma konusuyla uyumlu yayınlardır.

İncelenen makalelerin amacının belirlenmesi ve sınıflandırılması sürecinde aşağıdaki sorulara cevap aranmıştır;

- Bu çalışma ne tür bir tasarım problemini çözmeyi amaçlar?
- Bu çalışma hangi alanda yapılmıştır?
- Bu çalışmaya neden ihtiyaç duyulmuştur?
- Problem çözmede hangi YZ tekniği kullanılmıştır?
- Elde edilen bulgular nelerdir?

2.3. Yapay Zekâ Yöntemlerine Genel Bir Bakış

YZ düşünme, çıkarım, sınıflandırma, yorumlama, tahmin ve karar verme gibi zihinsel faaliyetleri taklit eden hesaplama yöntemleri olarak tanımlanabilir [5, 29-31]. Matematik, bilgisayar, nöroloji, biyoloji, genetik ve mühendislik gibi çeşitli bilimsel alanlardan gelen bilgileri birleştiren disiplinler arası bir çalışma alanıdır [32]. YZ araştırmaları genel olarak insana özgü zihinsel görevleri ve faaliyetleri bilgisayarlar tarafından hızlı, etkili, doğru ve verimli bir şekilde gerçekleştirmeyi amaçlar [18, 33]. Geleneksel yazılımlardan temel farkı, eksik ve belirsiz verilerle çalışabilmesidir. Yani veriler arasında anlamsal ilişkiler kurularak geçmişe yönelik çıkarımlar ve geleceğe yönelik tahminler yapılabilmektedir. Başta tasarım ve mühendislik alanında olmak üzere eğitim, sağlık, trafik, ekonomi, yargı ve üretim alanlarında da yaygın olarak kullanılmaktadır [31, 34].

Son yıllarda gelişen ve daha karmaşık hale gelen YZ teknolojisi hayatın her alanında kolaylık sağlasa da alınan kararların sebepleri algoritmaların kara kutu çalışma mekanizmasından dolayı bilinmemektedir. Bu nedenle, özellikle savunma, sağlık ve bankacılık olmak üzere kararların büyük önem taşıdığı çeşitli sektörlerde YZ uygulamalarının güvenilirliği ön plana çıkmıştır. YZ yöntemlerini içeren yüksek performanslı akıllı sistemlerin, bu tür uygulamalarda güvenilir olmaları için şeffaf ve açıklanabilir olmaları gerekir. Sadece alınan kararlara nasıl ulaşıldığı biliniyorsa bu eylemlere güven tesis edilebilir [35]. Karar gerekçesi bilindiğinde, sonuçların doğrulanmasına, iyileştirilmesine ve denetlenmesine izin verebilir. Ancak, YZ tarafından

verilen kararların sorumluluğu, bilinmeyen iç süreçler nedeniyle belirsizdir. Bu noktadan hareketle, yapay zekanın içsel çalışma yapısını ve alınan kararların nedenlerini netleştirmeyi amaçlayan Açıklanabilir Yapay Zekâ (AYZ) kavramı ortaya çıkmıştır. Diğer taraftan insan tasarımcılar, henüz keşfedilmemiş durumları AYZ destekli tasarımlardan öğrenebilirler. AYZ, neden-sonuç ilişkilerini anlamayı, güçlü ve zayıf yönleri belirlemeyi ve gelecekteki davranışlarını tahmin etmeyi amaçlamaktadır. Böylece şeffaf, açıklanabilir ve güvenilir insan-makine iş birliği sağlanabilir. Minh vd., AYZ yöntemlerini üç gruba ayırmıştır: Modelleme öncesi açıklanabilirlik, yorumlanabilir model ve modelleme sonrası açıklanabilirlik [36]. Modelleme öncesi açıklanabilirlik, eğitim veri setinin bir dizi veri işleme adımından sonra verilerden içgörü elde edilmesi olarak tanımlanır. Yorumlanabilir modeller, konunun uzmanları tarafından model yapısı ve parametreleri incelenerek anlaşılabilen AYZ yöntemleridir. Kural tabanlı öğrenme, doğrusal veya mantıksal regresyon ve karar ağaçları, bu gruptaki AYZ yöntemlerinden bazılarıdır. YZ kararlarının görsel, metinsel, sadeleştirme ve öznitelik etki düzeyi gibi tekniklerle incelenmesi modelleme sonrası açıklanabilirlik olarak kabul edilmektedir. Bu gruplardaki yöntemlerin temel amacı, YZ modeline verilen girdilerin eğitim performansını belirlemektir.

YZ yöntemleri, kullanılan problem çözme yöntemine göre iki kategoriye (güçlü ve zayıf YZ) ayrılabilir. Güçlü YZ teknikleri, insanların bir problemi çözerken kullandıkları zihinsel ve buluşsal süreçleri taklit etmeye çalışır [24, 37]. Bu tür sistemlerin amacı, bilgisayarlara düşünme, algılama ve akıl yürütme yeteneği kazandırmaktır. Öte yandan zayıf YZ, genellikle belirli görevleri başarılı bir şekilde gerçekleştiren, ancak buluşsal süreçleri içermeyen hesaplama yazılımlarıdır. "Zayıf" kelimesi aksini düşündürse de zayıf YZ yöntemleri genellikle belirli bir görevde bir insandan daha verimli ve başarılıdır. Ancak geliştirilme amacı dışındaki görevlerde aynı başarıyı sürdürülebilir şekilde gösteremezler [5, 24]. Günümüzde kullanımda olan YZ yöntemlerinin çoğunun zayıf YZ olarak nitelendirildiğine dikkat edilmelidir. Bunların yanında henüz ön araştırma aşamasında olmasına rağmen son yıllarda süper yapay zekâ kavramı da ortaya çıkmıştır. Bu kavram, insanlardan daha yüksek işleme ve düşünme yeteneklerine sahip yazılımları ifade eder.

Bu tezin bir diğer amacı da tasarım süreçlerinde en çok tercih edilen yapay zekâ yöntemlerini ve kullanım alanlarını belirlemektir. Son 16 yılda (2006-2022) YZ yöntemlerinin tasarımda kullanımına ilişkin binlerce çalışmadan yararlanılarak bir anahtar kelime havuzu oluşturulmuştur. Bu kelime havuzu incelendiğinde sırasıyla makine öğrenmesi, genetik

algoritma, yapay sinir ağıları, bulanık mantık, sürü zekâsı, veri madenciliği ve uzman sistemlerin en çok tekrarlanan anahtar kelimeler olduğu anlaşılmaktadır. Şekil 2.1, 2006-2022 yılları arasında bu YZ yöntemlerinin her birine ilişkin yayın sayısını göstermektedir. Bu YZ yöntemlerine olan ilginin zaman içindeki değişimi şekilde açıkça görülebilir. Öncelikle YZ'nın tasarımda kullanımına yönelik akademik çalışmaların sayısı 2014 yılından itibaren hızla artmıştır. Bu durum kısmen bilgisayar teknolojisindeki hızlı gelişme ve veri depolarına erişimin kolaylaşmasına bağlanabilir. Ayrıca bu artışta makine öğrenmesi ve derin öğrenmenin önemli bir payı vardır. Uzman sistemler, bulanık mantık, yapay sinir ağıları, genetik algoritmalar gibi diğer YZ tekniklerine olan ilgi eskisi kadar fazla değildir ve yıllar geçtikçe kullanım oranı azalmaktadır.


2.4. Yapay Zekâ Yöntemleri

Uzman sistemler, bulanık mantık, yapay sinir ağıları ve genetik algoritmalar çok uzun süredir tasarım değerlendirme ve optimizasyon süreçlerinde en sık kullanılan klasik yöntemlerdir. Ancak makine öğrenmesi ve onun alt dalı olan derin öğrenme gibi modern veri odaklı yöntemlerin tasarım sürecine uygulanması son yıllarda artış göstermiştir. Fikir ilhamı, konsept oluşturma, değerlendirme, optimizasyon ve karar verme süreçleri gibi tasarım sürecinin bir veya daha fazla aşamasında çeşitli diğer YZ teknikleri kullanılabilir. Bazen sinir ağıları, bulanık mantık ve kollektif zekâ (İng. Swarm intelligence) gibi yöntemleri birleştiren hibrit YZ da bazı tasarım uygulamalarında eş zamanlı olarak kullanılabilir [34]. Yaygın olarak kullanılan YZ tekniklerinin birbirleriyle olan ilişkileri Şekil 2.2'de gösterilmektedir. Evrimsel algoritmalar, büyük veri, sürü zekâsı ve bilgi tabanlı sistemler diğer bazı uygulamalarda da kullanılabileceğinden (klasik bilgisayar programlama ve istatistiksel hesaplama gibi), bu şekilde yalnızca YZ'nın bir alt dalı olarak sınıflandırılmamışlardır.

2.4.1. Makine öğrenmesi


Makine öğrenmesi, verilere dayalı tahminler ve çıkarımlar yapabilen istatistiksel YZ yöntemleri olarak tanımlanabilir [4-6]. Bu bazen geleneksel programlama ile karıştırılabilir. Ancak makine öğrenmesi, programlamada olduğu gibi öğrenmek için net bir algoritmaya ihtiyaç duymaz [7]. Bunun yerine, mevcut herhangi bir veri setindeki benzerlikleri ve kalıpları tespit eder ve bunları gelecekteki verileri yorumlamak için kullanır. Dolayısıyla

klasik programlama ile yapılması zor olan doğal dil işleme, ses, görüntü ve örüntü tanıma gibi görevlerde makine öğrenmesi kullanılabilir. Verileri anlamak ve yorumlamak için kullanılan istatistiksel öğrenme, modern makine öğrenmesi algoritmalarının arkasındaki temel teoridir [38].



Şekil 2.1. 2006 ve 2021 yılları arasında tasarımda yapay zekâ konulu yayınlanan makale sayısı

İstatistiksel öğrenme ve makine öğrenmesi örtüşen kavramlar olsa da özellikle yorumlanabilir olma konusunda belirli farklılıkları vardır. Birincisi, doğrusal regresyon ve lojistik regresyon gibi girdi verileri (bağımsız değişkenler) ile çıktı (bağımlı değişkenler) arasında doğrusal bir ilişkinin olduğu problemlerde kullanılır. Bağımsız değişkenlerdeki değişimlerin bağımlı değişkene nasıl yansıtacağı belirlenebildiği için kolay açıklanabilir. Makine öğrenmesinde ise girdi ve çıktı değişkenleri arasında doğrusal bir ilişki olmadığı için sonuçların yorumlanması daha zordur. Makine öğrenmesinin uygulama kolaylığı ve büyük veri kümelerindeki başarısı nedeniyle bazı durumlarda yorumlanabilir olması göz ardı edilebilmektedir. Bu algoritmalar, tıpkı insanın öğrenme mekanizması gibi, verilerin artmasıyla yorumlama becerisini geliştirir.



Şekil 2.2. Yaygın kullanılan YZ yöntemleri ve birbirleri ile ilişkileri

Son 15 yılda veri miktarının artması (sosyal medya, online alışveriş siteleri, nesnelerin interneti, fotoğraf ve 3D model depoları vb.), süper performanslı bilgisayarlar ve büyük veriye uygun algoritmaların geliştirilmesi öğrenme, tahmin ve tanımlama başarısına katkı sağlamakta ve artırmaktadır. Böylece makine öğrenmesi algoritmaları ile kullanıcı-ürün etkileşimini artıracak ve kullanıcının satın alma tercihini etkileyecek özgün tasarım konseptleri oluşturulabilmektedir [39-42]. Ayrıca yüksek hesaplama gücü gerektiren sonlu elemanlar analizi yerine makine öğrenmesi modelleri ile topoloji optimizasyonu yapılabilmektedir [43]. Bununla birlikte, bu algoritmaların sonuçlara nasıl ulaştığı tam olarak açıklanmadığı için makine öğrenmesi kara kutu bir mekanizmaya sahiptir. Makine öğrenmesi kavramında genel olarak üç farklı öğrenme modeli mevcuttur; denetimli, denetimsiz ve pekiştirmeli (Şekil 2.3).

Denetimli öğrenme

Denetimli öğrenme, girdi ve etiketli çıktı değişkenleri arasındaki modeli tanımlayan en iyi fonksiyonu elde etmeyi amaçlar. Diğer bir deyişle öğrenme, girdi değerleri ile etiket

değerleri arasındaki ilişkiyi belirleyerek gerçekleşir [4]. Denetimli öğrenme ile bir dizi kategoriden oluşan çıktıların sınıflandırılması (kötü-ortalama-iyi, kadın-erkek, kabul-ret vb.) veya sürekli sayılardan oluşan regresyon görevleri (hava sıcaklığı, maaş, kilo vb.) yapılabilir [44]. Kullanılan veri kümeleri, eğitim ve test olmak üzere iki bölüme ayrılmıştır [45]. Model özellik seçimi ve ağ ağırlıklarının ayarlanmasında eğitim veri seti kullanılırken, test veri seti ile makine öğrenmesi modelinin başarısı ölçülmektedir. Burada etiketli veri kümeleri oluşturmanın külfetli olduğu ve veriler arasındaki girdi-çıkı ilişkilerinin net olması gerektiği belirtilmelidir. Bu öğrenme tekniği, minimum hata payı ile çok yüksek bir başarı oranına sahiptir [46]. Yapay sinir ağları, lojistik regresyon, doğrusal regresyon, k-en yakın komşu, karar ağaçları ve destek vektör makineleri en yaygın denetimli makine öğrenmesi algoritmalarıdır.



Şekil 2.3. Yaygın kullanılan makine öğrenmesi algoritmaları

Yapay Sinir Ağları (YSA), canlı sinir sistemini (ör. nöronlar, dendritler ve aksonlar) ve bunların ilişkilerini taklit eder. Sinir sistemi ve özellikleri basit bir yapıya indirgenerek matematiksel bir işlem modeli oluşturulur [47-50]. YSA'nın en belirgin özelliği, bilginin etkinleştirildiği birbirine bağlı nöronlar arasındaki ağ ağırlıklarının optimizasyonu yoluyla karmaşık ve formüle edilmemiş sorunları çözebilmesidir. Derin öğrenme yöntemlerinin temelini oluşturan bu işleme ağ eğitimi denir. YSA, literatürde denetimli öğrenme başlığı altında sınıflandırılrsa bazı derin öğrenme algoritmaları denetimsiz öğrenme ile de eğitilebilmektedir [51].

Bazıları diğerlerinden daha yaygın olarak kullanılsa da pek çok sinir ağı çeşidi vardır. Örneğin, İleri Beslemeli Sinir Ağı, bilginin ilk önce çıkış katmanına ulaştığı ve daha sonra önceki katmanlara doğru ilerlediği ileri besleme ve geri yayılım algoritmalarıyla eğitilir. İlk algoritmada, önceki katmandan gelen bilgi mevcut katmandaki ağırlıkları ile çarpılır ve aktarım fonksiyonu oluşturmak için bir sapma (bias) değeri eklenir. Bu fonksiyondan gelen net girdi bir sonraki aşamadaki aktivasyon fonksiyonunda değerlendirilir ve verilen eşik değeri aşan bilgi (net girdi) bir sonraki katmana aktarılır. İleri beslemeli algoritmanın son adımında çıktı katmanında elde edilen değer ile veri etiketi arasındaki farka (ör. 1-0) kayıp veya hata denir [52]. Ağırlıkları, geri yayılım algoritması ile çıkış katmanından giriş katmanına güncellenir (eğitilir). Bu amaçla kullanılan gradyan iniş algoritması, hedef değer ile gerçek değer arasındaki farkı azaltmayı amaçlar. Yapay sinir ağlarının eğitim süresi, tahmin edilmesi zor birçok parametreye (nöron ve katman sayısı, aktivasyon fonksiyonu, öğrenme hızı, başlangıç ağırlık değerleri vb.) bağlıdır [6]. Ayrıca ağı eğitimi için yüksek bilgisayar işlem gücü gerekebilir. Bu yöntemin bir diğer kısıtı sonuçların nasıl elde edildiği açıklanamadığı için sonuçlara ulaşmadaki belirsizliktir. Ayrıca yapay sinir ağlarının tasarım probleminde kullanılabilmesi için tasarım değişkenlerinin sayısal olması veya sayısal verilere dönüştürülebilir olması gerekmektedir.

YSA tasarım alanında olduğu kadar finans, bankacılık, ilaç üretimi, iletişim, pazarlama ve üretim sektörlerinde de birçok uygulaması bulunmaktadır. Bu yöntem erken tasarım aşamasında ürün konfigürasyonu oluşturma, seçenekleri değerlendirme ve optimizasyon süreçlerinde kullanılmaktadır [53-55]. Ayrıca sinir ağları, tasarımcıların müşteri ihtiyaçlarını analiz etmelerine ve bunları mühendislik özellikleriyle ilişkilendirmelerine yardımcı olabilir [56].

Derin sinir ağları, birden çok katmandan oluşan ve büyük veri kümeleri kullanılarak eğitilebilen YSA'dır. Derinlik kavramı, sinir ağının katman sayısını ve öğrenilen bilginin yoğunluğunu ifade eder. Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN) ve Üretken Çekişmeli Ağlar (GAN), uygulama alanı en geniş olan derin sinir ağları arasında yer almaktadır [8]. Evrişim (convolution), havuzlama (pooling) ve tamamen bağlantılı (full connected) katmanlardan oluşan CNN, özellikle görüntü işlemede en yaygın kullanılan derin öğrenme yöntemidir. Burada yinelenen evrişim ve havuzlama katmanları, belirli bir veriden çeşitli bilgileri (öznitelikleri) filtrelemek, öğrenmek ve önemsiz bilgileri ortadan kaldırarak görüntü boyutunu küçültmek için kullanılır. CNN mimarisinin son aşamasında, tamamen

bağlı düz katmanlara ve bir çıktı çözümünü birleştiren kademeli olarak azaltılmış nöronlara sahip bir sinir ağı vardır. Evrişim ve havuzlama katmanlarından gelen piksel matrisi, bu son aşama sinir ağı veri girişi için düzleştirilerek tek boyutlu bir diziye dönüştürülür. Görsel veriler üzerinde öğrenilen özniteliklerin sayısı evrişim katmanlarının sayısı ile artar. Burada, kullanıcı tanımlı makine öğreniminin aksine, hangi özelliğin öğrenileceğine CNN karar verir. Bu da derin öğrenme algoritmalarını görüntü sınıflandırma, 2B ve 3B nesne tanıma, ses tanıma, yüz tanıma ve dil çevirisi gibi işlemlerde daha başarılı kılmaktadır [7, 57]. Ayrıca topoloji optimizasyonu, benzersiz tasarım konseptleri oluşturma ve hatta bilgisayar destekli mühendislik ve simülasyon gibi mühendislik tasarım görevleri derin öğrenme yöntemleri ile gerçekleştirilebilir [3]. Bu tür özel uygulamalar hakkında daha fazla ayrıntı sonraki bölümlerde verilmektedir. Tasarım uygulamalarında sıklıkla kullanılan bir başka derin öğrenme yöntemi olan GAN, daha önce olmayan görseller oluşturma, mevcut görsellerin çözünürlüğünü artırma, 2B görsellerden 3B model oluşturma, bir açıdan görünüşü verilen bir nesnenin farklı görünüşlerini tahmin etme ve metinden resme çeviri gibi görevleri yapabilme özelliği ile derin öğrenmeye yeni bir bakış açısı kazandırmıştır [9, 11]. GAN, tek bir mimarisinde eş zamanlı olarak kullanılabilen iki farklı ağ (üretici ve ayrıcı) benzersiz verilerin oluşturulmasını sağlar [10]. Ancak bu algoritma, başarılı öğrenme için çok büyük miktarda veri gerektirir ve bu da uzun işlem sürelerine neden olabilir [58].

Denetimsiz öğrenme

Denetimsiz öğrenme algoritması, YZ modelinin etiketlenmemiş bir veri kümesinden ortak özelliklere sahip verileri kendi kendine keşfetmesini ve veriler arasındaki gizli kalıpları ortaya çıkarılmasını sağlar [59, 60]. Denetimli öğrenmeden farklı olarak, model eğitiminde bir denetleyiciye ihtiyaç yoktur. Bu nedenle model performanslarını objektif olarak değerlendirmek zordur. Bu algoritmalar genellikle veri kümelemeyi ve boyut küçültmeyi algılamak için kullanılır. K-Means kümeleme, İlişkilendirme Kuralları, Otomatik Kodlayıcı ve Temel Bileşen Analizi en yaygın olarak kullanılan denetimsiz öğrenme algoritmalarıdır [61]. K-means kümeleme, veriler arasındaki mesafeleri dikkate alarak verileri anlamlı gruplara ayırmayı sağlar. Öte yandan, İlişkilendirme Kuralları, veriler arasındaki ilişkileri tanımlamaya çalışır. Temel bileşen analizi ve otomatik kodlayıcı, işlem hızını artırmak ve gereksiz hesaplama yükünü azaltmak için boyut küçültmeyi mümkün kılar [45].

Pekiştirmeli öğrenme

Pekiştirmeli öğrenme, geleneksel deneme yanılma yöntemine benzer yüksek bir gelecek potansiyeline sahip öğrenme algoritmasıdır. Burada belirli görevleri yerine getirmek için bir dizi eylem gerçekleştirilir. Doğru sonuca götüren eylemler ödüllendirilir (onaylanır), yanlış sonuca götüren eylemler ise cezalandırılır (reddedilir) [6, 59]. Örneğin hedefine en kısa yoldan ulaşmaya çalışan bir robotun harcadığı enerji ve zaman, ödül/ceza notları olarak değerlendirilebilir. Pekiştirmeli öğrenmenin temel amacı rastgele denemelerle üst düzey taktikler geliştirmektir. Bu yöntem, çözümleri kendi başına araştırır. Ancak geliştiricinin net hedefler tanımlaması, ödül ve cezaları belirlemesi gerekir [6]. Bütün bunlar dikkate alındığında pekiştirmeli öğrenme modeli, bir problemi çözmek için farklı yollar bulabildiğinden yaratıcılık potansiyeli en yüksek öğrenme modelidir.

2.4.2. Genetik algoritma

1970'lerin başında John Holland tarafından geliştirilen Genetik Algoritma (GA), güçlü bireylerin hayatta kaldığı ve zayıfların yok olduğu doğal seçilimin evrimsel mekanizmasını taklit eden buluşsal bir arama algoritmasıdır [62, 63]. GA sisteminde kullanılan birçok terim (gen, kromozom, popülasyon, çaprazlama, mutasyon vb.) doğal sistemlerden uyarlanmıştır. Aday çözümler (kromozomlar), çözüm özelliklerini gösteren “gen” dizilerinden oluşur. Buradaki seçim, çaprazlama ve mutasyon gibi genetik operatörler bir dizi yinelemeli adımla çözüm uzayındaki en iyi seçeneği belirlemek için kullanılır [64, 65].

Başlangıç çözüm uzayı (popülasyon olarak da adlandırılır), problemin karmaşıklığına bağlı olarak rastgele seçilen onlarca veya binlerce homojen kromozomdan oluşabilir [66]. Her bir kromozomun çözüm değeri, daha sonra amaç fonksiyonuyla (hedeflenen çözüm değeri) karşılaştırılarak uygunluk fonksiyonu hesaplanır. Yeni (yavru) kromozomların üremesi, kromozomların çözüm uzayında yüksek uygunluk değerine sahip kromozomların eşleştirilmesi ile sağlanır [67, 68]. Popülasyondan zayıf kromozomları çıkararak yalnızca umut verici çözümlerin hayatta kalmasına izin verilir. Bu aynı zamanda popülasyon sayısını sabit tutmak ve çözüm kalitesini iyileştirmek için de gereklidir [69]. Genetik çeşitliliği arttırmak için kromozom çiftleri arasında sınırlı sayıda çaprazlama veya mutasyon işlemleri uygulanmaktadır. Mutasyon, kromozom üzerindeki bir veya daha fazla genin belirli kurallara dahilinde modifikasyonunu ifade eder. İyi sonuçlar elde etmek için çaprazlama ve mutasyon

işlemleri sürekli olarak tekrarlanır. Hedeflenen nesil sayısına, hedef değere veya başlangıç durumundan belirli bir dereceye kadar iyileştirmeye ulaşıldığında, GA işlemi sonlandırılır. GA, özellikle geniş çözüm uzaylarında ve karmaşık problemlerde başarılı sonuçlar elde edebilir. Bununla birlikte, küresel en iyiye ulaşılması popülasyon büyüklüğü, mutasyon oranı, çaprazlama yöntemi ve seçim yöntemi gibi parametrelere bağlıdır. Ayrıca kromozomların kodlanması yoğun bir kullanıcı deneyimi gerektirir. Pahalı bir hesaplama yöntemi olmasına rağmen nihai çözümün kalitesi istenilen düzeyde olmayabilir.

GA, planlama (ör. robot yolu), navigasyon (ör. gezgin satıcı problemi), düzen (ör. fabrika düzeni oluşturma) ve arama (ör. strateji oluşturma) gibi optimizasyon problemlerinde yaygın olarak kullanılır. Ayrıca mühendislik tasarımının kavramsal tasarım aşamasında, tasarım seçeneklerinin oluşturulması, karar verme ve değerlendirme aşamalarında GA kullanılabilir [70, 71]. Bunların dışında GA, ürün formu ve renk belirleme, montaj sırası planlama, bileşen yerleştirme gibi tasarım görevleri için de kullanılabilir [72]. Binlerce kavramsal çözümü değerlendirmek için klasik yöntemler yerine GA'nın tercih edilmesi zamandan ve emekten tasarruf sağlayabilir.

2.4.3. Bulanık mantık

Bulanık mantık, klasik/ikili mantığın genişletilmesiyle oluşturulan bir teoridir. Klasik/ikili mantığın yetersiz kaldığı, insan düşünce sistemlerine ve gerçek hayattaki karmaşık problemlere benzer belirsiz ifadelerin (kısa, uzun, çok uzun vb.) matematiksel modellemesinde kullanılır [73-75]. Bulanık mantık sistemi, 1960'ların ortalarında Lotfi Zadeh tarafından geliştirilmiştir [76].

Klasik 'bir' ve 'sıfır' ikili kategorik kümelerin aksine, bir elemanın kategorik bir kümeye ait olması, bulanık kümelerdeki üyelik derecesine göre belirlenir. Bu, bulanık mantıkta bir elemanın aynı anda iki farklı kümenin belirli bir dereceye kadar üyesi olabileceği anlamına gelir [75]. Üyelik derecesi 0 ile 1 arasındaki değerlerle ifade edilir [77]. Bulanık mantık sistemi kural tabanı, bulanıklaştırıcı, çıkarım mekanizması ve durulaştırıcı olmak üzere dört ana birimden oluşur. Kural tabanı, sisteme akıl yürütme yeteneği kazandıran “Eğer-O halde” formatlı bir bilgi deposudur. Bulanıklaştırma, sayısal değerlerin çok az, az, hızlı, yavaş gibi üyelik fonksiyonlarına dönüştürülmesini içerir [77, 78]. Çıkarım mekanizmasında, bulanık

girdi değerleri kural tabanı aracılığıyla yorumlanır ve bulanık sonuçlar elde edilir. Durulaştırma işlemi ile bulanık sonuçlar anlamlı sayısal değerlere dönüştürülür [74].

Sistemin başarısı, girdi ve çıktı değişkenlerinin sayısı, üyelik fonksiyonlarının sayısı, çıkarım yöntemi (örn. Mamdani, Sugeno, vb.) ve durulaştırma yöntemine (örn. alan vb.) bağlıdır. Girdi ve çıktı değişkenlerinin sayısındaki bir artış aynı zamanda kural sayısında da bir artışı gerektirir. Ayrıca, üyelik fonksiyonları ve bir kural tabanı oluşturmak, önemli ölçüde kullanıcı tecrübesi gerektirir.

Bulanık mantık otomasyon, kontrol sistemleri, robotik, tıp, ekonomi, satış ve pazarlama, yönetim, çevre ve mühendislik gibi alanlarda geniş bir kullanım alanına sahiptir. Tasarım varyantlarının kullanıcı beklentileri doğrultusunda değerlendirilmesi, karar verilmesi, ürün yaşam döngüsü değerlendirmesi, yeni ürün geliştirme süreci yönetimi gibi kavramsal tasarım süreçlerinde de başarıyla kullanılmıştır [73, 79-84].

2.5. Tasarımda Yapay Zekâ Uygulamaları

Bu bölümde, çeşitli tasarım aşamalarında kullanılan YZ uygulamaları kullanım amaçlarına göre sınıflandırılmıştır. Bu kapsamda ilham alma, fikir ve konsept üretme, konsept değerlendirme, optimizasyon, karar verme ve modelleme gibi tasarım görevlerindeki uygulamalar ele alınmıştır [16].


2.5.1. İlham alma

Ürün tasarımının en kritik aşamalarından biri fikir üretimidir. Ancak psikolojik atalet (tasarım saplantısı) nedeniyle yaratıcı ve yenilikçi fikirler üretmek her zaman mümkün olmamaktadır [85]. İnsan tasarımcılar, kavramsal tasarım sürecinde yeni konseptler oluşturmaya yönelik düşünme sürecini engelleyen bazı fikirlerine kolayca takılıp kalabilir [86, 87]. Bu, ideal/mükemmel tasarıma ulaşmanın önünde büyük bir engeldir. Esinlenme süreci, kapsamlı pazar araştırmasının yanı sıra alan uzmanlığı, sezgi, parlak bir zihin ve yaratıcı beceriler gerektiren karmaşık bir süreçtir. Bu sürecin uzaması ürün maliyetlerini artırabilir ve pazar payını düşürebilir. YZ sözlü, yazılı ve görsel ilhamlar yoluyla bu engelin üstesinden gelmek için kullanılabilir [88-90]. Patentler, bahsedilen son iki ilham kaynağının mükemmel örnekleridir. Patent içeriğindeki teknik işlevler, malzemeler, çalışma prensipleri

ve kavramlar gibi teknoloji ve tasarım bilgilerini içeren teknik belgeler, tasarım ve ürün geliştirme için önemli bir ilham kaynağı olarak kullanılabilir [91-93]. Hao vd. yeni ve uygulanabilir fikirler/kavramlar oluşturmak için Baskın Olmayan Sıralama Genetik Algoritması II (NSGA-II) ile patent veri tabanlarından ilham verici işlevsel terimler elde etmeye çalışmıştır [94]. Yöntemin etkinliği ve uygulanabilirliği yenilikçi bir fan tasarım problemi için gösterilmiştir. Sarica vd., ABD Patent Veritabanını (USPTO) kullanarak yalnızca teknoloji ve tasarım tabanlı bir anlamsal ağ (TechNet) geliştirmiştir (Şekil 2.4.) [93]. Anlamsal (Semantik) ağlar, ilgili kavramları bulmak ve görselleştirmek için etkili bir araçtır. Burada patent verilerinde kullanılan teknik terimlerden doğal dil işleme teknikleri ile bilgi elde edilmekte ve ardından ilgili kavramlar bir makine öğrenmesi algoritması ile birleştirilmektedir. Daha sonra, terimler arasındaki mesafe yaratıcı fikirlerin oluşumunu etkilediği için terimler arasındaki bağlantılar belirlenir. Mesafe arttıkça yaratıcı fikir üretme olasılığı da artmaktadır. Bununla birlikte, bu oran fikirlerin uygulanabilirliği için tam tersidir. Bu nedenle her zaman ikisi arasında bir uzlaşma vardır. Liu vd., ise işlev tabanlı bir patent bilgi erişim aracı geliştirmiştir [95]. İşlevsel terimler, yarı denetimli bir Naive-Bayes makine öğrenimi algoritması kullanılarak sınıflandırılmıştır. Patent bilgileri soyutlanıp fonksiyonlara dönüştürüldüğünde farklı alanlar arasındaki terim çelişkileri önlenmiş/azaltılmıştır. Luo vd., 5 milyondan fazla patenti, kullanılan teknolojilere göre sınıflandırarak "Teknoloji Alanı Haritası" oluşturmuştur [96]. Burada benzer yaklaşımların uygulandığı teknolojiler "yakın", birbirinden bağımsız olan teknolojiler ise "uzak" olarak tanımlanmıştır. Daha sonra farklı mesafelerdeki teknolojiler arasında bilgiler birleştirilmiştir. Belirsizlik içeren açık uçlu muğlak problemlerde fikir üretilmesi amaçlanmıştır.

Bazı araştırmacılar ise bilimsel literatür ve web kaynaklarından ilham alarak çalışmalarını sürdürmüştür. Liu vd., web kaynaklarından kritik önem taşıyan kavramsal kelimeleri tanımlayarak veri odaklı bir kavram ağı oluşturmuş ve erken tasarım aşamasındaki literatür taraması yükünü hafifletmiştir [97]. Bahsi geçen bu makine öğrenmesi temelli yaklaşım, kavramlar arasındaki mesafeyi ölçme imkânı sağlayarak, yakın-uzak ilişkileri tespit ederek yaratıcılık seviyelerini ölçmektedir [98]. Benzer bir yaklaşım kullanan, Han vd. "The Combinator" adlı bir yazılım geliştirmiş ve doğrudan ilişkili olmayan kavramları birleştirmiştir [85]. Web tarayıcılarından elde edilen veriler doğal dil işleme araçlarıyla analiz edilerek, semantik ağlarla ilişkilendirilmektedir. Yazarlar benzer kavramların benzersiz kombinasyonlarıyla yaratıcı ürün fikirleri sunmuştur. Burada, büyük çözüm

alanlarını keşfetmek için tasarımcılara kolaylık sağlayan farklı şekillerde görüntü ve metin verilerinin birleştirilmesiyle yeni fikirlerin ortaya çıkması tetiklenmektedir [99, 100]. Başka bir çalışmada, Jin ve Dong, 998 RedDot ödülü kazanan ürünlerden ilham alarak ve veri analizi yazılımı (QSR NVivo) kullanarak tasarım prensiplerini analiz etmiş ve 10 yeni Sezgisel tasarım [101] kartı oluşturmuştur [102]. Bazı araştırmacılar ise makine öğrenmesi, metin madenciliği ve doğal dil işleme araçlarıyla kavramlar arasındaki ilişkileri açığa çıkarmak için ontoloji tabanlı yöntemler kullanmıştır. Shi vd., “WordNet” adlı tasarım ve mühendislik odaklı bir denetimsiz ontoloji ağı geliştirmiştir. Akademik dergilerden ve tasarım / mühendislik sitelerinden alınan metinsel veriler, veri madenciliği teknikleri kullanılarak elde edilmiştir [103]. WordNet, basitleştirilmiş bir doğal dil işleme aracı ve semantik ağlar kullanılarak tasarım ve mühendislik kavramları arasındaki ilişkiyi bir ontoloji ağıyla temsil etmektedir.



Şekil 2.4. TechNet ile oluşturulan “uçan araba” konsept ağı [93]


Bazı araştırmacılar, Facebook, Twitter, LinkedIn gibi sosyal ağlar gibi milyarlarca insanın aktif olarak veri oluşturduğu sosyal medya gibi zengin veri kaynaklarından ilham oluşturma

çalışmaları yürütmüştür. Han vd., ürün tasarım süreçlerinde tasarımcıların yaratıcılığını artırmak için sosyal medya verilerinin edinimi, işlenmesi ve kullanımı için hesaplamalı bir yaklaşım geliştirmiştir [104]. Twitter gönderilerinden anahtar kelimeler, ticari bir metin madenciliği aracıyla toplanmış ve daha sonra, elde edilen kavramlara anahtar kelime ile olan ilişkilerine göre sayısal değerler atanmıştır. Bu, doğal dil işleme süreci veri analizi ile devam ederek tasarımcılara ilham vermek için kullanılmıştır. Başka bir çalışmada, Han ve Moghaddam, sosyal ağ sitelerinden müşteri ihtiyaçlarını belirlemek için derin bir dil işleme modeli oluşturmuştur [39]. Bu çalışma, Google AI Language tarafından eğitilen BERT-NER modeline dayanmaktadır. BERT-NER, büyük metin verileri üzerinde önceden eğitilmiş bir doğal dil işleme modelidir ve alandan bağımsız sonuçlar üretir, böylece müşteri ihtiyaçlarını çok az manuel veri etiketleme ile belirlenebilir.

Son yıllarda yapılan ilham uygulamalarında derin öğrenme yöntemlerinin kullanımı yaygınlaşmaktadır. Bell ve Bala, gerçek ürün fotoğraflarını kullanarak bir Siamese CNN modeli eğitmiştir [105]. Böylece, fotoğraftaki nesne (koltuk, dolap, lamba gölgesi vb.) ile benzer yüksek çözünürlüklü görüntüler bulunarak hedef ürün için bir çağrışım oluşturulur. Yu vd., biyolojik nesnelerden ilham alan otonom bir tasarım yaklaşımı geliştirmiştir [106]. Burada, CycleGAN mimarisi geliştirilerek DesignGAN modeli oluşturulmuştur. Bu model, biyolojik nesnelerin (şapka, lamba, vazo vb.) ve hedef nesnelerin (ahtapot, çiçek, ananas vb.) çizimlerini içeren Quick Draw veri kümesiyle eğitilmiştir. Böylece, ağ biyolojik nesnelerin özelliklerini içeren benzersiz çizimler elde edebilir. Chen vd., tasarımcılar için iki farklı model ile ilham oluşturma çalışması gerçekleştirmiştir [107]. İlk model, veri madenciliği ve doğal dil işleme teknikleri kullanılarak oluşturulan (yukarıda da bahsedilen) bir kavram ağıdır. İkinci model ise görsel kavram kombinasyonuna dayalı ilham üretme modelidir. Burada, biyolojik nesne ve hedef nesne görüntüleriyle eğitilen GAN modeli, bu iki nesnenin kombinasyonundan oluşan yeni görüntüler üretir. Şekil 2.5'te bu çalışmadan bir örnek verilmiştir. GAN, kaşık ve yaprak görüntüleriyle eğitilerek doğadan ilham alan benzersiz bir tasarım konsepti ortaya çıkarır. Bu şekilde biyolojik ve hedef nesne özelliklerini içeren benzersiz konsept ürünler üretilebilir. Böylece, tasarımcının zihninde yeni ilhamlar/ilişkiler oluşturmak için etkili bir yol oluşturur. Ürün tasarımının yanı sıra, bu görsel kombinasyon modeli reklamcılık ve genel fikir oluşturma için de kullanılabilir.

Özetle, literatürdeki ilham verici araştırmalar genellikle büyük veri madenciliği, makine öğrenmesi, derin öğrenme ve doğal dil işleme algoritmalarını içermektedir. Kitle kaynak

tarama araçlarının yaygın kullanımı bu amaç için gerekli veri ve bilgiye erişimi kolaylaştırmaktadır. Burada bahsi geçen tüm ilham yöntemleri yeni ve yaratıcı fikirlerin ortaya çıkmasını sağlamakta, sözlü, yazılı ve görsel verilerin farklı kombinasyonları ile bu fikirlerin yeni ilişkilendirmeleri elde edilebilmektedir.



Şekil 2.5. Kaşık ve yaprak görüntüleri (a) ile eğitilmiş GAN modeli tarafından üretilen görüntüler (b) [107]


2.5.2. Fikir ve konsept oluşturma

Kavram oluşturma süreci, erken tasarım aşamasında sorunun belirlenmesiyle başlar [108]. Bu süreçte kullanıcı talebi, maliyet, estetik, ergonomi, işlevsellik, üretim yöntemi ve geri dönüşüm gibi birçok kriter dikkate alınmalıdır. Kavramsal tasarımın ana zorluğu, bu kriterleri dengeleyen yeni kavramlar üretmektir. Geleneksel olarak, benzersiz, yaratıcı ve kullanışlı kavramların oluşturulması zorlu bir süreçtir ve yaratıcı bir zihin yanı sıra bilgi ve deneyim gerektirir [99, 109]. Önceki bölümde ele alınan ilham yoluyla fikir oluşturma yanında, YZ doğrudan konsept oluşturmak için de kullanılabilir. Özellikle makine ve derin öğrenme yöntemleri tasarımcılara yaratıcı konsept oluşturmada yardımcı olur [110, 111]. Genetik algoritmalar bir optimizasyon tekniği olarak sınıflandırılırsa da bazen tasarım çözüm alanı keşfi ve konsept oluşturma için de kullanılmaktadır. Örneğin, Matei, GA'yı ürün konfigürasyon alanını keşfetmek ve ürün tasarımlarında çözüm seçenekleri oluşturmak için kullanmıştır [112, 113]. Lin vd. tarafından yapılan başka bir çalışmada, müşteri tercihlerine göre ideal tasarım konfigürasyonunu belirlemek için etkili bir araç olan yapay sinir ağı ile ürün konfigürasyon uygulaması yapılmıştır [114]. Tüm olası kavram çözümlerini elde etmek

için ürün formu öğelerinden oluşan bir morfolojik kart kullanılmıştır [108]. Burada ürün görünümü ile ürün formu öğeleri arasındaki sayısal ilişki Kansei Mühendisliği yaklaşımıyla elde edilmiştir [115]. Chen ve Chiang, müşteri beklentilerini dikkate alan bir yapay sinir ağı modeli geliştirmiştir ve sadece hızlı ve etkili ürün kavramları değil, aynı zamanda ideal ürün konfigürasyonlarını da oluşturmuşlardır [53]. Lin ve Chen, yapay sinir ağı kullanarak ideal parfüm şişesi formunu belirlemek için kullanıcı merkezli bir çalışma yapmışlardır ve ürün form kombinasyonları oluşturmak için ürün formu öğelerini kullanmışlardır [116]. Camburn vd., yapay sinir ağları ve kitle kaynak taraması kullanarak yeni tasarım kavramları belirleme üzerine çalışmıştır [117]. Konuşma dilinden oluşturulan veri kümelerinde tasarım fikirleri belirlenmiştir. Ayrıca bu tasarım fikirleri ayrıntı ve açıklık düzeylerine göre sınıflandırılmıştır. Bu yöntem, büyük veri kümelerini (anket, yarışma, patent vb.) hızlı bir şekilde tarayarak fikirleri belirlemede yardımcı olabilir. Yapay sinir ağı ile ürün formu özellikleri ve estetik değer katan renk uyumu da belirlenebilir. Bu, bazı ürün formu özelliklerinin insan zihninde estetik algı yarattığı için ürün tasarımının önemli bir yönüdür. Soni vd. tarafından yapılan örnek bir çalışmada hem yapay sinir ağı hem de GA kullanarak estetik ürünler için temel tasarım formülasyonu geliştirilmiştir [118]. Burada anket verileri kullanılarak belirlenen ürün form özellikleri, GA tarafından alternatif estetik tasarım kavramları oluşturmak için kullanılmıştır. Şekil 2.6 bu şekilde oluşturulan mikser, kahve makinesi ve çamaşır makinesi için kavramsal tasarımlar göstermektedir [118]. Şekilde, ürün estetiği ile ilgili üç farklı tasarım seçeneği oluşturulmuştur. Ancak, ürünlerin estetik kalitesi sadece kaba geometrik özelliklerle değil, aynı zamanda malzeme, doku, renk ve marka kimliğiyle de belirlenir. Bu nedenle, oluşturulan tasarım seçenekleri gerçek hayat uygulamaları için düzenlenmeli veya yeniden tasarlanmalıdır.

Veri madenciliği ve makine öğrenme teknikleri fikir üretimi için de başarılı bir şekilde kullanılmaktadır. Bu yöntemler özellikle metin ve görüntülerden gizli ve açık fikirler elde etmek için etkili olabilir. Patent veri tabanları, akademik dergiler, web sayfaları, anket ve konuşma verileri gibi büyük veri kümeleri taranabilir ve bu kaynaklardan fikirler çıkarılıp sınıflandırılabilir [39, 103]. Örneğin, Zhou vd., makine öğrenmesi yöntemi kullanarak online anketler, ürün incelemeleri ve şikayetler gibi büyük bir veri kaynağına dayalı müşteri ihtiyaç analizi yapmıştır [40]. Bu çalışma, denetimli (örn. fastText) ve denetimsiz (örn. VADER) makine öğrenimi algoritmalarının bir kombinasyonunu kullandığı için önemlidir. FastText algoritması alakasız verileri elemek için kullanılmış ve VADER ise müşteri ihtiyaçlarını belirlemek ve sınıflandırmak için kullanılmıştır. Bae ve Kim, müşteri ihtiyaçlarını

belirleyerek ürün tasarımında yeni fikirler oluşturdıkları bir karar ağacı yöntemi kullanmıştır [119]. Bu yaklaşımı kullanarak, yazarlar üretim maliyetlerini azaltmayı, ürün kalitesini artırmayı, yeni ürün geliştirme süreçlerini kısaltmayı ve rekabet gücünü artırmayı hedeflemişlerdir.




Şekil 2.6. Yapay sinir ağı ve genetik algoritma iş birliği ile üretilen konsept tasarımlar: Mikser (M), kahve makinesi (C) ve çamaşır makinesi (W) [118]

Derin öğrenme algoritmaları, fotoğraf ve video gibi görsel verileri tanımak, yorumlamak ve analiz etmek için bilgisayarla görme becerisiyle yeni ürün seçenekleri üretmek için de kullanılabilir. GAN ve Varyasyonel Otomatik Kodlayıcılar (VAE) gibi derin öğrenme üretici modelleri ile yeni tasarım konseptleri üretme yeteneği göstermektedir [3, 120]. Raina vd., fikir ve konsept üretme sürecinde insan tasarım stratejilerini derin öğrenme yöntemiyle taklit etmiştir [121]. İnsan tasarımcıların stratejik ve soyut düşünme, yaratıcılık gibi konuları içeren kara kutu fikir üretme süreçleri, kuralların ve stratejilerin belirsiz olduğu tasarım problemlerinde uygulanmıştır. Bu amaca ulaşmak için görüntü işleme tabanlı bir yaklaşım önerilmiştir. Bu çalışmada, tasarımcılar tarafından uygulanan tasarım aşamalarının birkaç ardışık görüntüsünden tasarım bilgisi elde etmek için bir otomatik kodlayıcı kullanılmıştır. Daha sonra bazı benzersiz tasarım önerileri üretmek için denetimsiz bir sinir ağından yararlanılmıştır.

Yu vd. tarafından yapılan bir başka çalışmada, GAN modeli ile biyolojik nesnelerden esinlenen bir üretken tasarım modeli geliştirmek için kullanılmıştır [106]. Hedef ve biyolojik nesnelerin görüntüleri birleştirilerek biyolojik olarak esinlenilmiş çeşitli görüntüler


oluşturulmuştur (Şekil 2.7). Resimde iki farklı vaka çalışması gösterilmektedir: Armuttan ilham alan bir şişe ve balıktan ilham alan bir çaydanlık tasarımı. Burada bir tasarımcı, oluşturulan konseptlerden manuel olarak 3B modeller de oluşturmuştur. Oh vd. ise yüksek mühendislik performansına sahip estetik ürün tasarımları elde etmek için topoloji optimizasyonunu GAN algoritmasına entegre etmiştir [3]. Topoloji optimizasyonu sürecinden elde edilen büyük miktarda görüntü verisi, GAN modellerini eğitmek ve başarılı konsept ürünler oluşturmak için kullanılmıştır. Buradaki topoloji optimizasyonu, eğitim setinin çeşitliliğini ve kalitesini artırmak için mevcut verilerin çoğaltılmasını sağlamıştır. Şekil 2.8, bu çalışmada iddia edildiği gibi sadece estetik açıdan değil mühendislik performansı açısından da çekici bazı örnek konsept modelleri göstermektedir. Ancak, mühendislik açısından tasarımın uygulanabilirliği 3B konsept ürünler üzerinde test edilmemiştir.



Şekil 2.7. (a) Şişe ve armuttan esinlenen tasarım konseptleri (b) Çaydanlık ve balıktan esinlenen tasarım konseptleri (c) Üretilen konseptlerin 3B modelleri [106]

Bir başka GAN tabanlı çalışmada ise veri kümesindeki bazı öznitelikler değiştirilmeden konseptler oluşturulmaya ve sadece istenilen öznitelikler düzenlenmeye çalışılmıştır [122]. Ancak bu model yüz fotoğraflarını düzenleme ve üretme konusunda başarılı sonuçlar elde etmesine rağmen diğer veri kümelerinde aynı başarıyı gösterememiştir. Bu sorunu gidermek için Yuan ve Moghaddam, AttGAN modelinde özel bir kayıp fonksiyonu ve bir ayırt edici kayıp kullanarak tekstil ürünleri için Tasarım Özellikli GAN (DAGAN) modelini daha da geliştirmiştir [110]. Buradaki amaç yine moda ürünlerini (örn. yelek, t-short) içeren görsel veri setinde, sadece belirlenen özellikleri düzenleyerek istenilen özellikleri değişmemiş


özgün konsept moda ürünleri üretmektedir. Belirli bir tasarım problemi için modifiye edilmiş GAN' başarılı olmasına rağmen, yukarıda bahsedilen problem için hala kesin bir çözüm olmadığı ve dolayısıyla her farklı uygulamanın bu tür modifikasyonlar gerektirdiği belirtilmelidir. Chen ve Ahmed, tarafından yapılan bir başka çalışmada, GAN modelinin performansını artırmak için yeni bir olasılıksal nokta süreci tabanlı kayıp fonksiyonu kullanan Çeşitlilik Performansı Artırılmış GAN (PaDGAN) modeli önerilmiştir [123]. Bu modelin tasarım örneklerinde (ör. kanat tasarımı) kaliteli çözümler için tasarım alanını genişlettiği ve üretilen tasarımların yenilikçiliğini ve çeşitliliğini artırdığı belirtilmektedir. Bu bağlamda ilgi çeken bir diğer çalışma, kullanıcı tarafından istenen özelliklere sahip ürün konseptleri elde etmek için nöro-bilimsel bir yöntem önermiştir [124]. Fiziksel ürünlere veya görüntülere maruz kalan insan beyninin elektriksel aktivitesini tespit etmek için Elektroensefalografi (EEG) sinyalleri kullanılmıştır. Beynin nöronları içindeki iyonik akımdan kaynaklanan kaydedilmiş voltaj dalgalanmaları kullanılarak üretilen bir veri kümesi kullanılmış. Sonraki aşamada bu veriler tasarım özelliklerinin arzu edilebilirliğiyle eşleştirmek için bir RNN algoritmasını eğitmek için kullanılmıştır. Daha sonra bu tasarım özellikleriyle koşullandırılmış bir GAN modeli, yalnızca EEG sinyallerinden ürün konsepti görüntüleri üretilmesini sağlamak üzere eğitilmiştir. Bu yöntem, YZ yöntemlerinin sözel olarak açıklanamayan tasarım gereksinimlerini öğrenmesine olanak sağlaması açısından da önemlidir.



Şekil 2.8. BeGAN modeli ile üretilen 2 boyutlu jant konseptleri [3]

Gu vd. (2022), Şekil 2.9'da gösterildiği gibi benzersiz 3B yay konsept modelleri üretmek için hem CNN hem de Derin Evrişimli GAN (DCGAN) mimarilerini kullanmıştır [125]. Yazarlar, yeni 2B yay modelleri üretmek üzere DCGAN modelini ve 2B yay görüntülerinden 3B modellerin geometrik ve yapısal özelliklerini eşleştirmek üzere CNN

modelini eğitmek için 130 3B yay modelinin perspektif görünümünü kullanmışlardır. Daha sonra tahmin edilen geometrik ve yapısal özelliklere göre şekilde gösterilen benzersiz bir 3B yay modeli oluşturulmuştur. Bu yay modelin nispeten küçük verilerle üretilmesi etkileyicidir ve üretilen modeller eğitim setine dahil edilerek sonuçlar daha da iyileştirilebilir.



Şekil 2.9. (a) DCGAN modeli ile üretilen 2B yay görüntüleri (b) CNN modeli tarafından tahmin edilen geometrik parametrelerle oluşturulan bir 3B yay modeli [125]

2.5.3. Fikir ve konsept değerlendirme

Erken tasarım aşamalarında üretilen çok sayıda tasarım fikri ve konsept, ideal tasarımı bulmak için değerlendirilmelidir [108]. Tasarım konseptlerinin yaratıcılık, yenilikçilik, uygulanabilirlik, çeşitlilik, estetik ve işlevsellik gibi özellikleri çeşitli yöntemlerle değerlendirilebilir [126]. Bu özelliklere dayalı değerlendirme genellikle kullanıcılara ve alan uzmanlarına ihtiyaç duyar. Ancak kullanıcı talepleri genellikle açıklığa kavuşturulması gereken belirsizlikler içerir. Ayrıca, bu geleneksel değerlendirme süreci çok sayıda tasarım seçeneği için son derece zor ve zaman alıcı hale gelmektedir [127]. YZ yöntemleri ile objektif ve hızlı bir değerlendirme yapılabilir ve böylece önemli ölçüde zaman ve maliyet tasarrufu sağlanabilir [128].


YZ yöntemleri kullanılarak nicel ve nitel değişkenlere bağlı olarak tasarım seçeneklerinin kalite ve başarı kriterlerini değerlendirmek için çeşitli çalışmaları yapılmıştır. Her iki değişken de bulanık küme teorisi ile değerlendirilebilir. Bu yaklaşımın Sharif Ullah tarafından yapılan tasarım bir uygulamasında, sandalye kavramsal tasarımları bulanık mantık yaklaşımı kullanılarak değerlendirilmiştir [129]. Estetik ve işlevsellik kriterlerine göre en iyi tasarım seçeneği belirlenmiştir. Diğer birçok araştırmacı da bulanık mantığı veya

bu algoritmanın diğer yöntemlerle bir kombinasyonunu kullanmıştır. Örneğin, Ayağ erken tasarım aşamasında zayıf tasarım seçeneklerini elemek için Analitik Hiyerarşi Süreci (AHP) ve bulanık mantık yöntemini birleştirmiştir [130]. Sarfaraz vd. mühendislik tasarımında malzeme seçimi için matematiksel bir hesaplamanın yanı sıra bulanık mantık kullanımını önermiştir [131]. Ko ise kavramsal tasarımda estetik parametreleri dikkate alan bir bulanık eleme ve değerlendirme yöntemi geliştirmiştir [132]. Bir başka çalışmada Yüksel ve Börklü, erken tasarım aşamasında hızlı ve kesin konsept değerlendirmesi için bulanık mantık yöntemini Pahl ve Beitz'in kavramsal tasarımı ile birleştirmiştir [133]. Yöntemin geçerliliği bir tekerlekli sandalye kavramsal tasarımı için gösterilmiştir. Bir başka kural tabanlı YZ yönteminde Wang, ürün form elemanları ve ürün görüntüleri arasındaki ilişkiyi belirlemek için hibrit bir Kansei mühendislik tasarım uzman sistemi geliştirmiştir. Bu yöntem, müşteri beklenti seviyelerini belirlemek ve değerlendirmek için Gray sistem teorisi ile birlikte de kullanılabilir [134].

Fikirleri ve kavramları değerlendirmek için makine öğrenimi algoritmaları da kullanılmaktadır. Toh vd., fikirlerin yaratıcılık düzeyini belirlemek için bu yöntemi veri madenciliği ile birlikte kullanmayı önermiştir [135]. Burada, Rastgele Orman (Random Forrest) makine öğrenimi modelleri, yaratıcı fikirleri %90 doğrulukla tespit etmek için az sayıda etiketli veri ile eğitilmiştir. Li vd. da ürün görselleri ile müşterilerin duygusal tepkileri arasındaki ilişkiyi belirlemek için makine öğrenmesi kullanmıştır [136]. Ürün bilgisi verileri, bir veri madenciliği uygulaması (Web Spider) ile çevrimiçi alışveriş sitelerinden otomatik olarak elde edilmiştir. Veriler daha sonra etiketli veri kümeleri elde etmek için çevrimiçi bir değerlendirme anketinde kullanılmıştır. Tasarım seçenekleri dört farklı makine öğrenmesi yöntemiyle (Destek vektör regresyonu, Ridge regresyonu, Sınıflandırma ve regresyon ağacı ve Yapay sinir ağı) değerlendirilmiş ve karşılaştırılmıştır. Şekil 2.10, tasarım parametreleri ile müşteri beklentileri arasındaki ilişkiyi anlamak için bu yöntemlerden en yaygını olan yapay sinir ağının kullanımını göstermektedir. Girdi katmanı ürünün temel özellikleridir. Çıktı katmanı ise ürünün müşteri tarafından nasıl algılandığını ifade eder.

Naive bayes ve Yapay sinir ağı gibi diğer makine öğrenimi algoritmaları da geniş çözüm uzayında tasarım konseptlerini değerlendirmek için kullanılmaktadır. Örneğin, Hao vd. yapay sinir ağı ile tasarım konseptlerinin inovasyon değerlerini belirlemiştir [137]. Bu tasarım konseptlerinin uygulanabilirliği daha sonra Naive Bayes algoritması kullanılarak değerlendirilmiştir. Yazarlar bu çalışmada geniş çözüm uzayını daraltarak umut vadeden

çözümleri öne çıkarmayı amaçlamıştır. Bu çalışma, tasarım konseptinin yenilik derecesinin ve uygulanabilirliğinin makine öğrenmesi algoritmalarıyla yüksek bir başarı oranıyla tahmin edilebileceğini göstermiştir. Ancak bilgi tabanının (popüler e-ticaret sitelerinden elde edilen ürünlerin incelenmesiyle oluşturulan) manuel olarak oluşturulması süreci uzatmaktadır. Camburn vd., kitle kaynak taramasından metin sınıflandırması üzerine çalışmıştır [138]. Elde edilen fikirlerden oluşan büyük veri tabanları denetimsiz bir sinir ağı ile taranmış ve başarı seviyeleri değerlendirilmiştir. Wang ve Liu, konsept ürün tasarımı değerlendirme süreci için Ürün Yaşam Döngüsü'nde (İng. Product Life Cycle, PLC) üretilen büyük hacimli verilerin (tasarım, üretim, kullanım vb.) kullanımı için çok aşamalı bir yapay sinir ağını eğitmiştir [139]. Parçacık Sürü Optimizasyonu (PSO) ve Adam algoritmaları da eğitim sürecine dahil edilmiştir. PSO, ağ eğitimi için gerekli başlangıç parametrelerini belirlemek için kullanılırken, Adam algoritması değişen ağ parametrelerine uyum sağlama yeteneğini artırmıştır. Yazarlar bu entegrasyon ile tasarım değerlendirme süreçlerinin hızını ve doğruluğunu artırdıklarını iddia etmektedir.




Şekil 2.10. Akıllı saat tasarımı için oluşturulmuştur Ağ modeli [136]

Derin öğrenme algoritmaları, istenen yaratıcılık seviyesindeki fikirleri ortaya çıkarmak ve değerlendirmek için de kullanılabilir. Han vd. (2020), yenilikçi fikirler üretmek ve fikirlerin kavramsal mesafelerini değerlendirmek için veri odaklı bir yaklaşım önermiştir [140]. Kavramlar arasındaki mesafeyi ölçülerek yaratıcılık seviyesi belirlenmiştir. İki kavram arasındaki mesafe arttıkça yaratıcılık seviyesi artmakta, uygulanabilirlik seviyesi ise

azalmaktadır. Mesafe ölçümü için ConceptNet ve TechNet olmak üzere iki farklı araç kullanılmıştır. Benzer bir çalışma da Chen vd. tarafından ideal kavram mesafelerini hesaplamak ve yaratıcı fikirler üretmek için semantik bir ağ algoritması kullanılarak gerçekleştirilmiştir [107].

Üretken tasarım yöntemleri de tasarım değerlendirme süreçlerinde yaygın olarak kullanılmakta ve başarılı sonuçlar elde edilmektedir [106, 141]. Shu vd. tarafından yapılan bir çalışmada, tasarım konseptlerini değerlendirmek için işlevsel bir üretken tasarım modeli geliştirilmiştir [142]. Burada, üretken bir modelleme algoritması olan GAN'lar tarafından üretilen 3B uçak modelleri, Hesaplamalı Akışkanlar Dinamiği (CFD) analizi ile değerlendirilmiştir. En düşük sürtünme kuvvetine sahip yüksek performanslı uçak modelleri, Şekil 2.11'de görüldüğü gibi GAN modelinin yeniden eğitilmesi için eğitim veri setine dahil edilmiştir. CFD analizi ile doğrulanan yüksek performanslı 3B modeller daha sonra GAN model başarısını artırmak için kullanılmıştır. Eğitim sayısı arttıkça, yüksek performanslı uçak modelleri üretme olasılığı da artmaktadır. Dolayısıyla bu kavram üretme ve değerlendirme döngüsü tekrarlanarak en düşük sürtünme kuvveti performansına sahip ideal konseptler elde edilebilir. Bu süreç, sadece estetik açıdan çekici tasarımlara odaklanan önceki çalışmalardan farklı olarak işlevsel konseptler üretilmesine olanak sağlamaktadır. Ayrıca, sunulan yaklaşım topoloji optimizasyon yöntemine kıyasla hassasiyetten bir miktar ödün vererek daha hızlı yakınsama sağlamaktadır. Veri odaklı bir YZ yaklaşımı kullanan bir başka konsept değerlendirme çalışmasında Wu vd., tasarım yarışmaları için oluşturulan ürün posterlerinden tasarım konseptlerini değerlendirmek için CNN modellerinin kullanılmasını önermiştir [127]. Model, ürün posterlerini ödül alan, ön elemenden geçen ve elenen tasarımlar olarak kategorize eden yedi farklı CNN mimarisi ile eğitilmiştir. Bu çalışmada kullanılan CNN mimarilerinden biri (SEFL-ResNet) %70,79 sınıflandırma başarısı elde etmiştir. Ancak bu yaklaşımın sadece estetik kaliteyi dikkate alması ve uygulanabilirlik, üretilebilirlik ve maliyet gibi diğer önemli faktörleri göz ardı etmesi, tasarım kalitesinin değerlendirilmesi açısından yetersiz kalmasına neden olmaktadır. Yine de otomatik ön değerlendirme süreçlerinde faydalı olabilir. Bir başka çalışmada Yoo ve Kang, kavramsal tasarım aşamasında karmaşık yapıların CNC işleme sürecinde işlenebilirliğini ve ilgili maliyetleri tahmin etmek için derin öğrenmeye (yani CNN) dayalı açıklanabilir bir YZ yöntemi kullanmıştır [143]. İşlenebilirliği ve tahmini üretim maliyetlerini göstermek için 3B Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama (Grad-CAM) ile model görselleştirme yöntemi kullanılmıştır. Bölgesel işleme zorlukları model üzerinde belirtilerek tasarım

değişikliğinin gerekli olduğu yerler gösterilmiştir. Buradaki yöntem genel olarak tahmin sonuçlarını açıklamak için veri toplama, işleme ve görselleştirme adımlarına dayanmaktadır.



Şekil 2.11. Shu vd.'nin işlevsel üretken tasarım modeli [142]; (a) Tasarım veri kümesi (b) GAN modeli ile üretilen yeni kavramlar (c) Üretilen kavramların CFD analizi (d) Yüksek performanslı kavramlar, eğitim veri kümesine dahil edilen CFD ile doğrulanır ve süreç tekrarlanır

2.5.4. Tasarım optimizasyonu


Tasarım optimizasyonu, ideal ürün konfigürasyonunu belirlemek, ürün özelliklerini iyileştirmek, işlevselliği artırmak, maliyetleri düşürmek, daha hafif parçalar üretmek vb. amaçlarla kullanılır. Burada genellikle çeşitli kısıtlayıcılar altında en iyi tasarımın seçeneğinin belirlenmesi amaçlanır. Geleneksel optimizasyon sürecinde, optimum tasarım değişkenlerini belirlemek için ileri mühendislik bilgisi ile problemin matematiksel formülasyonu oluşturulur. Son zamanlarda, evrimsel algoritmalar, kolektif zekâ, yapay sinir ağları ve makine öğrenimi gibi yapay zekâ yöntemleri, tasarım optimizasyon problemlerini minimum mühendislik bilgisi ile çözmek için tasarımcılar tarafından giderek daha fazla kullanılmaktadır.

Kollektif zekâ algoritmaları, böcek kolonilerinden insan topluluklarına kadar sosyal canlıların kolektif davranışlarından esinlenmiştir. İş birliği, etkileşim ve rekabet yoluyla optimum çözümler bulabilirler. Optimizasyon alanında Parçacık Sürü Optimizasyonu (PSO), Karınca Kolonisi Optimizasyonu (ACO), Diferansiyel Evrim (DE) gibi çok sayıda algoritma ve bunların varyasyonları geliştirilmiştir [144, 145]. Parçacık Sürüsü ve Karınca

Kolonisi Optimizasyonları (PSO ve ACO), düşük bellek gereksinimleri ve uygulama kolaylıkları nedeniyle optimizasyon problemleri için en çok tercih edilen sezgisel yaklaşımlardan bazıları haline gelmiştir. PSO, kuş veya balık sürüsünün sosyal davranışından esinlenirken, ACO gerçek hayattaki karıncaların yiyecek arama davranışını taklit eder [146]. PSO, mühendislik problemleri için optimuma yakın çözümler sunarak yüksek performans sağlar [147]. Zhengtong vd., çok malzemeli yerleşim ve tasarım konfigürasyonlarına sahip 15, 39 ve 47 düzlemli kafes problemleri için PSO algoritmaları sunmuştur [148]. PSO'nun kafes ve çerçeve yapıların daha karmaşık optimizasyon problemlerine uygulanabileceğini belirtmişlerdir. Jafari vd., kafes yapıların optimum tasarımı için verimliliği artırılmış hibrit bir algoritma oluşturmak üzere Kültürel Algoritmayı (CA) PSO'ya entegre etmiştir [149]. PSO'nun verimliliği, takviyeli öğrenme algoritmalarının entegre edilmesiyle de artırılmıştır [150]. Samma vd., bu hibrit algoritmayı dişli tasarımı ve basınçlı kap tasarımı problemleri gibi çeşitli kıyaslama problemleri kullanarak değerlendirmiştir [151]. Deneysel sonuçlar, Takviyeli Öğrenme tabanlı Parçacık Sürü Optimizasyonunun yararlı olduğunu ve bir dizi son teknoloji PSO tabanlı algoritmadan daha iyi performans gösterdiğini göstermektedir. Tasarım optimizasyon problemleri, Parçacık Sürüsü Karınca Kolonisi Optimizasyonu (PSACO) olarak adlandırılan PSO ve ACO algoritmalarının bir kombinasyonu ile ele alınabilen konveks olmayan bir davranışa sahip olabilir.

Diferansiyel Evrim (DE), belirli bir kalite ölçüsüne göre aday bir çözümü iteratif olarak iyileştirmeye çalışarak bir problemi optimize eder. DE, klasik optimizasyon yöntemlerinin gerektirdiği gibi optimize edilen problemin gradyanını kullanmadan çok boyutlu gerçek değerli fonksiyonlar için kullanılabilir. Ayrıca süresiz, gürültülü, zamanla değişen vb. optimizasyon problemlerinde de kullanılabilir [152]. DE, bir popülasyonu koruyarak ve mevcut olanları basit formüllerine göre birleştirerek yeni aday çözümler oluşturarak ve daha sonra optimizasyon problemi üzerinde en iyi uygunluk değerine sahip adayı tutarak bir problemi optimize eder. Bu şekilde optimizasyon problemi gradyana ihtiyaç duymayan bir kara kutu olarak ele alınmaktadır. Nadimi-Shahraki bir Diferansiyel Evrim (DE) algoritması önermiş ve bunu tek modlu, çok modlu, hibrit ve bileşim fonksiyonlarını ve dört karmaşık mühendislik tasarım problemini içeren bir kıyaslama paketi üzerinde değerlendirmiştir [153]. Bu sezgisel optimizasyonlara ek olarak, gelişmiş uçuş performansı ve genişletilmiş uçuş zarfları sağlayan kanat tasarım parametrelerini belirleyebilir. Leylek vd., yarası kanatlarının tasarımını, optimizasyon yöntemi olarak küresel optimumu bulmada sağlam ve

güvenilir olduğu kanıtlanmış Simulated Annealing (SA) kullanarak ele almış ve optimize etmiştir (Şekil 2.12) [154].




Şekil 2.12. Tavlama benzetimi kullanılarak kanat morfolojisi optimizasyonu için farklı yarasa kanat topolojileri [154]

Genetik algoritmalar ve karma modeller de özellikle büyük çözüm uzaylarında ideal tasarım varyantlarının oluşturulması ve seçilmesinde yaygın olarak kullanılmaktadır [112, 155]. Jiao vd., Üretken Genetik Algoritma ile en uygun ürün ailesi konfigürasyonunu belirlemeye çalışmıştır [156]. Buradaki amaç, aynı tasarım maliyeti ile ürün çeşitliliğini artırmaktır. Ürün ailesindeki parçalar ve alt sistem arayüz bağlantıları gibi ortak ürün bileşenleri, tasarım maliyetini ve üretim süreci teslim süresini azaltmak için optimize edilmiştir. Bu çalışmada çeşitli ürün ailesi tasarımlarına uyarlamak için genel bir kodlama şeması oluşturulmuştur. Bu çalışma, müşteri beklentilerini karşılamak için parça ve bileşen entegrasyonu için uygulanabilir çözümler ortaya koymuştur. Bir başka çalışmada Brintrup vd. nicel ve nitel kriterleri birlikte ele alan Çok Amaçlı İnteraktif Genetik Algoritma çerçevesini sunmuştur [157]. Yöntemin geçerliliği ve uygulanabilirliği fabrika yerleşim probleminde test edilmiştir. Burada, etkileşimli genetik algoritmanın kullanıcı yorgunluğu ve aşırı popülasyon gürültüsü gibi genel başarısını tehlikeye atabilecek bazı dezavantajlara sahip olduğu belirtilmelidir. Dou vd. bu tür dezavantajların üstesinden gelmek için Çok Aşamalı Etkileşimli Genetik Algoritma (MS-IGA) geliştirmiştir. Burada tasarım problemi, adım adım değerlendirilen anlamlı parçalara bölünmüştür [158]. Bu şekilde sistem aslında gerçek bir evrim modeline yaklaşmaktadır. Buradaki amaç, tasarım problemini basitten karmaşığa doğru bölümlere ayırarak müşteri-ürün etkileşimini artırmaktır. Önerilen çerçeve ve diğer etkileşimli genetik algoritmalar (Geleneksel IGA ve MAN-IGA), başarı ve verimliliği karşılaştırmak için bir araba gösterge paneli tasarımına uygulanmıştır. Araştırmacılar, algoritmanın diğer yöntemlere göre daha hızlı bir şekilde doğru sonuçlara ulaşabildiğini belirtmişlerdir. Yıldız, Diferansiyel Evrim algoritması ve Taguchi yöntemine dayalı karma bir optimizasyon tekniği önermiştir [159]. Burada Taguchi yöntemi, global optimumun bulunmasında yakınsama

oranını artırmayı sağlayan güçlü bir başlangıç popülasyonu oluşturmak için kullanılmaktadır. Önerilen yöntem genetik, yapay arı kolonisi ve diferansiyel evrim algoritmaları gibi yöntemlerle karşılaştırılmıştır. Bir araç bileşeni üzerinde yapılan testlerde, bu hibrit tekniğin diğer optimizasyon yöntemlerinden daha iyi performans gösterdiği belirtilmiştir.

Zha, çeşitli kısıtlar altında ideal ürün konfigürasyonlarını belirlemek için Hibrit İkili Çapraz Eşleme Sinir Ağı (HDC MNN) modelini önermiştir [160]. Model, Geri Yayılım Sinir Ağı (BPNN) ve Hopfield Sinir Ağı (HNN) kombinasyonu ile oluşturulmuştur. Burada, BPNN net ağırlık değerlerini tanımlar ve sınıflandırırken, HNN bu ağırlık değerlerini tasarımı optimize etmek için kullanır. Lin vd. ürün imajı ve form özellikleri arasındaki ilişkiyi anlamak için yapay sinir ağlarını kullanmıştır [114]. Buradaki amaç, ideal ürün formunu ve optimum ürün konfigürasyonunu belirlemektir. Bu model ile basit ürün form tasarımları oluşturulabilir. Chen ve Chiang, tüketici memnuniyet verilerinden optimum tasarım konfigürasyonunu belirlemek için geri yayılım sinir ağını kullanmıştır [53]. Yapay zekâ modeli, anketlerden ve satın alma verilerinden elde edilen bilgilerle eğitilmiştir. Model daha sonra en yüksek müşteri memnuniyetine sahip optimum ürün konfigürasyonunu üretmek için kullanılmıştır. Bu çalışmaya benzer şekilde, Kutschenreiter-Praszkiewicz, müşteri beklentilerine uygun ürün özelliklerini belirlemek ve ürün kalitesini iyileştirmek ve değer yaratmak için YSA ve Kalite Fonksiyon Dağılımı (QFD) yöntemini kullanmıştır [56]. Nguyen tarafından yapılan bir diğer ilginç çalışma ise insansız hava aracı kanadının optimizasyonu için Tekrarlı Geliştirilmiş Sinir Ağı (RENN) yöntemini kullanmıştır [161]. RENN, geleneksel sinir ağlarının geliştirilmesiyle oluşturulan aşırı uyumdan kaçınan sinir ağıdır. Bu yöntemde aşırı uyumdan kaçınmak için geri yayılım algoritması ve Bayesian öğrenme algoritması birlikte uygulanmaktadır. Model, maksimum kaldırma katsayısı, hücum açısı, sürüklenme katsayısı ve kalınlık oranlarını optimize etmek için geometrik kısıtlamalarla eğitilmiştir. Şekil 2.13, RENN ve simülasyon analizine göre optimum kanat şekillerini göstermektedir. Bu şekiller arasında çok az geometrik fark olmasına rağmen, RENN simülasyon analizine (yani CFD) kıyasla hesaplama süresinde %81,2'lik bir azalma sağlamıştır. Daha yeni bir çalışmada, Zhang vd., küresel optimumu bulmada yüksek performansa sahip Sinir Ağı Algoritması (NNA) ile yüksek yakınsama oranına sahip Öğretme-Öğrenme Tabanlı Optimizasyon (TLBO) yöntemlerini birleştirerek yeni bir optimizasyon çerçevesi önermiştir [162]. Bu kombinasyon modeli, küresel optimumun hızlı bir şekilde bulunmasını sağlamıştır.




Şekil 2.13. CFD analizi ve RENN yöntemi ile aerofoil şekil optimizasyonu sonuçları [161]

YSA dışında makine öğrenmesi algoritmaları da çeşitli tasarım optimizasyonu çalışmaları için kullanılmıştır. Örneğin, Sharpe vd. bu amaçla dört farklı makine öğrenmesi algoritmasını karşılaştırmıştır [163]. Rastgele Orman, Gaussian Naive Bayes, Sınır ve Destek Vektör Makine algoritmalarının keşif ve optimizasyon problemlerindeki avantaj ve dezavantajları araştırılmıştır. Bu algoritmalar altı farklı tasarım probleminde karşılaştırılmış ve sonuç olarak diğerlerine göre belirgin bir üstün teknik tespit edilememiştir. Uygun makine öğrenmesi algoritmaları, problem özelliklerine bağlı olarak farklılık gösterebilir. Kullanılan yöntem ne olursa olsun, optimizasyon problemi çözümlerinde makine öğrenme algoritmalarının kullanılması tasarımcılara sezgisel bir bakış açısı kazandırarak genel tasarım sürecini daha verimli hale getirmektedir.

Son zamanlarda, derin öğrenme yöntemleri özellikle topoloji ve şekil optimizasyonu problemleri için giderek daha fazla kullanılmaktadır [164-166]. Tasarımın uygulanabilirliği biçim, işlev ve davranış özelliklerine göre belirlenmekle birlikte, derin öğrenme algoritmalarına dayalı üretken tasarım modelleri genellikle biçim iyileştirmeyi hedeflemektedir. Modern üretken tasarım çalışmaları ise fizik tabanlı simülasyon analizleri ile form ve fonksiyonu birlikte geliştirmeyi hedeflemektedir. Bunun bir örneği, Oh vd.'nin yukarıda bahsedilen, topoloji optimizasyonu ve Sınır Dengeli GAN'ın (BeGAN'lar) entegrasyonu ile yüksek mühendislik performansına sahip estetik tasarımların ortaya konduğu çalışmasıdır [3]. Üretken modellerde aşırı uyum hatalarından kaçınmak için büyük miktarda veriye ihtiyaç duyulduğu unutulmamalıdır. Bu kritik ön gereksinimi karşılamak için, topoloji optimizasyonundan elde edilen veriler bu çalışmada eğitim verisi olarak kullanılmış ve yüksek performanslı modeller üretilmiştir. Şekil 2.14'te tekerlek

konseptlerinin BeGAN ile uyum, yenilik ve maliyet açısından üretildiği bir örnek verilmiştir. Başka bir çalışmada, Sasaki vd. genetik algoritma ve denetimli derin öğrenme (CNN) tabanlı AYZ kombinasyonu ile motor kesit görünüşlerini kullanarak yüksek tork performansına sahip bir Dahili Kalıcı Mıknatıslı (IPM) motora topoloji optimizasyonu uygulamıştır [167]. Bu Derin Sinir Ağının (DNN) sonuca ulaşmasında hangi parametrelerin daha etkili olduğunu anlamak için Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) kullanılmıştır. Yazarlar, AYZ ile hem yüksek performans hem de yorumlanabilir topoloji optimizasyonu elde edildiğini iddia etmektedir.



Şekil 2.14. BeGAN ile üretilen jant konseptlerinin uyumluluk, yenilikçilik ve maliyet açısından analizi [3]

Şimdiye kadar bahsedilen YZ optimizasyon algoritmaları birçok tasarım optimizasyonu vakası için başarılı olsa da büyük tasarım değişkenleri ve alternatifleri içeren karmaşık ve büyük sistemler için verimsizdir. Çünkü bu durum tasarım süreçlerinin uzamasına ve dolayısıyla maliyetlerin artmasına neden olmaktadır [168]. Büyük boyutların neden olduğu sorunlarla farklı açılardan başa çıkabilmek için tasarım alanını azaltma, kritik parametreleri belirleme, paralel hesaplama, bilgisayar gücünü artırma, tasarım problemlerini alt problemlere ayırıştırma, haritalama ve tasarım uzayını görselleştirme gibi farklı stratejiler/teknikler geliştirilmiştir [169, 170]. Bu stratejiler tek başına veya birlikte kullanılarak büyük boyutlu tasarım problemlerinin üstesinden gelinebilir. Örneğin; Du ve Zhu, karmaşık mekanik sistem optimizasyonları için tasarım alanı azaltma ve kritik

parametreleri belirleme stratejilerini aynı anda uygulamak için yeni bir veri odaklı metodoloji önermiştir [168]. Kritik tasarım parametreleri ve parametre değer aralıkları, bir Karar Ağacı (Decision Tree) istatistiksel öğrenme algoritması kullanılarak belirlenmiştir. Yöntemin uygulanabilirliği bir otomobil S-şekilli kirişi üzerinde test edilmiş ve geleneksel yöntemlerle karşılaştırılmıştır. Bir diğer kritik tasarım parametre belirleme çalışması ise çok boyutlu mühendislik optimizasyon problemlerinden biri olan kanat tasarımında kullanılmıştır. Echeverria vd., lojistik regresyon ve karar ağaçları gibi istatistiksel öğrenme yöntemleri ile optimizasyon öncesinde istenmeyen dinamik yük dağılımlarına yol açan tasarım parametrelerini belirlemiştir [171]. Bu stratejilerin dışında, büyük boyutlu, hesaplama açısından pahalı, kara kutu problemlerini çözmek için iki farklı optimizasyon stratejisi vardır: Model yaklaşımı tabanlı teknikler ve kaba-ince model tabanlı teknikler. Model yaklaşımı tabanlı optimizasyon teknikleri, pahalı modeli optimize etmek için hesaplama açısından ucuz olan modeli optimize ederek elde edilen bilgileri kullanmaktadır. Kaba-ince model tabanlı tekniklerde ise kaba model optimizasyonu kısa sürede ve düşük maliyetle tamamlarken, ince modelin görevi optimizasyonun doğruluğunu test etmektir [172, 173].


2.5.5. Tasarım destek sistemleri

Tasarımda YZ yöntemlerinin kullanımı, tasarım sürecine tam veya kısmi destek sağlamak ve tasarımcılara çeşitli karar verme aşamalarında yardımcı olmak için doğrudan veya dolaylı olarak uygulanabilir [174]. YZ tarafından üretilen fikirler ve kavramlar her zaman iyi bir tasarımla sonuçlanmayabilir. Ancak insan müdahalesi ile kademeli olarak istenilen seviyeye getirilebilir [16]. Tüm YZ yöntemleri arasında uzman sistemler, makine öğrenmesi ve derin öğrenme algoritmaları, tasarımcılara yardımcı olmak için en yaygın kullanılan karar destek araçlarıdır [134, 175, 176]. Zarandi vd., sürdürülebilir ürün tasarımında malzeme seçimi için kullanım ömür sonu mühendisliği yaklaşımını desteklemek üzere bir uzman sistem geliştirmiştir [177]. Malzeme seçimi, ürünün çevresel etkisini belirleyen önemli bir parametredir ve bilgi eksikliği nedeniyle tasarımın ilk aşamalarında yönetilmesi oldukça zordur. Buna ek olarak her bir malzeme seçeneği için kullanım ömür sonu mühendisliği yapmak uzun ve maliyetli bir süreçtir. Yazarlar tarafından geliştirilen uzman sistem, önce tüm malzemeleri değerlendirmiş ve ardından uygulanabilir olmayanları listeden çıkarmıştır [177]. Bu sayede tasarımcılar daha az sayıda malzeme seçeneği arasından seçim yapabilmıştır.

Makine öğrenmesi, bu tür tasarım karar problemleri sırasında hangi seçeneğin daha uygun olduğunu belirlemede tasarımcılara ve teknik personele yardımcı olmak için yaygın olarak kullanılan bir başka algoritmadır [93, 128]. Romeo vd., üretim ve/veya süreç simülasyonlarında elde edilen operasyonel verilerden (ör. tork, verimlilik, hız, maliyet vb.) makine yapısını ve malzemesini tahmin etmek için yenilikçi bir bulut tabanlı Tasarım Destek Sistemi önermiştir [128]. Buradaki nihai amaç, ideal bir tasarım çözümü için önemli performans parametrelerini tahmin etmede tasarımcılara rehberlik etmektir. Model doğruluğu iki farklı veri kümesi ve üç farklı makine öğrenmesi algoritması (Karar/Regresyon Ağacı, k-En Yakın Komşular ve Komşuluk Bileşen Özellikleri Seçimi) ile sunulmuştur. Akbari vd., müşteri yorumlarını dikkate alan yenilikçi bir ürün geliştirme süreci için karar destek sistemi olarak makine öğrenmesi algoritmasının bir alt kategorisini olan Yinelemeli Sinirsel Tensör Ağı kullanmıştır [178]. Sosyal medya platformlarından toplanan müşteri görüşleri, belirli bir ürüne yönelik duygusal durumlarını belirlemek için analiz edilmiştir. Diğer müşteri duyarlılığı belirleme çalışmalarından farklı olarak bu algoritma, bir kullanıcının yorumunun diğer kullanıcıları nasıl etkilediğini incelemek üzere tasarlanmıştır. Duygu durumu belirleme çalışması sonucunda elde edilen bilgiler, yenilikçi ürün geliştirme sürecinde kullanılmak üzere tasarımcıya sunulmuştur. Ayrıca topluluk üzerinde olumlu bir görüş oluşturmak için gerekli maliyet de hesaplanmıştır. Ferrero vd., karar destek bağlamında işlev tabanlı tasarım çalışmalarını kolaylaştırmak için bir makine öğrenmesi algoritması kullanmıştır [179]. Sınıflandırma ve regresyon ağaçlarının yanı sıra Birliktelik Kurallarına Dayalı Sınıflandırma (CBA) ile her bir ürün bileşeninin yerine getirebileceği işlevler belirlenmiş ve sınıflandırılmıştır [180]. Çalışma için gerekli veriler, mühendislik ve tasarım faaliyetlerini desteklemek amacıyla kurulan Oregon Eyaleti Tasarım Deposu'ndan (OSDR) elde edilmiştir. Buradaki işlev tabanlı çözümler filtrelenerek tasarımcıların daha dar bir alanda çalışmasına olanak sağlanmıştır. Bu yöntem, özellikle acemi tasarımcılara, işleve uygun ürün bileşenlerinin seçiminde yardımcı olabilir.

Raina vd. bir mühendislik tasarım problemi için derin öğrenme tabanlı bir tasarım destek sistemi kullanarak ardışık tasarım aşamalarının arkasındaki zihinsel süreçleri takip etmiştir [121]. Yöntemin etkinliği ve uygulanabilirliği Şekil 2.15'te bir kafes tasarım probleminde gösterilmiştir. Tasarım sürecinin tüm aşamaları ekran görüntüleri ile kaydedilmiş ve derin öğrenme modelleri (VAE ve CNN) tasarım sürecinin sıralı görüntüleri ile eğitilmiştir. Model, tasarımın mevcut durumunu tespit etmekte ve bir sonraki adım için bir tasarım önerisi yapmaktadır. Tasarım sürecinin ardındaki bilinmeyen zihinsel faaliyetleri takip eden

derin öğrenme desteğiyle üretilen basit kiriş tasarımları, emniyet faktörü ve mukavemet-ağırlık oranına göre değerlendirilmiştir. YZ algoritmalarının soyut düşünme, yaratıcılık ve açıklanabilirlik gibi konularda insan tasarımcıların gerisinde kaldığı bilindiğinden, başlangıçta bilinmeyen insan zihinsel sürecini takip ederek tasarım stratejileri geliştiren bu yöntem, özellikle tasarımcıların bilgi ve deneyimlerine dayalı tasarım stratejileri oluşturmada değerlidir.




Şekil 2.15. Sıralı tasarım görselleri ile eğitilen derin öğrenme modelinin önerilen tasarım adımları yeşil olan basit kafes sistemleri. Soldan sağa; tasarımın mevcut durumu, derin öğrenme modelinin önerisi ve bir sonraki gerçek tasarım adımı [121]

2.5.6. Modelleme ve geri çağırma

Modelleme, belirlenen tasarım konseptinin ve geometrik temsilinin bilgisayar ortamında 3 boyutlu görüntülerinin oluşturulması olarak tanımlanmaktadır. Bir başka deyişle nesnenin uzayda kapladığı hacmin matematiksel bir ifadesidir. Tasarımcılar için olduğu kadar ürün paydaşları için de ürünün genel yapısı hakkında fikir veren değerli bir araçtır. 3B modeller, geleneksel mühendislik sürecinde haftalar veya aylar süren kavramsal tasarım aşamasından sonra oluşturulabilir. Ayrıca insan kapasitesine bağlı olarak oluşturulan 3B sayısı sınırlıdır. YZ yöntemleri, tasarımcılar tarafından Bilgisayar Destekli Tasarım (BDT) ortamlarında yürütülen modelleme sürecinin otomatikleştirilmesinde tasarımcılara yardımcı olabilir [181]. Son yıllarda 2B ve 3B model depolarının geliştirilmesi, 3B model üretiminin YZ aracılığıyla otomasyonunu kolaylaştırmıştır [182].

Gologlu ve Mizrak tarafından müşteri taleplerine göre 3B BDT modelleri oluşturmak için bulanık mantık entegreli bir yöntem önerilmiştir [183]. Müşterilerden gelen sözlü ve belirsiz talepler bulanık mantık algoritması ile ürün parametrelerine dönüştürülmüştür. Bu parametreler daha sonra BDT ortamında otomatik olarak ürünün katı modelini oluşturmak için kullanılmıştır. Böylece müşteriler, modelleme bilgisine ihtiyaç duymadan taleplerini BDT modellerine dönüştürerek tasarım sürecine doğrudan dahil olmuşlardır.

Derin öğrenme yöntemleri, benzersiz 3B model varyasyonları oluşturmada ve hatta 2B'den 3B modele geçişte otomasyon sağlayabildikleri için özellikle 3B BDT modeli oluşturmada kullanışlıdır [142, 184-186]. Ayrıca, ikinci kavram olan 2B görüntülerden 3B modeller oluşturmak daha karmaşık bir süreçtir [187-189]. Wu vd., gerçekçi 3B görseller üretmek için derin öğrenme algoritmaları geliştirmiş ve ayrıca sırasıyla 3DGAN ve Varyasyonel Otomatik Kodlayıcı ve GAN (3D-VAE-GAN) modellerini kullanarak 2B görsellerden 3B modeller üretmiştir [190]. Kodlayıcı, kod çözücü ve ayırıcıdan oluşan ikinci model, tek bir 2B görüntüden bir 3B model oluşturulabilmesi için hem 2B görüntülerle hem de ilgili 3B modellerle eğitilmiştir. Gadelha vd. Perspektif Üretken Çekişmeli Ağ (PrGAN) ile 2B ürün görüntülerinden 3B yapılar elde etmiştir. Üretken ağı bir projeksiyon modülü eklenerek rastgele açılardan verilen 2B görüntülerin 3B modelleri elde edilmiştir [191]. Çalışma, 2B görsellerle eğitilen PrGAN'ın 3B modellerle eğitilen GAN'dan daha iyi performans gösterdiğini ortaya koymuştur. Ancak, PrGAN sonuçları Şekil 2.16'da görüldüğü gibi voksellerle temsil edildiğinden nispeten düşük çözünürlüklü modellerdir. Ayrıca, gölge eksikliği ve eksik iç detaylar hatalı geometriye neden olabilir. Sun vd., bir GAN algoritması kullanarak 2B görsellerden 3B modeller oluşturmak için bir veri seti ve yöntem geliştirmiştir [187]. Pix3D adı verilen veri seti, dokuz farklı kategoride eşleştirilmiş görüntü-model çiftlerinden oluşmaktadır. Görsel ve 3B model ilişkisini oluşturmak için referans noktaları hizalanmıştır. 2B görüntülerden 3B modeller üreten model, Pix3D veri kümesi üzerinde eğitilen alternatiflerle (3D-VAE-GAN [190], MarrNet [189]) karşılaştırılmış ve daha iyi performans gösterdiği kanıtlanmıştır. Zhang vd., verilen el çizimi veya teknik çizim görünüşlerine karşılık gelen 3B BDT modeli geri alma için CNN tabanlı FilterNet ve RankNet modelleri kullanmıştır [192]. Adından da anlaşılacağı gibi, FilterNet modeli kütüphanedeki kategorileri filtrelerken RankNet modeli ise giriş değişkenleri ile BDT modelleri arasındaki benzerliği hesaplamaktadır. Bu süreç, kütüphanedeki 3B BDT modellerinin yeniden kullanılmasını sağlar ve böylece tasarım süresini ve maliyetlerini azaltır.




Şekil 2.16. PrGAN modeli ile üretilen 3B sandalye modelleri [191]

2.6. Tartışma

Önceki bölümlerde mühendislik ürünü tasarımlarında kullanılan mevcut YZ yöntemlerinin kapsamlı bir eleştirel incelemesi yapılmıştır. Klasik YZ yöntemleri (örn. Bulanık Mantık, Genetik Algoritma ve Sinir Ağları) ve modern veri odaklı yaklaşımlar (örn. Makine Öğrenmesi ve Derin Öğrenme), tasarım süreçleri/problemleri için uygun YZ yöntemlerini belirlemek ve güçlü ve zayıf yönlerini değerlendirmek için tartışılmıştır. Bu konuda verilen kapsamlı bilgiler ve eleştiriler, özellikle yeni araştırmacılar ve tasarımcılar için yol gösterici olabilir.

Şekil 2.17, 2006 ve 2022 yılları arasında Scopus veri tabanından elde edilen YZ makalelerinde yer alan tasarım sayısını göstermektedir. Şekilden de anlaşılacağı üzere, geçtiğimiz on yıllar boyunca, tasarım çalışmalarında YZ yöntemlerini içeren makalelerin sayısında önemli bir artış olmuştur. Bu önemli artışta yüksek performanslı bilgisayarlardaki gelişmelerin önemli bir rolü vardır. Özellikle 2014 yılından sonra makale sayısındaki artış dikkat çekicidir.




Şekil 2.17. 2006 ve 2021 yılları arasında YZ yöntemlerini içeren makale sayısı (Scopus veri tabanı)


Şekil 2.18, yıl aralıklarına göre tasarım uygulamalarında YZ yöntemlerinin kullanım oranlarını göstermektedir. Bu şekilde, araştırma yoğunluğunda bilgi tabanlı YZ yöntemlerinden veri odaklı yaklaşımlara doğru belirgin bir kayma olduğu da görülmektedir; yani, Makine Öğrenmesi ve Derin Öğrenme, 2015 sonrası araştırma çalışmalarında ve yayınlarda giderek daha fazla kullanılmaktadır. 2006-2009 yılları arasında yapılan çalışmalara bakıldığında, Şekil 21'de görüldüğü gibi uzman sistemlerin ve genetik algoritmaların popülaritesi diğer yöntemlere göre %15 daha fazladır. 2010'lu yılların başında makine öğrenmesi tabanlı tasarım çalışmaları literatürde yer almaya başlamıştır. YZ içeren tüm tasarım çalışmalarının yaklaşık %64'ünü oluşturan makine ve derin öğrenme yöntemleri, 2016 ve sonrasında en popüler araştırma konularından biri haline gelmiştir.

Tasarımda YZ araştırma konuları da Şekil 2.19'da gösterildiği gibi, zaman içinde değişmiştir. Bu şekil, Bölüm 2.5'te detaylandırılan YZ araştırma konuları yöntemlerini (yani ilham, fikir ve kavram üretme, fikir ve kavramları değerlendirme ve tasarım ve modellemeyi optimize etme) içeren yayınların 2006 ve 2022 yılları arasındaki dağılımını göstermektedir. Şekilde de görüldüğü gibi, 2006 ve 2009 yılları arasında tasarım alanındaki YZ araştırma

konularının çoğu (%71); Değerlendirme (E), Optimizasyon (O) ve Karar Verme (DM) süreçleriyle ilgilidir. Sonraki 5 yılda optimizasyon temelli YZ araştırmalarında bir artış görülmüş ve son 5 yılda Fikir (Id) ve İlham (In) çalışmaları daha belirgin hale gelmiş ve hatta yüzde 37 ile en baskın araştırma konuları olmuştur. Modelleme çalışmalarında (M) da (çoğunlukla derin öğrenme yöntemleriyle 3B modeller üretme), bu zaman diliminde bir artış olduğu görülmektedir.



Şekil 2.18. 2006 ve 2021 yılları arasında YZ yöntemlerine dayalı tasarımı içeren yayınların dağılımı, (ES: Uzman Sistemler, FL: Bulanık Mantık, GA: Genetik Algoritma, YSA: Yapay Sinir Ağları, ML: Makine Öğrenmesi, DL: Derin Öğrenme)



Şekil 2.19. 2006 ve 2021 yılları arasında YZ yöntemlerine dayalı tasarım konusunu içeren yayınların dağılımı (In: İlham, Id: Fikir üretimi, E: Değerlendirme, O: Optimizasyon, DM: Karar verme, M: Modelleme)

Tasarım çalışmalarında YZ kullanımının temel amacı tasarımcının yükünü hafifletmek, tasarım maliyetlerini düşürmek, süreçleri ve otomasyonu hızlandırmak olarak açıklanabilir. YZ uygulamaları hakkında detaylı bilgi Bölüm 2.4'te sunulmuştur. Ancak, herhangi bir YZ yöntemi tasarım süreçlerinin tümünde kullanılması mümkün olmayabilir. YZ yönteminin problemin doğasına uygun olması gerekir. Tasarım çalışmalarında yaygın olarak kullanılan

YZ yöntemleri ve bunların en belirgin avantaj ve dezavantajları Çizelge 2.2'de özetlenmiştir. Tabloya göre, genel olarak, veri odaklı tasarım yöntemleri öznel yargılardan uzaktır ve tasarımcıların yaratıcılığını engelleyen psikolojik atalet gibi olguların üstesinden gelmek için iyidir [87, 193]. Fikir ve kavramların değerlendirilmesinde kişisel ön yargılar arka plana atılabilir [137, 194]. Verilerden öğrenen derin öğrenme modelleri, değişen ortam ve koşullara hızla adapte olabilir ve minimum tasarım ve mühendislik bilgisi gerektirir. İnsan odaklı bulanık mantık ve uzman sistemler ise insan bilgisi ve deneyimi ile oluşturulan kurallar temelinde çalışabilmekte, belirsiz ve eksik veri/bilgi ile çalışabilmektedir [24]. Sözel ifadelerle çalışabilmesi gerçek hayat problemlerine uygulanabilmesini mümkün kılmaktadır. Bu yöntemler, yüksek yorumlanabilirlikleri sayesinde tıp, savunma ve finans sektörlerinde kullanılabilmektedir. Ayrıca bazı YZ yöntemlerine bulanık mantık entegre edilerek açıklanabilirlik düzeyi artırılabilir [195]. Bununla birlikte, bulanık mantık modelleri değerlendirme dışında sınırlıdır ve karar verme süreçleri özel durum tabanlı problemlerdir ve başka herhangi bir probleme uygulanamaz. Verilerin/bilgilerin toplanması, işlenmesi ve kural yapısının oluşturulması zaman almakta ve çok fazla çaba gerektirmektedir. Çok boyutlu tasarım problemi çözümlerinde kullanılan genetik algoritmalar uzun süredir kullanılan bir optimizasyon yöntemidir. Çözüm uzayının büyük ve çok çeşitli olması işlem sürelerini artırsa da ideal çözüme ulaşma olasılığı artar. Model, performansını artırmak için diğer yöntemlerle entegre edilebilir [158, 196, 197]. Popülasyon büyüklüğü, mutasyon oranı, çaprazlama oranı, seçim yöntemi gibi deneyim gerektiren birçok parametre global optimuma ulaşmayı etkilemektedir. Genetik algoritma dışında tasarım performansını artırmak için kullanılan PSO, ACO ve DE gibi birçok algoritma bulunmaktadır [144].

YZ yöntemleri birçok tasarım ve mühendislik uygulamasında kullanılmaktadır. İlk olarak, klasik YZ yöntemlerinden bulanık mantık ve uzman sistemler, tasarımcılara değerlendirme ve karar süreçlerinde yardımcı olabilir. Genetik algoritmalar ve hibrit yöntemler ise alternatif çözümlerin oluşturulmasında ve ideal tasarım seçeneğinin belirlenmesinde daha etkilidir. Modern YZ yöntemlerinden veri madenciliği ve makine öğrenimi yöntemleri ise müşteri taleplerinin belirlenmesi, duygusal ihtiyaçların ortaya çıkarılması, tasarımcılara ilham verilmesi, fikir üretilmesi, karar verilmesi ve optimizasyon konularında verimli sonuçlar vermektedir. Derin öğrenme yöntemleri ile eskizleri resme dönüştürmek ve 2B görüntülerden yeni görüntüler, 2B görüntülerden 3B modeller ve 3B modellerden yeni 3B modeller oluşturmak mümkündür.

YZ algoritma seçimi

Tasarım problemi için uygun bir YZ yönteminin belirlenmesi, tasarım problemlerinin çözümünde birçok avantaj sağlar. Bu nedenle, sürecin en karmaşık kısmı olan belirli bir tasarım problemi için uygun yöntemin tanımlanması son derece önemlidir. Özellikle YZ yöntemleri hakkında yeterli bilgiye sahip olmayan tasarımcılar doğru yöntemi seçmekte zorlanabilirler. Açık literatürde yer alan başarılı uygulamalara dayanarak tasarımcılara rehberlik etmek için oluşturulan iki seviyeli YZ yöntemi seçim akış şeması Şekil 2.20'de sunulmuştur. Burada, işleme tasarımcıya verilerin kullanılabilirliğini sorularak başlanır. Bunun nedeni, problemin çözümünde kullanılacak verilerin mevcudiyetinin doğru YZ yönteminin belirlenmesinde en önemli kriterlerden biri olmasıdır. Bu sorunun cevabı olumsuzsa, süreç, bazı durumlarda (hesaplamalı tasarım, topoloji optimizasyonu, üretken tasarım vb.) sentetik veri üretmek mümkün olabileceğinden, üretilip üretilmeyeceğini sorar. Sunula nakış şeması, öyle ya da böyle, yeterli veri mevcutsa (veya üretilbiliyorsa), veriye bağlı yöntemlerin tercih edilmesi gerektiğini önermektedir. Daha sonra veri sayısı ve türleri değerlendirilerek uygun YZ tekniği seçilir. Öte yandan, veri bulunmaması durumunda kural tabanlı sistemler veya genetik algoritmalar kullanılabilir. Birini diğerine tercih etmek için kriter, objektif ve biraz da yaratıcı sonuçlar üreten kural/bilgi tabanlarına ihtiyaç olup olmadığıdır. Kural tabanı oluşturulmıyorsa genetik algoritma tek alternatiftir. Aksi takdirde kural tabanı bilgisinin nasıl elde edildiğine göre uzman sistemler veya bulanık mantık tercih edilir. Seçim işlemi ilk seviyenin sonunda bir YZ yöntemi önerir ve tasarımcının problemi bu yöntemin yaygın uygulamalarından biriyle eşleşiyorsa kullanılabilir. Çözüm, uygulamalarla eşleşmiyorsa veya YZ yöntemi yeterli bir çözüm sağlamıyorsa, işlemin ikinci seviyesi devreye girer ve hibrit YZ yöntemlerinin kullanılmasını önerir. Farklı YZ tekniklerinin birleştirilmesi aslında mühendislik problemlerinde güncel bir eğilimdir ve yüksek performanslı çözümler sağlayabilir. Bu amaçla akış şeması, mühendislik tasarım uygulamasının türüne, tasarımcının ihtiyaçlarına ve birinci seviyede seçilen yöntemle birleştirilebilecek başka bir YZ yöntemine ilişkin bilgileri sorar. Tasarımcının tasarım desteğine veya karar vermeye ihtiyacı varsa, uzman sistemlerle bir kombinasyon önerilir. Tasarımcının ihtiyacı bir ilham ve/veya konsept oluşturma ise "Veri üretilbilir mi?" sorusu tekrar sorularak veri odaklı yaklaşımlara yönlendirilir. Öte yandan veri odaklı yöntemlerin yeterli çözüm sunmadığı durumlarda tasarımcının yeni kombinasyonlar yapmak için kural tabanlı sistemleri veya genetik algoritmaları denemesi önerilir. Burada YZ yöntemini

belirleme sürecinin son 15 yılı kapsayan önceki YZ destekli tasarım çalışmalarına dayandığı unutulmamalıdır. Önerilen akış şeması özellikle acemi tasarımcılar için faydalıdır.


Çizelge 2.2. Yapay zekâ yöntemlerinin tasarım süreçlerindeki uygulama alanlarının avantaj ve dezavantajları

YZ yöntemleri	Tasarım Uygulamaları	Avantajlar	Dezavantajları
<i>Makine öğrenmesi</i>	İlham kaynağı Fikir üretme Konsept oluşturma Değerlendirme Karar verme Tasarım desteği Optimizasyon	- İnsan müdahalesine çok az ihtiyaç vardır. - Çok boyutlu tasarım problemlerinde kullanılabilir. - Birçok tasarım problemine uygulanabilir. - Küçük veri kümelerinde iyi performans gösterebilir. - Hesaplama açısından verimli - Algoritmalar denetimli, denetimsiz ve takviyeli öğrenme için uygundur.	- Birçok makine öğrenimi algoritması vardır. Hangi algoritmanın kullanılacağını belirlemek zordur. - Etiketli bir veri kümesi oluşturmak zordur, Veri ön işleme gerekebilir. - Sonuçların yorumlanması uzmanlık gerektirir. - Yüksek hata oranı. - Eğitim süresi donanıma bağlıdır.
<i>Yapay Sinir Ağları</i>	İlham kaynağı Karar verme Tasarım desteği Optimizasyon	- Eksik ve gürültülü bilgi ile çalışabilir. - Çok boyutlu tasarım problemlerinde kullanılabilir. - Denetimli ve denetimsiz eğitim için uygundur.	- Eğitim süresi donanıma bağlıdır. - Çözüme nasıl ulaşıldığı tam olarak açıklanamaz. - Yalnızca sayısal verilerle çalışır. - Özellik seçimi deneyim gerektirir.
<i>Derin öğrenme</i>	İlham kaynağı Fikir üretme Konsept oluşturma Değerlendirme Karar verme Tasarım desteği Optimizasyon Modelleme	- Minimum mühendislik ve alan bilgisi gerektirir. - Ağ, veri setinden hangi özelliklerin öğrenileceğine kendisi karar verir. - Birçok tasarım problemine uygulanabilir. - Yaratıcılığı artırır. - Değişen durumlara uyum sağlar. - Veri sayısı arttıkça model performansı da artar. - Algoritmalar denetimli, denetimsiz ve takviyeli öğrenme için uygundur.	- Ağ eğitimi çok fazla veri gerektirir. - Tasarım veri setleri sınırlıdır. - Özellikle 3D modellere ulaşmak zordur. - Etiketli bir veri kümesi oluşturmak zordur, Veri ön işleme gerekebilir. - Eğitim süreleri uzundur (donanıma bağlı olarak). - Üretken modeller sadece yeni formlar üretebilir. İşlevsel özellikleri zayıftır. - Çözüme nasıl ulaşıldığı tam olarak açıklanamaz.
<i>Genetik algoritma</i>	Optimizasyon Değerlendirme Fikir üretme	- Geniş bir çözüm uzayında çalışmaya uygundur. - Çok parametrelili optimizasyonda kullanılabilir. - Diğer optimizasyon algoritmalarına göre daha hızlıdır.	- Popülasyon büyüklüğü, yakınsama oranı, uygunluk fonksiyonu, mutasyon oranı ve çaprazlama oranının belirlenmesi deneyim gerektirir. - Her zaman ideal çözümü bulamama olasılığı vardır.
<i>Bulanık mantık</i>	Değerlendirme Karar verme	- Belirsiz ve eksik bilgilerle çalışabilir. - Karmaşık tasarım problemlerine uygulanabilir. - Tasarım problemlerine uygulanması kolaydır. - Otomasyon için uygundur.	- Probleme özgüdür, diğer problemlere uygulanması zordur. - Bir kural tabanı oluşturmak bilgi ve deneyim gerektirir. - İnsan odaklıdır. - Yaratıcılığı geliştiremez.
<i>Uzman sistemler</i>	Karar verme Değerlendirme Tasarım desteği	- Uzman bilgi ve deneyiminin her zaman kullanılmasını sağlar. - İnsani durumlardan (önyargı, yorgunluk, hastalık vb.) kaynaklanan hataları önler. - Çözüme nasıl ulaşıldığını açıklar. - Sonuçlar güvenilirdir. - Otomasyona uygundur. - Güncellenebilir.	- Probleme özgüdür, diğer problemlere uygulanması zordur. - Saha uzmanlığı gereklidir. - Bir kural tabanı oluşturmak bilgi ve deneyim gerektirir. - Yaratıcılığı geliştiremez. - Karmaşık sorunlara uygulanması zordur.

Özetle, YZ yöntemleri, tekrarlayan tasarım, analiz ve yeniden tasarım süreçlerinin bağımsız olarak gerçekleştirilmesini sağlayarak zamandan ve emekten tasarruf sağlar. Özellikle

Bilgisayarla görme teknolojisindeki gelişmeler sayesinde, 2B ve 3B tasarım konseptleri oluşturma ve değerlendirme görevleri son derece basitleştirilmiştir. Ayrıca daha kısa sürede daha kesin sonuçlar elde edilebildiği için geleneksel tasarım yöntemlerine kıyasla uygun maliyetli olmuştur. Ayrıca, tasarım seçenekleri oluşturulurken ve değerlendirilirken önyargıların ve bir fikre aşırı bağlılığın önlenmesine yardımcı olarak tasarımcıların çok çeşitli çözüm alanlarında küresel optimuma ulaşmasını sağlamıştır. YZ yöntemleri objektiftir ve aynı koşullar altında benzer sonuçlar elde eder. YZ destekli tasarımın bir diğer avantajı da tasarımcıların sınırlı bilgi birikiminin zamanla kaybolmasına dayanan insan merkezli tasarımın aksine, YZ'de öğrenilen bilgi ve becerilerin asla kaybolmaması ve herhangi bir zamanda geri çağrılabilmesidir. Öte yandan, bilgisayar işlemci hızının ve depolama kapasitesinin artması, etiketli/etiketsiz veri setlerinin oluşturulması ve devasa verilere erişimin kolaylaşması nedeniyle son yıllarda veri tabanlı yöntemlerin popülaritesi artmaktadır. Modern veri odaklı yöntemlerin geliştirilmesi, ilham alma, konsept oluşturma ve 3B model oluşturma gibi tasarım araştırmalarında büyük bir artışa yol açmıştır. Bu yöntemler, insan kapasitesinin yetersiz kaldığı devasa verileri işleyebilme yetenekleriyle tasarım sürecinde yeni bir dönem başlatmıştır. Bir başka deyişle, veri tabanlı yöntemler bilgi ve deneyim merkezli yaklaşımların yerini almaktadır.

Yapay zekanın geleceği büyük olasılıkla makine öğrenmesi ve derin öğrenme yöntemleri etrafında şekillenecektir. Bu devam etmekte olan bir süreçtir ve veriye erişimin kolaylaşması, bilgisayar işlem ve depolama kapasitesinin artması bu eğilimi hızlandıracaktır. Buna rağmen derin öğrenme modellerinin eğitiminde hala büyük miktarda veriye ihtiyaç duyulmaktadır. Nesnelerin İnterneti (IOT), çevrimiçi alışveriş siteleri, arama motorları ve anketler tarafından sürekli olarak veri üretilmektedir. Ancak bu verilerin işlenmesi, düzenlenmesi ve etiketlenmesi yüksek maliyetli ve zaman alıcıdır. Mevcut metin, ses, görüntü ve 3B model veri tabanları ise bu sorunları çözmek için yeterli değildir. Ayrıca YZ süreçlerinin altında yatan mekanizmanın anlaşılmaması YZ sistemlerinin güvenilirliğini sarsmaktadır. Öte yandan tasarım sadece estetik görünümünden ibaret değildir. İyi bir tasarım ürünün hangi amaçla tasarlandığını ifade eden işlev ile ürünün kullanıcı ve çevre ile ilişkisini temsil eden davranışı bir bütün olarak ele almalıdır. Görüntü işleme tabanlı yaklaşımlar genellikle ürün formları üzerinde çalışır. Uygulanabilir tasarımlar için işlevsel ve davranışsal özellikleri de dikkate alınmalıdır [3, 142].



Şekil 2.20. Tasarım uygulamaları için uygun YZ yönteminin seçilmesine ilişkin akış şeması

2.7. Sonular

Tasarım problemlerinde YZ yönteminin seçimi, problemin doğasına ve veri miktarına bağlıdır. Klasik YZ teknikleri (yapay sinir ağları, bulanık mantık, uzman sistemler ve genetik algoritmalar), uzman bilgisi ve deneyimi gerektiren tasarım konseptlerinin değerlendirilmesi, optimizasyonu ve karar verme süreçlerinde uzun süredir kullanılmaktadır. Öte yandan, bilgisayar işlemci hızının ve depolama kapasitesinin artması, etiketli/etiketsiz veri setlerinin oluşturulması ve devasa verilere erişimin kolaylaşması nedeniyle son yıllarda veri tabanlı yöntemlerin önemi artmaktadır. Modern veri odaklı yöntemlerin geliştirilmesi, ilham alma, konsept oluşturma ve 3B model oluşturma gibi tasarım araştırmalarında büyük bir artışa yol açmıştır. Son yıllarda tasarım ilhamı ve konsept yaratma çabalarındaki artış, büyük miktarda verinin kullanılabilirliği ile doğru orantılıdır. Bu yöntemler, insan kapasitesinin yetersiz kaldığı devasa verileri işleyebilme yetenekleriyle tasarım sürecinde yeni bir dönem başlatmıştır. Bir başka deyişle, veri tabanlı yöntemler bilgi ve deneyim merkezli yaklaşımların yerini almaktadır.

Tasarımda YZ yöntemlerini kullanmanın bazı dezavantajları da var. Bunlardan ilki, belirli bir tasarım problemi için geliştirilen bir YZ algoritması, sezgisel yeteneklerden yoksun olduğu için genellikle diğer tasarım problemlerine uygulanamaz. Bu nedenle, bazı derin öğrenme modelleri hariç, değişen koşullara uyum sağlama yeteneği zayıftır. Öte yandan, derin öğrenme modellerinin eğitimi çok fazla veri ve yüksek kapasiteli bilgisayarlar gerektirir. Tüm bunlara ek olarak, birçok YZ uygulaması kullanıcılar/tasarımcılar tarafından tam olarak açıklanamayan 'kara kutu' çözüm süreçleri içermektedir. YZ kararlarının arkasındaki nedenselliği anlamak, daha güvenilir ve yorumlanabilir tasarım çözümleri sağlar. Bu amaçla, yorumlanabilir ve yüksek performanslı Açıklanabilir Yapay Zekâ (AYZ) yöntemlerinin tasarım uygulamalarında yaygınlaşacağı öngörülmektedir. Tasarım alanında gelecekteki çalışmalar, iyileştirilmiş biçim, işlev ve davranışa sahip tasarımlar geliştirmeyi amaçlayan YZ sistemleri üzerinde olmalıdır. Özellikle, üretim kısıtlamalarını önemli ölçüde azaltan ve tasarım yinelemelerini basitleştiren hızlı prototipleme teknikleri YZ süreçlerine dahil edilebilir. Böylece, ilk konseptlerin çok daha kısa sürede işlevsel ürünler haline gelmesi daha mümkün olacaktır. Sanal Gerçeklik (VR) ve Artırılmış Gerçeklik (AR) teknolojileri de üretken tasarım modellerinin verimliliğini ve performansını artırmak için tasarım sürecine entegre edilebilir.

3. ÜRETKEN ÇEKİŞMELİ AĞLAR (GAN) İLE TASARLANAN EKLEMELİ OLARAK ÜRETİLMİŞ KAFES YAPILARIN MEKANİK ÖZELLİKLERİNİN ARAŞTIRILMASI

Tekrarlayan hafif hücreli formları ile karakterize edilen kafes yapılar, katı gövdelere kıyasla daha etkili yük dağılımı sağlar. Özel mekanik özelliklere sahip 2B kafes yapıların tasarlanması, çok sayıda tasarım değişkeni ve bunların mekanik performansla olan karmaşık ilişkisi nedeniyle oldukça zordur. Bu bölümde bahsedilen zorluğun üstesinden gelmek için Üretken Çekişmeli Ağ (GAN) modeli kullanan bir ön çalışma yapılmıştır. Bu ön çalışma tez kapsamında önerilen yöntemin uygulanabilirliğini ve kısıtlarını net bir şekilde ortaya koymaktadır. Eğitim kümesinin yüksek mukavemet ağırlık oranına sahip kafes yapılardan oluşturularak gelişmiş mekanik özelliklere sahip kafeslerin üretilmesini sağlanmıştır. Bu kafes tasarımları, karmaşık yapıların üretilmesine olanak tanıyan ticari bir Malzeme Püskürtmeli Katmanlı Üretim (İng. Material Jetting Additive Manufactured, MJ-AM) makinesi kullanılarak üretilmiştir. Eklemeli imal edilmiş hücreli kafes yapıların mekanik performansı Sonlu Elemanlar Analizi (FEA), basma ve darbe testleri ile değerlendirilmiştir. Sonuçlar, GAN modeli kullanılarak üretilen kafes yapıların gelişmiş mekanik mukavemet gösterdiğini ortaya koymaktadır (yani, sırasıyla %108 ve %150'ye kadar gelişmiş mukavemet ve uzama performansı). Bu bölüm, GAN'ın kafes yapı tasarım alanını genişletme ve gelişmiş mekanik özelliklere sahip özel parçalar oluşturma potansiyelini göstermektedir. Burada ayrıca parça tasarımı ve üretimine yeni bir yaklaşım sunarak GAN'ların yapısal olarak işlevsel bileşenler üretme konusundaki potansiyeline ışık tutmaktadır.

3.1. Eklemeli İmalat İçin Tasarımda Derin Öğrenme

Eklemeli imalat (Eİ) teknolojisi, bilinen tüm ürün ve bileşen tasarım kurallarını yeniden yazma potansiyeline sahiptir. Eİ, geleneksel imalat yöntemleri ile üretilmesi zor veya imkânsız olan karmaşık geometri ve formlara sahip parçaların hızlı ve uygun maliyetli bir şekilde oluşturulmasını sağlar [198, 199]. Böylece otomotiv, havacılık, motor sporları, enerji ve medikal sektörlerinde üstün işlevselliğe sahip ürünler üretmenin yeni bir yolu haline gelmiştir [200]. Ayrıca, geleneksel yöntemlere göre daha fazla tasarım esnekliği sunarak kişiselleştirilmiş ve organik geometrilerin üretilmesine olanak sağlamaktadır [201]. Eİ teknolojisinin bu yeteneği, yüksek enerji emilimi ve mükemmel bir sertlik-ağırlık oranına sahip kafes yapıların üretilmesini teknik ve ekonomik olarak mümkün kılmaktadır [202,

203]. Kafes yapılar yapı ağırlığını önemli ölçüde azaltır ve bileşen işlevselliğini artırır [204]. Eİ'ya dayalı kafes yapıların tasarımında önemli ilerlemeler kaydedilmiş olsa da tam potansiyelleri ortaya çıkarmak ve çeşitli endüstrilerdeki ek uygulamaları keşfetmek için daha fazla araştırma ve geliştirmeye ihtiyaç vardır [204]. Eİ teknolojisi kafes yapılar için üretim zorluklarını etkili bir şekilde aşmakla birlikte bu yapıların tasarım karmaşıklığı ve mekanik performansla olan karmaşık ilişkileri zorlayıcı olmaya devam etmektedir [205, 206]. Derin öğrenme yöntemlerinin artan gücünü sürece dâhil etmek, özel mekanik özelliklere sahip benzersiz kafes yapılar üretmenin olası yollarından biridir. Derin öğrenmenin bir başka yaygın kullanım alanı da maliyeti ve üretim sürelerini azaltırken parça kullanılabilirliğini en üst düzeye çıkaran Katmanlı Üretim için Tasarım (İng. Design for Additive Manufacturing, DfAM) yaklaşımını optimize etmektir. Derin öğrenme teknolojisinin DfAM'ye dâhil edilmesi, üretim sürecinin doğruluğunu, hassasiyetini, otomasyonunu ve özelleştirilmesini geliştirmeye yardımcı olabilir. Ayrıca bu birleşim, kafesler ve diğer düşük ağırlıklı fonksiyonel yapılar için yeni performans geliştirme ve özelleştirme fırsatları oluşturur [207, 208].

Eİ, ağırlık azaltmaya odaklanan kafesler ve diğer işlevsel yapılar için yeni performans geliştirme ve tasarım özelleştirme fırsatları oluşturur [209]. Bununla birlikte, destek yapısı, duvar kalınlığı, yüzey kalitesi ve maksimum kendini destekleme açısı gibi Eİ tekniğinin kısıtlamaları, hücresel yapı tasarımını önemli ölçüde etkiler [210, 211]. Optimal hücresel yapı tasarımı, gerekli işlevselliği destekleyen tüm bileşenleri içermelidir. Bu, ayrı ayrı inşa edilmiş hücrelerin bir araya getirilmesiyle mümkündür. Bu tür yapıları verimli bir şekilde imal etmek için çeşitli tasarım ve imalat stratejileri önerilmiştir [212, 213]. Örneğin Lucklum vd., 100 μm 'ye kadar küçük unsur boyutlarına sahip kafes yapıları 3B fononik malzemeler üretmek için yansıtım tabanlı bir stereolitografi (SLA) yöntemi önermiştir [214]. McGregor vd., kafes bileşenlerinin üretimini düzenlemek için belirli kafes özelliklerini otomatik olarak kavrayan bir sistem oluşturmuştur [215]. Başka bir çalışmada, Lui vd. polimer kafes yapıları oluşturmak için malzeme püskürtme tabanlı Eİ teknolojisini kullanarak geleneksel Eİ tekniklerine kıyasla %80'in üzerinde malzeme ve zaman tasarrufu sağlamıştır [216]. Sathishkumar vd., hücresel yapının mekanik özelliklerinin boyut eşleştirme, ölçeklendirme ve dikme çapları gibi tasarım unsurlarından nasıl etkilendiğini araştırmıştır. Yazarlar, değişken yoğunluklu topoloji optimizasyonuna dayalı hücresel yapı tasarımlarının daha iyi fiziksel ve mekanik sonuçlar elde ettiğini göstermiştir [217].


Verimli kafes yapıları oluşturma ve değerlendirme bir başka yolu da güncel derin öğrenme tekniklerini kullanmaktır [218-220]. Hassanin vd., derin öğrenme algoritmalarının eklemeli imalat ile üretilen mikro yapıların mekanik özelliklerini tahmin etme ve iyileştirmedeki başarısını göstermiştir [221]. Benzer bir çalışmada Ma vd., hücreli malzemelerin mekanik tepkilerini tahmin etmek için bir makine öğrenme çerçevesi sunmuştur. Bu çerçevenin hücreli malzemelerin tasarım verimliliğini artırdığı sayısal analizlerle doğrulanmıştır [222]. Öte yandan, Bhuwal vd., farklı düzensizlik derecelerine sahip kafes meta malzemeleri tasarlamak için derin öğrenme ve küresel optimizasyon algoritmaları kullanmışlardır. Bal peteği gibi doğal malzemelerden esinlenen hesaplama yöntemleri kullanılarak, sadece küçük sertlik ve çekme mukavemeti kayıpları ile iki kat daha fazla sünekliğe sahip yapılar elde edilmiştir [223]. Bir GAN modeli kullanan benzer bir çalışmada, Zheng vd. kafes yapı tasarımı için derin öğrenme tabanlı, kontrol edilebilir bir tersine tasarım yaklaşımı sunmuştur [224]. Rastgele oluşturulmuş voronoi desenleri üzerinde eğitilmiş bir GAN modeli kullanan yöntem, kullanıcı tarafından belirlenen elastik modüle sahip 2B kafes üretimini kolaylaştırmaktadır. Wang vd., değişken yoğunluklu hücreli yapıları optimize etmek için koşullu üretken bir derin öğrenme modeli kullanmıştır. Sezgisel yaklaşımların aksine, sunulan model, birim hücre geometrilerini malzeme özellikleriyle doğru bir şekilde eşleştirerek yapısal performansı önemli ölçüde geliştirmiştir [225].

En son YZ, EI ve BDT teknolojilerinin güçlerinden yararlanmaya yönelik ilk girişimlere rağmen, özel mekanik özelliklere sahip kafes yapılar üretmek, kapsamlı araştırma gerektiren bir mühendislik sorunu olmaya devam etmektedir [218, 219]. Bu bölüm, parametrik bir tasarım yöntemi ve GAN'ın gücünden yararlanarak yüksek performans-ağırlık özelliklerine sahip kafes yapılarının tasarlanması ve üretilmesine yönelik yeni bir yaklaşım sunmaktadır. Süreç, benzersiz ve yapısal olarak üstün 2B kafes konfigürasyonları üretebilen bir GAN modelini eğitmek için parametrik tasarım yöntemiyle 2B kafes veri kümesi oluşturmakla başlar. Daha sonra, tasarlanan kafes yapılarını üretmek için malzeme püskürtme (İng. Material Jetting, MJ) tekniği kullanılır. GAN tarafından tasarlanan benzersiz kafes yapıların mekanik özellikleri mekanik testlerle belirlenmiş ve Sonlu Elemanlar Analizi (FEA) ile doğrulanmıştır. Bu yaklaşım, parametrik tasarım sürecinde gerçekleştirilen yapısal analizler sayesinde yalnızca yüksek mekanik performanslı kafeslere odaklanarak GAN modellerinin fonksiyonel tasarım varyantları üretme yeteneğini geliştirmeyi hedeflemektedir. Ayrıca, GAN ve parametrik tasarımın birleştirilmesi, kafes yapılar için belirli performans

kriterlerinin (örneğin, dayanıklılık, güç ve ağırlık) yerine getirilmesini ve optimize edilmesini sağlar.

3.2. Metodoloji

Derin öğrenme ile tasarlanan, eklemeli imalat ile üretilen kafes yapıların mekanik özelliklerinin incelenmesi için kapsamlı bir yaklaşım sunulmaktadır. Bu süreç, üretken derin öğrenme modelinin eğitiminde kullanılacak veri setinin oluşturulmasıyla başlar. Ardından, eğitilen GAN modeli ile benzersiz kafes geometrileri oluşturulmuş ve üretim için düzenlenmiştir. Kafes tasarım adımlarının ardından oluşturulan test numuneleri, ticari bir eklemeli üretim tekniği olan MJ yöntemi kullanılarak üretilmiştir. Son adımda, üretilen test numunelerinin basma ve darbe testleri yoluyla mekanik tepkileri değerlendirilmiştir. Hücresel yapının tasarlanması ve geliştirilmesi süreci Şekil 3.1'de gösterilmekte olup, her bir adımın detayları ilerleyen bölümlerde açıklanmaktadır.











Şekil 3.1. Kafes yapıların tasarım (hesaplamalı tasarım, Derin öğrenme ile kafes üretimi), üretim (3B Baskı) ve doğrulama (Kalite kontrol, Basma testi, Darbe testi) adımlarını gösteren akış şeması.

3.2.1. Parametrik tasarım

Parametrik ve hesaplamalı yöntemler, tasarım sürecinin verimliliğini ve performansını artırmak için üretken araçlar olarak sıklıkla kullanılmaktadır. Parametrik tasarım, tasarım öğelerinin bilgisayar teknolojisi yardımıyla matematiksel ifadelerle dönüştürülmesi ve bir algoritma yapısına dahil edilmesi olarak tanımlanabilir. Bu algoritmalar form ve geometri çeşitliliğini artırarak dinamik, tekrarlanabilir ve sürdürülebilir bir süreç oluşturur [226, 227]. Bu modeller mimari, inşaat ve makine tasarımı gibi yapısal performans ve düşük ağırlık gerektiren tüm mühendislik işlerinde kullanılmaktadır [228, 229].


Çizelge 3.1. Parametrik modelde bazı parametreler ve oluşturulan bir dizi tasarımı, temel blokları, birim hücreleri ve bunlara karşılık gelen 3B modelleri gösteren parametrik BDT modeli formülasyonuna genel bakış

	Hacim Aralığı	von Mises Eşiği	Temel Blok	Birim Hücre	3B Model
Model 1	31-35 mm ³	8 MPa		 Parametre sayısı = 3 Üretilen tasarım = 418	 Unsur çapı = 0.80 mm
Model 2	20-23 mm ³	3 MPa		 Parametre sayısı = 2 Üretilen tasarım = 245	 Unsur çapı = 0.80 mm
Model 3	27-43 mm ³	12 MPa		 Parametre sayısı = 2 Üretilen tasarım = 1164	 Unsur çapı = 0.80 mm

Bu görevlerden biri, derin öğrenme modelini eğitmek için parametrik tasarım yoluyla bir kafes veri kümesi oluşturmaktır. Parametrik tasarım araçlarıyla oluşturulan tüm kafes tasarımları, sürekliliği ve belirtilen tasarım kısıtlamalarına uygunluğu garanti eder. Burada, standart birim hücrelere dayalı üç farklı parametrik tasarım mimarisi kullanılmıştır. Bu mimariler, bir birim hücreyi oluşturan temel yapıların simetrik olarak yeniden üretilmesini sağlar. Temel blok üzerinde belirlenen dikme uzunlukları, konumları, açıları ve sınır koşulları tüm yapıya yayılır. Parametrik tasarım algoritmaları, parametrelerin bir kombinasyonu ile alternatif kafes geometrileri üretir. Çizelge 3.1, kullanılan parametrik mimarilerinin formülasyonunu tanıtmaktadır. İlk sütun ayarlanabilir parametrelerin sayısını gösterirken, ikinci sütun ilgili mimari kullanılarak üretilen kafes tasarımlarının miktarını göstermektedir. Üçüncü sütunda, temel yapıdaki düğümlerin ve payandaların hareket

yönünü belirleyen parametreleri göstermek için renk ve semboller kullanılmaktadır. Birim hücre geometrisi, 3B model görünümü, unsur boyutu ve hacim aralıkları sırasıyla son iki sütunda gösterilmiştir.

Parametrik tasarım tarafından oluşturulan yeni kafes geometrilerinin yapısal performansını doğrulamak için Grasshopper'da bir ön değerlendirme yapılmıştır [230]. Bu adım, yalnızca yüksek performanslı kafes geometrilerinin seçilerek eğitim veri kümesine dahil edilmesini sağlar. GAN mimarisinin veri kümesinden öğrendiği düşünüldüğünde, veri kümesinin yalnızca yüksek yapısal performansa sahip kafes yapılarından oluşturulması, GAN modeli tarafından oluşturulan kafes yapılarının da yüksek yapısal performans sergilemesini sağlar [231].




Şekil 3.2. Yüksek yapısal performanslı kafes yapıların üretilmesi ve test edilmesi için yinelenmeli parametrik tasarım süreci

Kafes geometrilerinin değerlendirilmesi sırasında, gelişmiş yapısal performansa sahip kafes yapıları elde etmek için Benzetimli Tavlama (İng. Simulated Annealing, SA) algoritmasına sahip Galapagos eklentisi kullanılmıştır. SA, metalurjik tavlama işleminden esinlenen bir optimizasyon algoritmasıdır [232, 233]. Bu algoritma, bir başlangıç çözümünü değerlendirerek çözüm uzayını keşfetmeyi ve ardından küresel optimumu bulmak üzere yeni bir aday çözüm oluşturmayı amaçlamaktadır [232]. SA algoritması, ağırlığa göre yüksek mukavemetli kafes geometrilerini veri kümesine dahil edebilmek için parametrik tasarım sürecine dahil edilmiştir. Parametrik modelleme yoluyla oluşturulan kafes geometrileri kapsamlı bir yapısal analize tabi tutulmuş ve bu değerlendirmenin ardından, von Mises eşik gerilme değerlerinin altında kalan geometriler veri setine eklenmiştir (Şekil 3.2). Eşik gerilme değeri, kafes hacminin, von Mises değerine oranı olarak belirlenmiştir. Kafes

kafes görüntüleri bu modelin eğitiminde kullanılmıştır. Burada, üretici ağ Gauss nokta dağılımını kullanarak yeni veriler üretmeyi öğrenir. İlk olarak, rastgele bir z boyutlu piksel kümesi, tensör oluşturmak için yeniden şekillendirilir. Ardından, tersine evrişim katmanları kullanılarak daha yüksek boyutlu bir tensör (sentetik görüntü) oluşturulur. Leaky ReLU aktivasyon fonksiyonları bilgiyi bir katmandan diğerine taşırken, Tanh aktivasyon fonksiyonu son tersine evrişim katmanında kullanılır. Burada kullanılan tensör boyutları, katman sayısı ve filtre sayısı sezgisel olarak ayarlanır. Standart bir CNN mimarisi içeren ayırıcı ağ ise eğitim setindeki görüntüler ile sahte olanları birbirinden ayırır. Evrişim katmanları gerçek boyutlu görüntüyü daha küçük boyutlu bir tensöre dönüştürür. Daha sonra bu tensör tek boyutlu bir matris haline getirilir. Son aşamadaki tamamen bağlı katmanlar ise sınıflandırma (gerçek/sahte) işlemini gerçekleştirir. Bu derin öğrenme modelinde kullanılan geleneksel kayıp fonksiyonu, üretici ve ayırıcı ağ eğitimi için bir performans metriğidir (Eş. 3.1). Bu fonksiyon, her iki ağ tarafından gerçekleştirilen görevlerin kalitesini değerlendirir [236]. E_x terimi, ayırıcının görüntüleri (gerçek veya sahte) sınıflandırmadaki başarısını ölçerken, E_z terimi, üreticinin sahte görüntüler üretme yeteneğini değerlendirir. Böylece maliyet fonksiyonu, ayırıcı ağı gerçek ve sentetik görüntüleri ayırt etme kabiliyetini en üst düzeye çıkarırken üreticinin hatasını en aza indirmeyi amaçlamaktadır. Bu denklemde x gerçek görüntüleri, z ise gürültü girişini temsil etmektedir.

$$\min \max(D, G) = E_x[\log(D(x))] + E_z[\log(1 - D(G(z)))] \quad (3.1)$$

Parametrik tasarım ile üretilen 3.654 kafes görüntüsü DCGAN model eğitimi için kullanılmıştır. Adam optimizasyon tekniği, 0,0001 öğrenme oranı ve 64 yığın boyutu ile DCGAN model eğitimi 1.500 döngü sonunda tamamlanmıştır. Eğitim RTX 3090 GPU ekran kartı kullanılarak yaklaşık 7 saat sürmüştür. Şekil 3.4, DCGAN mimarisiyle oluşturulan benzersiz kafes tasarımlarını göstermektedir. Bu tasarımlardan bazıları araştırmanın sonraki aşamalarında kullanılmak üzere rastgele seçilmiştir. Seçilen tasarımlar kırmızı çerçeve ile gösterilmiştir. GAN'lar gerçek verilere benzeyen veriler üretmek için güçlü araçlar olsalar da kafes gibi karmaşık yapılarda eksik veya hatalı geometriler üretilebilir. Eksik veya hatalı kafes, yapının bütünlüğünü ve mekanik performansını tehlikeye atarak hem simülasyon hem de mekanik testlerde hatalara yol açabilir. Bu yapılar, güvenilir mekanik analizler sağlamak ve üretilebilirliği garantilemek amacıyla BDT ortamında orijinal modele bağlı kalarak yeniden düzenlenmiştir.



Şekil 3.4. DCGAN tarafından oluşturulan kafes tasarımı çeşitleri, kırmızı kare 3B baskı için kullanılan tasarımları gösterir
















3.2.3. Hüresel yapı tasarım süreci

Kafes yapılar, birim hücrelerin düzenine göre iki sınıfa ayrılır: stokastik ve stokastik olmayan [198]. Stokastik bir kafesi oluşturan birim hücreler belirsiz ve rastgele olduğundan, herhangi iki bölge farklı yapısal özelliklere sahip olabilir. Bu tür yapılar, yüksek gerilmelere karşı plastik olarak deforme olabildikleri için şok emici olarak kullanılabilirler [207]. Öte yandan, stokastik olmayan kafesler, birbirini tamamlayan ve tekrarlayan özdeş periyodik birim hücrelerden oluşur [46]. Havacılık, otomotiv ve inşaat gibi yüksek yapısal performans, düşük ağırlık ve maliyet etkinliği gerektiren çeşitli uygulamalarda kullanılır [237, 238]. Ayrıca, tüm kafes yapılar, boşluklu geometrileri sayesinde üstün termal, akustik ve titreşim yalıtımı sağlarken, bazı kafes yapılar da gelişmiş yük taşıma kapasitesi ve uyarlanabilirlik sunar [239, 240].


















Bu çalışmada, dördü standart ve altısı GAN tarafından oluşturulan on farklı birim hücre tasarımından oluşan kafes yapıların mekanik özellikleri incelenmiştir (Çizelge 3.2). Bu birim hücreler, basma ve darbe test numunelerine sorunsuz bir şekilde dahil edilmiştir. Test numuneleri, sırasıyla $19,2 \times 19,2 \times 19,2 \text{ mm}^3$ ve $10 \times 10 \times 55 \text{ mm}^3$ boyutlarında rijit hüresel

plastik basma ve darbe testi standartlarına göre modellenmiştir [214, 241]. Destek malzemesinin birim hücrelerden çıkarılmasını zorlaştırdığı için minimum özellik boyutu 0,8 mm ile sınırlandırılmıştır. Hücre tipi ve boyutu ile mekanik performans arasındaki ilişki, gözeneklilik (aynı hücre tipleri için boşluk hacminin toplam hacme oranı olarak ölçülür) sabit tutularak incelenmiştir. Çizelge 3.2'de gösterildiği gibi, basma testi numunelerinin gözenekliliği, kafes yapısının yoğunluğunun referans yapının (gözeneksiz) yoğunluğuna oranı olan bağıl yoğunluk ile ters orantılıdır.

Çizelge 3.2. Birim hücre tipleri, boyutları ve fiziksel özelliklerinin karşılaştırılması

Hücre tipi	Birim hücre boyutu	Hücresel model	Unsur boyutu (mm)	Kütle (gr)	Özgül yoğunluk	Gözeneklilik
	Kare 6 x 6 x 6 (mm x mm x mm)			2,00	0,23	%77
	Diamond 6 x 6 x 6 (mm x mm x mm)			3,08	0,36	%64
	Diamond-Squared 6 x 6 x 6 (mm x mm x mm)			3,62	0,43	%57
	Body-Centered-Squared 6 x 6 x 6 (mm x mm x mm)			3,64	0,43	%57
	MG-1 6 x 6 x 6 (mm x mm x mm)			4,90	0,58	%42

Çizelge 3.2. (devam) Birim hücre tipleri, boyutları ve fiziksel özelliklerinin karşılaştırılması

Hücre tipi	Birim hücre boyutu	Hücresel model	Unsur boyutu (mm)	Kütle (gr)	Özgül yoğunluk	Gözeneklilik
	MG-2 6 x 6 x 6 (mm x mm x mm)			3,54	0,42	%58
	MG-3 6 x 6 x 6 (mm x mm x mm)			4,44	0,52	%48
	MG-4 6 x 6 x 6 (mm x mm x mm)			3,62	0,43	%57
	MG-5 6 x 6 x 6 (mm x mm x mm)			3,92	0,46	%54
	MG-6 6 x 6 x 6 (mm x mm x mm)			5,42	0,64	%36
	Katı 6 x 6 x 6 (mm x mm x mm)			8.48	1	0

3.2.4. Mekanik tepki tahmini

Gibson-Ashby modeli (Eş. 3.2), birim hücreye dayalı kafes yapıların mekanik özelliklerini tahmin etmek için kullanılan çeşitli yöntemler arasında en öne çıkanıdır [242].

$$P^* = cP_s(\rho^*/\rho_s)^n \quad (3.2)$$

Burada P^* , katı malzemenin kafes yapısının bağıl yoğunluğuna (ρ^*/ρ_s) üs (n) ve orantılılık sabitinin (c) gücüne orantılı tepkisini temsil eder [242]. Bu üs, yapının eğilme veya gerilme olabilen baskın davranışı tarafından belirlenir. Maxwell'in düzlemsel 2B kafes sistemleri için stabilite kriteri (Eş. 3.3), incelenen modellerin sınıflandırılmasını belirlemek için kullanılmıştır

$$M = s - 2j + 3 \quad (3.3)$$

Çizelge 3.3. Kafes yapıların mekanik tepkilerinin Maxwell stabilite kriteri ile belirlenmesi. 's' ve 'j' sırasıyla dikiş ve düğüm sayılarını temsil etmektedir. 'M' değeri yapısal sertliği göstermektedir


Kafes yapı	s	j	M	Mekanik tepki
Kare	4	4	-1	Eğilme baskın
Diamond	4	4	-1	Eğilme baskın
DS	12	8	-1	Eğilme baskın
BCS	8	5	1	Gerilme baskın
MG-1	20	8	7	Gerilme baskın
MG-2	16	8	3	Gerilme baskın
MG-3	12	9	-3	Eğilme baskın
MG-4	16	12	-5	Eğilme baskın
MG-5	8	8	-5	Eğilme baskın
MG-6	32	24	-13	Eğilme baskın

Burada "j" düğüm sayısını, "s" ise birim hücredeki payanda sayısını göstermektedir. Hesaplanan M değeri 0'ın altındaysa, yapının dış kuvvetleri dengelemek için yapıda yeterli destek olmadığı ve kafes sisteminin gerekli rijitliğe sahip olmadığı sonucuna varılabilir. Eğer bir kafes yapısı yeterli rijitliğe sahip değilse, deformasyonlar, düğüm noktalarında eğilme şeklinde meydana gelir. Bu nedenle bu tip yapılar, "eğilme baskın" yapılar olarak adlandırılır. M değeri 0'ı aşarsa, kafes sistemin aşırı rijit olması beklenir. Rijit yapılar yükü dikme elemanlarının basma ve gerilmesiyle taşır ve düğüm noktalarında eğilme olmaz. Bu

tür yapılar “gerilme baskın” yapılar olarak bilinir. Çizelge 3.3, çalışmada kullanılan kafes yapıların Maxwell stabilite kriteri hesaplamalarını ve buna bağlı olarak beklenen mekanik tepkileri vermektedir.

3.2.5. Kafes yapıların malzeme püskürtme ile üretilmesi


Bu araştırmada, Çizelge 3.1'de gösterilen kafes yapılarının BDT verilerinden fiziksel numuneler üretmek için malzeme püskürtmeli 3B baskı tekniği kullanılmıştır. Malzeme püskürtmeli 3B baskı, en son teknolojiye sahip ve yüksek hassasiyetli Eİ tekniklerinden biridir. Bu yöntem, ortalama 16 μm 'lik katman kalınlığına sahip olan ve voksel olarak adlandırılan 3B piksellerle oluşturulan parçaları üretebilmektedir. İşlem sırasında, mor ötesi (UV) ışık kullanılarak anında katılaşabilen küçük damlacıklar, katmanlar halinde püskürtülerek çalışır. Bu teknik, yüksek çözünürlüklü ve detaylı üretim yapabilme kapasitesiyle dikkat çeker (Şekil 3.5). Bu çalışmada, RGD720 malzemesinden (opak akrilik bazlı fotopolimer reçine) kafes yapılar oluşturmak için bir malzeme püskürtmeli yazıcı (PolyJet Objet30 Prime by Stratasys) kullanılmıştır. Kullanılan fotopolimer malzemenin mekanik özellikleri Çizelge 3.4'te sunulmuştur.



Şekil 3.5. Malzeme püskürtmeli Eİ yönteminin süreç şeması [204]

Test numuneleri, 5 saat boyunca 40°C'de NaOH bazlı çözelti kullanılarak kimyasal olarak çıkarılabilen jel benzeri SUP 706 fotopolimer destek yapıları kullanılarak oluşturulmuştur. Karmaşık ve hassas yapıları basarken desteğin çıkarılmasının çok zor olduğu belirtilmelidir.

Sonuç olarak, mikro gözenekler destekten tamamen çıkarılamadığı için yazdırılabilir hücrelerin minimum boyutu sınırlıdır. Bu nedenle, 2B kafes yapılar minimum destek yapısının kullanıldığı yönde üretilir. Resim 3.1, kafes yapıların yapı plakası üzerindeki baskı konumlarını göstermektedir.






























Resim 3.1. Minimum destek yapısı kullanımı ve en hızlı baskı süresi için yapı plakası üzerinde yönlendirilmiş kafes yapı örnekleri

Çizelge 3.4. RGD 720'nin mekanik özelliklerine genel bir bakış ürün veri sayfasında verilmiştir

Özellik	Standart	Birim	Değer
Polimerize Yoğunluk	M	g/cm ³	1,17-1,18
Çekme Dayanımı	ASTM D-638-03	MPa	40-55
Izod Çentikli Darbe	D-256-06	J/m	20-30
Elastikiyet modülü	D-638-04	MPa	2200-3000
Eğilme dayanımı	D-790-03	MPa	70-85
Kopma uzaması	D-638-05	%	5-20
Bozulma sıcaklığı	D-648-06	°C	45-50

Eklemeli olarak üretilen parçalar genellikle tarama açısına ve yapı yönüne bağlı olarak anizotropik özellikler gösterir. Malzemeleri katılaştırmak veya bağlamak için kimyasal reaksiyonlara dayanan malzeme püskürtme ve stereolitografi gibi teknolojiler, yapı yönleri değiştirildiğinde mekanik anizotropi sergilese de, toz yatağı füzyonu ve malzeme ekstrüzyonu gibi diğer tekniklere göre yapı yönü değişikliklerine daha az duyarlıdır [243]. Buna rağmen, araştırmalar malzeme püskürtme ile basılan parçaların yatay yöne kıyasla dikey yönde daha güçsüz olduğunu göstermiştir [244]. Bu nedenle, çeşitli kafes yapı tasarımları arasında adil bir karşılaştırma sağlamak için, bu çalışmadaki tüm kafes yapılar, anizotropinin mekanik özellikler üzerindeki etkilerini en aza indirecek tam hizalama ile basılmıştır.

Çizelge 3.5. Kafes test numuneleri için kullanılan malzeme, baskı süresi ve üretim maliyetlerinin karşılaştırılması

<i>Birim Hücre</i>	<i>Kafes Test Numunesi</i>	<i>Model (gr)</i> <i>Destek (gr)</i> <i>Süre (Saat/dk)</i> <i>Maliyet (\$)</i>	<i>Birim Hücre</i>	<i>Kafes Test Numunesi</i>	<i>Model (gr)</i> <i>Destek (gr)</i> <i>Süre (Saat/dk)</i> <i>Maliyet (\$)</i>
		4 gr 3 gr 4:03 3,7 \$			6 gr 3 gr 4:03 5,1 \$
		3 gr 2 gr 2:25 2,7 \$			4 gr 2 gr 2:25 3,4 \$
		6 gr 3 gr 4:03 5,1 \$			6 gr 3 gr 4:03 5,1 \$
		5 gr 2 gr 2:25 4,1 \$			5 gr 2 gr 2:25 4,1 \$
		8 gr 3 gr 4:03 6,5 \$			6 gr 3 gr 4:03 5,1 \$
		6 gr 2 gr 2:25 4,8 \$			5 gr 2 gr 2:25 4,1 \$
		8 gr 3 gr 4:03 6,5 \$			6 gr 3 gr 4:03 5,1 \$
		6 gr 2 gr 2:25 4,8 \$			5 gr 2 gr 2:25 4,1 \$
		7 gr 3 gr 4:03 5,8 \$			9 gr 3 gr 2:25 7,2 \$
		5 gr 2 gr 2:25 4,1 \$			7 gr 2 gr 2:25 5,5 \$

Çizelge 3.5, parça ağırlığı, baskı süresi malzeme tüketimi ve tahmini maliyet gibi Eİ için kafes yapıların tasarım kısıtlarını sunmaktadır. Malzeme tüketimi, katı yapıya kıyasla en çok

malzeme kullanılan MG-6 yapısında %35, en az malzeme kullanılan kare yapıda ise %70 oranında azalmaktadır. Destek yapısı kullanımı, sadece yapı plakası ile model yapısının arayüzünde kullanıldığı için tüm modellerde neredeyse aynıdır. Ayrıca, özdeş test numunelerindeki kafes yapıların z yükseklikleri eşit olduğundan, baskı sürelerinde fark edilebilir bir değişiklik yoktur. Bu sonuçtan da görülebileceği gibi, malzeme püskürtme teknolojisinde parçaların x uzunluğu ve z yüksekliği, baskı süresi üzerinde yapının dolgu oranından çok daha önemli bir etkiye sahiptir. Sonuç olarak, toplam üretim maliyeti yaklaşık %65 oranında azaltılabilmektedir.

3.2.6. Mekanik testler ve sayısal analiz

Kafes yapının mekanik özelliklerini belirlemek için basma ve darbe testleri gerçekleştirilmiştir. Basma testi, 50 kN kuvvet limitine sahip 2580 serisi yük hücreli Instron 5969 universal test cihazı kullanılarak yapılmıştır. Rijit hücresel polimer basma testi standartlarına (ASTM, 2000) uygun olarak, basma kuvveti kübik numunelerin ($19,2 \times 19,2 \times 19,2 \text{ mm}^3$) üst yüzeyinden uygulanmıştır. Hız 3 mm/dk olarak ayarlanmış ve test, numune tamamen yoğunlaşana veya dağılana kadar sürmüştür. Basma testinin bir parçası olarak, test numunelerinde gözlemlenen herhangi bir kırılma hatasını tespit etmek için bir video kaydı alınmıştır. Ardından, kırılan yüzeyler arıza mekanizmasını anlamak için bir stereo mikroskop (Leica DMC2900) ile incelenmiştir.

Charpy darbe testi, kırılmadan önce bir malzeme tarafından emilen enerji miktarını ölçen standartlaştırılmış bir testtir [245]. Emilen enerji, bir malzemenin tokluğunun bir ölçüsüdür ve enerjiyi emme ve kırılmadan plastik olarak deforme etme yeteneğini gösterir. Charpy darbe testleri, çentiksiz numuneler ($10 \times 55 \times 10 \text{ mm}^3$) üzerinde, 5-J enerjili darbe çekici ve 1.024 darbe/devir döner kodlayıcı ünitesi ile donatılmış bir Alarge darbe test makinesi kullanılarak gerçekleştirilmiştir. Kırılma yüzeyleri, kırılma mekanizmasını anlamak için bir stereo mikroskop ile gözlemlenmiştir. Testler oda sıcaklığında 40 ± 10 bağıl nemde gerçekleştirilmiştir.

Son olarak, ANSYS statik yapısal modülü kullanılarak test numuneleri üzerinde basma testi simülasyonu gerçekleştirilmiştir. Modeller, yama uyumlu bir yaklaşımla tetrahedral elemanlar kullanılarak mesh haline getirilmiştir. Meshten bağımsızlığı sağlamak için ağ, ardışık mesh boyutları arasındaki fark %5'ten az olana kadar rafine edilmiştir. Elasto-plastik


analiz, akma sonrası aşama için bir gerinim sertleştirme modeli ile malzemenin doğrusal olmayan durumlarını anlamak için kullanılmıştır. Küp kafes numunelerinin bir yüzünün sabitlendiği tek eksenli basma için özel sınır koşulları belirlenmiş ve karşı yüze 1 saniye boyunca 1 mm doğrusal deformasyon uygulanmıştır. Kafes numuneler yoğunlaşma noktasına ulaştığında simülasyon durdurulmuştur. Yük, ayrıntılı analiz için 30 kademede uygulanmıştır.

3.3. Bulgular

GAN ile oluşturulan kafes yapıları sayısal analizler ve mekanik testler ile değerlendirilmiştir. Bu kapsamda ilk olarak, eklemeli imalat sürecinin hassasiyetini belirlemek için üretilen test numunelerinin boyutsal doğruluğu ve kalite kontrolü gerçekleştirilmiştir. Ardından, bu yapıların mekanik karakteri basma testleri ve sayısal analizlerle karşılaştırmalı olarak ortaya konmuştur. Bir sonraki değerlendirme adımında, dinamik yükleme koşulları altında enerji yayma kabiliyeti darbe testi ile analiz edilmiştir. Son olarak, elastik modül belirlenerek kafes tasarımlarının malzeme verimliliği karşılaştırılmıştır. Bu çok katmanlı değerlendirme çerçevesi, derin öğrenme ile oluşturulan kafes yapıların üretim yetenekleri ve sınırlamaları hakkında bütünsel bir bakış açısı sağlamaktadır.

3.3.1. Boyutsal doğruluk ve kalite kontrol

Katmanlı imalatla, parçanın geometrik doğruluğu katman kalınlığı ve baskı çözünürlüğünün bir sonucu olarak değişebilir. En hassas ticari baskı teknolojilerinden biri olan malzeme püskürtme Eİ teknolojisi, 600 x 600 dpi (x ve y eksenleri) baskı çözünürlüğüne ve 16 µm katman kalınlığına sahiptir. Yazıcının katalog verilerine göre, 100 mm'nin altındaki özellikler ± 100 µm sapma gösterirken, daha geniş boyutlu özellikler için doğruluk ± 200 µm veya özellik uzunluğunun $\pm 0,06$ 'sıdır. Basılı hücresel yapıların boyutsal değişimlerini araştırmak için Leica DMC2900 mikroskobu kullanılarak kafes yapılarının görüntüleri elde edilmiştir. Mikroskop görüntülerinde ölçülen değerler ile BDT verileri arasında bir karşılaştırma yapılmıştır (Şekil 3.6). Çizelge 3.6, boyutsal doğruluğu göstermek için çeşitli konumlardan alınan üç ölçümden hesaplanan yüzde sapmayı göstermektedir.



Şekil 3.6. BDT verileri ile 3B baskılı modeller arasında boyutsal karşılaştırma. Tüm boyutlar mm cinsindendir

Ölçülen değerler, eklemeli imal edilmiş yapıların katalog veri kılavuzunda belirtilen sınırlar içinde kaldığını göstermektedir (Çizelge 3.6, Şekil 3.6). Çizelge, nispeten daha küçük tasarım unsurlarına (payanda, düğüm, delik, boşluk vb.) sahip MG-6'nın en yüksek sapmaya sahip olduğunu göstermektedir. Tüm modellerde düğüm geometrilerinin çapı azaldıkça boyutsal sapmanın arttığı anlaşılmaktadır. Boyutsal sapmalar 3B yazıcıların ve baskı teknolojisinin sınırlamalarından kaynaklanmaktadır. Nozullar çalışma sırasında doğrusal bir yol izlediği için mükemmel dairesel ve diyagonal geometriler oluşturmak zordur.


Tüm kafes yapılarda, düğümlerin sınır katmanlarında net bir ayrılma ve çatlak yayılımı görülmemiştir. Bu da yapıların mukavemetini olumlu yönde etkilemektedir. Tüm modellerdeki doğrusal dikmeler çok hassas bir şekilde basılmıştır (sapma < %5). Bununla birlikte, boyutsal sapmalar dikme uzunluğunda ve unsurlar arasındaki mesafede daha belirgindir. Ayrıca dairesel düğümlerde ve birleşme noktalarında aşırı malzeme birikimi görülmektedir. MG-2, MG-4 ve MG-6 gibi ince detaylı yapılarda daha yoğun olarak görüldüğü gibi malzeme enjekte etmek için kullanılan dairesel nozullar nedeniyle keskin köşeler üretilmemektedir. Bu nedenle, en önemli geometrik sapmalar bu modellerde görülmektedir. Ayrıca, MG-3 ve MG-5'teki çapraz yönelimli dikmeler, baskı yönüne paralel olanlara göre %5'e kadar daha fazla sapmaya sahiptir. Beklendiği gibi, açısız özellikler ve dairesel düğümler olmaksızın sadece doğrusal yönlü dikmelerden oluşan kare yapıda minimum sapma gözlenmektedir. Sonuç olarak parça doğruluğu baskı yönünden de etkilenmektedir. Bu nedenle çalışmada adil bir karşılaştırma sağlamak için tüm kafes yapıları benzer şekilde yönlendirilmiştir.

Çizelge 3.6. BDT verilerinin ve basılı özelliklerin kritik bölümlerindeki boyutsal farklılıklar. Sapmalar, basılı özelliklerin BDT verilerinden daha küçük olduğu durumlarda negatif olarak ifade edilir. Tüm boyutlar mm cinsindendir

		<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>			<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>
		<i>BDT</i>					<i>BDT</i>		
<i>Kare</i>	<i>BDT</i>	0,8	8,4	8,4	<i>Diamond</i>	<i>BDT</i>	0,8	5,47	5,94
	<i>Baskı (Ort.)</i>	0,81	8,46	8,48		<i>Baskı (Ort.)</i>	0,82	5,56	6,01
	<i>Sapma (%)</i>	1,25	0,71	0,95		<i>Sapma (%)</i>	2,5	1,65	1,18
		<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>			<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>
		<i>BDT</i>					<i>BDT</i>		
<i>Diamond-Squared</i>	<i>BDT</i>	0,8	5,47	3,4	<i>Body-Centered</i>	<i>BDT</i>	0,8	5,14	3,63
	<i>Baskı (Ort.)</i>	0,79	5,53	3,17		<i>Baskı (Ort.)</i>	0,82	4,97	3,63
	<i>Sapma (%)</i>	-1,25	1,10	-6,76		<i>Sapma (%)</i>	2,5	-3,31	0
		<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>			<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>
		<i>BDT</i>					<i>BDT</i>		
<i>MG-1</i>	<i>BDT</i>	0,8	4,2	3,4	<i>MG-2</i>	<i>BDT</i>	0,8	8,26	3,1
	<i>Baskı (Ort.)</i>	0,78	4,22	3,46		<i>Baskı (Ort.)</i>	0,83	8,3	3,06
	<i>Sapma (%)</i>	-2,5	0,48	1,76		<i>Sapma (%)</i>	3,75	0,48	-1,29
		<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>			<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>
		<i>BDT</i>					<i>BDT</i>		
<i>MG-3</i>	<i>BDT</i>	0,8	8,16	3,55	<i>MG-4</i>	<i>BDT</i>	0,8	7,9	3,21
	<i>Baskı (Ort.)</i>	0,82	7,9	3,56		<i>Baskı (Ort.)</i>	0,83	7,91	3,12
	<i>Sapma (%)</i>	2,5	-3,19	0,28		<i>Sapma (%)</i>	3,75	0,13	-2,80
		<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>			<i>D (1)</i>	<i>D (2)</i>	<i>D (3)</i>
		<i>BDT</i>					<i>BDT</i>		
<i>MG-5</i>	<i>BDT</i>	0,8	4,2	3,21	<i>MG-6</i>	<i>BDT</i>	0,8	3,3	2,8
	<i>Baskı (Ort.)</i>	0,84	4,17	3,33		<i>Baskı (Ort.)</i>	0,84	3,4	2,56
	<i>Sapma (%)</i>	5	-0,71	3,74		<i>Sapma (%)</i>	5	3,03	-8,57

3.3.2. Basma testi ve sonlu elemanlar analizi

Basma testi sırasında test numunelerinin görünümü basma testinden önce, test sırasında ve testin sonunda kaydedilmiştir (Resim 3.2). Kare ve MG-5 yapıları herhangi bir kırılma olmaksızın tamamen yoğunlaşmıştır. Bu numunelerde yüksek gerinim değerlerinin yanı sıra baskın bir eğilme özelliğinin olduğu görülmektedir. Öte yandan, BCS ve MG-2 numuneleri kritik bir yük eşiğinden sonra dağılmıştır. Bu da bu numunelerin gerilme baskın özelliğine bağlı gevrek davranış sergilediğini kanıtlamaktadır. Öte yandan, kayma ve basma gerilmesinin diğer numunelerin kafes tasarımına bağlı olarak kritik düğüm noktalarında ve payandalarda kırılmalarına neden olduğu görülmektedir.



Resim 3.2. Hücresel numunelerin basma testi sürecindeki deformasyon adımları.

Kafes numunelerin basma testi sırasında üç farklı deformasyon aşaması gözlemlenir: doğrusal elastik deformasyon, plastik deformasyon ve yoğunlaşma. Basma testinde, kafes

yapı aynı zamanda akma, burkulma ve kırılma olmak üzere üç temel kırılma mekanizmasına karşı savunmasızdır. Polimer kafes yapısını basitleştirerek doğrusal elastikiyet ile mükemmel plastisite arasındaki doğrusal olmayan geçiş bölgesini minimize etmek mümkündür. Bu süreçte, narinlik oranı, bir dikmenin uzunluğunun çapına oranı olarak tanımlanır ve bu oranın büyüklüğü, dikmenin davranışını etkileyen önemli bir faktördür. Yüksek narinlik oranına sahip uzun ve ince dikmeler, elastik burkulmaya daha yatkındır. Bu durum malzemenin elastik sınırları içinde kalırken, yapısal elemanın yanal olarak saptığı bir hali ifade eder. [216, 246]. Eş. 3.4, bir dikmenin uzunluğunun en küçük dönme yarıçapına olan yüzdesine dayalı olarak narinlik oranını hesaplama sağlar. Kafes yapıların narinlik oranı, dikme uzunluğunun en küçük dönme yarıçapına oranı olan Eş. 3.5 kullanılarak belirlenmiştir.

$$S = \frac{L_e}{r_{min}} \quad (3.4)$$

Bu durumda, minimum dönme yarıçapı, minimum atalet momenti ve dikmenin minimum alanı tarafından belirlenir (Eş. 3.5).


$$r_{min} = \sqrt{\frac{I_{min}}{A}} \quad (3.5)$$

Daha yüksek dikme narinliği, artan burkulma eğilimi ile ilişkilidir [246]. Ayrıca, düşük bağıl yoğunluğa sahip modeller elastik burkulmanın daha güçlü bir baskınlığını sergilemektedir [216]. Euler burkulma gerilmesi, payandalar plastik akma öncesinde elastik burkulma ile çöktüğünde kritik gerilmeyi hesaplamak için kullanılır. Narinlik oranının bir fonksiyonu olarak en yüksek burkulma gerilmesini ortaya koyan Euler burkulma gerilmesi (Eş. 3.6), plastik akma öncesinde elastik burkulmaya neden olan kritik gerilmeyi tanımlamak için kullanılabilir.

$$\sigma_{crit} = \frac{\pi^2 E}{s^2} \quad (3.6)$$

Kırılma mekanizmalarını daha iyi anlamak için basma testinden sonra numuneleri incelemek için bir mikroskop kullanılmıştır (Resim 3.3). Çizelge 3.7'de kafes konfigürasyonlarının bağıl yoğunlukları, narinlik oranı (İng. Slenderness ratio) ve Euler burkulma kritik gerilmeleri gibi yapısal ve mekanik özellikleri listelenmektedir. Çizelge 3.7'ye göre,

maksimum narinlik oranına (36,4) ve en düşük bağıl yoğunluğa (0,23) sahip kare yapı, burkulma kaynaklı deformasyonlara karşı daha hassastır. Bu durum, Şekil 3.9'daki kırılmış numune görüntüsü ile gösterilmektedir. Buna karşın, MG-2 tasarımı daha yüksek bağıl yoğunluğa ve daha düşük narinlik oranına sahip olduğu için burkulma kaynaklı deformasyona daha az eğilimlidir (Çizelge 3.7). Bu da, Resim 3.3'de görüldüğü gibi, aşırı sert gerilme baskın yapının gevrek kırılmasına neden olmaktadır.



Resim 3.3. Basma testinin ardından çeşitli hücresel numunelerde çatlakların oluşması ve yayılması.




Çizelge 3.7. Hücre yapılarının yapısal ve mekanik özellikleri

Hücresel yapı	Narinlik oranı	Özgül yoğunluk	Modül (MPa)	Euler-burkulma kritik gerilmesi (MPa)
Kare	36,4	0,23	320	2,38
Diamond	26,0	0,36	215	3,13
DS	17,0	0,43	335	11,42
BCS	16,0	0,43	380	14,63
MG-1	8,0	0,58	650	100,13
MG-2	5,6	0,42	750	235,80
MG-3	9,6	0,52	420	44,93
MG-4	20,0	0,43	380	9,36
MG-5	20,36	0,46	280	6,65
MG-6	16,4	0,64	420	15,39


Düşük bağıl yoğunluk elastik burkulmaya neden olsa da yüksek narinlik daha baskın bir etkiye sahiptir. Akma deformasyonlu MG-2 ile benzer bağıl yoğunluğa sahip olan MG-4,

yüksek narinlik oranı nedeniyle burkulma kaynaklı deformasyonlar göstermektedir. Son olarak, Maxwell'in stabilite kriterine göre (Eş. 3.3) gerilme baskın özellikli BCS tasarımında gevrek kırılmalar gözlenirken, eğilme baskın MG-6 yapısında burkulma kırılmaları gözlenmiştir. Resim 3.3'ün alt satırındaki yapılar belirgin bir burkulma belirtisi göstermemiş ve plastik deformasyon olmaksızın aniden kırılmıştır. Bu gevrek kırılma gösteren yapılar tipik olarak rijit ve güçlüdür ancak yük altında deforme olmazlar. Çizelge 3.7'de gösterilen Euler burkulma gerilmesinin tahmini değerleri bu argümanı desteklemektedir. Euler'in kritik yükü, ince bir kolonun aniden büküldüğü basınç yükünü ifade eder. Yük, kritik yükün üzerine çıkarılırsa, yanıl sapmalar artar ve malzeme akma gibi başka mekanizmalarla kırılabilir. Euler burkulma gerilmesi değerleri akma dayanımının altında olan modellerde (Resim 3.3'de üstte) burkulma kırılması gözlenirken, akma dayanımının üzerindeki modellerde (Resim 3.3'de altta) gevrek göçme meydana gelmektedir.


Şekil 3.7, basma testinden elde edilen gerilme-gerinim grafiklerini göstermektedir. BCS ve MG-1 kafes yapıları nihai basma dayanımı değerlerine ulaştıktan sonra aniden kırılmıştır. Bu esneme ağırlıklı kafes sistemi, deformasyon modu yerel burkulma ve kırılmaya kaydığı için yıkıcı bir başarısızlığa neden olur. Bu durum yük taşıma kapasitesinde belirgin bir düşüşle sonuçlanır. DS, MG-2 ve MG-3 kafes yapıları doğrusal olmayan elastik tepki gösterir. Doğrusal olmayan elastik tepki, kafes dikme elemanlarının doğrusal olmayan elastik burkulmasını gösterebilir. Bu nedenle, kritik gerilmeden sonra yapıların uzaması belirli bir dereceye kadar artar ve ardından bir kırılma meydana gelir. Diamond ve MG-4, kafes yapı içindeki kritik bölgelerin sıralı kırılması ile ilişkili döngüsel bir tepki gösterir. Eğilme baskın Kare ve MG-5 yapıları, fark edilebilir bir basma mukavemeti olmaksızın kademeli olarak plato gerilmesine geçiş yapar. Yoğunlaşma, bu yapılardaki normalde ayrı olan kafes elemanları arasında temas kurarak gerçekleşir ve bu da kırılma olmadan bu büyük deformasyona izin verecek kadar sünektir. Yoğunlaşma sırasında kafes yapı katı bir yapı gibi davranmaya başlar ve bu nedenle gerilme katlanarak artar.




Şekil 3.7. Eklemeli olarak imal edilen kafes yapılar için basma testlerinden elde edilen gerilme-gerinim diyagramı: (a) Standart kafes yapılar, (b) MG-1, MG-2, MG-3, (c) MG-4, MG-5, MG-6



Şekil 3.8. Tek eksenli sıkıştırma altındaki kafes test numuneleri için ANSYS statik yapısal modülü aracılığıyla elde edilen Sonlu Elemanlar Analizi (FEA) sonuçları: (a) Standart kafes yapılar, (b) MG-1, MG-2, MG-3, MG-4, (c) MG-5, MG-6



Şekil 3.8. (devam) Tek eksenli sıkıştırma altındaki kafes test numuneleri için ANSYS statik yapısal modülü aracılığıyla elde edilen Sonlu Elemanlar Analizi (FEA) sonuçları: (a) Standart kafes yapılar, (b) MG-1, MG-2, MG-3, MG-4, (c) MG-5, MG-6




Şekil 3.8. (devam) Tek eksenli sıkıştırma altındaki kafes test numuneleri için ANSYS statik yapısal modülü aracılığıyla elde edilen Sonlu Elemanlar Analizi (FEA) sonuçları. (a) Standart kafes yapılar, (b) MG-1, MG-2, MG-3, MG-4, (c) MG-5, MG-6 (devam)

Şekil 3.7, MG-2 yapısının deformasyon koşulları altında 25,8 MPa ile kaydedilen en yüksek stres seviyelerini yaşadığını göstermektedir. Buna karşılık, Kare yapı 2,18 MPa ile ölçülen en düşük basınç dayanımını sergilemektedir. Grafik ayrıca BCS yapısının deformasyon altında erken kırılmaya daha yatkın olduğunu, MG-5 modelinin ise deformasyona daha uzun süre dayanabildiğini göstermektedir. Mekanik testlere ek olarak, kafes yapıların yük altındaki deformasyonunu ve eşdeğer gerilmelerini belirlemek için Sonlu Elemanlar Analizi (FEA) yapılmıştır. Hücresel yapıların FEA ile elde edilen eşdeğer gerilme sonuçları Şekil 3.8'de verilmiştir. Şekil, tek eksenli sıkıştırma altındaki kafes test numuneleri için ANSYS statik yapısal modülü aracılığıyla elde edilen Sonlu Elemanlar Analizi (FEA) sonuçlarını içermektedir. Modeller, yama uyumlu bir yaklaşıma bağlı kalınarak dört yüzlü elemanlarla dikkatlice ağ haline getirilmiş ve ağ bağımsızlığı açısından titizlikle test edilmiştir. Doğrusal olmayan malzemeleri simüle etmek için akma sonrası aşamada gerinim sertleşmesi ile elastoplastik malzeme davranışı dikkate alınmıştır. Sonuçlar, malzeme yoğunlaşmasının kırılma olmadan gerçekleştiği koşullara özgüdür. Kafes yapısı içinde en yüksek düzeyde gerilme ve deformasyona maruz kalan alanlar kırmızı ile işaretlenmiştir. Şekil, belirli bir dizi

sınır koşulu, malzeme modeli ve yükleme şeması altında kafes yapıların hem maksimum gerilme hem de deformasyon özelliklerinin kapsamlı bir görüntüsünü sağlamayı amaçlamaktadır.

Şekil 3.7, mekanik basma testlerinden elde edilen gerilme-gerinim eğrileri ile Sonlu Elemanlar Analizi (FEA) yoluyla üretilenler arasında bir uyum olduğunu ortaya koymaktadır. Bu yakın eşleşme, FEA'nın kafes yapıların mekanik performansını tahmin etmek için güvenilir bir teknik olduğunu kanıtlamaktadır. Bununla birlikte, FEA çentikler veya boyutsal yanlışlıklar gibi imalat hatalarını dikkate almaz. Sonuç olarak, gerilme ve gerinim eğrileri, birim hücre yapısının ve boyutunun özelliklerine göre değişerek hafifçe yukarı doğru eğilebilir.

Şekil 3.7'deki gerilme-gerinim grafiklerinden çıkarılan en yüksek mekanik özelliklere ilişkin veriler, kafes yapıların birbirlerine kıyasla gerilme-gerinim değerlerini daha iyi anlamak için Şekil 3.9'da bir harita olarak sunulmuştur. Şekil 3.9'dan açıkça görüldüğü gibi, MG-1 ve MG-2 modelleri elde edilen maksimum gerilme (sırasıyla 26,06 ve 25,16 MPa) açısından diğerlerinden daha iyi performans göstermektedir. Gerilme baskın olarak sınıflandırılan bu yapılar nispeten yüksek sertlik sergilemektedir. Bu gerilme baskın yapı, kuvvete hafif bir sapma ile dayanır. Gerilme baskın BCS yapısı en düşük maksimum gerinimi (0,37 mm/mm) vermektedir. Buna karşılık, en yüksek gerinim MG-5 modelinde görülmektedir (0,51 mm/mm). Eğilme baskın özelliklere sahip Diamond, Kare ve MG-5 yapıları nispeten düşük maksimum gerilme değerlerine sahipken, gerinim değerleri oldukça yüksektir. Bu yapılarda dış kuvvetleri dengeleyecek yeterli sayıda payanda bulunmamakta ve düşük rijitlik göstermektedir. Bu nedenle, kare yapı artan süneklik ve tokluğa rağmen en düşük mukavemete sahiptir. Basma testi sonuçları, birim hücre yapısının mekanik özellikleri önemli ölçüde etkilediğini göstermektedir. Bir kafes yapı, yükleme koşullarını karşılayan özelleştirilmiş birim hücrelerle tasarlanabilir. Genel olarak, GAN ile tasarlanan yapıların bilinen yapılardan daha iyi mekanik performans sergilediği görülmektedir. Gelişmiş mekanik özellikleri sağlayan benzersiz kafes yapıları, derin öğrenme algoritmaları ile hızlı ve kolay bir şekilde uyarlanabilir.



Şekil 3.9. Tüm kafes tasarımları için maksimum gerilime karşı maksimum gerinim haritası

3.3.3. Darbe testi

Kafes yapılar düşük ağırlıkları ve yüksek şok emme kabiliyetleri ile bilinmektedir. Kafes yapıların pratik uygulamalardaki tepkisini anlamak için bir Charpy darbe testi gerçekleştirilmiştir. Bu testte, test numunelerinin maksimum darbe dayanımı, 5 J potansiyel enerjili ve 3,01 m/s darbe hızına sahip bir sarkaç kullanılarak değerlendirilmiştir. Kafes hücrelerinin darbe dayanımları Çizelge 3.8'de gösterilmektedir. İlk bakışta, en yüksek darbe dayanımına sahip kafes yapısının MG-6 olduğu görülmektedir. En yüksek bağıl yoğunluğa sahip olan bu model, dikme yapıları darbe eksenine çapraz olarak uzandığı için güçlü şok emme kabiliyeti sergilemektedir. Öte yandan, MG-4 ve MG-5 modelleri birim hücreler arasındaki noktasal birleşimlerde oluşan yüksek kayma gerilmeleri nedeniyle en düşük darbe emilimine sahiptir. Bağıl yoğunluklar incelendiğinde, gerilme baskın MG-1 modelinin yüksek bağıl yoğunluğuna rağmen diğer modellerden daha düşük darbe emilimine sahip olduğu görülmektedir. Buna karşılık en düşük bağıl yoğunluğa sahip eğilme baskın kare modeli yüksek darbe emme performansı göstermektedir. Buna ek olarak, yüksek gerilimli ve düşük bağıl yoğunluklu Diamond modeli en verimli ağırlık-darbe oranına sahiptir. Genel

olarak, derin öğrenme modeli tarafından üretilen kafes yapıları, standart kafeslere göre daha üstün bir şok emme aralığı sunar.

Çizelge 3.8'in normalleştirilmiş enerji soğurma değerleri, bağıl yoğunluğun etkisi göz önüne alındığında, enerji soğurmada çeşitli kafes yapıların performans verimliliğinin daha derinlemesine anlaşılmasını sağlar. Bu, her bir kafes yapısının enerji emme uygulamalardaki etkinliğinin ayrıntılı bir karşılaştırmasını ve tartışmasını mümkün kılmaktadır. Çizelge, Kare kafes yapısının birim bağıl yoğunluk başına 256,52 kJ/m²'lik normalleştirilmiş enerji emme değeriyle en yüksek enerji emme verimliliğini sergilediğini göstermektedir. Kare kafes yapının yüksek normalleştirilmiş enerji emme değeri, Şekil 3.10'da gösterildiği gibi, düşük gerilme yoğunluğu ve yüksek gerinim kapasitesine atfedilebilir. Bu, kare kafes yapının akma veya kırılma noktasına ulaşmadan önce daha fazla deforme olmasını sağlayarak birim kütle başına diğer daha karmaşık kafes yapılardan daha fazla enerji emmesine olanak tanır. Bu arada, MG-4 kafes yapısı, birim bağıl yoğunluk başına 72,09 kJ/m²'lik normalleştirilmiş enerji emilim değeri ile nispeten yüksek bağıl yoğunluğuna rağmen en düşük enerji emilim verimliliğini sergilemektedir. Bu düşük verimlilik geometriyle ilgili birkaç faktörle açıklanabilir. İlk olarak, yapı, darbe sırasında stres yoğunlukları oluşturan unsur veya düğüm düzenlemelerine sahiptir. İkinci olarak, MG-4 kafesindeki dikmelerin özel yönü ve düzeni optimum yük dağılımını desteklememekte, bazı dikmelerin aşırı stres yaşamasına ve erken kırılmasına yol açmaktadır.

3.3.4. Elastik modülün belirlenmesi ve karşılaştırılması

Belirli bir stres miktarı altında malzeme deformasyonunun (gerinim) bir ölçüsü olan elastikiyet modülü, yük altında malzemenin gerilme veya sıkıştırma miktarını belirlediği için yapısal uygulamalarda kullanılan malzemelerin önemli bir özelliğidir. Hücre tipi, elastik modülü ve dolayısıyla kafes yapıların mukavemetini etkiler [247]. Kafes yapıların elastik modülünü hesaplamak için Hooke yasası (Eş. 3.7) ve Gibson-Ashby denklemi (Eş. 3.8) kullanılmıştır.

Hooke elastik modülü, kafes numunelerin basma testi ile elde edilen doğrusal elastik bölgedeki deformasyon ve yükün ham verileri kullanılarak hesaplanmıştır (Eş. 3.7). Belirli bir akma noktası olmayan bu tür termoplastik malzemelerin akma noktasını belirlemenin

zorluğu nedeniyle, elastik bölge, basma gerilme-gerinim eğrisinin doğrusal bölgesinin %2 oranında kaydırılmasıyla belirlenmiştir.

Çizelge 3.8. Kafes yapıların kafes yapıların Charpy darbe testi sonuçları

<i>Kafes yapısı</i>	<i>Özgül Yoğunluk</i>	<i>$\beta [^\circ]$</i>	<i>Enerji</i>		<i>Normalleştirilmiş Enerji</i>
			<i>Sönümleme [J]</i>	<i>[kJ/m²]</i>	
Kare	0,23	108,6	0,59	59	256,52
Diamond	0,36	110,7	0,48	48	133,33
DS	0,43	107,9	0,65	65	151,16
BCS	0,43	104,8	0,81	81	188,37
MG-1	0,58	108,7	0,53	53	91,38
MG-2	0,42	108,6	0,88	88	209,52
MG-3	0,52	98,8	1,15	115	221,15
MG-4	0,43	113,9	0,31	31	72,09
MG-5	0,46	111,8	0,42	42	91,30
MG-6	0,64	98,1	1,21	121	189,06

$$E = \frac{\sigma}{\epsilon} = \frac{F/A}{\Delta l/l_0} \quad (3.7)$$

Burada, F kuvvet (N), Δl (mm) numunedeki deformasyon, A kuvvetin uygulandığı yüzey alanı (mm²) ve l_0 (mm) deforme olmamış numune uzunluğudur.

Gibson-Ashby ölçeklendirme yasasına göre, elastisite modülü katı yapıların mekanik özelliklerinin ve kafes yapısının bağıl yoğunluğunun bir fonksiyonu olarak ifade edilir (Eş. 3.8).

$$E_{lat} = cE_{sol} \left(\frac{\rho_{cell}}{\rho_{sol}} \right)^n \quad (3.8)$$

Burada, E_{sol} ve E_{lat} sırasıyla yığın malzemenin ve kafes yapının elastikiyet modülüdür. ρ_{cell} / ρ_{sol} hücresel yapının yoğunluğunun katı modelin yoğunluğuna oranını veya daha doğrusu kafes yapının bağıl yoğunluğunu gösterir. Eşit hacimli kafes yapı örneklerinin yoğunluklarını belirlemek için ağırlıkları hassas terazi ile ölçülmüştür (Çizelge 3.9). Gibson-Ashby ölçeklendirme denklemine göre, gözenekli yapıların mekanik özellikleri, yapılara ve birim hücre tiplerine verilen mekanik tepkilerin türlerine (eğilme veya gerilme baskın) bağlı olarak belirlenen katsayılarla değişir. Bu katsayılardan n , eğilme veya gerilmenin baskın olduğu hücresel yapılara [242], c ise birim hücre tipine ve malzemeye bağlıdır.

Gibson-Ashby ölçeklendirme yasasını etkili bir şekilde kullanmak için, hücresel yapıya bağlı olarak korelasyon katsayılarını doğru bir şekilde belirlemek önemlidir. Eş. 3.8'deki 'c' ve 'n' sabitleri doğrusal olmayan bir regresyon yöntemi kullanılarak belirlenir. Ayrıca, Eş. 3.8, yoğunluk ($\rho_{\text{hücre}} / \rho_{\text{sol}}$) ve bağıl elastik modül ($E_{\text{lat}}/E_{\text{sol}}$) sırasıyla x ve y değişkenleri ile değiştirilerek bir güç fonksiyonu (Eş. 3.9) olarak ifade edilebilir.

$$y = cx^n \quad (3.9)$$

Gauss-Newton iterasyon yöntemi daha sonra Eş. 3.9'daki c ve n değerlerini hesaplamak için kullanılır. Çizelge 3.9, Gibson-Ashby ölçeklendirme yasası ile yapının elastikiyet modülünü hesaplamak için Gauss-Newton iterasyon yöntemi ile elde edilen sabitleri göstermektedir.


Şekil 3.10'dan, her iki yöntemle elde edilen elastikiyet modülünün Diamond, DS ve MG-6 gibi modeller için nispeten yakın olduğu görülmektedir. Gerilme baskın MG-2 (en yüksek mukavemetlerden biri) ve MG-5 (en yüksek gerilmelerden biri) için hesaplanan elastik modülde önemli bir fark gözlenmiştir. Bu da Gibson-Ashby metodolojisi ile mekanik özellikler belirlemede ancak payandalar belirli bir narinlik derecesine sahipse yüksek hassasiyet sağladığını doğrulamaktadır. Bu denklemdaki değişkenlerin her farklı kafes yapısı için yeniden hesaplanması ve test edilmesi gerektiği de unutulmamalıdır.

Çizelge 3.9. Gibson-Ashby elastisite modülünü hesaplamak için kullanılan korelasyon katsayıları

Kafes Yapı	Özgül Yoğunluk	c	n	Gibson-Ashby Elastik Modülü (MPa)
Kare	0,23	0,7	1	402,5
Diamond	0,36	0,7	2	226,8
DS	0,43	0,7	2	323,5
BCS	0,43	0,4	1	430,0
MG-1	0,58	0,4	1	580,0
MG-2	0,42	0,4	1	420,0
MG-3	0,52	0,7	2	473,2
MG-4	0,43	0,7	2	323,5
MG-5	0,46	0,4	2	211,6
MG-6	0,64	0,4	2	409,6

MG-2 yapısının modülü Diamond yapısından yaklaşık dört kat daha fazladır. Gelişmiş elastikiyet modülünün bir sonucu olarak yapı, plastik (kalıcı) deformasyona uğramadan daha büyük kuvvetleri taşıyabilir. Bu nedenle, MG-1 ve MG-2 gibi gerilme baskın olan modeller,

elastik uzama oranı eğilme baskın olanlardan daha az olsa da daha büyük gerilimlere dayanabilir. Öte yandan, eğilme baskın MG-5 modeli, üstün gerinim değerine rağmen en düşük elastik modüle sahiptir. MG-5 modelindeki yüksek gerinim değeri, malzemenin stres altında daha fazla deforme olmasına izin veren daha mükemmel sünekliliği gösterir. Tersine, daha düşük elastik modül, yapının daha az sert ancak daha uyumlu olduğunu ve enerjiyi verimli bir şekilde emebildiğini göstermektedir. Düşük elastik modüllerine rağmen, Diamond, Kare ve MG-5 modelleri yüksek gerinim/ağırlık oranının istendiği uygulamalarda tercih edilebilir.



Şekil 3.10. Hooke ve Gibson-Ashby denklemleri ile hesaplanan elastik modülün karşılaştırılması

3.4. Tartışma

Bu çalışma, parametrik tasarım yöntemlerinin GAN sürecini birleştirerek kafes yapıların tasarımına yenilikçi bir yaklaşım sunmaktadır. Bu araştırmanın en kritik adımlarından biri, veri kümesini oluşturmak için parametrik tasarıma bir optimizasyon algoritmasının stratejik entegrasyonudur. Bu entegre yaklaşım, GAN model eğitiminin verimliliğini önemli ölçüde artırarak yüksek performanslı kafes geometrilerinin oluşturulmasını sağlar.

GAN'lar, veri odaklı metodolojileri sayesinde tasarım uzayını verimli bir şekilde keşfedebilir, yeni ve alışılmadık kafes yapılarını ortaya çıkarabilir. Önceden tanımlanmış kısıtlamalarla sınırlı olan optimizasyon tabanlı yöntemlerin aksine, GAN'lar benzersiz bir yenilik potansiyeline sahiptir [248]. Ayrıca, GAN'lar bir kez eğitildikten sonra hızla yeni kafes yapıları oluşturabilir [249]. Bu da onu ölçeklenebilir bir çözüm haline getirir. Böylece GAN'lar, zahmetli ve programlama açısından yoğun yinelemeli prosedürlere kıyasla tasarım sürecinin verimliliğini artırır. GAN'ların üstün yeteneklerine rağmen, çalışma gerçek verileri

yakından yansıtan veriler üretmede zorluklarla karşılaşmıştır. Model mimarisi bu zorluğa yanıt olarak ayarlanmış ve eğitim süresi, iterasyon sayısı ve hiper-parametreler optimize edilmiştir. Bu gelişmelere rağmen, GAN modeli, az miktarda anlamsız geometriler üretmeye devam etmektedir. Gelecekteki araştırmalar, üretilen verilerin kalitesini artırmak için eğitim veri kümesinin boyutunu ve çeşitliliğini genişletmeyi düşünmelidir.

Üretilirlik ve boyutsal doğrulukla ilgili olarak, hücresel yapıların malzeme tüketimi katı modele kıyasla MG-4 için %57, Kare için %70 ve üretim maliyeti %52 ve %65 oranında azalmıştır. Boyutsal doğruluklar açısından incelendiğinde, MG-4 modelinin kendini taşıyan açılı sayesinde %0,1'e varan boyutsal doğrulukla üretildiği görülmektedir. Öte yandan MG-6 gibi ince diyagonal elemanlara sahip modellerde %8,57'ye varan boyutsal sapmalar yüksek hassasiyet gerektiren uygulamalar için dezavantaj oluşturmaktadır. Bu veriler, diyagonal desteklerin paralel olanlara göre %5 daha fazla sapma gösterdiğini ortaya koymaktadır. Bu nedenle, yaklaşım malzeme ve maliyet açısından verimli hücresel yapılar için umut vaat ederken, boyutsal doğruluk ve hesaplama gereksinimleri ile ilgili zorlukları da beraberinde getirmekte ve daha fazla araştırma ve optimizasyon çabası gerektirmektedir.

Sonlu Elemanlar Analizinin (FEA) kafes performansını tahmin etmede güvenilir olduğu ve mekanik test verileriyle yakından uyumlu olduğu doğrulanmıştır. MG-2 25,8 MPa ile en yüksek gerilimi gösterirken, Kare yapı 2,18 MPa ile en zayıf yapı olmuştur. MG-5, kırılmaya eğilimli BCS yapısının aksine deformasyona karşı oldukça dirençli olduğu görülmüştür. Öte yandan, FEA sonuçları ile mekanik testler arasındaki hafif yukarı yönlü farklar, FEA'nın üretim kusurlarını göz ardı etmesine bağlanabilir.

Bu çalışmada, değişen tasarım parametrelerinin mekanik performansı nasıl etkilediğini anlamak için on farklı (4 standart, 6 GAN tarafından oluşturulan) hücresel konfigürasyonun basma ve Charpy darbe testi numunelerini malzeme püskürtme Eİ tekniği kullanılarak basılmıştır. Maxwell stabilizasyon kriterlerine göre değerlendirilen bu hücresel konfigürasyonlar, gerilme baskın ve eğilme baskın mekanik tepkiler olarak sınıflandırılmıştır. Mekanik özellikleri belirlemek için üretilen numuneler üzerinde basma ve darbe testleri gerçekleştirilmiştir. Sonuçlar, bağıl yoğunluk ve hücresel konfigürasyonun kafes yapının mekanik özelliklerini önemli ölçüde etkilediğini göstermektedir. Buna göre, çeşitli uygulamalar ve yükleme koşulları için çeşitli hücre tipleri veya kombinasyonları uyarlanabilir.

Basma testi sonuçlarına göre, GAN modeli ile üretilen kafes yapıların en iyi mukavemete (MG-1 ve MG-2) ve en iyi uzamaya (MG-5) sahip olduğu görülmektedir. MG-1 en yüksek standart yapıya (DS) göre %108 daha fazla mukavemet performansı gösterirken, MG-5 en yüksek uzamaya sahip standart yapıya (Kare) göre %150 daha fazla uzama performansı göstermektedir. Benzer şekilde, derin öğrenme ile oluşturulan modeller yüksek darbe emme kabiliyetine sahiptir. Özellikle MG-6 ve MG-3 en yüksek darbe direncine sahiptir. MG-4 eğilme baskın bir mekanik tepkiye sahip olmasına rağmen, birim hücreler arasındaki zayıf bağlantı nedeniyle en düşük darbe emme kabiliyetine sahiptir.

Dikkat çekici bir şekilde, MG-2'nin modülü Elmas yapının neredeyse dört katıdır ve kalıcı deformasyon olmadan daha büyük streslere dayanmasını sağlar. Bu durum, daha yüksek sünekliliğin göstergesi olan daha yüksek gerinim değerlerine rağmen daha düşük bir elastik modül kaydeden MG-5 modeliyle tam bir tezat oluşturmaktadır. Bu özellik, MG-5'i daha fazla sertlik yerine yüksek esneklik ve verimli enerji emilimi gerektiren uygulamalar için uygun hale getirmektedir. Özetle, GAN gibi derin öğrenme yaklaşımları, kafes yapılarını belirli mekanik özellik gereksinimlerine göre uyarlamaya yönelik geleneksel yöntemlerden daha iyi performans göstermektedir.

3.5. Sonuçlar

Bu bölümde, derin öğrenmenin Eİ 2B kafes yapıların mekanik özelliklerine katkısını detaylı bir şekilde incelemek için kapsamlı bir tasarım, üretim, kalite kontrol, test ve doğrulama süreci sunulmuştur. Standart ve GAN tarafından oluşturulan tasarımlar da dahil olmak üzere on farklı hücresel konfigürasyon, malzeme püskürtme Eİ tekniği kullanılarak basılmıştır. Mekanik performansları FEA, basma ve Charpy darbe testleri ile değerlendirilmiştir. Deneysel olarak doğrulanan sonuçlar, hücre yapısının kafes yapıların mekanik özelliklerini önemli ölçüde etkilediğini ve farklı hücre türlerinin veya bunların kombinasyonlarının çok amaçlı uygulamalar ve yükleme senaryoları için kullanılabileceğini göstermiştir. Bu çalışmanın sonuçları, gelişmiş mekanik performansa sahip kafes yapılar üretmek için bir GAN modeli kullanmanın etkinliğini göstermektedir. GAN modeli tarafından üretilen kafes yapılar, mukavemet ve uzamada kayda değer gelişmelerin yanı sıra yüksek şok emme yetenekleri sergilemiştir. Ayrıca, YZ güdümlü yaklaşım malzeme tüketimini ve üretim maliyetlerini önemli ölçüde azaltarak geleneksel tekniklere kıyasla daha verimli ve uygun maliyetli bir yöntem haline getirmiştir. Unsur boyutlarında bazı boyutsal sapmalar

gözlemlense de çalışmanın genel sonuçları, derin öğrenme tekniklerinin, özel mekanik özelliklere sahip kafes yapıların tasarımında ve üretiminde devrim yaratma potansiyelinin altını çizmektedir.

Bu bölüm, gelişmiş veri odaklı tasarım ve üretim araştırmaları için bir temel oluşturmaktadır. Bunlar arasında daha üstün kafes tasarımları üretmek için daha çeşitli eğitim veri kümelerinin kullanılması ve tasarımların birden fazla performans kriterine göre optimize edilmesi yer alabilir. Sonraki çalışmalar, yapısal bileşenler ile elastik modül, akma dayanımı ve enerji Emilimi gibi mekanik özellikler arasındaki ilişkilerin veri kümesine dahil edilmesini araştırabilir. Kafes tasarımı için alternatif derin öğrenme modellerinin yanı sıra gerçek zamanlı tasarım adaptasyonu için pekiştirmeli öğrenme yöntemleri de araştırılabilir. Son olarak, kafes yapıların mekanik özelliklerini daha iyi anlamak için kapsamlı testler (örneğin, yarı statik ve dinamik basma testleri) yapılmalıdır.

4. VORONOI DİYAGRAMLARI VE PARAMETRİK TASARIM ENTEGRASYONU İLE SENTETİK 3B VERİLER OLUŞTURMA

Derin öğrenme, karmaşık veri kümelerini kavramakta önemli bir kapasiteye sahip olmakla birlikte modelin başarısı ve genelleme yeteneği kaliteli ve çeşitli veri setlerine dayanmaktadır [250]. Özellikle 3B nesne tanıma ve üretken tasarım gibi alanlarda uygun veriye erişim oldukça zor olabilir. Çünkü üretken derin öğrenme modelleri, çeşitlilik eksikliği, model karmaşıklığı ve öğrenme zorlukları gibi olumsuzluklar içerebilir. Bu bölümde, "Parametrik tasarım" ile "Voronoi diyagramı" kombinasyonu kullanılarak oluşturulan sentetik 3B verilerin, model eğitimini nasıl optimize edebileceği incelenmiştir. Önerilen yöntem, tasarım değişkenlerini kolaylıkla düzenleyerek farklı ve özelleştirilmiş veri kümelerinin oluşturulmasını mümkün kılar. Araştırma, özellikle derin öğrenme modellerinin 3B BDT verilerini tanıma ve oluşturma eğitimleri için sentetik veri üretim yöntemini ele almaktadır. Bu yaklaşım, geniş ve çeşitli eğitim verileri ile derin öğrenme modellerinin tanıma ve oluşturma yeteneğini artırabilir, hızlı prototipleme ve mühendislik süreçlerini hızlandırabilir. Ayrıca bu yöntem, karmaşık geometrik parçaları üretme ve özelleştirilmiş veri kümelerini hazırlama süresini ve maliyetini ciddi şekilde azaltabilir.

4.1. Derin Öğrenme Eğitiminde Veri Kümeleri

Derin öğrenme modellerinin başarılı olabilmesi için büyük miktarda, kaliteli ve çeşitliliği yüksek eğitim verileri hayati derecede önemlidir. Bu veriler derin öğrenme model performansını ve genelleme yeteneklerini doğrudan etkiler. Buna karşın yüksek kaliteli ve çeşitli veri kümelerine erişmek her zaman mümkün olmayabilir. Bu durum makine öğrenmesi ve derin öğrenme uygulamalarında karşılaşılan en önemli sorunlar arasındadır. Kalitesiz ve/veya yetersiz verilere bağlı olarak özellikle üretken derin öğrenme modellerinde; yaratıcılık ve çeşitlilik eksikliği, düşük model performansı, aşırı öğrenme, öğrenme zorluğu, sınıf dengesizliği, model karmaşıklığı gibi problemler ortaya çıkmaktadır [251]. Bu sorunu çözmek için azınlık sınıfındaki örnek sayısını artırarak veri kümesini dengeli hale getirmeye çalışan aşırı örnekleme teknikleri geliştirilmiştir [252]. Bir başka seçenek olarak, derin öğrenme yöntemleri ile de sentetik veriler üretilir ve kullanılabilir. Örneğin, otomatik kodlayıcılar, orijinal verilere benzer veriler üretebilen ve yüksek boyutlu verileri düşük boyutlu temsil şeklinde sıkıştıran özel bir sinir ağıdır. Bu nedenle de üretilen

veri çeşitliliği sınırlıdır [253]. Bunun dışında GAN'lar da güvenilir yeni ve çeşitli sentetik veriler üretebilmektedir.

Nispeten yeni bir çalışma alanı olan 3B nesne tanıma ve üretken tasarım yöntemlerinde model eğitimi için yeterli veriye ulaşmak daha zor ve karmaşık bir problemdir. Bu alandaki mevcut veri kümeleri sınırlı sayıda nesne içermesinin yanında model genelleştirme kabiliyetleri de düşüktür. Bu kapsamda yeni veri üretme kabiliyetleri ile GAN modelleri mevcut veri kümelerine ait verileri artırmayı mümkün kılmaktadır. GAN tabanlı modeller kolay bir şekilde gerçek dünya verilerine benzer ve çeşitliliği yüksek veri kümeleri oluşturabilmektedir [254]. Ancak bu modelleri eğitmek için de büyük boyutlu veri kümeleri gerekir [249]. Bu nedenle 3B veri kümeleri oluşturmak için farklı yöntem ve süreçler kullanılır. Örneğin; Planche vd. sensör gürültüsü, malzeme yansıması ve yüzey geometrisi gibi derinlik algılama cihaz mekanizmalarını simüle ederek gerçekçi 3B derinlik verileri üreten bir çerçeve önermiştir. Bu yaklaşım ile elde edilen gerçekçi veriler çeşitli tanıma görevleri için sinir ağlarının eğitim performansını iyileştirdiği belirtilmiştir [255]. Bir başka çalışmada Ibrahim ve Kashef el hareketi tanıma araştırması için insan figürü tasarım yazılımıyla oluşturulan sentetik 3B animasyon modelleri kullanarak istatistiksel ve görsel sentetik veri üretimine ait karşılaştırmalı bir çalışma yapmıştır. Burada görsel sentetik veri oluşturma/artırma sürecinin eğitim veri kalitesi ve çeşitliliğine katkı sağlandığı gösterilmiştir [256]. Siu vd. sanal simülasyon, stil aktarımı ve karşılaştırmalı öğrenme kullanan bir çerçeve ile kanalizasyon borusu kusur tespitindeki veri eksikliği sorununu 3B sentetik veriler üreterek ele almıştır. Bu araştırma büyük miktarda gerçek denetim verisine olan ihtiyacı azaltmayı ve kusur tespiti performansını iyileştirmeyi amaçlamaktadır [257]. Mursalin ve İslam ise sentetik veri üretimi ve veri etiketlemeyi içeren, 3B nokta bulutlarında kulak tespiti için kapsamlı bir iş akışı önermektedir. Yazarlar PointNet++'ın değiştirilmiş bir versiyonu olan EarNet ile döndürme ve büyütme yoluyla gerçek verilerdeki farklı poz varyasyonlarını ele almıştır. Burada, deneysel sonuçların, mevcut son teknoloji yaklaşımlara göre daha yüksek lokalizasyon gösterdiği belirtilmiştir [258]. Diğer bir çalışmada karmaşık ortamlarda nesne tanımak için 22 nesneden oluşan bir sentetik veri kümesi oluşturularak derin bir nesne tanıma çerçevesi geliştirmeye ve doğrulamaya çalışılmıştır. Bu çalışma sentetik derinlik verilerinin derin nesne algılama modellerini eğitmek için kullanıldığında veri toplama süre ve emeğinin azaldığını göstermiştir [259]. Benzer bir çalışmada Salas vd. makine parçalarını ayırma/tasnif için bilgisayar grafikleri ve gerçek makinelerin 3B modellerini kullanan bir yaklaşım sunmuştur. Yazarlar oluşturulan veri kümesini gerçek bir veri kümesi ile

karşılaştırmak için Mask-R-CNN modelini kullanmışlardır. Elde edilen sonuçlar sentetik veri üretiminin makine tasnif alanındaki derin öğrenme model eğitiminde kullanılabileceğini göstermektedir [260].


Yukarıdaki çalışmaların haricinde otonom 3B sentetik veri üretimi amaçlı birçok çalışma mevcuttur. Ancak bu çalışmaların çoğu genel amaçlı olup, iş parçası ve makine imalatı alanında sentetik veri üretimi çalışmaları sınırlı sayıdadır. Bu bağlamda farklı tasarım bileşenleri arasındaki ilişkileri tanımlamada parametre ve algoritma kullanımını içeren karmaşık geometrik formlar oluşturmak ve değiştirmek için parametrik tasarım yaklaşımı kullanılabilir. Parametrik tasarıma bir alanı bazı noktalara olan mesafelere göre bölgelere ayırmaya yarayan matematiksel bir araç olan Voronoi diyagramlarını entegre etmek, bu yöntemin yeteneklerini daha da geliştirebilir. Bu araştırmada derin öğrenme modellerini eğitiminde kullanılacak çeşitli ve kaliteli 3B veri kümeleri oluşturmak için Voronoi diyagramları ile parametrik tasarımın birleştirilmesi incelenmiştir. Voronoi diyagramlarını parametrik tasarıma entegre etmek, 3B veri kümeleri oluşturmak için birçok avantaj sunar. İlk olarak, gerçek nesneleri ve ortamları tanımak ve analiz etmek için derin öğrenme modelleri eğitiminde gerekli olan karmaşık geometrileri oluşturma sağlar. İkincisi, bu yaklaşımın parametrik yapısı, çeşitli ve özel veri kümelerini kolay oluşturma ve sorunsuz tasarım parametre değiştirilmesine izin verir. Son olarak, Voronoi diyagramları ve parametrik tasarımın birleşimi büyük ölçekli 3B veri kümeleri oluşturmak için gerekli zaman ve hesaplama kaynaklarını büyük ölçüde azaltabilir.

Bu bölüm, Voronoi diyagramının parametrik tasarıma entegrasyonu sayesinde, yapısal iş parçalarını tanıma ve üretme için derin öğrenme model eğitimi amacıyla sentetik 3B BDT verileri üretmeye yönelik yeni bir yöntem önermektedir. Yapısal iş parçalarından oluşan sentetik 3B veri kümeleri, derin öğrenme ve makine imalatı alanında önemli katkılar sağlar. Öncelikle, geniş ve çeşitli eğitim veri setleri ile derin öğrenme modellerin karmaşık yapıları tanıma ve üretme yeteneğini geliştirir. Ayrıca, gerçek verilere benzer yapılar sunarak modellerin gerçek koşullarda doğru ve güvenilir sonuçlar sağlamasına yardımcı olur. Sentetik veriler gerçek veri eksikliği ve dengesizliği sorunlarını da azaltarak derin öğrenme modellerin daha iyi ve kapsamlı performans göstermelerini sağlar. Son olarak sentetik 3B veri kümeleri yeni ve özgün yapısal iş parçalarını belirleme ve üretmek için derin öğrenme modelleri kullanmayı mümkün kılar. Böylece inovatif tasarım ve üretim süreçleri geliştirmeyi kolaylaştırır.

Önerilen yöntemin geçerliliği ve uygulanabilirliğini gösterebilmek için helikopter rotorlarında yük ve hareket iletimi sağlayan bir bileşen için gerçek verilere dayalı sentetik bir 3B veri kümesi oluşturulmuştur. Oluşturulan bu veri kümesi tez kapsamında önerilen çalışma için gerekli veri kaynağını içermektedir. Dahası bu çalışma 3B veri kümeleri oluşturma amaçlı yeni bir yaklaşımı sunarak, derin öğrenme modellerinin performansını ve genelleştirme yeteneklerini artırma kapsamlı araştırmalara katkıda bulunmayı hedeflemektedir.

4.2. Metodoloji

Voronoi diyagramının parametrik tasarım sürecine dahil ederek sentetik 3D BDT veri kümesi elde edilmesi süreci Şekil 4.1’de gösterilmektedir. Her adımın ayrıntıları sonraki bölümlerde açıklanmaktadır. Ancak, sentetik 3B kümeleri oluşturmadan önce 3B model temsil yöntemlerini kavramak gerekir.



Şekil 4.1. Sentetik veri kümesi oluşturma akış şeması


4.2.1. 3B model temsil yöntemleri

3B model nesne, ortam ve canlıların bilgisayar ortamında görselleştirilmesi için kullanılan matematiksel temsillerdir. Bu modeller tasarım, simülasyon ve üretim alanlarında yaygın olarak kullanılmaktadır. 3B modelleme için poligon mesh, voksel ve nokta bulutu olmak üzere 3 farklı temel temsil yöntemi vardır [261]. Bu temsil yöntemleri Şekil 4.2’de gösterilmiştir.


Poligon Mesh

Poligon meshler, 3B nesneleri temsil etmek için kullanılan yaygın bir yöntemdir. Bu temsil yöntemi, nesnenin yüzeyini basit geometrik şekiller olan poligonlarla (üçgen, dörtgen gibi) kaplar [263]. Her poligon, 3B uzayda belirli bir konumu olan köşe noktalarıyla tanımlanır ve bu köşe noktaları arasındaki doğru parçaları kenar olarak adlandırılır. Poligonlar, üç veya daha fazla kenarın sınırladığı 2B yüzeyler olarak düşünülebilir. Bu yüzeyler birleşerek 3B uzayda bir nesnenin yüzeyini oluşturur.


Nokta bulutu



Voksel



Poligon Mesh



Şekil 4.2. 3B model temsil yöntemleri: Nokta bulutu, Voksel ve Poligon mesh [262].

Poligon meshleri, karmaşık yüzey geometrilerini temsil edebilme esnekliğine sahiptir. Köşe noktaları (İng. vertex), kenarlar (İng. edge) ve yüzler (İng. faces) eklenip silinebilir ve kolayca düzenlenebilir. Ancak, pürüzsüz yüzeyleri temsil etmede sınırlamaları vardır. Yeterli mesh yoğunluğuna ulaşamadıklarında özellikle tekrarlayan yapılar veya çok pürüzsüz yüzeyler için bu sınırlamalar ortaya çıkar. Yüksek ayrıntılı modellerde mesh yoğunluğu arttıkça hafıza kullanımı da artabilir. Poligon meshleri, bilgisayar grafikleri, oyun geliştirme, film ve animasyon, sanal gerçeklik ve bilgisayar destekli tasarım gibi birçok endüstride yaygın olarak kullanılır. Modelleme yazılımları, kullanıcıların 3B poligon meshleri oluşturmalarına, düzenlemesine ve görselleştirmesine olanak tanır.

Voksel

Vokseller, 3B uzayda bir nesnenin veya sahnenin temsil edilmesi için kullanılan hacimsel piksellerdir. Bu temsil yöntemi, 2B görsellerde piksellerin ızgara şeklinde düzenlenmesine benzer şekilde, 3B uzayda düzenli bir ızgara üzerine yerleştirilmiş küçük hacimli

birimlerden oluşur [264]. Her voksel, belirli bir hacim, konum, renk, yoğunluk gibi özelliklere sahiptir.

Voksel temsilinin en belirgin avantajlarından biri boşluklu yapılar ve hacimsel özelliklerin doğrudan temsil edilmesidir. Bu, özellikle iç yapıların önemli olduğu bileşenlerde oldukça kullanışlıdır. Bununla birlikte, yüksek çözünürlüklü voksel verileri, çok miktarda bellek ve depolama kapasitesi gerektirebilir [265]. Çoğu BDT yazılımı voksel temsillerini doğrudan desteklemez. Vokselleri görselleştirmek için çeşitli teknikler vardır, bu teknikler genellikle vokselleri poligon meshlerine dönüştürür.

Nokta bulutu


Nokta bulutu, 3B uzayda nesneleri veya sahneleri temsil etmek için bireysel noktaların bir araya gelmesiyle oluşan model temsil yöntemidir [264]. Her nokta, genellikle bir X, Y ve Z koordinatıyla belirtilen bir konuma sahiptir. Bu noktalar, genellikle lazer veya optik tarama gibi tekniklerle toplanır. Oluşturulan noktalar, genellikle, nesnenin veya sahnenin dış yüzeyini temsil eder.

Nokta bulutu nesne veya ortamın yüksek hassasiyet ve doğrulukla bilgisayar ortamına aktarılmasına olanak tanır [266]. Özellikle lazer tarama yöntemi kullanılarak toplanan verilerde mikrometre düzeyinde hassasiyet elde edilebilir. Ancak nokta bulutları birçok işlem için diğer temsil yöntemlerine dönüştürülmesi gerekir. Nokta bulutundan mesh oluşturma, özellikle büyük ve karmaşık nesneler söz konusu olduğunda zorlayıcı bir problem olabilir.

Nokta bulutları, genellikle mimari belgeleme, tarihi eser restorasyonu, sanayi uygulamaları, şehir modelleme ve jeodezik ölçümler gibi birçok alanda kullanılır. Özellikle, 3B lazer taramanın giderek daha erişilebilir hale gelmesiyle birlikte, nokta bulutları daha geniş bir kullanıcı kitlesi tarafından kabul görmeye başlamıştır.

Bu yöntemlerin birbirine karşı bazı üstün ve zayıf yönleri mevcuttur. Uygulama alanına göre ideal temsil yöntemi seçilir. Bir uygulamanın farklı aşamalarında farklı temsil yöntemleri de kullanılmaktadır. Temsil yöntemleri arasındaki dönüşüm Şekil 4.3'te temsili olarak gösterilmiştir. Bu temsil yöntemlerinin haricinde ileri modelleme ve özel uygulamalar için

geliştirilmiş başka yöntemler de mevcuttur. Bunlar genellikle mesh temelli özelleşmiş temsil yöntemleridir. Bunlardan en bilinenleri NURBS ve Bölütlenmiş Yüzeylerdir.



Şekil 4.3. Nokta bulutunun mesh ve Voksel temsiline dönüştürülmesi

NURBS

Düzgün Olmayan Rasyonel Temelli Eğri (İng. Non-Uniform Rational B-Spline, NURBS), 3B nesnelerin ve yüzeylerin matematiksel olarak temsil edilmesi için kullanılan bir tekniktir. NURBS, karmaşık ve düzgün yüzeylerin oluşturulmasını ve düzenlenmesini sağlar. Bu yöntem, endüstriyel tasarım, BDT, animasyon ve diğer birçok alanda yaygın olarak kullanılır. NURBS'lerin temel bileşeni kontrol noktaları ve ağırlık eğrileridir. Kontrol noktaları, yüzeyin veya eğrinin genel şeklini tanımlar, ancak yüzey doğrudan bu noktalar üzerinden geçmez. Bunun yerine, bu noktaların etrafında bir yüzey veya eğri oluşturulur. Ağırlıklar, kontrol noktalarının yüzeye veya eğriye olan etkisini değiştirmek için kullanılır, bu sayede daha fazla kontrol ve esneklik sağlanır.

NURBS'lar hem basit (düz çizgiler, daireler) hem de karmaşık yüzeylerin (karmaşık organik şekiller) temsil edilmesine olanak tanır. Ayrıca, NURBS yüzey ve eğrileri, kesinlikle tanımlanmış matematiksel formüllere dayandığı için yüksek hassasiyette ve düzgünlükte olabilir. Bu, özellikle hassas mühendislik ve üretim gereken uygulamalarda tercih sebebidir. Bununla birlikte, NURBS temsilinin bazı sınırlamaları da vardır. Örneğin, karmaşık ve ayrıntılı yüzeylerin oluşturulmasında, kontrol noktalarının sayısının artmasıyla yönetilmesi zorlaşabilir.

NURBS temsili, otomotiv tasarımı, havacılık mühendisliği, endüstriyel ürün tasarımı, karakter ve nesne modellemesi gibi birçok alanda tercih edilen bir yöntemdir. Bu temsil, yüzeyin düzgünlüğü ve kontrollü şekilde düzenlenebilmesi nedeniyle bu uygulamalar için idealdir.

Bölütlenmiş yüzeyler

Bölütlenmiş Yüzeyler (İng. Subdivision Surfaces) ise poligon meshlerini daha yüksek çözünürlükte ve daha pürüzsüz hale getirmek için kullanılan bir diğer geometri temsil yöntemidir. Bu yöntem, bir meshin poligonlarını bölme ve ardından sonucu pürüzsüzleştirme sürecidir. Bu süreç, istenen düzgünlük ve detay seviyesine ulaşılan kadar tekrarlanabilir.

Bölütlenmiş yüzeylerin ana fikri, başlangıçta düşük çözünürlükte bir meshle başlamak ve ardından onu iteratif olarak iyileştirmektir. Her bölütlenme adımında, meshin poligon sayısı artar ve yüzey daha pürüzsüz hale gelir. Bu, özellikle animasyon ve oyun endüstrisinde kullanışlıdır. İlk aşamada düşük çözünürlükte bir model ile hızlı bir görselleştirme sağlanır ve daha sonra yüksek çözünürlükte bir yüzey elde edebilirler.

4.2.2. Parametrik tasarım

Hesaplamalı tasarım, matematiksel işlemler, algoritmalar ve yapay zekayı tasarım süreçleriyle birleştiren disiplinler arası bir yaklaşımdır [267]. Burada mimari, mühendislik, ürün geliştirme ve dijital ürünler gibi konular ile ilgili tasarım, analiz ve optimizasyon vb. işlemleri için bilgisayar tabanlı teknikler kullanılır [268]. Bu yaklaşım ile daha büyük bir tasarım uzayı oluşturulması ve etkin tasarım optimizasyon işlemleri mümkün olabilir. Bu yaklaşımın bir alt dalı olan “parametrik tasarım” ise parametre ve matematiksel ilişkilere dayalı tasarım öğelerini tanımlama ve belirli kurallara göre değiştirmeye izin veren bir tasarım metodolojisidir. Bu metodoloji; kolay değiştirilebilen, esnek, uyarlanabilir ve hassas tasarım modelleri oluşturmaya olanak tanır [269]. Parametrik tasarımda geometrik unsur özellikleri ve diğer unsurlarla ilişkiler bazı değişken ve sınırlayıcılar ile tanımlanır. Bu değişken ve sınırlayıcıların düzenlenme ve değiştirilmesi ile de birçok tasarım varyantı elde edilebilir [270].

Parametrik tasarımın temel avantajlarından birisi uygulanabilir ve verimli tasarım varyantları oluşturmayı kolaylaştırmasıdır. Parametrelerin değiştirilmesi ile tasarım modeli eş zamanlı olarak güncellenir [271]. Bu durum yapılan değişiklik ve düzenleme etkilerini hızla görselleşme ve değerlendirmeye olanak tanır. Bu yinelemeli süreç, belirli hedeflere ve kısıtlamalara göre tasarımın sürekli iyileştirilmesine ve optimize edilmesine olanak sağlar [272]. Böylece daha yüksek kalite ve daha yenilikçi çözümlere ulaşılabilir. Bu modeller ayrıca disiplinler arası iş birliğini teşvik eder. Bunlar; bilgisayar bilimi, matematik, malzeme bilimi ve uygulamaya göre özel alan bilgisi gibi bazı kaynaklardan beslenir [226]. Bu uzmanlık alan etkileşimleri karmaşık sorunlara ait daha bütünsel ve dengeli tasarım çözümleri bulmayı sağlar [273]. Böylece tasarımcılar için aralarında en iyi ve mükemmel olanları seçebilecekleri birçok tasarım varyantı üretebilir. Tasarım sürecini otonom hale getirerek tasarım çözümleri oluşturma ve geliştirme sürecinde gereken zaman ve çabayı önemli ölçüde azaltır [274]. Bu artan verimlilik ile tasarımcılar yüksek düzeyde karar süreçleri ve yaratıcı keşiflere odaklanabilir. Ayrıca parametrik tasarım, bazı performans kriterleri ve sınırlayıcılara göre özel ve özgün çözümler geliştirmeye olanak tanır [275]. Bu yaklaşımın bir başka özelliği ise karmaşık 2/3B veri kümeleri oluşturma ve değerlendirme yeteneğidir. Yukarıda değinilen iteratif tasarım süreci sonunda tasarım varyantları üretme, değerlendirme ve geri bildirimle dayalı olarak veri kümeleri oluşturulabilir. Bu yeni kümeleri derin öğrenme modelleri için rafine edilmiş eğitim malzemesi olarak kullanılabilir.

Parametrik tasarım karmaşık ve büyük 3B parçaların kısa sürede oluşturulması ile derin öğrenme çalışmalarına, özellikle 3B veri analizi ve işleme kapsamlı, önemli katkılar sağlar [12]. Örneğin derin öğrenme modelleri, etkili eğitim için genelde büyük miktarda etiketli veri gerektirir. Büyük ölçekli 3B model veri kümelerinin otomatik olarak üretmesi, (veri kıtlığı sorununu aşmada) araştırmacılara, derin öğrenme modellerini etkin bir şekilde eğitmek ve test etmek için yeterli veri sağlar [276]. Ayrıca otomatik süreçlerle üretilen 3B farklı ve özgün veri kümeleri, derin öğrenme modellerine daha iyi genelleme yeteneği sağlar. Kapsamlı ve çeşitli bir veri kümesi ile eğitilen derin öğrenme modeli daha önce karşılaşmadığı verilerde daha iyi performans gösterebilir. Bunun dışında sentetik 3B veri kümeleri üretmek, manuel veri toplama ve ön işleme için gerekli zaman ve çabayı azaltarak araştırma sürecini hızlandırır. Böylece belirli bir uygulamaya ait sorun ve gereksinimlere hitap için özellikle tasarlanmış derin öğrenme modelleri geliştirmeyi mümkün kılar.

Parametrik tasarım, modern tasarım süreçlerinde parametrik tasarım geleneksel uygulamaları dönüştürme ve kolaylaştırma sağlar. Bu bağlamada; yaratıcılık, verimlilik, optimizasyon ve disiplinler arası iş birliği oluşturur. Bu yaklaşım ile tasarımcılar, değişen ihtiyaçları karşılayan inovatif, işlevsel ve sürdürülebilir çözümler geliştirebilir. Ayrıca, parametrik tasarımın otonom veri kümesi oluşturma kabiliyeti ile büyük ölçekli ve normalize edilmiş 3B model veri kümeleri, 3B veri analizi ve işleme kapsamlı derin öğrenme çalışmalarına önemli katkıda bulunur.

4.2.3. Voronoi diyagramı

20. yüzyılın başlarında matematikçi Georgy Voronoy tarafından geliştirilen “Voronoi diyagramı” matematik, hesaplamalı geometri ve uzamsal analiz gibi çeşitli alanlarda önemli bir araştırma konusu haline gelmiştir. Bu diyagramlar bir alanı bölmek için bazı çekirdek (odak) noktalarına dayalı verimli bir alan kullanımı sağlar. Ortaya çıkan bölümler (Voronoi hücreleri), uzayda ilgili çekirdek noktasına diğer herhangi bir çekirdek noktasından daha yakın olan tüm noktaları dahil eden uzamsal alanlardır [277]. Voronoi diyagramlarına ait bu uzamsal bölümlene özelliği, bilgisayar grafiği, robotik ve makine öğrenimi gibi çeşitli alanlarda yakınlık ve bitişiklik ilişkilerinin daha kolay, etkin ve manidar incelenme, düzenlenme ve tasarlama sağlar.


Voronoi diyagramlarını daha iyi anlamak ve uygulayabilmek için öncelikle nokta kümeleri, metrik uzaylar ve yakınlık grafikleri ile ilgili bazı kavramları anlamak gerekir. Böylece yapılacak uygulamalar için gerekli çalışmalar daha kolay gerçekleştirilir. Bu kavramlardan ilki olan “nokta kümesi”, bir, iki veya üç boyutlu (1B, 2B veya 3B) geometrik bir uzayda yer alan noktalar bütünüdür. Bu boyutlar, uzayda bir noktanın konumunu tanımlayan eksen sayısına (veya serbestlik derecesi) karşılık gelir. Nokta kümesi içindeki herhangi iki nokta arasındaki mesafeyi tanımlayan fonksiyona metrik uzay olarak ifade edilir. Bu uzaklık fonksiyonu; negatif olmama, simetri ve üçgen eşitsizliği gibi bazı özellikleri taşımalıdır. Metrik uzayda en sık kullanılan mesafe fonksiyonu, Pisagor teoreminden türetilen Öklid mesafesidir [278]. Öklid uzaklık fonksiyonu nokta koordinatları arasındaki farkların kareleri toplamının karekökü olarak hesaplanır. Örneğin, 2B uzayda bulunan iki nokta $P_1(x_1, y_1)$ ve $P_2(x_2, y_2)$ arasındaki Öklid mesafesi, Eş. 4.1 ile gösterilmiştir. Manhattan ve Chebyshev fonksiyonları ise farklı özelliklere sahip metrik uzayları tanımlamada kullanılan başka mesafe fonksiyonlarıdır [279].

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (4.1)$$

Voronoi diyagramları, hesaplamalı geometrinin temel konulardan biri olup belirli bazı çekirdek (odak) noktası veya bölgesine yakınlık derecesine bağlı olarak kolay ve etkili bir şekilde uzamsal bölümlendirme yöntemini içerir. Voronoi diyagramı metrik uzayda belirli bir sayıda çekirdek noktası verildiğinde, $S = \{s_1, s_2, \dots, s_n\}$ uzayın n bölgeye bölünmesini sağlar. Her bir Voronoi hücresi $V(s_i)$, bir çekirdek noktası s_i ile ilişkilendirilir ve uzaydaki (S) diğer herhangi bir çekirdek noktasından daha yakın olan tüm noktalardan oluşur. Bir Voronoi hücresinin $V(s_i)$ formal ifadesi Eş 4.2'de gösterilmiştir. Burada $d(x, y)$, x ve y noktaları arasındaki mesafe fonksiyonunu belirtirken S başlangıç noktaları kümesini ifade eder.

$$V(s_i) = \{x \mid d(x, s_i) < d(x, s_j) \forall s_j \in S\} \quad (4.2)$$

Bir Voronoi diyagramı, düğümlerin Voronoi köşelerine karşılık geldiği ve kenarların bitişik Voronoi hücreleri arasındaki sınırları temsil ettiği düzlemsel bir grafik olarak gösterilebilir. Voronoi köşeleri, uzayda en az üç çekirdek noktasına eşit uzaklıkta olan noktalardır. Voronoi kenarları, Voronoi hücrelerini ayıran çizgi parçaları (2B'de) veya yüzeylerdir (3B'de) ve en az iki çekirdek noktasına eşit uzaklıkta olan noktalardan oluşur. Şekil 4.4'de de görüldüğü gibi her bir Voronoi kenarı, iki Voronoi köşesini birbirine bağlar ve iki Voronoi hücresini ayırır.



Şekil 4.4. Temel bir Voronoi grafiği

Voronoi diyagramı, mühendislik tasarımında kullanılması her geçen gün daha fazla popüler olmaktadır. Geometrik desenler ve yapılar, bir projenin performansını ve estetiğini önemli ölçüde etkileyebilir. Voronoi diyagramları, esneklik, optimizasyon ve estetik çözümler sunarak tasarım sürecini iyileştirmeye yardımcı olur. İlk olarak Voronoi diyagramları, tasarımların belirli performans kriterlerine göre optimize edilmesine olanak tanır. Voronoi diyagramları, kaynak kullanımını en üst düzeye çıkarmak ve belirli hedeflere ulaşmak için tasarımları revize etmeye yardımcı olur. Diğer taraftan Voronoi diyagramları görsel olarak cazip ve benzersiz tasarımlar oluşturmayı kolaylaştırır. Doğada bulunan yapılar ve desenlerle benzerlik gösteren Voronoi desenleri, organik ve doğal görünümlü tasarımlar oluşturmak için kullanılabilir.

Mühendislik tasarımında Voronoi diyagramlarının kullanımı, geometrik desenlerin ve yapıların kolayca değiştirilmesine ve yeniden şekillendirilmesine olanak tanır. Bu durum, tasarımcıların değişen gereksinimlere ve sınırlamalara hızlı bir şekilde uyum sağlayabilen tasarımlar üretmesine yardımcı olur. Bu, özellikle mimari, ürün tasarımı ve peyzaj mimarisi gibi alanlarda çok önemlidir.

4.2.4. Voronoi diyagramının parametrik tasarıma entegre edilmesi

Güçlü bir uzamsal bölme aracı olarak Voronoi diyagramı bilimsel disiplinlerde yaygın kullanılır. Bunlardan ilki alan planlama ve bölme, görünürlük ve erişilebilirlik analizi uygulamalarını içeren mimari ve şehir planlamadır [280]. Bir diğer kullanım alanı ise gelişmiş performans özelliklerine sahip inovatif yapılar ve malzemeler ait malzeme tasarımı ve yapısal optimizasyonu içerir. Mekânsal bölme özellikleri, gözenekli malzeme, kafes yapıları ve optimize edilmiş gerilim dağılımına sahip yük taşıyan yapılar oluşturmaya olanak sağlar. Voronoi diyagramı, kontrollü bir gözenek dağılımı ve değişken mekanik özellikler ile bu tür yapılar oluşturmada etkili bir yöntemdir. Ayrıca bu diyagramların yakınlığa dayalı alan bölme yetenekleri, yük ve gerilmeleri en uygun şekilde dağıtan yapıları ile gerilime maruz kalan parçaların tasarımı ve analizinde de kullanılmalarını mümkün kılar. Bunlara ek olarak Sonlu elemanlar Analizi (FEA), yapı tasarımını iteratif iyileştirmek için Voronoi diyagramlarıyla birleştirilerek yapısal elemanlarda optimum gerilim dağılımı ve malzeme verimliliği sağlayabilir.

Parametrik ve üretken tasarım yaklaşımları tasarım parametrelerine dayalı ve kolayca özgün, inovatif ve uyarlanabilir / uygulanabilir tasarım varyantları oluşturma sağladıkları için son yıllarda büyük rağbet görmektedir [281]. Voronoi diyagramı da tasarım istek ve sınırlayıcılarına yanıt veren işlemsel model ve uyarlanabilir tasarımlar yaratmak için parametrik ve üretken tasarıma dahil edilmiştir [282]. İşlemsel model oluşturma algoritması ile tasarım verimliliğini artırma, özgün ve probleme özel tasarımlar üretme yeteneği ve geniş tasarım alanlarını keşfetme ve değerlendirme gibi bazı avantajlar sunar. Bunlara ek olarak yakınlık tabanlı bölme ve mozaik oluşturma özellikleri ile Voronoi diyagramları gerçekçi ve çeşitli sentetik veri kümeleri oluşturma sağlayabilir. Bu diyagramların özelleştirilmesi uyumlu/tutarlı veri kümeleri oluşturulmada önemli bir özelliktir. Voronoi diyagram ile parametrik tasarımın birleşimi, parametreleri kolayca düzenleyerek birçok tasarım varyantı oluşturma sağlar. Bu özellik farklı ihtiyaç ve tercihlere uygun veri kümeleri üretmek için çok yararlı olabilir. Örneğin, 3B nesneleri veya sahneleri temsil eden sentetik nokta bulutları oluşturmak için Voronoi diyagramları kullanılabilir. Voronoi hücreleri kullanılarak, makine öğrenme algoritmalarını eğitmek ve test etmek, bilgisayarlı görü tekniklerini doğrulamak, görselleştirme veya simülasyon için 3B modeller oluşturmak gibi amaçlar için çeşitli ve gerçekçi nokta bulutları/geometrilere oluşturabilirler. Özellikle makine öğrenmesi algoritmalarını bu sentetik verilerle eğitmek ve test etmek veri kıtlığı ve yanlılıkla ilgili zorlukların üstesinden gelmeye yardımcı olabilir.

Son zamanlarda bu diyagramları oluşturma ve değiştirmeyi kısmen basitleştiren bilgisayar yazılımları geliştirilmesi, parametrik tasarımda Voronoi diyagramları kullanmaya olan ilgiyi artırmıştır [283]. İlk olarak Voronoi diyagramlarını oluşturmak ve görselleştirmek için özel olarak geliştirilmiş birkaç bağımsız uygulama vardır. Bu uygulamalar genelde tasarımcıların program yazmaya ihtiyaç duymadan Voronoi diyagramları oluşturmaya olanak tanıyan, kullanıcı dostu bir grafik arabirimi sağlar. Örneğin; “Qhull”, 2B ve 3B boyutlu Voronoi diyagramları oluşturabilen ve yaygın kullanılan açık kaynaklı bir uygulamadır. Bir diğer uygulama ise Voronoi diyagramları oluşturmak için bir C++ kitaplığı kullanan “Voro++” yazılımıdır.

Bunların dışında Rhinoceros, Autodesk Maya ve Blender gibi birçok popüler BDT yazılımı, Voronoi diyagramları oluşturmak ve değiştirmek için eklentiler veya yerleşik işlevler sunar. Bu eklentiler, tasarımcıların Voronoi diyagramlarını doğrudan mevcut tasarım iş akışları ile birleştirme ve yazılımın gelişmiş modelleme ve görselleştirme özelliklerinden

yararlanmalarını sağlar. Örneğin; bu çalışmada da olduğu gibi Grasshopper parametrik ve üretken tasarım ortamı, Voronoi diyagramları oluşturmak ve değiştirmek için kullanılabilir. Tasarımcılar, Voronoi diyagramlarını bu ortamlara entegre ederek parametrik modelleme, algoritmik tasarım ve gerçek zamanlı görselleştirme gibi gelişmiş özelliklerinden yararlanabilirler.

Bu yöntemde önce 3B veri kümeleri oluşturmak için genel geometri ve Voronoi desenlerine ait tasarım alanı tanımlanır. Bu süreç genelde yapısal iş parçaları için birlikte çalışan diğer bileşenlerle ilişkilerine göre belirlenir. Örneğin montaj ara yüzleri, maksimum-minimum hacim/boyut, Voronoi diyagramı uygulanacak hacim, Voronoi desen karmaşıklık ve yoğunluğu tasarım alanı belirlemede önemli olur.


İkinci aşamada Voronoi diyagram hesapları için kullanılan başlangıç noktaları olan Voronoi çekirdekleri oluşturulur. Bu çekirdeklerin tasarım alanı içinde rastgele örnekleme tekniği ile dağıtılması, olası desenlerin makul düzey ve çeşitte olmasını sağlayacaktır. Oluşturulan her çekirdek noktasına en yakın Voronoi hücre duvarları belirli bir et kalınlığı ile sabit hale getirilir.

Üçüncü aşamada ise Voronoi diyagramına bağlı 3B geometriler oluşturmak için parametrik tasarım teknikleri kullanılır. Yapısal parça genel boyutları ve Voronoi hücre sınırlarına ait parametreler kullanılarak tasarım varyantları oluşturulur. İstenirse 3B modellerin bazı gereksinim veya kriterleri karşılaması için üretilebilirlik, dayanım hedefleri gibi ek tasarım sınırlayıcıları da kullanılabilir. Bu süreç performansa dayalı optimizasyon algoritmaları içerebilir veya çelişen tasarım hedeflerini dengelemek için çok amaçlı optimizasyon teknikleri kullanarak yapısal kararlılık, üretilebilirlik ve estetik gibi faktörleri dikkate almayı gerektirir.

Tüm bu adımlar tamamlandıktan sonra elde edilen 3B geometrileri içeren bir veri kümesi oluşturulur. Bu veri kümesi, farklı Voronoi desenleri, yapılar ve parametrelerle elde edilen birçok 3B BDT modelinden oluşur ve çokça varyant içerir. Anılan 3B veri kümesi, derin öğrenme model eğitimi için ön işlem ve normalleştirme adımlarından geçirilir. Burada geometriler uygun ölçek ve veri yapılarına dönüştürülür, eksik veya hatalı veriler ise tekrar düzenlenir ve düzeltilir. Bu yaklaşımın mühendislik tasarımı ve mimari gibi alanlarda uygulanması ile de inovatif, özgün ve uygulanabilir birçok tasarım varyantı elde edilebilir.

4.3. 3B Veri Kümesi Oluşturma

Bölüm 4.2’de tanıtılan yöntemin yapısal iş parçaları üzerinde test edilmesi için örnek bir çalışma yapılmıştır. Bu kapsamda bir helikopterde yön tayini sağlayan rotor hareketine izin veren özel bir mafsal bileşeni ele alınmıştır. Şekil 4.5’de bu bileşenin genel montaj içindeki konumu, hareket serbestliği ve orijinal görünümü gösterilmektedir. Derin öğrenme modelinin bu bileşeni başarıyla tanıması ve işlemesi amacıyla, Voronoi diyagramı, parametrik tasarım sürecine dahil edilmiştir. Bu entegrasyon ile karmaşık ve birçok çeşit içeren sentetik bir 3B BDT model veri kümesi oluşturulmuştur. Bu veri kümesinin uygulanabilir olduğunu doğrulamak amacıyla oluşturulan bu modeller bazı farklı metrik kriterler kullanılarak değerlendirilmiştir. Bu değerlendirme süreci modelin doğruluğunu teyit etmiş ve oluşturulan sentetik 3B BDT veri kümesinin gerçek uygulamalarda kullanımına uygun olduğunu göstermiştir.




Şekil 4.5. Helikopter rotoru montajının bir bölümü ve orijinal mafsalı gösteren BDT modeli

4.3.1. Parametrik tasarım

Önerilen yöntemin ilk adımında yapısal iş parçasının parametrik BDT modeli oluşturulmuştur. Bu amaçla Rhinoceros isimli ticari BDT yazılımı üzerinde çalışan bir görsel programlama aracı olan Grasshopper yazılımı kullanılmıştır. Tüm model bu yazılıma ait geometrik ve matematiksel ilişkiler kullanılarak modellenmiştir.

Grasshopper, Rhino 3B modelleme yazılımı için geliştirilmiş bir görsel programlama eklentisidir. Kullanıcılara kod yazma ihtiyacı olmadan algoritmalar oluşturma yeteneği sunar. Parametrik tasarım anlamında, Grasshopper, belirli girdi parametrelerine bağlı olarak tasarımın nasıl değiştiğini gözlemlemek için ideal bir platform sunmaktadır. Ayrıca, Grasshopper'ın modüler yapısı sayesinde çok sayıda eklenti ve bileşenle genişletilebilir olma avantajı bulunmaktadır. Bu, kullanıcılara özel işlevselliği eklemelerine veya mevcut işlevleri değiştirmelerine olanak tanır. Mimariden endüstriyel tasarıma kadar birçok farklı alanda kullanılmaktadır.



Şekil 4.6. Parametrik olarak modellenmiş iş parçası ve kullanılan parametreler

Çizelge 4.1. Parametre değer aralıkları

<i>Parametre Adı</i>	<i>En küçük Ölçü (mm)</i>	<i>En büyük Ölçü (mm)</i>	<i>Değişim Aralığı</i>
<i>Parametre A</i>	8	15	8
<i>Parametre B</i>	5	15	11
<i>Parametre C</i>	10	25	16
<i>Parametre D</i>	3	10	8
<i>Parametre E</i>	3	11	9
<i>Parametre F</i>	5	20	16
<i>Parametre G</i>	0	50	51
<i>Parametre H</i>	15	90	76
<i>Parametre I</i>	0	10	11

Belirlenen iş parçası üzerinde rotor montajını oluşturan diğer bileşenlerle uyumlu çalışabilmesi için bazı geometrik sınırlayıcılar söz konusudur. Bu nedenle parametrik

modellemeye önce çalışma arayüzleri tanımlanarak başlanmıştır. Şekil 4.6’te kırmızı renkli dairesel delikler montajın diğer bileşenleriyle ortak çalışabilmesi için sabit bir çap değerine sahiptir. Aynı sebeple bu deliklerin aralarında X, Y ve Z harfleriyle ile gösterilen mesafeler de sabit uzunluktadır. Parçanın geri kalan kısmı da yine çalışma ortamı göz önünde bulundurularak, belli sınırlar içerisinde parametrik olarak modellenmiştir. İlk olarak Şekil 4.4’te A ve B harfleriyle ile gösterilen göbek çapları minimum ve maksimum sınırlar içinde olacak şekilde tanımlanmıştır. Daha sonra C, D ve E harfleriyle gösterilen levha kalınlıkları ayrı ayrı değiştirilebilir uzunluk değerleri ile sınırlandırılmıştır. F ve G harfleri ile gösterilen geometrik sınırlar feder uzunluklarını gösterir ve değiştirilebilir özelliktedir. Son olarak I harfi ile temsil edilen feder yüksekliği simetrik olarak belirli sınırlar içinde uzayıp kısalabilen bir yapıyı ifade eder. Belirlenen parametreler ve sınır koşulları Çizelge 4.1’de gösterilmiştir.




Şekil 4.7. Parametrik tasarımla üretilmiş konsept tasarımların bazıları

Yukarıda ayrıntıları verilen parametrik BDT modeli üzerinde parametre değişiklikleri yapılarak alternatif tasarım varyantları (konseptleri) oluşturulabilir. Burada toplamda 9

parametre ile 60 milyarın üzerinde birbirinden farklı tasarım varyantı üretilebilmesi mümkündür. Bu sayı parametre aralık değerlerinin birbirleriyle çarpılmasıyla ($8 \times 11 \times 16 \times 8 \times 9 \times 16 \times 51 \times 76 \times 11$) elde edilmiştir. Bu veri sayısı parametre aralıklarının yalnızca tam sayı olarak hesaplandığında geçerlidir. Rasyonel sayılar hesaba katıldığında ulaşılabilecek veri sayısı çok daha yüksek olacaktır. Şekil 4.7’de bu yöntemle üretilmiş konsept BDT modellerinden (tasarımlarından) bazıları görülmektedir. Ancak bu tasarım konseptlerinde nicelik olarak hedeflenen veri miktarını fazlasıyla karşılasa da veri çeşitliliği istenilen düzeye ulaşmamaktadır. Birbirine benzer verilerden oluşan veri setleri derin öğrenme modellerinde aşırı öğrenme problemlerine neden olabilmektedir [284].

4.3.2. Voronoi diyagramının parametrik tasarıma entegre edilmesi

Parametre değişikliği ile geometride yapılan değişiklikler çok sayıda tasarım konseptleri oluşturma yeteneğine sahip olsa da elde edilen veri çeşitliliği derin öğrenme model eğitimi için yeterli değildir. Bu çalışmada, veri çeşitliliğini artırmak, parça yüzey ve kenar detaylarını çoğaltmak ve tutarlı bir veri kümesi oluşturmak amacıyla Voronoi diyagramının parametrik tasarıma entegrasyonu üzerinde durulmuştur.



Şekil 4.8. Voronoi diyagramlarının iş parçasına entegrasyon adımları

Öncelikle, parçaların hangi yüzey ve hacimlerine Voronoi diyagramı uygulanacağını belirlenmesi gerekir. Şekil 4.6'da görüldüğü üzere, dairesel elemanlar arasındaki bağlantı yapıları, Voronoi diyagramları için uygun bir platform sağlamaktadır. Sürecin ikinci aşamasında, belirlenen bu alana, parametrik kontrol altında rastgele Voronoi noktaları

yerleştirilmiştir. Voronoi diyagramının temel teorisine göre, bu noktalar bir dizi Voronoi hücresi oluşturacak şekilde konumlandırılır. Noktaların dağılımı ve sayısı, hücrelerin büyüklüğü ve şeklini belirleyerek çeşitlilik oluşturur. Üçüncü aşamada, nokta konumlarından başlayarak Voronoi hücrelerinin oluşumu sağlanmıştır. Burada, bir Voronoi hücresi, içerisindeki noktaya diğer herhangi bir noktadan daha yakın olan tüm alanları içerir. Bu hücreler, genel geometriyi ve boşlukları belirler. Dördüncü aşamada, elde edilen Voronoi hücrelerinin her biri sabit bir değerde ötelenerek boşluklu yapı için temel geometri oluşturulmuştur. Bu öteleme, parametrik kontrolle ayarlanabilir ve tasarımın detaylarını ve karmaşıklığını yönetmek için kullanılabilir. Beşinci ve son aşamada, Voronoi hücrelerinin duvarları arasında kalan hacimler boşaltılarak boşluklu ve özgün bir yapı tasarlanmıştır. Bu süreçte, Voronoi hücrelerinin duvarları arasındaki boşluklar, malzeme tasarrufu ve parçanın ağırlığını azaltmayı sağlar. Aynı zamanda bu boşluklar tasarıma fonksiyonel ve estetik özellikler ekleyebilir. Şekil 4.8, Voronoi diyagramının bu yapısal iş parçasına entegrasyonu öncesi ve sonrası geometride yapılan değişiklikleri açıkça göstermektedir. Voronoi diyagramlarının parametrik tasarıma entegrasyonunun nasıl bir süreç ve çıktı sağladığını Şekil 4.8’de ayrıntılı bir biçimde ortaya koymaktadır.

4.3.3. Veri kümesi oluşturulması ve veri ön işleme

Oluşturulan parametrik tasarım algoritması rastgele ve çok çeşitli verilerin üretilebilmesi için özgün bir yol sunar. Ancak burada rastgele parametre ataması ve oluşturulan yeni modelin dosyaya kaydedilmesi için otonom bir sürece ihtiyaç vardır. Bu problemi ele almak için Rhinoceros program üzerinde çalışan Python dilinde bir betik (script) yazılmıştır (Şekil 4.9). Bu betik her 3 saniyede bir yeni bir parametre seti üretir ve bu parametrelerle oluşturulan 3B BDT modelini kaydeder. Son aşamada ise mevcut 3B modeli silerek yeni model için BDT ortamını hazırlar. Bu çalışma için yaklaşık 14 saat sonunda 15.120 yeni 3B mafsallı verisi oluşturulmuştur (Şekil 4.10). Burada her model yüzey noktaları ve bunlara karşılık gelen yüzey normal vektörlerini içeren mozaik bir gösterim olan “OBJ” dosya formatında kaydedilmiştir. Bu veri kümesi farklı duvar kalınlığı, Voronoi hücre büyüklüğü ve hücre sayısına sahip modellerden oluşmaktadır. Bu durum veri kümesinin gerçek veri çeşitliliğini taklit etmesine yardımcı olmaktadır. Derin öğrenme modellerinin eğitilmesinde kalitenin iyileştirilmesine izin veren temel faktör bu veri çeşitliliğidir.

İçe Aktar:
 rhinoscriptsyntaxfonksiyonlarını
 zaman fonksiyonlarını
 işletim sistemi fonksiyonlarını
 Başlat:
 Dosyanın kaydedileceği yolu belirle: "models"
 Modeli kaydetme aralığını belirle: 3 saniye
 Dosya adı için örnek belirle: "_mafsal_"
 Toplam tekrar sayısını belirle: 20,000
 Sayaç başlangıç değerini belirle: 0
 20,000 kez tekrarla:
 Dosya adını oluştur: Örnek + sayaç değeri + ".obj"
 Modeli kaydet:
 Rhino komutunu çalıştır: "Farklı kaydet" komutu ve dosya adını kullanarak
 2 saniye bekle
 Tüm nesneleri seç ve sil:
 Rhino komutunu çalıştır: TümünüSeç ve Sil komutlarıyla
 1 saniye bekle
 Sayaç değerini bir artır


Şekil 4.9. Oluşturulan modellerin bir dizine kaydedilmesi için algoritma



Şekil 4.10. Voronoi diyagramlarının parametrik tasarıma entegre edilmesi elde edilen veriler

Elde edilen 3B model veri setlerinin derin öğrenme modellerinin eğitiminde kullanılması için bazı ön işlemlerden geçirilmesi gerekir. Burada ilk olarak hatalı, eksik veya anormal

verilerin tespit edilip veri kümesinden çıkarılmıştır. Ardından, makine öğrenmesi algoritmalarının performansını optimize etmek için tüm veriler belirli boyuta getirilmiştir. Son olarak tüm veriler bir nesneyi birim küpler kümesi olarak temsil eden “binvox” formatına dönüştürülmüştür (Şekil 4.11). Vokseller, boşluklu ve karmaşık içyapıları temsil etme yeteneğine sahip olduğundan bu çalışmada üretilen yapısal iş parçası için uygun veri temsil yöntemidir. Ancak yüzey çözünürlüğünün voksel sayısına bağlı olarak değişebileceği dikkate alınmalıdır. Bu çalışma için bilgisayar işlem kapasitesine bağlı olarak ideal ızgara boyutu 128 x 128 x 128 olarak belirlenmiştir. Daha sonra Python üzerinde “binvox” kütüphanesi kullanılarak OBJ formatındaki BDT modelleri voksel formatına dönüştürülmüştür [285]. Tüm bu veri ön işlemleri sonucunda 15.017 sentetik yeni veri üretilmiştir.



Şekil 4.11. Mesh yapısının voksel formatına dönüştürme süreci

4.3.4. Oluşturulan Tasarımların Değerlendirmesi


Önerilen yöntem kullanılarak üretilen sentetik 3B modellerin gerçek modellere ait fiziksel ve görsel özellikleri ne düzeyde yansıttığını belirlemek amacıyla iki farklı analiz uygulanmıştır. İlk olarak görsel benzerlik açısından orijinal veri ile kıyaslanmıştır. Bu yöntem, sentetik veri kümesinin orijinal parçaya ait temel özellikleri temsil etme yeteneğini belirler. Burada, üretilen modellerin temel boyut ve tasarım özelliklerini başarılı bir şekilde temsil ettiği belirlenmiştir. Ardından, modellerin yapısal özelliklerini değerlendirmek için fizik temelli bir yöntem kullanılmıştır. Bu kapsamda, orijinal ve Voronoi entegrasyonu ile elde edilen modeller deformasyon, gerilme ve emniyet katsayıları bakımından karşılaştırılmıştır. Ayrıca veri kümesi ve orijinal model hacimleri kullanılan malzeme ve yük taşıma kapasitesine göre karşılaştırılmıştır.

Çizelge 4.2. Sonlu Elemanlar Analizi sonuçları

	Kütle (g)	Hacim (cm ³)	Bağlı Kütle (%)	Maks. Deformasyon (mm)	Maks. Stress (MPa)	Emniyet Katsayısı
<i>Orijinal model</i>	579,8	193,266	100	0,084	41,9	5,72
<i>Sentetik-1</i>	273,6	91,2	47,19	2,297	187,4	1,28
<i>Sentetik-2</i>	201,2	67,067	34,70	0,635	83,72	2,87
<i>Sentetik-3</i>	241,5	80,5	41,65	0,471	77,6	3,09
<i>Sentetik-4</i>	171,6	57,2	29,60	0,508	128,8	1,87
<i>Sentetik-5</i>	240,1	80,034	41,41	3,956	247,5	0,97
<i>Sentetik-6</i>	239,4	79,8	41,29	8,127	326,1	0,74
<i>Sentetik-7</i>	268,7	100,67	46,34	0,657	77,93	3,08
<i>Sentetik-8</i>	272,6	102,112	47,02	0,286	61,97	3,873
<i>Sentetik-9</i>	317,6	118,952	54,78	0,217	88,3	2,718
<i>Sentetik-10</i>	222,1	83,196	38,31	0,894	133,5	1,796
<i>Sentetik-11</i>	226,1	84,651	39,00	12,52	1183	0,203
<i>Sentetik-12</i>	296,6	111,116	51,16	0,621	242,5	0,989
<i>Sentetik-13</i>	293,8	97,934	50,67	1,823	255,8	0,94
<i>Sentetik-14</i>	317,2	105,734	54,71	0,428	65,8	3,69
<i>Sentetik-15</i>	205,9	68,634	35,51	0,757	197,4	1,22
<i>Sentetik-16</i>	218,3	72,767	37,65	0,872	265,8	0,91
<i>Sentetik-17</i>	242,8	80,934	41,88	0,633	92,9	2,61
<i>Sentetik-18</i>	267,5	89,167	46,14	0,538	152,6	1,57

Simülasyon ortamında tasarımın karşılaşılabileceği gerçek yük ve kuvvetler dikkate alınarak analiz işlemi yapılmıştır. Parça üzerine etki eden kuvvetler ve sınır koşulları, tüm tasarımlar için sabit tutulmuştur. Analiz için, eklemeli imalat (İng. Selective Laser Melting – SLM gibi) ile uyumlu AlSi10Mg malzemesinin mekanik özellikleri dikkate alınmıştır. Bu çalışmada, orijinal modelle birlikte veri kümesinden rastgele seçilen 18 modelin mekanik karakteri incelenmiştir. Çizelge 4.2, maksimum gerilme, maksimum deformasyon ve emniyet katsayısı gibi Sonlu Elemanlar Analizi (FEA) ile yapılan analiz sonuçlarını göstermektedir. İlk olarak Bağlı Kütle, tasarımların verimliliği hakkında önemli bir gösterge olan orijinal modelin kütlelerine göre diğer model kütlelerinin yüzdesini gösterir. Kütle ve hacimdeki azalmalar malzeme kullanımı, üretim maliyeti ve üretim süresinde tasarruf sağlar. Burada tüm modellerin %45 ile %70 arasında daha düşük kütle değerlerine sahip olduğu görülmektedir. Maksimum deformasyon ve maksimum gerilme ise modellerin yük altında ne kadar deforme olacaklarını ve plastik deformasyonun başlayacağı kritik gerilme seviyesini belirler. Örneğin, Sentetik-3 modelinin deformasyon değeri oldukça yüksektir (8,127 mm) ve bu da yük altında önemli miktarda deforme olacağını gösterir. Benzer şekilde Sentetik-11 1.183 MPa maksimum gerilme değeri ve 0,203 emniyet katsayısı ile görece en

düşük yapısal performansa sahiptir. Diğer yandan Sentetik-3, Sentetik-7, sentetik-8 ve Sentetik-14 modelleri nispeten düşük stres değerleri ve yüksek emniyet katsayıları ile dikkat çekmektedir.



Şekil 4.12. Model ağırlıklarına göre emniyet faktörlerinin karşılaştırılması.

Şekil 4.12 ise modellerin emniyet katsayılarını grafiksel olarak göstermektedir. Burada siyah renkli noktalar veri kümesinden rastgele alınan modelleri temsil ederken, turuncu nokta ise orijinal modeli ifade eder. Sentetik modellerin emniyet katsayısı, orijinal iş parçasına kıyasla daha düşüktür. Bununla birlikte ağırlık değerleri normalize edildiğinde sentetik modellerin, normalize edilmiş deformasyon ve gerilim değerlerinin orijinal iş parçası ile benzer olduğu görülmektedir. Grafikteki kırmızı kesik çizgi, model ağırlıkları ve emniyet faktörü arasındaki bağlantıyı belirgin bir şekilde göstermektedir. Bu çizgi, sentetik modellerin, orijinal modele göre verimini ortaya koyar. Bu çizginin üzerindeki modeller, daha az malzeme kullanımına rağmen orijinal modele göre görece yüksek mekanik performansa sahiptir. Örneğin, sentetik model-8'de %53'lük bir ağırlık azalmasına karşın güvenlik faktörü orijinal modele göre sadece %32 azalmıştır. Çizgi altında kalan modeller ise orijinal modele göre mekanik performans açısından verimsizdir. Özellikle ağırlığın temel kriterlerden biri kabul edildiği havacılık sektöründe yüksek dayanıklılık ağırlık oranı (İng. Strength to weight ratio) önemli bir göstergedir. Yüksek dayanıklılık-ağırlık oranına sahip yapılar, aynı mukavemete sahip daha ağır yapılara kıyasla bu tür uygulamalar için tercih edilir. Elde edilen bulgular, genel olarak önerilen parametrik tasarım yönteminin yapısal iş

parçası üretme konusunda yeterli performans gösterdiğini ve Voronoi diyagramlarının sentetik veri kümesi oluşturmada alternatif bir yaklaşım olabileceğini net bir şekilde ortaya koymaktadır.

4.5. Bulgular ve Tartışma

Makine öğrenmesi ve derin öğrenme tekniklerinin sahip olduğu veriye dayalı tahmin ve çıkarım yapma yetenekleri bunları birçok alanda kullanılabilir yapmıştır [249]. Önceki bölümlerde de belirtildiği gibi, veri kalitesi ve çeşitliliği modelin başarılı olmasında önemli rol oynar. Özellikle 3D nesne tanıma ve üretken tasarım çalışmalarında kaliteli ve çeşitliliği yüksek veri kümelerine erişmek mümkün olmayabilir. Genellikle, mevcut veri kümeleri sınırlı sayıda nesne içerir ve bunların genelleme kabiliyetleri düşüktür. Ayrıca yapısal iş parçaları için yeterli sayıda veri bulunmamaktadır. Burada sentetik veri üretme teknikleri bu tür problemler için yeni bir çözüm yolu önermektedir.

Yapısal iş parçalarının tanınması ve üretilmesi için derin öğrenme modellerinin eğitimi amacıyla sentetik 3B BDT verileri üretme konusunda yapılan çalışmalar, özellikle mühendislik ve üretim alanları için çok önemlidir [260]. Bu veri kümeleri hızlı prototip oluşturma ve mühendislik süreçlerini iyileştirmeye katkı sağlar. Ayrıca derin öğrenme modellerinin karmaşık yapıları tanınması ve üretme yeteneklerinin gelişmesini de kolaylaştırabilir. Bu çalışmada parametrik tasarım ve Voronoi diyagramları entegrasyonu ile sentetik veri üretimi konusu sınırlı eğitim veri problemlerine olası bir çözüm olarak önerilmektedir. Yeni veri üretiminde Voronoi diyagramları veri noktaları arasındaki yakınlık ve yoğunluk ilişkilerini belirleyerek veri çeşitliliğine katkı sağlar. Özellikle veri ihtiyacının yoğun olduğu derin öğrenme modelleri göz önüne alındığında, bu yöntem, modelin genel performansı ve öğrenme kabiliyetini artırmak için daha geniş ve çeşitli bir veri kümesi oluşturabilir. Ayrıca bu yöntem tasarım uzayını keşfetme, 3D BDT modellerinin hedeflere uygun olarak optimize edilmesi gibi avantajlara sahiptir.

Bu çalışmada derin öğrenme modelleri için gerçek verilere uygun yeni ve amaca göre özelleştirilmiş sentetik verilerin üretilmesi için özgün bir yöntem önerilmektedir. Bir 3B BDT veri kümesinin kalitesi; geometrik doğruluk, yeterli detay, ölçek, standart dosya formatı kullanımı, yeterli veri sayısı gibi kriterlere bağlıdır [286]. Bu nedenle üretilen sentetik veri kümesi bu kriterler ile değerlendirilmiştir. İlk olarak oluşturulan sentetik veriler

gerçek modelin boyut, açı ve yüzey özelliklerini yansıtmaktadır. Ayrıca gerçek modele ait delik konumu, montaj ara yüzleri ve çalışma alanı ölçüleri gibi sınır koşullarını eksiksiz olarak karşılamaktadır. Bunların haricinde parametrik tasarım aşamasında oluşturulan amaca uygun formülasyon ile veri kümesinde minimum sayıda hatalı, eksik veya uyumsuz veri bulunur. Bu modeller tek bir BDT programından elde edildiği için standart bir dosya formatına sahip olur. Parametrik tasarım koşulları uç örnekleri de veri kümesine dahil edebildiğinden esnek, çeşitli ve bol sayıda veri elde edilmiştir. Bu durum kullanılan modelin temel boyut ve tasarım özelliklerini etkin bir şekilde temsil kapasitesini ve bu sayede karmaşık 3B geometrileri başarıyla oluşturabilme yeteneğini gösterir.

Sonuç olarak bu çalışma sınırlı eğitim verisi problemini çözmek için yeni bir yaklaşım sunmaktadır. Voronoi diyagramları ve parametrik tasarımın entegrasyonu (özellikle 3B modelleme) kullanan derin öğrenme algoritmaları için veri artırma konusunda önemli bir strateji olabilir. Bu yaklaşımın daha geniş çapta araştırılması ve test edilmesi derin öğrenme uygulamalarında genel performansı artırmak için oldukça değerli olabilir. Tasarımcılar ve mühendisler bu yaklaşımları kullanarak daha karmaşık ve optimize edilmiş tasarımlar ve çözümler elde edebilirler.

4.5.1. Derin öğrenmede parametrik tasarımın rolü

Parametrik tasarımın modern tasarım süreçlerindeki önemi, mimarlık, mühendislik, ürün tasarımı ve dijital üretim gibi farklı alanlarda meydana getirdiği dönüştürücü etkisine dayandırılabilir. İlk olarak, parametrik tasarım, üretken teknikler kullanarak verimli bir tasarım keşif alanı sunar. Böylece, yenilikçi ve daha önce keşfedilmemiş çözümleri keşfetmeye olanak tanıyan çok sayıda tasarım varyasyonu üretebilir. Tasarım sürecinin otomatikleştirilmesi, tasarım çözümlerini oluşturma ve geliştirme sürecinde gereken zaman ve çabayı önemli ölçüde azaltır. Bu artan verimlilik, tasarımcıların yüksek düzeyde karar verme ve yaratıcı keşiflere odaklanmalarını sağlar. Dahası parametrik tasarım, belirli performans kriterleri ve kısıtlamalara göre özelleştirilmiş çözümler geliştirme imkânı sunar. Böylece verilen hedeflere göre verimli, sürdürülebilir ve yüksek performanslı çözümler belirlenebilir [275].

Parametrik tasarım, bilgisayar, matematik, malzeme ve hedef uygulama alanlarından gelen bilgileri birleştirerek disiplinler arası iş birliğini teşvik eder [274]. Bu iş birliği, karmaşık,

gerçek dünya zorluklarına yanıt veren kapsamlı ve dengeli tasarım çözümlerinin geliştirilmesine katkıda bulunur. Bunun yanı sıra parametrik tasarım, üretim süresini ve maliyetleri önemli ölçüde artırmadan son derece özelleştirilmiş tasarımlar oluşturabilir [287]. Bireysel tercihlere ve gereksinimlere uygun benzersiz, özel çözümlerin geliştirilmesi sağlanır. Ayrıca, parametrik tasarım atık malzeme miktarını azaltılması, enerji tüketimini en aza indirmesi veya tasarımın genel çevresel performansının artırılmasına katkı sağlayarak sürdürülebilir ve çevre dostu çözümler üretebilir.

Yukarıda bahsedilen avantajlarının yanı sıra parametrik tasarım karmaşık ve büyük boyutlu 3B geometrilerin hızlı bir şekilde oluşturulmasını ve işlenmesini sağlar. Otonom olarak büyük ölçekli ve normalize edilmiş 3B model veri kümeleri üretmek, derin öğrenme çalışmalarına, özellikle 3B veri analizi ve işleme bağlamında önemli katkılarda bulunmaktadır [12]. Örneğin, derin öğrenme modelleri, etkili eğitim için genellikle büyük miktarda etiketli veri gerektirir. Büyük ölçekli 3B model veri kümelerini otonom olarak üretmek, veri kıtlığı sorununu ele alarak araştırmacılara modellerini etkili bir şekilde eğitmek ve doğrulamak için yeterli veri oluşturur. Dahası otomatik süreçlerle üretilen yüksek veri çeşitliliğine sahip 3B veri kümeleri, derin öğrenme modellerinde iyileştirilmiş genelleme yeteneği kazandırır. Kapsamlı ve çeşitli bir veri kümesi üzerinde eğitilen derin öğrenme modelinin daha önce görülmemiş verilerde daha iyi performans gösterme olasılığını artırır. Ayrıca, manuel veri toplama ve ön işleme için gereken zamanı ve çabayı azaltarak araştırma sürecini hızlandırır. Bu durum belirli bir uygulamaya ait sorunlara ve gereksinimlere hitap edecek ve özel tasarlanmış derin öğrenme modellerinin geliştirilmesine olanak tanır.

4.6. Sonuçlar

Bu bölümde makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak sınırlı 3B BDT veri setlerinden yeni ve kullanılabilir sentetik veriler üretme imkanını araştırılmıştır. Bu amaçla parametrik tasarım ve Voronoi diyagramları kullanılarak veri çeşidi ve kalitesini artırma çalışmaları yapılmıştır. Yapılan analizler ve testler bu tekniklerin yüksek kaliteli ve çeşitli veri setleri üretme potansiyeline sahip olduğunu göstermiştir.

Sentetik verilerin kullanımı makine öğrenmesi modellerinin eğitilmesinde ve genelleme yeteneklerinin artırılmasında oldukça etkili olmuştur. Bu yaklaşım gerçek dünya

problemlerine uygun, hafif ve organik formlu yeni 3B modellerin üretimine yardımcı olmuştur. Üretilen modellerin bazıları anlamsız form ve bozukluklar içerse de bu problemler ardıl işlemler ve veri işleme teknikleriyle giderilebilmiştir. Bu işlemler 3B BDT verilerinin kalitesini ve kullanılabilirliğini önemli ölçüde artırmıştır.

Son olarak bu çalışma sınırlı eğitim veri problemlerini çözmek için yeni bir yaklaşım sunmaktadır. Parametrik tasarım ve Voronoi diyagramları entegrasyonu kullanılarak üretilen sentetik veriler, 3B modelleme için veri genişletme stratejisi olarak önemli bir alternatif olabilir. Bu yaklaşımın daha geniş çapta araştırılması ve uygulanması, derin öğrenme uygulamalarında genel performansı artırabilir. Ayrıca mühendisler ve tasarımcılar, bu teknikleri kullanarak daha karmaşık ve optimize edilmiş tasarımlar oluşturabilirler. Son olarak bu çalışma, 3B modelleme, mühendislik ve üretim alanlarına önemli bir katkı sağlamaktadır. Gelecek çalışmalar sentetik verilerin geliştirilebilir olması ve çeşitli kullanım senaryolarına adaptasyon yeteneğini anlamak için çeşitli endüstri alanlarında, farklı tipte BDT veri setlerinde ve çeşitli derin öğrenme yöntemlerinde test edilmesine odaklanmalıdır. Ayrıca Voronoi diyagramları ile diğer veri genişletme ve çeşitlilik artırma tekniklerinin nasıl bir araya getirilebileceğine dair daha fazla çalışma ve araştırmalar yapılmasına ihtiyaç duyulmaktadır.




5. ÜRETKEN ÇEKİŞMELİ AĞLAR

Üretken Çekişmeli Ağlar, derin öğrenme dünyasındaki en devrimci yeniliklerden biridir. Bu modeller, eğitildikleri veri setlerini temel alarak, daha önce rastlanmamış yeni ve özgün veri örnekleri oluşturma kapasitesine sahiptir. GAN'ların sunduğu bu devrim niteliğindeki yetenek, sanattan tıba, oyun endüstrisinden mühendisliğe kadar birçok alanda etkili uygulamalara imkân tanımıştır. Bu bölümde GAN'ların temel çalışma mekanizmalarını ve zamanla ortaya çıkan gelişmiş GAN modelleri incelenmiştir. Özellikle, 3B veri üretme kapasitesiyle öne çıkan 3DGAN mimarisini detaylı bir şekilde ele alınmıştır. Bu mimari, 3B veriye özgü zorlukları aşmak için tasarlanmış olup, bu alanda yeni olanaklar sunmaktadır. 3DGAN'ın çalışma prensipleri, avantajları, nasıl eğitildiği ve potansiyel uygulamaları bu bölümde derinlemesine ele alınmıştır.

5.1. Üretken Tasarım

GAN, Ian Goodfellow ve meslektaşları tarafından 2014 yılında tanıtılan, gözetimsiz derin öğrenme modelleridir [236]. GAN'lar, yüksek kaliteli ve gerçekçi veri üretme yetenekleriyle önemli bir popülerite kazanmış ve çeşitli alanlarda başarılı uygulamalar gerçekleştirmiştir. GAN'lar, bir üretici (Ü) ve bir ayırıcı (A) olmak üzere iki rakip sinir ağından oluşur: Üretici ağ, gerçek veri dağılımına olabildiğince yakın sentetik veri örnekleri oluşturmaya çalışırken, ayırıcı ağ ise gerçek veri örnekleri ile sentetik veri örnekleri arasındaki farkı ayırt etmeye çalışır (Şekil 5.1).



Şekil 5.1. Temel GAN mimarisini ifade eden akış şeması

GAN'lar, çeşitli alanlarda uygulanmış ve farklı uygulamalar için başarılı sonuçlar sağlamıştır. Özellikle görüntü sentezi, stil transferi, görüntüden görüntüye çeviri ve veri artırma gibi alanlarda etkileyici başarılar elde etmiştir [9]. Ancak mod çökmesi, kaybolan gradyanlar ve kararsız eğitim dinamikleri gibi sorunlar GAN eğitimini zorlaştırmaktadır. Araştırmacılar, bu zorlukları aşmak ve farklı uygulamalar için performanslarını artırmak amacıyla orijinal GAN mimarisi üzerinde çeşitli değişikli ve iyileştirmeler yapmışlardır.

Geleneksel GAN'lar başarılı 2B veri sentezi sağlasa da 3B verilerin karmaşıklığına ve özelliklerine uyum sağlamak için özellikle tasarlanmamışlardır. Son yıllarda, alternatif GAN modelleri ve özellikle 3 Boyutlu Üretken Çekişmeli Ağ (Three Dimensional Generative Adversarial Networks, 3DGAN) modeli önemli bir araştırma alanı haline gelmiştir. 3DGAN'lar, klasik GAN model prensiplerini temel alan 3B veri temsillerini doğrudan oluşturacak şekilde genişleten üretken derin öğrenme modelleridir [190]. 3B veri temsili, artan önemini göz önünde bulundurarak ve çeşitli alanlardaki uygulamalar için daha başarılı sonuçlar sağlamak adına 3DGAN'ların geliştirilmesi amaçlanmaktadır. 3B veri temsili, özellikle bilgisayarlı görü, robotik, tıbbi görüntüleme, coğrafi analiz, endüstriyel tasarım ve eğlence endüstrileri gibi alanlarda önemlidir. Bu alanlardaki çeşitli uygulamalar, 3B nesne tanıma, bölümlendirme ve sahne kavrama gibi görevlerde olduğu gibi, daha doğru ve gerçekçi 3B veri üretimi olarak gösterilmektedir. 3DGAN modelleri, yalnızca gerçekçi 3B veri örnekleri üretme yeteneklerini geliştirmekle kalmaz, aynı zamanda karmaşık 3B uzamsal bilgiyi yakalama ve çeşitli endüstrilerde kullanılacak teknik bilgiyi doğru ve verimli ele alma kabiliyeti sunar [11].

Son yıllarda GAN ve 3DGAN modelleri daha büyük veri kümesi ve karmaşık veri yapıları ile başa çıkabilen kararlı mimarilere evrilmektedir. Bu gelişmeler sayesinde bu modellerin performansı ve uygulanabilirliği artmaktadır. Bir başka deyişle özellikle 3DGAN modeli başta olmak üzere GAN modelleri, veri temsili, artan önemini ve karmaşıklığını ele alarak, derin öğrenme alanına önemli katkılar sağlayan güçlü üretken modellerdir [110].

5.1. Üretken Çekişmeli Ağların Temelleri

GAN, özellikle sinir ağlarının evrimine paralel olarak gelişen derin sinir ağları teknolojisinin bir ürünüdür. Sinir ağlarının ilk ortaya çıkışından bu yana, bu modellerin kapasitesi,


öğrenme yetenekleri ve uygulama alanları genişlemiştir. Derin sinir ağları, bu evrimin en önemli dönüm noktalarından biridir ve GAN'ın temelini oluşturan yapıdır.

5.1.1. Derin sinir ağları


Yapay sinir ağları (YSA), biyolojik sinir sistemlerinin temel yapılarını ve fonksiyonlarını simüle eden bir yapay zeka yaklaşımıdır [288]. Canlılarda bulunan sinir hücreleri, dentritler ve aksonlar gibi yapıları temel alarak, bu kompleks yapıyı matematiksel bir modele dönüştürür [47-49]. YSA'nın temel bileşeni, bilginin aktarımında ve işlenmesinde görevli olan düğümler veya nöronlardır. Bu düğümler, ağıın veri akışını sağlayan elemanlardır ve bu akış, düğümler arasındaki bağlantılarla gerçekleşir (Şekil 5.2). Katman sayısı arttıkça ağıın derinliği artar. Bu ağlar Derin Sinir Ağları (DSA) olarak ifade edilir.

DSA'nın temel yapısı, giriş, gizli ve çıkış olmak üzere üç ana katmandan oluşur (Şekil 5.3). Gizli katmanda bulunan düğüm veya nöron sayısı, üzerinde çalışılan problemin karmaşıklığına göre ayarlanır [289]. Daha fazla düğüm, ağıın daha detaylı öğrenmesini sağlar, ancak eğitim süresinin uzamasına neden olabilir. Tersine, az sayıda düğüm, eğitim süresini kısaltabilir ancak modelin genel başarısını olumsuz etkileyebilir. Optimal düğüm ve katman sayısını belirlemek için kesin bir kural yoktur ve genellikle deneme-yanılma yöntemiyle en uygun yapı bulunmaya çalışılır [289]. DSA'nın çıkış katmanındaki değerler, istenen sonuç veya sınıflandırma değerleridir. Modelin ürettiği tahminler ile gerçek değerler arasındaki fark, hata (İng. loss) olarak adlandırılır [52]. Model eğitimi sırasında, bu hata değeri en aza indirilmeye çalışılır.

Sinir ağı eğitimi, ileri besleme ve geri yayılım algoritmalarıyla gerçekleştirilir. İleri besleme sürecinde, bir önceki katmandan gelen girdi değerleri, ağırlıklarla çarpılır, toplanır ve bir bias eklenir. Aktivasyon fonksiyonu, bu değerin belirli bir eşiğı geçip geçmediğini kontrol eder. Eğer eşiğı geçerse, bilgi sonraki katmana aktarılır. Bu süreç, çıkış katmanına kadar devam eder. Elde edilen sonuçlar, gerçek değerlerle karşılaştırılarak bir hata değeri hesaplanır. Geri yayılım algoritmasıyla, bu hatayı en aza indirmek için ağırlıklar güncellenir. Başlangıçta rastgele atanmış olan ağırlıklar, bu eğitim süreci sayesinde optimize edilir ve ağıın performansı artırılır.



Şekil 5.2. Yapay sinir hücresinin temsili gösterimi




Şekil 5.3. Derin sinir ağı mimarisi

Yapay sinir ağıları, karmaşık hesaplamalarda olağanüstü başarılı sonuçlar vermekle birlikte bunların kullanımlarını sınırlayan bazı faktörler olabilmektedir. İlk olarak, bu ağların doğru bir şekilde işlev görebilmesi için girdilerin sayısal formatta olması gerekmektedir. Ayrıca, eğitim süreçleri, nöron sayısı, katmanların derinliği, aktivasyon fonksiyonları, öğrenme oranı ve başlangıçta atanmış ağırlık değerleri gibi birçok parametrenin kombinasyonuna bağlıdır. Bu, eğitim süresinin öngörülememesi ve bu sürecin genelde uzun zaman almasına neden olabilir [290]. Özellikle derin sinir ağıları söz konusu olduğunda, bu süreçlerin gerçekleştirilmesi için yüksek işlem kapasitesine sahip bilgisayarlar gerekmektedir. Dahası, yapay sinir ağlarının ürettiği sonuçların arkasında yatan nedenleri ve mantığı açıklamak çoğu zaman mümkün değildir.


5.1.2. Evrişimli sinir ağları

Evrişimli Sinir Ağları (CNN), derin öğrenme modelleri arasında görüntü tanıma ve sınıflandırma görevlerinde öne çıkan bir yapıdır. CNN'nin temelini, evrişim işlemlerinin gerçekleştirildiği evrişimli katmanlar oluşturur [125]. Bu katmanlar, bir görüntü üzerinde hareket eden filtreler kullanarak yerel özellikleri öğrenir ve bu özellikleri daha sonraki katmanlara aktarır. CNN'nin temel bileşenlerinden biri de öznitelik haritalarıdır. Bu haritalar, evrişimli katmanlardan geçen verilerin aktivasyon değerlerini içerir (Şekil 5.4). Bu katmanların ardından, havuzlama (İng. pooling) işlemleriyle bu haritalar boyut açısından küçültülür. Havuzlama işlemi için genelde maksimum ve ortalama olmak üzere iki farklı yaklaşım kullanılır. Bunlardan ilki havuzlama matrisinin içinde kalan en büyük değeri dikkate alır. Diğeri ise havuzlama matrisinin ortalama değerini bir sonraki katmana aktarır (Şekil 5.5). Bu ağın hesaplama yükünü azaltarak verimliliği artırır. Ayrıca havuzlama katmanları, ağın daha yüksek seviye özelliklere odaklanmasına yardımcı olur. CNN'nin son bölümünde tamamen bağlı (İng. fully connected) katmanlar yer alır ve sınıflandırma işlemi için gerekli hesaplamaları gerçekleştirir. Bu katmanlarda, öğrenilen öznitelikler, problemle doğrudan ilgili çıktılara dönüştürülür. Örneğin, bir görüntü sınıflandırma probleminde, çıktı katmanındaki her nöron bir sınıfa karşılık gelir ve bu nöronların aktivasyon değerleri, sınıflandırmanın sonucunu belirler [90].



Şekil 5.4. Temel CNN mimarisi

CNN'nin eğitimi, YSA ve DSA'da olduğu gibi ileri besleme ve geri yayılım algoritmalarıyla gerçekleştirilir. Ancak, evrişimli katmanlar ve havuzlama katmanları gibi özel katmanların varlığı, bu ağın öğrenme sürecini biraz daha karmaşık hale getirir. Eğitim sırasında, modelin ürettiği tahminler ile gerçek değerler arasındaki farkı azaltmak için ağırlıklar güncellenir.



Şekil 5.5. Havuzlama işlemi için yaklaşımlar

Evrişimli Sinir Ağları, görüntü ve ses işleme gibi karmaşık veri tipleriyle başa çıkmada oldukça başarılıdır. Ancak, derin sinir ağları gibi, onları kullanan modellerin eğitilmesi zor olabilir ve yüksek hesaplama kapasitesine ihtiyaç duyulabilir. Ayrıca, ağın neden belirli bir sonucu ürettiği konusunda net bir açıklama yapmak her zaman mümkün olmayabilir.

5.2. 3DGAN Geliştirme Motivasyonu

3DGAN modelleri, GAN prensiplerini genişleterek voksel ve nokta bulutu gibi 3B veri temsillerini ele alırlar [188]. Geleneksel olarak, etiketli 3B veri toplamak, özellikle bilgisayarlı görü ve robotik gibi sektörlerde hem zaman alıcı hem de maliyetlidir. 3DGAN'lar, mevcut 3B veri kümelerini zenginleştirerek bu eksikliği doldurabilir ve sentetik örnekler oluşturarak algoritma gelişimini destekler [291]. Bu modellerin yetenekleri sadece sentetik veri oluşturma ile sınırlı değildir. [292]. 3B temsiller oluşturmak, makine öğrenimi algoritmalarının daha geniş bir yelpazede performans göstermelerine yardımcı olabilir. Dahası 3DGAN'lar, oyun, film veya sanal gerçeklik ortamları için 3B içerik üretimi gibi manuel çabaları azaltarak sanat ve eğlencede yeni olanaklar yaratabilir.

3DGAN'lar, ayrıca, endüstriyel tasarım ve eklemeli imalat olmak üzere birçok alanda benzersiz zorluk ve ihtiyaçlara cevap vermektedir. 3DGAN'lar 3B modellerin hızlı bir şekilde görselleştirme ve iyileştirmesine olanak tanır. Tasarım optimizasyonuna da katkıda bulunan 3DGAN'lar, çeşitli 3B tasarım seçeneklerini üreterek estetik, işlevsellik ve üretim kısıtları arasında en iyi dengeyi sağlayan tasarımları belirlemeye yardımcı olabilir [3]. Bu, ürün geliştirme sürecinde performansın iyileştirilmesine, malzeme kullanımının azaltılmasını ve genel maliyet tasarrufu sağlar. Dahası bu modellerin bilgisayar destekli mühendislik (CAE) araçlarına entegre edilmesi, statik, dinamik ve termal analiz ile tasarım

uzayını iyi yönde daraltılabilir [142]. 3DGAN'lar, geleneksel yöntemlerle tasarlaması zor veya imkânsız olan geometrileri üretmek için kullanılabilir. Bunlara ek olarak 3DGAN benzersiz ve gerçekçi 3B modeller üretme yeteneği sayesinde, üretim sektöründe özelleştirme ve kişiselleştirmeye katkıda bulunur [125].

3DGAN'lar 3B veri oluşturmayı verimli hale getirerek tasarım ve üretim süreçlerinde devrim yaratma potansiyeline sahiptir. Hızlı prototipleme, tasarım optimizasyonu ve özelleştirme görevlerinde önemli bir araçtır. Bu teknolojinin yaygınlaşması ve uygulanması sayesinde, endüstriyel tasarım ve üretim süreçleri daha esnek ve verimli hale gelecek ve böylece özelleştirilmiş ürün talepleri daha hızlı ve etkili bir şekilde karşılanabilecektir.


5.3. 3DGAN Teorisi

3DGAN mimarileri klasik GAN mimarisine benzer şekilde bir üretici (G) ve bir ayrıştırıcı (D) olmak üzere iki ana bileşenden oluşur. Üretici, sentetik 3B veri temsilleri oluşturmakla sorumluyken; ayrıştırıcı, üretilen örnekleri gerçek 3B verilere kıyaslayarak bunların ayrımını yapar. Bu modeller 3B verileri etkili bir şekilde oluşturmak için, 3B Evrişimli Katmanlar ve 3B Transpoze Evrişimli Katmanlar gibi özel katmanlar kullanır. Bu katmanlar, 3B verilerdeki mekânsal ilişkileri, derinlik bilgilerini ve yerel yapıları, klasik olanlardan daha etkili bir şekilde yakalar. Öncelikle üreticide kullanılan 3D Transpoze Evrişimli Katmanlar, ters evrişim işlemi gerçekleştirerek giriş verilerini aşamalı olarak çözünürlüğü yükselterek 3B temsiller üretir. Diğer taraftan, ayrıştırıcıda kullanılan 3B Evrişimli Katmanlar ise giriş verilerine evrişim işlemi uygulayarak voksel veya noktalar arasındaki mekânsal bağlamı ve ilişkileri tespit eder.

5.3.1. 3B evrişim katmanı

Evrişim, verilerden öznitelikleri öğrenmek için kullanılan matematiksel bir işlemdir. Evrişim işleminin tekrarlı uygulanması ile girdi verilerindeki özelliklerin konumu yoğunluğunu temsil eden bir özellik haritası (uzayı) oluşturulur. 3B evrişim işlemi ise genişlik, yükseklik ve derinlik gibi mekânsal bilgileri öğrenmek için kullanılır. Bir derin öğrenme modelinde evrişim katmanlarının sayısı giriş verilerinin karmaşıklığına göre belirlenir [293].

3B evriřim iřlemi 2B evriřim iřlemine benzer bir řekilde gerekleřir. 2B giriř matrisi zerinde daha kk boyutlu bir filtre (kernel) matrisinin kaydırılarak arpılması ile zellik haritası oluřturulur [294]. Eř. 5.1’de 2B evriřim katmanının ğrenme srecini ifade etmektedir. Burada $O(x, y)$ girdi matrisinde “ x, y ” konumundan ıkarılan zellikleri temsil ederken K ise evriřim filtresini ve boyutunu belirtir. $I(i, j)$ girdi matris giriř matrisinin i satırı ve j stnundaki elemanı ifade eder. Eğr 2B grsel RGB renk kanalları gibi birden fazla zellik haritası ierirse her bir kanal iin evriřim iřlemi tekrarlanır. Genel toplam, her kanal iin yapılan evriřim iřlemlerinin bir toplamıdır.



řekil 5.6. 3B evriřim iřleminin sembolik gsterim


$$O(x, y) = \sum_{i=-\infty}^{+\infty} \sum_{j=-\infty}^{+\infty} I(i, j) \cdot K(x - i, y - j) \quad (5.1)$$

3B evriřim iřlemi 2B evriřim iřleminin geometrik boyutunun artırılması ile elde edilir (Eř. 5.2). Burada boyut artıřına baėlı olarak girdi matrisi $I(i, j, k)$, ıktı matrisi $O(x, y, z)$ ve filtre (K) matrisleri 3B’lu veriler iin yeniden dzenlenmiřtir. Elde edilen sonuca bir “bias” deėeri eklenerek aktivasyon fonksiyonuna sokulur. Girdi verilerinin boyutu arttıėa bu hesaplama maliyetinde stel bir artıř grlr. Bu nedenle bir sonraki evriřim katmanının hesaplama ykn azaltmak ve genelleme yeteneėini artırmak iin havuzlama (pooling) teknikleri ile parametre sayısı azaltılır (řekil 5.6).

$$O(x, y, z) = \sum_{i=-\infty}^{+\infty} \sum_{j=-\infty}^{+\infty} \sum_{k=-\infty}^{+\infty} I(i, j, k) \cdot K(x - i, y - j, z - k) \quad (5.2)$$

5.3.2. 3B tersine evriřim katmanı

3B tersine evriřimli katmanı, evriřim katmanının aksine bir özellik haritasını kullanarak düşük çözünürlüklü verilerden yüksek çözünürlüklü veriler oluşturur. Üretici ağı temel bileřeni olan bu katman, düşük boyutlu gürültü vektöründen detaylı ve gerçekçi 3B veriler üretir [295]. Daha büyük bir boyut elde etmek için 3B filtreleri (kernel) özellik haritası üzerinde kaydırarak kullanılır (Şekil 5.7). 3B tersine evriřim katmanı Eş. 5.3'teki gibi formüle edilir. Evriřim ve tersine evriřim formüllerinin temel farkı, girdi özellik haritasından alınan indekslerdir. Evriřimde, filtre pozitif bir yönde kaydırılırken; tersine evriřimde, filtre negatif yönde kaydırılarak geriye doğru hareket eder.



Şekil 5.7. 3B tersine evriřim işleminin sembolik gösterimi

$$O(x, y, z) = \sum_i \sum_j \sum_k I(x - i, y - j, z - k) \cdot K(i, j, k) \quad (5.3)$$

Bu formülasyonla girdi $I(i, j, k)$ matrisinin belirli bir bölgesi ile evriřim filtresi (K) arasında bir toplam hesaplanarak çıkış değeri $O(x, y, z)$ elde edilir. Bu değer, bir bias değeri ile birlikte aktivasyon fonksiyonuna sokulur.

5.3.3. Toplu normalleştirme katmanı

Normalizasyon, çeřitli veri kaynaklarını aynı aralıkta tutmak (standartlaştırma) için kullanılan bir ön işleme tekniğidir. Veri normalleştirme derin öğrenme mimarilerinde eğitim

hızını artırmada kullanılan yöntemlerden biridir. Yığın (batch) normalleştirme ise derin öğrenme katmanları arasında tam veri kümesi yerine küçük partiler üzerinde yapılan normalleştirme işlemidir. Hem üretici hem de ayırıcı ağlarda yaygın olarak kullanılan yığın normalleştirme katmanı, her eğitim adımında önceki katmanın aktivasyonlarını normalleştirir. Bu işlem eğitimin istikrarını artırır ve yakınsamayı hızlandırır [296].

Normalleştirme katmanları, üzerinden geçen verileri optimize ederek derin öğrenme modelini daha kararlı hale getirir. Normalleştirme katmanı genel itibarı ile Eş 5.4'te formüle edilmiştir. Burada x , bir sinir ağı katmanından gelen çıktıları temsil eden girdi vektörüdür. μ ve σ sırasıyla bu girdi vektörünün tahmini ortalaması ve standart sapmasıdır. Ortalama, girdi vektörünün tüm elemanlarının ortalamasını alarak, standart sapma ise girdi vektörünün tüm elemanlarının standart sapmasını alarak hesaplanır. Diğer taraftan a ve b terimleri, modelin öğrenme süreci sırasında ayarlanabilen parametrelerdir. “ a ,” modelde her bir özelliğin önemini ölçeklendiren öğrenilebilir bir katsayıdır. “ b ” ise modelde her bir özelliğin çıktı üzerindeki etkisinin ayarlamasına olanak sağlayan öğrenilebilir bir yanlılık (bias) değeridir.

$$y = \frac{a}{\sigma}(x - \mu) + b \quad (5.4)$$

5.3.4. Aktivasyon katmanları

Aktivasyon fonksiyonu derin öğrenme modelinin doğrusal olmayan ilişkileri öğrenmesini sağlar. Ağa doğrusal olmayan özellikler ekleyerek veriler arasındaki karmaşık yapıları öğrenmenin yolunu açar. Aktivasyon fonksiyonu derin öğrenme modelinde her bir katman çıkışına uygulanarak çıktıların ağırlıklı toplamını bir sonraki katman için girdi olacak şekilde aktive eder. 3DGAN yapısında, üretici katmanlarında genellikle ReLU aktivasyon fonksiyonu kullanılırken, ayırıcı katmanlarında Leaky ReLU tercih edilir. Üreticinin çıktı katmanı için ise Sigmoid veya Tanh aktivasyon fonksiyonları yaygın olarak kullanılır.

5.3.5. Rastgele gürültü vektörü

Gürültü vektörü, derin öğrenme ve özellikle Üretken Çekişmeli Ağlar (GAN'lar) bağlamında önemli bir rol oynar. Temel olarak, bir gürültü vektörü, belirli bir olasılık dağılımından (çoğunlukla Gauss veya normal dağılımdan) örneklenen rastgele sayılardan oluşan bir

vektördür. Bu rastgelelik, modelin veri üretim sürecine özgünlük ve çeşitlilik katmasına yardımcı olur. Gürültü vektörünün amacı, sahte verinin neye benzediğini belirlemek için bir çeşit ‘çekirdek’ işlevi görmektir. Model bu ‘çekirdek’ üzerinde eğitilir ve sonuçta belirli bir veri dağılımını taklit eden veriler üretir.

Gürültü vektörünün boyutu genellikle deneysel olarak belirlenir ve modelin karmaşıklığına, öğrenme kapasitesine ve eğitilen veri kümesinin özelliklerine bağlıdır. Bu vektör, modelin her eğitim adımında veya sahte bir veri örneği üretmek istendiğinde rastgele olarak yeniden örneklenir. Bu, modelin aynı gürültü vektörü için tutarlı sahte veri üretmesini sağlar. Ayrıca modelin doğru bir şekilde eğitilip eğitilmediğini kontrol etmek için yararlıdır.

5.4. 3DGAN Eğitimi


GAN iki rakip ağı eş zamanlı eğitilmesiyle gerçek verilere benzer veriler üretebilen derin öğrenme mimarileridir. Bu ağların eş zamanlı eğitimi klasik öğrenme süreçlerinin dışına çıkılmasını gerektirir. Bu süreç temel olarak gürültü örnekleme, sahte veri üretme, gerçek ve sahte verileri ayırt etme ve ağ ağırlıklarını güncelleme adımlarından oluşur.

Gürültü örnekleme, üretken ağı daha yaratıcı hale gelmesine ve daha çeşitli sahte veriler üretmesine sağlayan işlemidir. Gürültü örnekleme adımında normal dağılım veya uniform dağılımdan alınan noktalar karmaşık veri yapıları elde edilmesi için gürültü vektörüne dönüştürülür. Bu örnekleme üretilen sahte verilerin çeşitliliğini artırmak için modele rastgelelik kazandırır. Gürültü vektörünün boyutu üretici ağı giriş boyutuna eşit değildir. GAN modellerinde gürültü vektörü ve üretici ağı giriş boyutunu artırmak, üretken ağı gerçekçi veriler üretmesine yardımcı olurken hesaplama maliyetini de artırır.

3DGAN’ın ikinci aşaması bir dizi derin öğrenme katmanından oluşan üretici ağ ile sahte veri üretimidir. Bu katmanlar, bir gürültü vektörünü daha karmaşık bir veri yapısına (3B model) dönüştürür. Bu ağ genellikle tamamen bağlı (İng. fully connected), evrişimli transpoze (İng. transpose convolutional), normalleştirme (İng. normalization) ve aktivasyon katmanları içerir (Şekil 5.8). Tamamen bağlı katmanlar gürültü girdisini daha yüksek boyutlu bir vektöre dönüştürür. Sonraki aşamada evrişimli transpoze katmanlar, yüksek boyutlu vektörlerin yerel özelliklerini öğrenmek ve vektör boyutunu artırmak için kullanılır.


Bu, modelin düşük çözünürlüklü bir gürültü vektörünü yüksek çözünürlüklü bir 3B modele dönüştürmesini sağlar.

Modelin genelleme yeteneğini geliştirmek, hesaplama maliyetini azaltmak ve eğitim sürecini hızlandırmak amacıyla normalleştirme katmanları kullanılır. Son olarak, aktivasyon fonksiyonları, bir katmanın çıktılarını bir sonraki katmanın girdisine dönüştürmek için kullanılır. Bu sürecin sonunda üretici model gürültüyü gerçek verilere benzer karmaşık veri yapısına dönüştürür. Üretici ağ, GAN modellerinin yeni ve çeşitli örnekler üretme yeteneğinin temelini oluşturur.



Şekil 5.8. Temel üretici ağ mimarisi

3DGAN modelinin üçüncü aşamasında gerçek ve sahte verilerin ayırt edildiği ayırıcı ağ yer alır. Ayırıcı ağ genellikle evrişimli, normalleştirme ve tamamen bağlı katmanlar ve aktivasyon fonksiyonlarından oluşur. Evrişimli katmanlar görsel (görüntü, 3B model gibi) veriler üzerinden yerel özellikleri öğrenmek ve özellik haritası oluşturmak için kullanılır (Şekil 5.9). Bu katmanlar girdi verisinin boyutunu azaltarak ağın genelleme kabiliyetini artırır. Evrişim katmanında filtrenin ilerleme miktarı (stride) ile boyut azaltma oranı belirlenir. Ağın son aşamasında klasik sinir ağlarından oluşan tamamen bağlı katmanlar ile sınıflandırma (gerçek veya sahte) işlemi yapılır. Üretici ağda da olduğu gibi normalleştirme katmanları eğitim sürecini hızlandırır ve modelin daha kararlı olmasını sağlar.



Şekil 5.9. Temel ayırıcı ağ mimarisi

Ayırıcı ağ, girdi verisinin boyutunu aşama aşama azaltarak sınıflandırma işlemini tamamlar. Tamamen bağlı katmanların sonunda modelin tahmin ettiği 0 ile 1 arasındaki değer ile gerçek durum karşılaştırılarak doğruluk hesaplanır. Gerçek ve tahmin değerleri arasındaki fark ise “kayıp” olarak isimlendirilir. Kayıpların toplamı ise maliyet fonksiyonunu belirler. 3DGAN mimarisi, Üretici ve Ayırıcı ağın performansını aynı anda artırmak amacıyla, Eş. 5.5'te belirtilen geleneksel kayıp fonksiyonu kullanılarak eğitilir [10]. Bu fonksiyonda, “min”, Üretici'nin (G) kaybını en aza indirmeyi, “max” ise Ayırıcı'nın (D) kaybını en üst düzeye çıkarmayı temsil eder. Burada x, gerçek modelleri ve z, gürültü girişini belirtmektedir. Genel olarak ağ eğitimi amaç ve kayıp fonksiyonları kullanılarak ağ ağırlıklarının optimize edilme sürecidir.

$$\min \max(D, G) = E_x[\log(D(x))] + E_z[\log(1 - D(G(z)))] \quad (5.5)$$

3DGAN model parametrelerinin güncellenmesi için üretici ve ayırıcı ağ için iki farklı kayıp fonksiyonu hesaplanır. Bu, tipik olarak stokastik gradyan iniş (İng. Stokastik Gradient Descent, SGD) ve bir optimizasyon algoritması (Adam vb.) kullanılarak gerçekleştirilir. Çıktı katmanından başlanarak her bir katman için geriye doğru ağ ağırlıklarının türevi alınarak geri yayılım algoritması ile ağ ağırlıkları güncellenir. Gradyan iniş tekniği ile kayıp değerini azaltacak şekilde ağ ağırlıkları güncellenir. Bu iteratif süreç belirli bir durdurma kriterine ulaşılan kadar devam eder. Diğer taraftan öğrenme hızı, yığın boyutu, eğitim

dönemi sayısı (epoch) ve katman sayısı, evrişim sayısı ve evrişim katman boyutları gibi ağ mimarisine özgü ayarlar hiper-parametre olarak isimlendirilir. Hiper-parametrelerin belirlenmesinde kesin bir formülasyon bulunmamaktadır. Bu hiper-parametreler derin öğrenme tasarımcıları tarafından tecrübeye bağlı olarak belirlenmektedir.

3DGAN eğitimi; üretici ve ayırmacı arasında bir denge bulmayı amaçlayan zor bir süreçtir. Bir ağın diğerine göre baskın olması durumunda GAN modeli etkili bir şekilde öğrenemeyebilir. Ayırmacı baskın olduğunda, üretici ağ gradyanları kaybolabilir. Üreticinin daha güçlü olduğu durumda ise ayırmacı sahte verileri gerçek veriden ayırt edilemeyebilir.

Geleneksel GAN'lar gibi, 3DGAN'larda da mod çökmesi, kaybolan gradyanlar ve kararsız eğitim dinamikleri gibi çeşitli eğitim zorluklarıyla karşılaşılabilir. Bu sorunları çözmek için gradyan cezası, spektral normalleştirme ve yardımcı görevler gibi çeşitli yöntemler önerilmiştir. Bu yöntemler, aşırı gradyanları önlemeye çalışan Lipschitz sürekliliği adı verilen bir özellik sağlar. Bu sayede, eğitim süreci daha istikrarlı hale gelir. Spektral normalleştirme, ağ ağırlıklarını normalleştirerek modelin genelleştirme kabiliyetini artırır ve eğitim sürecini stabilize eder.

5.5. Uygulama

Derin öğrenme çalışmalarında, model performansını ölçmek ve geliştirmek için kullanılan standart veri kümeleri vardır. Özellikle 3B nesne tanıma ve oluşturma alanında, sandalye gibi bazı belirli nesneler hem karmaşıklığı hem de çeşitliliği nedeniyle ideal test ögeleri olarak kabul edilir. Bu bölümde, 3DGAN modelinin eğitim sürecini detaylı bir şekilde ifade etmek için örnek bir uygulama yapılmıştır. 3DGAN modelinin eğitim süreci ve bu süreçte karşılaşılan zorluklar bu somut örnek üzerinden açıklanmaktadır. Bu, modelin gerçek dünya nesnelerini nasıl öğrendiği ve bu nesneleri nasıl yeniden oluşturduğu daha iyi bir şekilde ifade eder.

5.5.1. Eğitim veri kümesi

3B modelleme ve nesne tanıma çalışmalarında kaliteyi artırmak amacıyla pek çok veri kaynağına müracaat edilmiştir. ShapeNet, GrabCAD, Amazon Berkeley Objects ve Archive3D gibi öne çıkan veri depoları bu alanda kullanılan ana kaynaklardır. Bu

depolardan elde edilen veriler, çeşitli kategorilere ayrılmış olsa da sandalye gibi bazı kategoriler hemen hemen her depoda mevcuttur. Bu da sandalyenin derin öğrenme alanında bir referans nesne haline gelmesine neden olmuştur.



Şekil 5.10. Veri kümesinden 3B sandalye veri örnekleri

İlk olarak sandalye kategorisini merkeze alarak, farklı kaynaklardan gelen sandalye modelleri bir araya getirilmiştir (Şekil 5.10). Böylece modelin çeşitli stil ve formlardaki sandalyeleri genel bir kavram altında tanınması amaçlanmaktadır. Çizelge 5.1'de belirtilen veri kaynaklarından alınan sandalye model verileri, çoğunlukla “obj” uzantısına sahiptir. Ancak, üretken model eğitimi için bu verilerin standart bir formatta olması zorunludur. Bu sebeple, eksik veya hatalı verilerin olumsuz etkisini engellemek adına bu veriler elimine edilmiştir. Ardından, veriler, standart bir boyuta ve “binvox” formatına dönüştürülmüştür. Bu süreç sonunda, 9.940 adet 94 x 94 x 94 boyutunda 3B model elde edilmiştir.

5.5.2. Model eğitimi

3DGAN modelini eğitmek ve test etmek için oluşturulan kod yapısı, çeşitli modüllerden oluşan bütünsel bir yapıya sahiptir. Bu 3DGAN modeli, Wu vd.’nin modeline dayanarak geliştirilmiştir [190]. Temel olarak “model” ve “eğitim” olmak üzere iki ana modül

üzerinden gerçekleştirilmektedir. Diğer modüller ise hiper-parametreleri düzenleme ve eğitimi başlatmak için kullanılmaktadır.

Çizelge 5.1. Eğitim veri kümesini oluşturan veri kaynakları

Veri kaynağı	Model sayısı	Dosya uzantısı
<i>ShapeNet</i>	6.700	obj
<i>GrabCAD</i>	1.050	obj, step, stl, ply
<i>Amazon Berkeley Objects</i>	1.000	obj
<i>Archive3D</i>	540	obj
<i>Diğer</i>	650	obj, stl, max, c4d vd.

Parametre modülü, modelin eğitimi sırasında kullanılan tüm hiper-parametreleri yönetir. Bu modül, öğrenme oranları, havuz boyutu, eğitim döngüsü sayısı gibi temel hiper-parametrelerin yanı sıra, modelin ve verilerin kaydedileceği dizin yollarını da içermektedir. Aynı zamanda, seçilen hiper-parametrelerin konsola yazdırılmasını sağlayan bir fonksiyon sayesinde model eğitimi veya testi sırasında kullanıcının hangi parametrelerle çalıştığını görmesine olanak tanır. Ek olarak modelin çalıştırılacağı grafik işlemci için PyTorch'un GPU destekli fonksiyonlarını kullanır.

Çizelge 5.2. Eğitim hiper-parametreleri

<i>Hiper-parametreler</i>	
<i>Döngü</i>	: 300
<i>Veri boyutu</i>	: 96 x 96 x 96
<i>Havuz boyutu</i>	: 32
<i>Gürültü vektör boyutu</i>	: 200
<i>Öğrenme oranı (Üretici)</i>	: 0,00015
<i>Öğrenme oranı (Ayırıcı)</i>	: 0,00001
<i>Bitirme kriteri (Doğruluk)</i>	: 0,90

Başlatma modülü ise model eğitim sürecini başlatmak için giriş noktasıdır. Bu modül, eğitim fonksiyonlarını içe aktararak modelin nasıl çalıştırılacağını tanımlar. Aynı zamanda kullanıcıya, modelin eğitim sürecini özelleştirebilmek için bir dizi komut satır argümanı da sunar. Bu argümanlar arasında; modelin adı, eğitimin yapılıp yapılmayacağı, kayıt alma ve görselleştirme seçenekleri gibi parametreler bulunmaktadır. Bu iki modül, 3DGAN modelini eğitmek için gereken tüm seçenekleri ve özelleştirmeleri sağlayan kullanıcı arayüzüdür. Bu yapı sayesinde, model eğitimi sırasında kullanılan hiper-parametrelerin kolaylıkla izlenmesi

ve değiştirilmesi mümkün olur. Bu durum modelin performansını optimize etmek için gereken esnekliği ve özelleştirmeyi sağlar. Bu modelde kullanılan hiper-parametreler Çizelge 5.2’de gösterilmiştir.

Diğer taraftan “model”, ağ mimarisinin tasarlandığı temel modüldür. Bu modül, bir üretici ve bir ayırıcıdan oluşan 3DGAN modelini içerir. Öncelikle üretici ağ, rastgele bir gürültü vektörünü alır ve bu gürültüyü 3B bir veri noktasına dönüştürür. Model, tersine evrişim katmanlarını kullanarak 3B verinin özellik haritasını çıkarır. Buna karşılık Ayırıcı, gerçek bir veri noktası ile üretici tarafından üretilen sahte bir veri noktası arasında ayırım yapar. Bir başka deyişle, ayırıcı ağ, 3B veriyi girdi olarak alır ve bu verinin gerçek veya sahte olup olmadığını tahmin eden bir skor üretir.

Çizelge 5.3. 3DGAN model mimarisi ve öğrenilebilir parametre sayısı

	Katman Adı	Çıktı (Tensör) boyutu	Aktivasyon Fonksiyonu	Normalizasyon	Parametre Sayısı
<i>Üretici Ağ</i>	Giriş	[200, 1, 1, 1]	-	-	-
	Katman 1	[512, 3, 3, 3]	ReLU	BatchNorm3d	2 765 824
	Katman 2	[256, 6, 6, 6]	ReLU	BatchNorm3d	8 389 120
	Katman 3	[128, 12, 12, 12]	ReLU	BatchNorm3d	2 097 408
	Katman 4	[64, 24, 24, 24]	ReLU	BatchNorm3d	524 416
	Katman 5	[32, 48, 48, 48]	ReLU	BatchNorm3d	131 136
	Çıktı	[1, 96, 96, 96]	Sigmoid	-	2 048
<i>Ayırıcı Ağ</i>	Giriş	[1, 96, 96, 96]	-	-	-
	Katman 1	[32, 48, 48, 48]	LeakyReLU	BatchNorm3d	2 112
	Katman 2	[64, 24, 24, 24]	LeakyReLU	BatchNorm3d	55 424
	Katman 3	[128, 12, 12, 12]	LeakyReLU	BatchNorm3d	524 544
	Katman 4	[256, 6, 6, 6]	LeakyReLU	BatchNorm3d	2 097 664
	Katman 5	[512, 3, 3, 3]	LeakyReLU	BatchNorm3d	8 389 632
	Çıktı	[1, 1, 1, 1]	Sigmoid	-	32 768
Toplam					25 012 096

3DGAN modelinin iki ana bileşeni olan üretici ve ayırıcı ağların yapısal bilgileri Çizelge 5.3’de verilmiştir. Köşeli parantez içinde verilen değerler o katmandaki tensör boyutunu gösterir. Örneğin, [64, 24, 24, 24] ifadesi bu katmanda 64 farklı özellik haritası olduğunu ve her bir özellik haritasının 24 x 24 x 24 boyutunda bir 3B model olduğunu belirtir. Aktivasyon fonksiyonları, katmandan çıkan değerlere uygulanan matematiksel işlemlerdir. Üretici ağda modelin daha hızlı ve etkili öğrenmesini sağlayan “ReLU” aktivasyon fonksiyonu kullanılmıştır. Ayırıcı ağda ise ReLU’nun bir varyantı olup negatif değerlere de küçük bir tepki vererek modelin öğrenme sürecini stabilize eden “LeakyReLU” aktivasyon fonksiyonu

kullanılmıştır. “BatchNorm3d” normalizasyonu katman çıktılarını normalleştirerek modelin eğitim sürecini hızlandır ve istikrarlı bir eğitim süreci sağlar. Son olarak parametre sayısı, belirtilen katmanda eğitilebilir ağırlık ve bias değerlerinin toplam sayısını ifade eder. Bu parametreler, modelin eğitimi sırasında veriden öğrenilen değerlerdir. Yaklaşık 25 milyon parametre, oldukça derin ve kapasiteli bir ağı ifade eder. Bu, modelin karmaşık özellikleri yakalama yeteneğini artırırken, aynı zamanda daha fazla hesaplama maliyeti ve bellek ihtiyacı oluşturur. Özellikle 96 x 96 x 96 boyutunda yaklaşık 10.000 adet veri ile çalışmak için yüksek işlem kapasiteli bir iş istasyonu kullanılmıştır. Eğitim için kullanılan iş istasyonu, Intel Core i7 işlemciye, 64 GB RAM'e, NVIDIA RTX 3090 GPU'ya ve 1 TB SSD depolama birimine sahiptir.

Kodun temel bileşenlerinden biri olan “eğitim” modülü verilen argümanlara göre modelin eğitimini gerçekleştirir. İlk olarak, eğitim sürecinde model ağırlıklarının ve üretilen 3B nesnelerin kaydedileceği dizinler oluşturulur. Ardından eğitim verisi yolu tanımlanır ve bu veriler bir veri yükleyici yardımıyla modeli beslenmek üzere hazırlanır.

Üretici ve ayıcı modellere ait parametreleri optimize etmek amacıyla Adam optimizatörü kullanılmıştır. Adam, adaptif öğrenme oranlarına sahip gradyan tabanlı bir optimizasyon yöntemidir. Ayırt edici modelin performansı Ortalama Karesel Hata (İng. Mean Squared Error, MSE) metriği kullanılarak belirlenmiştir. Bu metrik, tahmin ile gerçek değerler arasındaki kare farkının ortalamasını ifade eder. Diğer yandan, üretici model için L1 normu bazlı bir kayıp fonksiyonu kullanılmıştır. L1 normu, bir vektörün bileşenlerinin mutlak değerlerinin toplamını belirtir. Bu kayıp fonksiyonu üretilen ve gerçek değerler arasındaki mutlak farkı en aza indirmeyi amaçlar.

Eğitim süreci belirlenen döngü sayısı kadar tekrarlanır. Her döngüde, üretici ve ayıcı kayıp değerleri hesaplanır ve bu değerler, ilerleyen analizler için kaydedilir. Ek olarak, eğitim sürecinde model performansının değerlendirilebilmesi için belirli döngülerde model ağırlıkları ve üretici tarafından üretilen 3B nesneler kaydedilir. Eğitim 300 döngü (İng. epoch) sonunda yaklaşık 18 saatte tamamlanmıştır.

5.5.3. Model testi


Derin öğrenme modelinin eğitimdeki başarısını ölçmek için optimize edilen ağırlıklarının kullanarak model test edilir. Modelin tüm eğitim ve doğrulama süreçleri tamamlandıktan sonra test verisi üzerinde değerlendirilmesi, modelin gerçekte ne kadar etkili olabileceği gösterir [297]. Bu değerlendirme, modelin daha önce hiç karşılaşmadığı veriler üzerindeki performansını belirlemek amacıyla tasarlanmıştır. Bu nedenle, genellikle; veri kümesi, model eğitimi için eğitim verisi (%60-80), hiper-parametre ayarlamaları için doğrulama verisi (%10-20) ve modelin nihai performansının değerlendirilmesi için test verisi (%10-20) olmak üzere üç farklı kümeye ayrılır. Model eğitimi sırasında test verisinin model tarafından hiç görülmemiş olması, modelin genelleme kabiliyetini objektif bir şekilde değerlendirme imkânı sunar. Modelin test verisi üzerindeki performansı, problem tipine göre seçilen çeşitli metriklerle ölçülür. Örneğin, sınıflandırma görevleri için doğruluk veya kesinlik gibi metrikler, regresyon görevleri için ise MSE gibi metrikler tercih edilebilir [298]. Eğer bir model, eğitim verisinde yüksek performans gösterirken test verisinde bu performansı gösteremiyorsa, bu durum genellikle modelin aşırı öğrenmeye maruz kaldığını gösterir.

Üretken Çekişmeli Ağlar, diğer derin öğrenme modellerinden farklı bir yapıya sahip oldukları için test süreçleri de farklıdır. Klasik sınıflandırma görevlerinde modelin, eğitim setinde öğrendiği bilgileri test setindeki verilere uygulanarak modelin sınıflandırma kabiliyetini değerlendirilir. Ancak GAN test süreci genellikle üreticinin gerçekçi veri üretme yeteneğini değerlendirmek için yapılır. GAN test aşamasında optimize edilen ağırlıkları kullanarak üretici ağı tarafından yeni veri örnekleri oluşturulur. Bu oluşturulan örneklerin kalitesi, çeşitliliği ve gerçek verilere olan benzerliği incelenir.

GAN modelleri tarafından üretilen verilerin kalitesi ve çeşitliliği genellikle görecelidir. Bu nedenle model performansını değerlendirmek genellikle sübjektif bir süreçtir. Bununla birlikte, objektif değerlendirme için birkaç yaygın metrik ve yöntem kullanılabilir. İlk olarak Başlangıç Puanı (İng. Inception Score), üretilen görsellerin çeşitliliği ve kalitesini ölçmek için kullanılır. Bu skor, üretilen görüntülerin Inception modeli üzerinden elde edilen özelliklerin dağılımını temel alır. Diğer bir metrik, “Fréchet Inception Distance”, Inception modeli üzerinden elde edilen özelliklerin ortalamaları ve kovaryans değerlerine dayanarak gerçek veri dağılımı ile üretilen veri dağılımı arasındaki mesafeyi ölçer. Ancak bu yöntemler 2B görseller üzerinde etkili bir değerlendirme sağlasa da 3B model performansını

değerlendirmek için uygun değildir. 3DGAN tarafından üretilen verilerin kalitesini değerlendirmek için kullanıcı anketleri gibi sübjektif yöntemler kullanılabilir.

Şekil 5.11, 3DGAN modelinin eğitim sürecinde belli döngülerde ürettiği sandalye modellerini göstermektedir. İlk döngülerde, modelin henüz veri dağılımını öğrenmediğini için üretilen sandalyelerin tanınmaları zordur. Eğitimin ilerleyen döngülerinde sandalye modelleri daha iyi tanınabilir hale gelmektedir. Ancak anormallikler ve hatalar hala gözlemlenmektedir. Son döngülerde ise üretilen sandalyeler belirgin bir şekilde daha gerçekçi ve detaylı hale gelmiştir. Modelin eğitimi süresince gözlemlenen bu gelişim, GAN modelinin veri dağılımını başarılı bir şekilde öğrendiğini ve sandalye modellerini doğru bir şekilde üretebildiğini gösterir. Çizelgede sunulan görseller nokta bulutu ile temsil edilmektedir.




Şekil 5.11. Eğitim aşamalarında üretilen yeni sandalye modelleri

Kayıp (İng. loss) değerleri 3DGAN model performansını değerlendirme kullanılan bir metriktir. Kayıp değerlerinin dinamikleri, GAN mimarisinde kullanılan çeşitli hiper-parametrelerin etkisindedir. Hiper-parametrelerin her birinin, 3DGAN modelinin eğitim sürecindeki kayıp değerlerinin dinamiklerine ve modelin genel performansına önemli etkileri vardır. Bu parametrelerin dikkatlice ayarlanması, üretici ve ayırıcı arasında istenen dengeyi sağlamak ve modelin başarılı bir şekilde eğitilmesi için kritik öneme sahiptir. Kullanılan hiper-parametrelerin ayarlanması büyük ölçüde sezgisel bir süreçtir. Gürültü vektörü boyutu, havuz boyutu, öğrenme oranı, bias, gürültü dağılımları ve katman sayısı gibi faktörlerin etkileri genellikle tahmin edilebilir olsa da her bir modelin ve veri setinin benzersiz özellikleri, bu parametrelerin ideal değerlerini belirlemeyi zorlaştırabilir. Bu nedenle, ideal GAN mimarisinin belirlenmesi için çeşitli parametre kombinasyonları ile denemeler yapılmıştır. Bu deneme sürecinde elde edilen sonuçlar kayıp grafikleri ile görselleştirilmiştir. Bu çalışmada incelenen 3DGAN modeli için yapılan bu tür denemeler ve elde edilen sonuçlar, ekler bölümünde detaylı bir şekilde sunulmuştur.

Gürültü vektörü boyutu, üreticinin başlangıçta üreteceği sahte verilerin karmaşıklığını belirler. Büyük gürültü vektörü boyutu, daha karmaşık veri üretimine olanak tanırken, modelin eğitimini zorlaştırabilir. Bu, üretici kaybının grafikte daha dalgalı bir seyir izlemesine yol açmaktadır. Havuz boyutu, özellikle ayırıcının performansını etkileyen diğer bir hiper-parametredir. Büyük havuz boyutları, ayırıcının sahte ve gerçek veriyi ayırt etme yeteneğini artırırken modelin aşırı uyum (ing. overfitting) eğilimini artırabilir. Öğrenme oranı hem üretici hem de ayırıcı için kritik bir hiper-parametredir. Yüksek bir öğrenme oranı, modelin hızlı bir şekilde optimal değerlere ulaşmasını sağlarken, çok düşük bir öğrenme oranı modelin yavaş öğrenmesine ve yerel minimumlarda takılıp kalmasına neden olabilir. Dengeli bir öğrenme oranı, kayıp değerlerin stabil bir şekilde azalmasını ve ideal GAN eğitim dengesinin sağlanmasını destekler. Diğer taraftan bias, modelin karar verme sürecine etki eder. Düşük bias değerleri, modelin daha genel veri özelliklerine odaklanmasını sağlar. Yüksek bias değerleri ise modelin belirli özelliklere aşırı duyarlı hale gelmesine neden olabilir. Son olarak, katman sayısı, modelin karmaşıklığını ve öğrenme kapasitesini doğrudan etkiler. Daha fazla katmana sahip modeller, daha karmaşık veri yapılarını öğrenebilir. Bu, aynı zamanda modelin aşırı uyum eğilimini ve eğitim süresini artırır.

Şekil 5.12, 3DGAN modelinin eğitim sürecinde en ideal üretici ve ayırıcı kayıp değerlerini sunmaktadır. Grafikteki mavi eğri, üretici kaybını; turuncu eğri ise ayırıcı kaybını temsil

etmektedir. Ayırıcının düşük kayıp değerleri, sahte ve gerçek veriyi etkili bir şekilde ayırt ettiğini göstermektedir. Üreticinin dalgalanan kayıp değeri ise sahte veri üretimindeki zorlukları ifade eder. İdeal bir GAN eğitiminde, üretici ve ayırıcı arasında bir denge olması beklenir. Bu eğitim sürecinin sonunda her iki ağıdaki kayıp değerlerin azalarak bu dengenin sağlandığı görülmektedir.



Şekil 5.12. Eğitim sürecinde üretici ve ayırıcı ağ kayıp değerleri

5.6. Sonuçlar

Tezin bu bölümünde, Üretken Çekişmeli Ağlar (GAN) ve özellikle 3DGAN'ların temel prensiplerini, teorisini ve uygulamaları detaylı bir şekilde ele alınmıştır. İlk olarak, GAN'ların derin sinir ağları ve evrişimli sinir ağlarıyla olan ilişkisini incelenmiştir. Daha sonra, 3DGAN'ın geliştirilmesinin arkasında yatan motivasyon tartışılmıştır. Bu ağların teorisi, bileşenleri ve katmanları derinlemesine incelenmiştir. Son olarak, Bölüm 6'da kullanılan 3DGAN model mimarisinin tasarlanması ve ağ parametrelerinin belirlenmesi için bir uygulama gerçekleştirilmiştir. Elde edilen sonuçlar 3DGAN mimarisinin 3B modelleri başarıyla üretebildiği ve ilerleyen uygulamalarda kullanılabileceğini göstermektedir.

6. 3DGAN VE SONLU ELEMANLAR ANALİZİ İLE MEKANİK PERFORMANSIN GELİŞTİRİLMESİ

Üretken Çekişmeli Ağların (GAN) tasarım yeteneğini sonlu elemanlar analizi (FEA) yöntemiyle birleştirerek 3B konsept tasarımların mekanik özelliklerini geliştirmesi hedeflenmektedir. Bu yaklaşım, tasarım özelliklerini ve otomasyonu iyileştirirken, üretken modellerin koşullandırılması konusunda yenilikçi bir perspektif sunmaktadır. GAN modellerine ait mekanik özelliklerin öğrenmedeki zorluklarına yanıt olarak yeni bir tasarım ve değerlendirme çerçevesi geliştirilmiştir. Bu çerçeve; veri kümesi oluşturma, GAN eğitimi ve Sonlu Elemanlar Analizi (FEA) aşamalarını kapsayan iteratif bir süreçtir. Her iterasyonda, üstün mekanik performanslı modeller belirlenip bir sonraki eğitim veri kümesine eklenir. Veri kümesini yüksek yapısal performanslı verilerle güncellemek, GAN modeliyle üretilen 3B modellerin de yüksek yapısal performans göstermesini sağlamaktadır. Önerilen yöntemin etkinliğini göstermek için havacılık sektöründe kullanılan iki bileşen ele alınmıştır. Başlangıçta, parametrik tasarım ve Voronoi diyagramlarının birleştirilmesiyle bu bileşenleri içeren veri kümeleri oluşturulmuştur. Daha sonra 3DGAN ile oluşturulan yeni tasarımlar FEA ile test edilmiştir. Üstün yapısal özelliklere sahip tasarımlarla güncellenen yeni eğitim veri kümesi, daha gelişmiş mekanik özelliklere sahip 3B model üretme potansiyeline ulaşmıştır. Bu iki uygulamada tasarımların ortalama emniyet faktöründe sırasıyla %6,8 ve %16,8'lik artış elde edilmiştir. Diğer yandan üretilen tasarımların çeşitliliği istenilen yönde daralmıştır. Bu bulgular, yapısal bileşenlerin üretken modellerle doğrudan üretiminin, mühendislik tasarımında derin öğrenmenin potansiyelini genişleteceğini göstermektedir. Bu çalışmanın diğer bir özgün yönü ise veri bağımlı üretken tasarım modellerinin koşullandırılması için yeni ve etkin bir seçenek sunmasıdır.

6.1. Fonksiyonel Üretken Tasarım Modeli

Hemen her konuda olduğu gibi ürün ve mühendislik tasarımı alanlarında da makine öğrenmesi modelleri kullanılmaktadır [106, 141, 299]. Özellikle derin öğrenme tabanlı üretken tasarım yöntemlerinin geliştirilmesi ve kullanımı; ilham verme, fikir üretimi, konsept oluşturma, değerlendirme, optimizasyon gibi tasarım süreçlerini hızlandırmıştır [5, 249]. Bu yöntemler kullanılarak çok kısa sürede ve minimum tasarımcı müdahalesi ile daha iyi ve kapsamlı tasarımlar oluşturulabilir. Üretken derin öğrenme modelleri tasarım uzayının basit bir temsili olan özellik uzayı ile tüm tasarım özelliklerini öğrenebilir. Özellik uzayı tasarıma ait temel noktaları yakalayarak yeni konseptlerin üretilmesini mümkün kılar [142].

Güncel veri bağımlı üretken tasarım sistemleri genelde GAN mimarisi üzerine kurulmuştur. GAN'ın yeni veri (yazı, görüntü, 3B model vb.) üretme kabiliyeti tasarım çalışmalarında kullanılmaktadır. Bu çalışma konularından birisi de 3B konsept üretimidir. 3B konseptler 2B konseptlerden daha fazla görsel ve fiziksel unsur içerdiğinden ayrıntı seviyesi daha yüksek olur. Bu durum 3B model üreten veri bağımlı üretken tasarım araştırmalarını daha önemli kılar [24]. Klasik GAN modelleri tasarım görseline bağlı form özelliklerini keşfedebilir. Ancak iyi bir tasarım temsilinde; biçim (form) ve fonksiyon özellikleri bir bütün olarak ele alınmalıdır. Biçim, ürünün geometrik ve topolojik özelliklerini içerir. Fonksiyon ise ürünün tasarım amacını ifade eder. Tasarımcılar form ve fonksiyon arasındaki ilişkiyi anlayabilir. Ancak YZ'nin bu tür karmaşık ilişkileri kavraması oldukça zordur. Bu nedenle veri bağımlı üretken tasarım çalışmaları genelde yeni formlar üretmeyi amaçlar. Burada üretilen konseptler fonksiyonel/yapısal iş parçaları olmaktan uzak olup, ancak ek düzenleme ve iyileştirmelerle kullanılabilirler. Bu kapsamlı zorluklar yeni ve geniş bir araştırma alanı oluşturmaktadır.

Bu bölümde üretilen tasarımların form ve fonksiyon özelliklerini değerlendirmek için bir üretken derin öğrenme modeli ve sonlu elemanlar analizi birleştirilmektedir. 3DGAN ile üretilen konseptlerin kalitesi ve çeşitliliği kontrol edilirken, sonlu elemanlar analizi (FEA) ile mekanik değerlendirmeler yapılabilir. Değerlendirme sonucunda form, ağırlık ve dayanım gibi açılardan iyi olan tasarım seçenekleri tekrar GAN eğitim kümesine eklenmektedir. Böylece daha iyi/kaliteli tasarımlar eğitim kümesinin kalitesini artırarak üretilen yeni 3B modeller gelişmiş fonksiyonel özelliklere sahip olabilecektir. Bu çalışmanın temel amacı derin öğrenme destekli üretken tasarım yöntemiyle oluşturulan 3B modellere fonksiyonel özelliklerini artıracak otonom bir yaklaşım geliştirmektir. Bu bağlamda tasarıma ait yük, kuvvet veya güç aktaran tüm bileşenler FEA ile değerlendirilir ve gerekirse yeniden tasarlanır. Literatürdeki diğer çalışmalardan farklı olarak bu çalışma kapsamında ilk defa veri bağımlı üretken tasarım ile FEA yöntemleri birleştirilmektedir. Böylece 3DGAN ile üretilen yapısal iş parçalarının mekanik özellikleri ele alınmaktadır. Bu durum zahmetli analiz-yeniden tasarım işlemleri daha kısa sürede ve minimum insan müdahalesi ile gerçekleşmesini sağlar. Üstün mekanik özelliklere sahip 3B konsept tasarımlar üretilmesi ile tasarım sürecinin otomasyon seviyesi de artacaktır.

Bu yaklaşımın diğer bir özgün yönü ise veri bağımlı üretken tasarım modellerinin koşullandırılması için yeni bir seçenek sunmasıdır. Bu modeller eğitim veri kümesi

dağılımını yansıtan veriler üretmesi ile bilinirler. Tekrarlanan tasarım ve değerlendirme adımları ile eğitim veri kümesinin genel özellikleri iyileştirilerek üretilen verilerin yüksek dayanım özelliklerine ulaşması sağlanır. Üretken modellerin mekanik özelliklerinin koşullandırılması ile mühendislik tasarımında derin öğrenme çalışmalarına potansiyel bir alan oluşturabilir

6.2. Derin Öğrenme Tabanlı Üretken Tasarım

Derin öğrenme tabanlı üretken tasarım yöntemleri, tasarım süreçlerinin otomasyonu ve optimizasyonu yenilikçi bir yöntemler sunmaktadır. Bu yöntemler, derin sinir ağları gibi derin öğrenme tekniklerini kullanarak, karmaşık ve yüksek boyutlu tasarım verilerini analiz eder ve kullanır. Derin öğrenme tabanlı üretken tasarımın temel bileşenleri, GAN ve otomatik kodlayıcılar gibi derin öğrenme modelleridir. Bu modeller konsept üretme, değerlendirme ve optimizasyon süreçlerinde kullanılabilir.

6.2.1. Üretken tasarım ile konsept üretme

Erken tasarım aşamasında problem belirlemeyle başlayan fikir üretimi, bu amaçlı yeni, yaratıcı ve faydalı çözüm önerileri oluşturma şeklinde sürer [99, 300]. Bu süreçte derin öğrenme yöntemlerinin kullanımı tasarım maliyetini azaltırken inovasyonu güçlendirir [110, 111]. Literatürde derin öğrenme modellerine dayalı fikir ve konsept oluşturma ve 3B model üretimi içeren çalışmaların sayısı hızla artmaktadır [301, 302]. Bu çalışmalardan birinde Raine vd., fikir üretme sürecinde insan tasarım stratejilerini derin öğrenme yöntemiyle taklit eden bir yaklaşım önermektedir [121]. Görüntü işleme temelli bu yaklaşım kural ve stratejilerin muğlak olduğu problemlerde bir sonraki tasarım adımını tahmin etmeyi amaçlar. Burnap vd., esnek ve gerçekçi ürün formları elde edebilmek için istatistiksel üretken bir yöntem önermiştir [303]. Bu yöntem, otomobil tasarımında farklı gövde tiplerine ve markalara sahip yeni tasarım seçenekleri sunar. Bir başka üretken tasarım çalışmasında Yu vd., biyolojik nesnelerden ilham alan “DesignGAN” modelini geliştirmiştir. Bu model hedef nesne ve biyolojik nesne görüntülerinin birleşimiyle yeni biyolojik ilhamlı görüntüler oluşturmaktadır [304]. Yuan ve Moghaddam, yeni bir kayıp fonksiyonu ve farklı bir ayırıcı kayıp mekanizması kullanarak “Design-Attribute GAN (DAGAN)” modelini oluşturmuşlardır. DAGAN modeli tasarımın sadece istenilen özelliklerini değiştirmeye izin vererek etkili bir şekilde moda ürünleri (gömlek, pantolon vb.) oluşturmaktadır [110, 122].

Diğer bir çalışmada Wang vd., kullanıcı tarafından arzu edilen özelliklerde ürün görselleri elde etmek için nöro-bilimsel bir yöntem önermiştir [124]. Bu yöntem beyin aktivitelerini tespit eden EEG sinyalleri vasıtasıyla insanı üretken tasarım sürecine dâhil etmeyi amaçlamaktadır. Böylece, RNN ve GAN modellerinin sıralı kullanımı ile yeni ürün tasarımlarında sözlü olarak açıklanamayan istekler tasarıma dahil edilmiştir.

6.2.2. Üretken tasarım ile konsept değerlendirme

Diğer taraftan üretken modeller dengeli mühendislik özellikleri içeren tasarımlar üretebilir [3, 120, 305]. Oh vd., mühendislik performansı yüksek estetik ürün tasarımları elde etmek için GAN modeline topoloji optimizasyonu entegre etmiştir. GANs modellerin başarısı için gerekli eğitim verisi topoloji optimizasyonu ile elde edilerek eğitim kümesinin çeşitlilik ve kalitesini artırılmıştır [3]. Keşif ve değerlendirme adımlarından oluşan çerçeve estetik ve uygulanabilir ürün tasarımları elde etmeyi amaçlamaktadır. Benzer bir çalışmada Yoo vd., kavramsal tasarım aşamasında 3B BDT modellerini otomatik olarak oluşturan ve mühendislik performanslarını değerlendiren derin öğrenme tabanlı bir çerçeve önermektedir [12]. Bu çerçeve oluşturulan 3B konseptlerin mühendislik performansını erken tasarım aşamasında tahmin edilmesine olanak tanır. Başka bir mühendislik tasarım çalışmasında Chen ve Fuge, bir veya birden fazla parçayla sınırları belirlenen gerçek dünya tasarımlarını oluşturmak için bir üretken model sunmuştur [306]. Bu model belirli ana parçalara dayalı olarak parça tasarımlarını düşük boyutlu bir temsil aracılığıyla ayrı ayrı oluşturmaktadır. Modelin geçerliliği çeşitli tasarım örnekleri üzerinde doğrulanmıştır. Chen ve Ahmed, üretken tasarımda çeşitliliği ve kaliteyi artırmak için Performance augmented Diverse Generative Adversarial Network (PaDGAN) modelini önermiştir [123]. PaDGAN, yeni bir olasılıksal nokta süreç tabanlı kayıp fonksiyonu ile tasarım uzay alanını yüksek kaliteli çözümlere doğru genişletebileceğini göstermiştir. Chen ve Ahmed, bir başka çalışmada, mühendislik tasarımında karşılaşılan çok amaçlı optimizasyon sorunlarını çözmek için “Multi-Objective Performance Augmented Diverse Generative Adversarial Network (MO-PaDGAN)” adlı bir model geliştirmişlerdir [307]. Bu model, tasarım çeşitlilik ve kalitesini artırmak için GAN’a özel bir kayıp fonksiyonu ekleyerek gerçek dünya uygulamalarında diğer yöntemlere göre %180 daha iyi bir performans göstermiştir. Nobari vd. ise hedeflenen performans gereksinimlerini karşılayan yeni tasarımlar üretmek için “Continuous Conditional Diverse Generative Adversarial Network (PcDGAN)” modelini önermişlerdir [308]. Yazarlar, PcDGAN'ın tasarım uzayını kapsama kabiliyetinin standart GAN

modellerinin yüksek olduğunu belirtmiştir. Nobari vd. bir başka çalışmada, mühendislik tasarım kısıtlamaları karşılamak için “Range-Constrained Generative Adversarial Network” modelini önermiştir [185]. Önerilen bu model, kendi-kendine genişletme yaklaşımı ve yeni bir kayıp fonksiyonu ile hedeflenen tasarım kısıtlarına karşılayan veriler üretmeyi amaçlamaktadır. Bir başka eğitim başarısını artırma çalışmasında Giannone vd., üretken modellerin hatalı geometriler oluşturma problemine çözüm bulmaya çalışmışlardır. Önerilen yeni eğitim metodu, hatalı veri noktalarını kullanarak üretken modelin üstün performans göstermesini amaçlamaktadır [309].

6.2.3. Üretken tasarım ile optimizasyon


Üretken tasarım yöntemlerinin tasarıma uygulandığı diğer bir alan ise tasarım seçeneklerinin değerlendirme ve optimizasyon sürecidir [164]. Bu çalışmaların birinde Behzadi ve Ilies, topoloji optimizasyonunun hesaplama maliyetlerini aşmak için Convolutional Neural Network (CNN) tabanlı bir transfer öğrenme modeli önermiştir [310]. Yazarlar geleneksel derin öğrenme yöntemlerine göre daha az örnekle yüksek çözünürlüklü 3B tasarım uzayını gerçek zamanlı olarak işlemeyi amaçlamıştır. Yüksek hesaplama maliyetlerini elen alan başka bir çalışmada Rawat ve Shen, Wasserstein Generative Adversarial Networks (WGAN) temelli bir yaklaşım ile 3B geometriler üretebilen bir model oluşturmuştur [311]. Bu model derin öğrenmenin tasarım alanında yinelemeli optimizasyon süreçlerini önemli ölçüde azaltma potansiyelini ortaya koymaktadır. Shu vd., GAN modeli ve Hesaplamalı Akışkan Dinamiği (CFD) yöntemlerini kullanan bir fonksiyonel üretken tasarım modeli geliştirmiştir [142]. Yazarlar GANs marifetiyle üretilen 3B uçak modellerinin CFD ile değerlendiren yinelemeli bir süreç tanıtmaktadır. Böylece hem iyi görünen hem de sürtünme katsayısı düşük uçak tasarımları üretilmiştir. Sunulan yaklaşım, topoloji optimizasyon yöntemlerine göre daha kaba sonuçlar elde etse de daha hızlı yakınsama sağlamıştır. Bir başka tasarım değerlendirme çalışmasında Wu vd., tasarım yarışmaları için oluşturulmuş ürün paftalarından ürünün başarısını tahmin eden bir CNN modeli önermiştir [127]. Bir başka çalışmada Oh vd., topoloji optimizasyonu ve “Boundary equilibrium GANs (BeGANs)” entegrasyonu ile mühendislik performansı yüksek estetik jant tasarımlar üretmeyi amaçlamıştır [3]. Bu çalışmada topoloji optimizasyonundan elde edilen veriler veri çeşitliliği sağlayarak model performansı iyileştirilmiştir. Yazarlar bu yaklaşımın minimum tasarım ve mühendislik alan bilgisi ile daha düşük maliyetli optimizasyon sağladığını iddia etmektedir.

Literatürde üretken derin öğrenme yöntemlerinin mühendislik tasarım sürecine dahil edilmesi üzerine birçok çalışma yapılmıştır. Bu çalışmalar fikir ve konsept oluşturmada tasarım optimizasyonuna kadar geniş bir uygulama yelpazesi içermektedir. Yapılan çalışmalarda GAN'ların üretken tasarım sürecindeki potansiyeli dikkat çekici şekilde vurgulanmaktadır. 3B konsept üretimi GAN modellerinin tasarım uygulamalarında en verimli kullanım alanını oluşturur. 3B konseptler daha fazla fiziksel boyut içerdiği için ayrıntı seviyesi yüksektir. İnsan merkezli klasik tasarım sürecinde 3B model oluşturma işlemi son tasarım aşamalarında yapılır. Bu aşamaya gelinceye kadar ihtiyaçları belirleme, tasarım fikirleri oluşturma, fikirleri değerlendirme ve ideal tasarım seçeneğini belirlemek gerekir. Veri bağımlı 3DGAN modelleri tasarımcı müdahalesi olmadan eğitim verilerinin özellik dağılımlarından öğrenerek 3B konseptler üretebilir. Böylece tasarımcı işi / çalışması azaltılabilir, tasarım maliyetleri düşürülebilir, süreçler kısalabilir ve tasarım otomasyonu sağlanabilir.

Bununla birlikte, literatürde GAN ile üretilen iş parçalarının yapısal dayanım performanslarını yükseltmeyi hedefleyen çalışmalarda hala belirgin bir eksiklik bulunmaktadır. Bu çalışmada önerilen tasarım çerçevesi GAN ile üretilen yenilikçi ve yaratıcı tasarım seçeneklerini FEA kullanarak yapısal dayanımlarını doğrulama ve geliştirmeyi amaçlamaktadır. Derin öğrenme destekli üretken tasarım yöntemlerine fonksiyonel özellik kazandıracak otonom bir yaklaşım geliştirilmiştir. Çalışma kapsamında uzun / zahmetli analiz-tekrar tasarım işlemleri daha kısa sürede ve insan müdahalesi olmadan gerçekleştirmek için veri bağımlı üretken tasarım ile FEA yöntemleri birleştirilecektir. Bu çalışmanın literatürdeki mevcut çalışmalardan bir diğer farkı ise üretilen konseptler gerçek iş parçalarıdır. Son olarak çalışmada kullanılacak veri kümesinin parametrik bir tasarım süreci ile üretilmesi önerilen çerçevenin diğer mühendislik problemlerini kapsamı için yeni ve özgün bir yol sunar.

6.3. Metodoloji

Fonksiyonel 3B model üretme otomasyonu için izlenecek yol ve kullanılacak yöntemler, genel hatlarıyla Şekil 6.1'deki akış şemasında gösterilmektedir. Bu çalışma; veri üretimi ve veri ön hazırlık (1), GAN model eğitimi (2), sonlu elemanlar analizi (3) ve eklemeli imalat (Eİ / 4) olmak üzere dört ana aşamadan oluşmaktadır. İlk üç aşamadaki tasarım, üretim ve değerlendirme döngüsü ile fonksiyonel özellikleri geliştirmek hedeflenmektedir.



Şekil 6.1. Fonksiyonel tasarım seçenekleri oluşturma sürecini ifade eden akış şeması

6.3.1. Veri üretimi ve ön hazırlık

Derin öğrenme yöntemleri eğitim kümesinden örüntü/kalıpları öğrenen ve bunları görüntü işleme, nesne tanıma ve yeni veri üretme amaçlı kullanan YZ algoritmalarıdır. Bu nedenle eğitim kümeleri oluşturma ve/veya derleme, derin öğrenme model başarısında temel etkindir. Model temsil yöntem farklılıkları, sınırlı veri sayısı, dosya boyutları, depolama zorluğu gibi nedenlerden dolayı 3B model kümeleri sınırlıdır [57]. Bu tür sınırlamalar üretken tasarım çalışmalarını olumsuz etkilemektedir. 3B verileri temsil etme ve farklı temsil yöntemleri arasında dönüşüm yapma bu tür sınırlamaların başında gelmektedir.

3B nesne tanıma ve model üretme işlemlerinde; voksel, nokta bulutu ve poligon mesh olmak üzere üç temel temsil yöntemi kullanılmaktadır. 3B uzayda bir nokta temsiliinde kullanılan hacimli piksellere voksel denir. Nokta bulutu ise bir 3B yapı yüzeyindeki noktaların bir araya gelerek oluşturduğu veri temsil yöntemidir. Her bir nokta koordinatlarla ifade edilmektedir. Ayrıca, nokta bulutu model temsilleri kolay modellenebilir olmaları ve düşük hesaplama maliyetleri sebebiyle derin öğrenme model eğitiminde sıklıkla tercih edilir [312, 313]. Son olarak poligon mesh ise 3B modellerin yüzeylerini tanımlayan köşe, kenar ve yüzey topluluğudur. Gerçekçi görünüm ve ayrıntılı temsil istenen uygulamalarda yaygın olarak kullanılır [57]. Bu temsil yöntemleri çeşitli avantaj ve sınırlamalara sahiptir. Örneğin, nokta

bulutları hesaplama maliyeti ve gerçekçi temsiller sunmasına rağmen tam bir yüzey tanım bilgisi sağlamamaktadır. Poligon meshlerde ise detaylı yüzey bilgisi mevcuttur, ancak hesaplama açısından verimli değildir. Diğer taraftan voksel tabanlı temsiller, içyapı tanımlarında iyi performans gösterirken yüksek yüzey kalitesi istenen uygulamalara uyumlu değildir. Bu nedenle kullanılacak temsil yöntemi uygulanacak işlemin ihtiyaçlarına göre belirlenir [312]. Ayrıca bir uygulama veya projenin farklı aşamalarında değişik veri temsil yöntemleri kullanılabilir.

3B model tanıma ve üretme çalışmalarına ait bir diğer sınırlama ise doğru, çeşitli ve kaliteli veriye ulaşma zorluğudur. Princeton shape benchmark, McGill 3D shape benchmark, 7 scenes, ModelNet, ShapeNet gibi popüler 3B veri depoları çeşitli sınıf ve boyutta 3B model içerse de yapısal iş parça (braket, menteşe, mafsalsal, kol, valf vd.) modellerini içermesi açısından oldukça yetersizdir [314]. Yapısal parçalar, başta mühendislik ve endüstriyel tasarım olmak üzere tüm tasarım disiplinlerinde parça tasarımı, üretimi ve montajı gibi süreçlerde kullanılmaktadır. Bu modeller karmaşık geometri ve fonksiyonel özellikleriyle mühendislik tasarımında üretken tasarım yöntemleri kullanma potansiyelini artırabilir. Bu veri kümeleriyle eğitilen üretken tasarım modelleri gerçek dünya koşullarına uygun ve fonksiyonel gereksinimleri karşılayan tasarımlar üretmeyi mümkün kılar.

Mühendislik tasarımında üretken tasarım modellerinin etkinliğini azaltan veri eksikliği problemi çeşitli algoritma ve yazılımlarla oluşturulmuş sentetik veri kümeleri ile aşılabılır. Bu amaçla burada Voronoi diagramları ve parametrik tasarımı birleştiren bir algoritma ile sentetik veri kümesi oluşturulmuştur. Parametrik tasarım; matematiksel işlemler, algoritmalar ve yapay zekayı tasarım süreçleriyle birleştiren disiplinler arası bir alandır [267, 268]. Bu yaklaşım, tasarım varyantlarını otomatik ve hızla güncelleyerek esnek ve etkin çözümler sunar. Parametrik tasarımın getirdiği otomasyon sürdürülebilir çözümler oluşturmayı mümkün kılar [271, 272, 275]. Parametrik tasarımda geometrik unsurlar ve bu unsurlar arasındaki ilişkiler bir dizi değişken ve sınırlayıcı ile tanımlanır [273]. Bu değişkenlerin tasarım sınırları içerisinde değiştirilmesi ile alternatif tasarımlar elde edilebilir [270]. Böylece büyük ölçekli 3B veri kümeleri bir otomasyon dahilinde üretilebilir [12, 276]. Parametrik tasarımın veri kümesi oluşturma kabiliyeti başarılı sonuçlar verse de oluşturulan sentetik veri kümelerinin kalitesini ve çeşitliliğini artırmak için ek algoritmalar ve teknikler gereklidir.

Bu tekniklerden biri olan Voronoi diyagramları belirli odak noktalarına göre bir alan veya hacmi bölümlere ayıran bir diyagramdır. Bu çalışmada Voronoi diyagramları tasarım istek ve sınırlarına yanıt veren 3B modeller oluşturmak için parametrik tasarım sürecine dahil edilmiştir [282]. Bu birleşim, tasarım verimliliğini artırma, özgün ve probleme özel tasarımlar üretme ve geniş tasarım alanlarını keşfetme gibi avantajlar sunar. Bu sayede makine öğrenme algoritmalarını eğitmek ve test etmek, bilgisayarlı görü tekniklerini doğrulamak, görselleştirme ve simülasyon için sentetik 3B modeller oluşturulabilir. Oluşturulan sentetik veriler özellikle derin öğrenme algoritmalarında veri kıtlığı, mahremiyet ve yanlılıkla ilgili zorlukların üstesinden gelmeye yardımcı olabilir. Bu sentetik veri kümeleri aynı zamanda kısıtlı iş parçası model veri kümeleri oluşturmak için potansiyel bir çözüm oluşturur.

6.3.2. Üretken model eğitimi

Üretken Çekişmeli Ağlar (GAN), Ian Goodfellow vd. tarafından 2014 yılında tanıtılan gözetimsiz derin öğrenme modelleridir [236]. Klasik bir GAN modeli, bir üretici (G) ve bir ayırıcı (D) olmak üzere iki rakip sinir ağı içerir. Üretici ağ sahte veriler üretirken, Ayırıcı ağ ise sahte verileri gerçek verilerden ayırmayı amaçlar. GAN modelleri 2B veri sentezinde başarılı olsa da 3B verilerin karmaşıklığına uyum sağlamak için geliştirilmemiştir. Bu nedenle 3B veri temsillerini doğrudan oluşturacak şekilde genişleten 3DGAN modelleri geliştirilmiştir [190]. 3DGAN modelleri, yalnızca gerçekçi 3B veri örnekleri üretme yeteneklerini geliştirmekle kalmaz, aynı zamanda veri temsiliinin artan önemini ve karmaşıklığını ele alarak derin öğrenme alanına önemli katkılar sağlar [11, 291].

3DGAN mimarileri klasik GAN mimarisine benzer şekilde bir üretici (G) ve bir ayırıcı (D) olmak üzere iki ana bileşenden oluşur. Üretici, sentetik 3B veri temsilleri oluşturmakla sorumluyken; ayırıcı, üretilen örnekleri gerçek 3B verilere kıyaslayarak bunların ayrımını yapar. Bu süreç temel olarak gürültü örnekleme, sahte veri üretme, gerçek ve sahte verileri ayırt etme ve ağ ağırlıklarını güncelleme adımlarından oluşur. Gürültü örnekleme adımında normal dağılım veya düzenli (uniform) dağılımdan alınan noktalar karmaşık veri yapıları elde edilmesi için gürültü vektörüne dönüştürülür. 3DGAN'ın ikinci aşaması bir dizi derin öğrenme katmanından oluşan üretici ağ ile sahte veriler üretimidir. Burada tersine evrişim, normalleştirme ve aktivasyon katmanları ile gürültü vektörü boyutu artırılarak 3B temsiller üretilir. 3DGAN model eğitiminin üçüncü aşamasında gerçek ve sahte verilerin ayırt edildiği

ayırıcı ağı yer alır. Burada evrişimli, normalleştirme ve tamamen bağlı katmanlar ve aktivasyon katmanları ile 3B veriyi oluşturan noktalar arasındaki mekânsal ilişkiler tespit edilir.

Derin öğrenme algoritmalarıyla 3B modeller üretmek için farklı stratejiler geliştirilmiştir. Bunlardan ilki 3B modellerden yeni (var olmayan) 3B modeller üretilmesidir [142, 186]. Daha karmaşık olan diğer strateji ise 2B görsellerden 3B modeller oluşturmaktır [187-189]. Wu vd. [190], kapsamlı bir çalışmada bu iki stratejiye dayalı iki farklı üretken derin öğrenme modeli geliştirmiştir. Bunlardan ilki 3B model veri kümesi ile eğitilen ve gerçekçi 3B görseller üretebilen 3DGAN modelidir. Diğer model ise 2B görsellerden 3B modeller oluşturmak için geliştirilen Variational Auto-Encoder ve GAN (3D-VAE-GAN) modelidir. Encoder, decoder ve discriminator ağlardan oluşan 3D-VAE-GAN modeli, 2B görseller ve bu görsellere karşılık gelen 3B modeller ile eğitilmektedir. Gadelha vd. [191], Projective Generative Adversarial Network (PrGAN) ile 2 boyutlu görsellerden 3 boyutlu yapılar elde etmişlerdir. Üretici ağı projection modülü eklenmesiyle bilinmeyen açılardan verilen 2B görsellerin 3B modelleri elde edilmektedir.

6.3.3. Tasarım Değerlendirme

Veri bağımlı üretken tasarım yöntemlerinde (GAN gibi) elde edilen tasarımların tasarım amacına uygunluğunu test edememek önemli bir eksikliktir. Üretken modeller eğitim kümesinin olasılıksal dağılımı kullanılarak eğitilirler. Bu nedenle üretilen veriler eğitim veri kümesine ait genel görünüm ve fonksiyon özelliklerini yansıtır. Üretken modellerin üstün fonksiyonel özelliklere sahip tasarımlar üretebilmesi için eğitim verilerinin üstün tasarım özelliklerine sahip olması gerekir. İş parçalarında fonksiyonellik kavramı çalışma esnasında parçaların yük taşıma kabiliyeti olarak tanımlanabilir. Mühendislik tasarımında bir parçanın fonksiyonel (dayanım) özelliklerini belirlemede Sonlu Elamanlar Analizi (FEA, CFD vb.) gibi fizik temelli yaklaşımlar kullanılır. FEA parça ve/veya montajın çalışma koşullarında mekanik davranışlarını tahmin etmeye çalışan sayısal bir analiz yöntemidir. İş parçasına ait karmaşık geometri, basit ve birbirine bağlı birçok sonlu eleman denilen alt bölgeye ayrılır. Daha sonra da bu elemanların yük ve kuvvetlere karşı gösterdiği tepkiler belirlenir. Parçanın nihai tepkisi, bireysel sonuçlar birleştirilerek hesaplanmaktadır. Bu amaçla iş parçaların dayanım özelliklerini belirlemek için simülasyon yazılımları kullanılır [315].

Bu çalışmada veri bağımlı üretken tasarım yöntemi ile yüksek dayanım ağırlık oranına sahip tasarım konseptleri geliştirmek amaçlanmaktadır. Üretilen tasarımlar bir tasarım-simülasyon ortamında (Catia V5) değerlendirilerek mekanik özellikleri belirlenir. Tüm konsept tasarımların aynı koşullar (sınır koşulları, mesh sayısı, malzeme özellikleri, kuvvet vb.) altında von Mises değerleri otonom olarak belirlenir. Von mises bir malzemenin elastik sınırı aşmadan ne kadar gerilmeyi taşıyabileceği gösteren eşdeğer gerilmedir. Bu değer yüksek olması iş parçasının plastik deformasyona uğrama olasılığını artırmaktadır.

Bu çalışmada analizi yapılan tasarım konseptleri von Mises değerlerine göre sıralanır ve %50'lik dilime giren tasarımlar belirlenir. Yüksek performanslı konsept tasarımlar eğitim kümesine eklenmek üzere voksel formatına dönüştürülür. Başlangıç veri kümesine eklenen veri kadar eğitim kümesinden rastgele 3B model çıkarılır. Böylece eğitim veri kümesine ait ortalama fonksiyonel başarı artırılmaya çalışılır. Eğitim kümesinin oluşturulması, GAN modelinin eğitilmesi, üretilen tasarım konseptlerinin değerlendirilmesi ve yüksek performanslı konseptlerin eğitim kümesine eklenmesi, fonksiyonel üretken tasarım döngüsünü oluşturur. Bu döngü eğitim kümesinin bir bölümü (sahte) modellerden oluşuna dek sürer. Böylece yüksek dayanıma sahip tasarım konseptleri üretilebilir.

6.3.4. Eklemeli imalat

Eklemeli İmalat, üç boyutlu objeleri, katman katman malzeme ekleyerek üretme sürecidir [316]. Bu üretim süreci, talaş kaldırmaya dayalı geleneksel üretim yöntemlerinin tam tersidir. Geleneksel yöntemlerde bir parçadan malzeme çıkartılarak ürün oluşturulurken, eklemeli imalatla malzeme adım adım eklenerek ürün oluşturulur. Sürecin başlangıç aşaması, bir 3B bilgisayar destekli tasarım (BDT) modelinin oluşturulmasıdır. Oluşturulan bu model, genellikle Standart Üçgen Dili (İng. Standard Triangle Language, STL) formatında kaydedilir. STL, standart üçgenleştirme dilini ifade eder ve bu format, objeleri bitişik üçgen yüzeyler kullanarak tanımlar. Bu üçgenler, modelin karmaşıklığına ve detayına bağlı olarak değişik yoğunlukta olabilir. Örneğin, organik formlar daha yoğun üçgen ağıyla oluşturulabilirken prizmatik objeler daha düşük yoğunluklu üçgen ağlarıyla ifade edilebilir. Ancak STL formatı renk, doku gibi yüzey özelliklerini içermediğinden model temsil yeteneği sınırlıdır. Bu sınırlamaları aşmak için, Poligon Dosya Formatı (PLY), Eklemeli İmalat Formatı (AMF) ve 3B İmalat Formatı (3MF) gibi daha gelişmiş dosya formatları ortaya çıkmıştır.

Model hazırlandıktan sonra eklemeli imalat süreci için hazırlık aşaması başlar. İlk adım, modelin üçgen ağ yapısına dönüştürülmesidir. Ardından, dilimleyici bir yazılım kullanılarak, model katmanlara bölünür. Katman sayısı model doğruluğunu ve baskı süresini belirleyen en önemli parametredir. Bu katmanlar, kullanılan teknolojiye göre takım hareketlerinin belirlenmesini sağlar [317]. Dilimleyici yazılımlar aynı zamanda, baskı hızı, yapı yönü, destek yapıları gibi önemli baskı parametrelerini de ayarlar. Bir diğer önemli husus, objenin iç yapısının dolgu yoğunluğudur. Tam katı bir nesnenin yazdırılması hem zaman alıcı hem de malzeme maliyetlidir. Bu nedenle, dilimleyici yazılımlar genellikle iç yapıyı, belirli bir dolgu yoğunluğuyla gözenekli hale getirebilir. Bu, hem malzeme tasarrufu sağlar hem de baskı süresini kısaltır. Ancak seçilen dolgu yoğunluğu, nesnenin son mekanik özelliklerini etkiler. Hazırlık süreci tamamlandığında, takım yolu verisi 3B yazıcıya aktarılır ve asıl baskı süreci başlar. Baskı süreci tamamlandığında, destek yapıları çıkarılır ve nesne son işlemler için hazır hale getirilir.

Eİ makinelerinin temel çalışma ilkesi, objeyi katman katman inşa etmesine rağmen, kullanılan malzemenin türüne ve seçilen baskı metoduna göre çeşitli yöntemleri bulunmaktadır. Bu yöntemler kullanılan malzemenin fiziksel özelliklerine göre sıvı, katı ve toz olmak üzere 3 kategoriye ayrılabilir. Ancak en bilinen yöntemler polimer bazlı Eriyik Biriktirme Tekniği (FDM), Stereolitografi (SLA) ve Malzeme Püskürtme (MJ) olarak sıralanabilir.

Eriyik Biriktirme Tekniği (FDM)

FDM, 3B yazdırma teknolojisinde kullanılan en yaygın yöntemlerden biridir. Bu yöntem, filament halindeki bir malzemenin sıcak bir nozül aracılığıyla belirli bir tasarım doğrultusunda tabaka tabaka eklenerek üç boyutlu bir nesnenin oluşturulmasını sağlar [318]. FDM, genellikle Polilaktik Asit (PLA) ve Akrilonitril Bütadien Stiren (ABS) gibi termoplastik malzemelerle çalışır. Yazıcıda bulunan ısıtma elemanı, filamentin erimesini sağlar ve eriyen bu filament, nozül aracılığıyla kontrollü bir şekilde tabana yerleştirilir. Nozül, genellikle, X ve Y eksenlerinde hareket ederken, yazdırma tablası Z eksenini boyunca hareket kabiliyetine sahiptir. Eriyik haldeki filament, yazdırma tablasına yerleştiğinde hızla soğur ve katılaşır. Böylece üç boyutlu bir nesnenin katmanları oluşturulur. FDM'nin diğer teknolojilere görece düşük maliyeti, kullanım kolaylığı ve geniş malzeme seçenekleri, onu hızlı prototipleme, eğitim ve bazı endüstriyel uygulamalar için ideal bir seçenek haline

getirmektedir. Ancak, diğer 3B yazdırma yöntemlerine göre yüzey kalitesi ve detay çözünürlüğü konusunda sınırlamaları bulunmaktadır.

Stereolitografi (SLA)


SLA, ilk geliştirilen 3B yazdırma teknolojileri arasında olan SLA fotopolimerizasyon adlı bir ışıkla malzeme sertleştirme sürecine dayanır. SLA, sıvı bir fotopolimer reçineyi ultraviyole (UV) ışık ile katılaştırarak üç boyutlu nesneler oluşturur. SLA makinelerinde genellikle bir reçine havuzu bulunur ve bu havuz, UV ışığına duyarlı sıvı fotopolimer reçine ile doldurulur. Yazdırmanın başlangıcında, yazdırma platformu reçine havuzunun hemen üzerine yerleştirilir. Yazdırma işlemi sırasında UV ışığı, belirli bir desene göre reçineye uygulanır. Işıkla temas eden reçine katılaşır. İlk katman tamamlandığında, yazdırma platformu bir katman kalınlığı kadar aşağıya iner ve bir sonraki katman UV ışığıyla sertleştirilir. Bu süreç, tüm katmanların tamamlanmasıyla sona erer.

Yazdırma tamamlandığında, sıvı reçineden yapılmış olan nesne reçine havuzundan çıkarılır. Bu aşamada, nesne genellikle tamamen sertleşmediği için bu nedenle, ek UV ışığına maruz bırakılarak tamamen sertleştirilmesi sağlanır. Son olarak, olası destek yapıları ve fazlalıklar manuel olarak kaldırılır ve nesne son şeklini alır.

SLA, yüksek detay çözünürlüğü ve pürüzsüz yüzey kalitesi sunmasıyla bilinir. Bu özellikleri ince detay gereksinimleri olan diğer birçok alanda kullanılmasını sağlar. Bununla birlikte, SLA ile oluşturulan parçalar genellikle mekanik dayanıklılık açısından diğer 3B yazdırma yöntemleriyle üretilen parçalar kadar sağlam değildir.

6.4. Uygulama 1

Üretken tasarım yaklaşımının etkinliğini test etmek amacıyla, helikopter rotor mekanizmalarının temel bileşenlerinden biri olan ve rotor bıçaklarının pozisyonunu ayarlayan döner tabla (İng. swashplate) mekanizmasının bir bileşeni üzerinde bir uygulama gerçekleştirilmiştir. Pilot komutlarını rotor bıçaklarına ileten bu bileşen, helikopterin yükseklik ve yön kontrolüne izin verir. Bu bileşenin montaj konumu, hareket yeteneği ve orijinal tasarımı Şekil 6.2'de gösterilmektedir.




Şekil 6.2. Ele alınan bileşen ve rotor montajındaki konumu (uygulama-1)

Parametrik tasarım teknikleri kullanılarak bu parçadan esinlenilmiş bir sentetik veri seti oluşturulmuş ve 3DGAN modeli eğitilmiştir. Model, yeni veriler üretmiş ve bu verilerin mekanik özelliklerini belirlemek için kapsamlı veri işleme adımları uygulanmıştır. Gelişmiş bir tasarım ve analiz yazılımı kullanılarak bu bileşenlerin mekanik performansları von Mises gerilme kriterine göre değerlendirilmiştir. Performansı yüksek olan tasarımlar, eğitim veri setine entegre edilmiş ve başlangıç veri setinden seçilen eşit sayıda veri çıkarılarak tasarım ve değerlendirme döngüsü tekrar başlatılmıştır. Bu süreç, tasarımın doğruluğunu ve mekanik uygunluğunu temin edecek şekilde titizlikle sürdürülmüştür.

6.4.1. Veri ön hazırlık

Bu ilk uygulamada, derin öğrenme modelinin eğitimi için 3B model veri kümesi bir dizi işlemten geçirilmiştir. İlk adımda, veri kümesindeki hatalı veya eksik veriler tespit edilerek çıkarılmıştır. Daha sonra, modelin üretken tasarım performansını artırmak için, tüm veriler standardize edilerek aynı boyuta getirilmiştir. Bu süreçte Python'daki “binvox” kütüphanesi kullanılarak, STL formatındaki 3B modeller, birim küplerin birleşimini temsil eden voksel formatına dönüştürülmüştür. Çalışma için ideal ızgara boyutu, bilgisayar işlem kapasitesine bağlı olarak 96 x 96 x 96 olarak belirlenmiştir. Veri düzenleme işlemleri sonucunda 4.192 veri elde edilmiştir. Şekil 6.3’de veri setinden örnekler gösterilmektedir.




Şekil 6.3. Kullanılan sentetik veri kümesinden bazı örnekler

6.4.2. Derin öğrenme eğitimi

Bu uygulamada, 3D DCGAN mimarisi oluşturulup eğitilmiştir ve bu süreçte PyTorch kütüphanesinden faydalanılmıştır. İlk olarak, bir gürültü vektörü, üretici ağda dört tersine konvolüsyon katmanı aracılığıyla kademeli olarak genişletilerek $96 \times 96 \times 96$ boyutunda bir 3B matrise dönüştürülmüştür. Ayrıcıcı ağ ise bu 3B matrisi, dört konvolüsyon katmanı kullanarak tek boyutlu bir diziye indirir. Her iki ağda da normalleştirme ve aktivasyon fonksiyonları kullanılmıştır. Ağın yapılandırılmasında önceki bölümde belirlenen katman sayısı, parametreler, batch boyutu, gizli vektör boyutu, epoch sayısı ve öğrenme hızı değerleri kullanılmıştır. Yaklaşık 6 saat süren 500 döngü sonunda elde edilen 3B modeller, Şekil 6.4’te gösterilmiştir.

3DGAN modelinin eğitim süreci boyunca, üretici ve ayrıcıcı ağları için hesaplanan kayıp (loss) değerleri, model performansını anlamak için kritik bir ölçüttür. Her döngü sonunda elde edilen kayıp değerleri, öğrenme sürecini gözlemlemek ve modeli değerlendirmek amacıyla bir grafiğe aktarılır.




Şekil 6.4. 3DGAN modeli tarafından oluşturulan yeni iş parçası örnekleri

Üretici kayıp değeri, üretilen verinin gerçek veriye benzerliğini değerlendirmeyi amaçlar. Eğer üretici kayıp değeri sürekli yükseliyorsa bu durum üreticinin performansının kötüleştiğine ve üretilen örneklerin gerçek veriden daha uzak olduğuna işaret eder. Ayırıcı kayıp değeri ise, ayırıcının gerçek ve üretilen veriyi ne kadar iyi ayırt edebildiğini ölçer. Ayırıcı kayıp değerinin azalması ayırıcının gerçek ve sahte örnekleri daha iyi ayırt etmeye başladığını gösterir. İdeal bir eğitim sürecinde üretici ve ayırt edici arasında bir denge oluşur. Her iki ağın kayıp değerlerinin zamanla düşmesi ve ardından belirli bir noktada stabil (kararlı) olması ağ eğitiminin istenilen sonucudur.


Bu çalışmada kullanılan 3DGAN modeli eğitim sürecinde elde edilen kayıp değerleri Şekil 6.5’de gösterilmiştir. Grafikte görüldüğü üzere, eğitim başladığında hem üretici hem de ayırıcı kayıpları yüksek ve dalgalıdır. Bu durum ağın henüz eğitim sürecinin başında olduğunu ve iki ağ arasındaki dengenin oluşmadığını gösterir. GAN eğitiminin başlangıcında üretici ve ayırıcı birbirlerine adapte olmaya çalıştığından yüksek kayıp değerleri beklenir.

Eğitimin ilerleyen safhalarında üretici kaybının genel bir düşüş eğilimi gösterdiği, ayırıcı kaybının ise daha stabil bir duruma geldiği görülmektedir. Bu durum, üreticinin giderek daha inandırıcı örnekler üretmeye başladığına ve ayırıcının bu örnekleri gerçeklerden ayırt etmekte zorlandığına işaret eder. Özellikle, 200. döngüden sonra dalgalanmalar daha düşük genlikte gerçekleşmektedir. Bu, iki ağın birbirleriyle rekabet ederken birbirlerini geliştirdiği ve yararlı bir eğitim süreci geçirdiği anlamına gelebilir.



Şekil 6.5. Üretken çekişmeli ağ eğitim sürecinde kayıp değerleri (uygulama-1)

6.4.3. Tasarım değerlendirme



Şekil 6.6. Veri hazırlık ve yapısal analiz süreci

Yapısal iş parçalarının fonksiyonelliği, von Mises gerilme değerleri kullanılarak değerlendirilmiştir. Bu değerler, CATIA V5 yazılımındaki bir betik ile STL formatındaki 3B mesh modeller üzerinden otomatik olarak hesaplanmıştır. Mesh modeller, önce yüksek doğrulukta yüzey modellerine, ardından katı modellere dönüştürülmüş ve sonlu elemanlar analizi için hazırlanmıştır. AlSi10Mg malzemesi, katmanlı imalata uygun olduğu için tercih edilmiş ve analizde kullanılmıştır (Şekil 6.6). Bu süreç, GAN tarafından üretilen her bir 3B model için ortalama 35,8 saniyede tamamlanarak, toplamda yaklaşık 5 saat sürmüştür. Her

iterasyonda seçilen en iyi 250 model, veri kümesine eklenmiştir. Altı iterasyon boyunca bu adımlar takip edilerek GAN modelinin eğitimi bu güncellenmiş veri kümeleri ile gerçekleştirilmiştir. Altı döngü sonunda, GAN tarafından üretilen modeller eğitim kümesinin yaklaşık %30'unu oluşturur. Çizelge 6.1, son iterasyonda 3DGAN modeli tarafından üretilen yapısal bileşenlerden örnekler göstermektedir. Bu modellere ait fiziksel ve mekanik özellikler de tabloda verilmiştir. Burada, üretilen modellerin orijinal iş parçasının geometrik ve mekanik özelliklerini büyük ölçüde karşıladığı görülmektedir. Özellikle, parça kolları arasında büyük oranda geometrik tutarlılık vardır. Ayrıca delik konum ve pozisyonları orijinal iş parçası ile uyumludur.


Çizelge 6.1. Altıncı iterasyon sonunda 3DGAN modeli tarafından üretilen mafsalsal örnekleri ve fiziksel özellikleri

Üretilen modeller	Özellikler
	Parça adı : P_07 Malzeme : AlSi10Mg Hacim (cm³) : 301,63 von Mises (MPa) : 53,9 Emniyet faktörü : 5,01
	Parça adı : P_54 Malzeme : AlSi10Mg Hacim (cm³) : 344,12 von Mises (MPa) : 55,3 Emniyet faktörü : 4,88
	Parça adı : P_109 Malzeme : AlSi10Mg Hacim (cm³) : 426,94 von Mises (MPa) : 49,9 Emniyet faktörü : 5,41
	Parça adı : P_199 Malzeme : AlSi10Mg Hacim (cm³) : 429,9 von Mises (MPa) : 56,8 Emniyet faktörü : 4,75


Şekil 6.8, her iterasyon sonrası von Mises gerilmesine dayalı hesaplanan emniyet faktörü değerlerini göstermektedir. Grafiklerde, x ekseninde üretilen tasarımların hacimleri, y ekseninde ise tasarımların von Mises gerilmelerine bağlı emniyet faktörleri yer alır. İlk iterasyonda, emniyet faktörünün ortalama (μ_{SF}) ve standart sapma (σ_{SF}) değerleri sırasıyla 1,611 ve 0,977 olarak hesaplanmıştır. İkinci iterasyonda ortalama emniyet faktöründe hafif

bir azalma söz konusudur. Ancak üçüncü iterasyonla birlikte ortalama emniyet faktörü bir artış eğilimine girmiştir. Bu artış beşinci ve altıncı iterasyonlarda belirgin bir şekilde görülmektedir. İlk iterasyona kıyasla, dört, beş ve altıncı iterasyonlarda ortalama emniyet faktörü sırasıyla %2,6, %5,2 ve %6,8 artmıştır. Bu bulgular, önerilen yöntemin 3B modellerin mekanik özelliklerinde istatistiksel olarak belirgin bir iyileşme sağladığını göstermektedir. Bunun yanı sıra süreç boyunca üretilen tasarımların hacimsel olarak genişlediği gözlemlenmektedir.


Şekil 6.7 her iterasyonda elde edilen ortalama emniyet faktörlerini bir arada göstererek mekanik performans değişimine kapsamlı bir bakış sağlamaktadır. Grafik üzerindeki daire çapları, emniyet faktörlerinin standart sapma değerlerine göre düzenlenmiştir. İlk iki iterasyonlarda görülen yüksek veri çeşitliliği, son iterasyonlarda azalır. Bu durum, sürecin daha stabil ve öngörülebilir bir hale geldiğini göstermektedir. Şekil 6.7'de, ilk iki iterasyonda yüksek standart sapma değerleri, emniyet faktörlerindeki geniş varyansı ve dolayısıyla yüksek veri çeşitliliğini yansıtır. Ancak, dört, beş ve altıncı iterasyonlarla birlikte, standart sapma değerlerindeki azalma, üretilen tasarımların daha tutarlı ve öngörülebilir olduğunu gösterir. Ayrıca, her bir iterasyonda kullanılan veri setindeki GAN tarafından üretilen model oranları grafik üzerinde gösterilmektedir. Bu iteratif süreç, özellikle karmaşık geometrilere ve yüksek performans gereksinimlerine sahip mühendislik uygulamaları için hem verimliliği hem de tasarım süreçlerinde yenilikçi çözümler sunma potansiyelini artırır.



Şekil 6.7. Eğitim ve değerlendirme iterasyonu için ortalama güvenlik faktörleri



Şekil 6.8. Süreç boyunca üretilen tasarımların hacim ve güvenlik faktörlerini



Şekil 6.9. Sonlu elemanlar analiz otomasyonunun doğrulanması. a) orijinal model, b) GAN ile üretilmiş model, c) düzenlenmiş model

Elde edilen statik analiz sonuçları, Ansys yazılımı ile yeniden simüle edilerek doğrulanmıştır. İlk olarak, model geometrisi ve malzeme özellikleri tanımlanmıştır. Sonra, uygun yük ve sınır koşulları belirlenerek model üzerinde statik analiz yapılmıştır. Mesh oluşturma aşamasında yapılan optimizasyon ile analiz sonuçlarının doğruluğu sağlanmıştır. Simülasyon sonuçları, gerilme ve deformasyon açısından incelenerek son iterasyonda üretilen en iyi performansa sahip iş parçasının mekanik özellikleri ile karşılaştırılmıştır. Sonuçlar, FEA otomasyonu ile büyük oranda benzerlik göstermektedir. İki simülasyon arasında maksimum gerilme değerlerinde %0,6'lık bir sapma görülmektedir. Şekil 6.9,

bileşenin yükleme koşulları altındaki mekanik davranışı göstermekte ve özellikle kritik kesitlere odaklanmaktadır. Şekil orijinal, GAN ile üretilen ve modifiye edilen modellerin von Mises gerilimleri ve ağırlıkları hakkında da bilgi sağlamaktadır. İlk olarak ele alınan orijinal model, görece yüksek ağırlığa sahip olmasına rağmen, geometrisinde bulunan keskin köşeler nedeniyle gerilme birikmelerine oldukça yatkındır. Bu durum, yapısal performansının daha verimsiz olmasına neden olmaktadır. GAN ile üretilen model ise orijinal modele göre %35 daha hafif olmasına rağmen mekanik özelliklerinde büyük bir kayıp göstermemektedir. Diğer taraftan, GAN ile üretilen model üzerinde yapılan manuel müdahaleler, modelin mekanik performansını daha da geliştirmiştir.


6.5. Uygulama 2

Fonksiyonel üretken tasarım yaklaşımının etkililiğini daha geniş bir ölçekte doğrulamak amacıyla, kapsamlı ikinci uygulama daha gerçekleştirilmiştir. Bu kapsamda rotora hareket serbestliği sağlayarak helikopterin yönlenmesine yardımcı olan özel bir mafsallı bileşeni ele alınmıştır. Bu bileşenin montajdaki yeri, hareket kabiliyeti ve orijinal tasarımı, Şekil 6.2’de gösterilmiştir. Uygulamanın ilk adımında Voronoi diyagramının parametrik tasarıma dahil edilmesiyle geniş bir tasarım uzayını kapsayan sentetik bir veri kümesi oluşturulmuştur. İkinci adımda bu sentetik veri kümesi kullanılarak bir 3DGAN modeli eğitilmiştir. Bu model tarafından üretilen sahte verilerin mekanik özelliklerinin belirlenmesi için çeşitli veri hazırlık işlemleri uygulanmıştır. Üçüncü adımda düzenlenmiş 3B bileşenlerin mekanik performanslarını değerlendirmek için CATIA V5 isimli tasarım ve analiz yazılımı kullanılmıştır. Bu değerlendirme sonucunda von Mises performans kriterine göre üstün olan tasarımlar eğitim veri kümesine dahil edilmiştir. Başlangıç veri kümesinden aynı sayıda veri sürecin dışına çıkarılarak eğitim ve analiz döngüsü yeniden başlatılır. Süreç tamamlandıktan sonra oluşturulan tasarımların imal edilebilirliği El yöntemleri ile değerlendirilmiştir.

6.5.1. Veri üretimi ve ön hazırlık

3DGAN model eğitiminde oldukça farklı ve çok sayıda veri içeren veri seti gerekir. Bu araştırmada tez kapsamında oluşturulmuş sentetik bir veri kümesi kullanılmıştır. Sentetik veri kullanımının başlıca nedeni iş parçaları için gerçek 3B model verilerinin eksik ve yetersiz olmasıdır. Sentetik veri kümesini oluşturmak için iş parçasının parametrik bir modeli oluşturulmuştur. Bu modelde geometrik sınır koşulları göz önünde tutularak parametre değer

aralıkları belirlenmiştir. Şekil 6.10’de bu parametreler ve tasarım sınır koşulları görülmektedir.




Şekil 6.10. Uygulama-2’de ele alınan bileşenin helikopter rotor montajındaki konumu ve parametrik model

Parça üzerinde kırmızı ile gösterilen unsurlar sabit değerlere sahipken, mavi renkli unsurlar parametrik olarak değişebilmektedir. Burada kullanılan 9 parametre ile yaklaşık 60 milyarın üzerinde tasarım varyantı (konsepti) oluşturulabilmektedir. Ancak bu konseptler veri çeşitliliği açısından derin öğrenme eğitimi için yeterli değildir. Veri çeşitliliğini artırmak için Voronoi diyagramları parametrik tasarım sürecine dahil edilmiştir. Parça üzerinde belirlenen alanlara Voronoi diyagramları uygulanarak 4.635 özgün tasarım varyantı oluşturulmuştur. Bu veri kümesi farklı duvar kalınlığı, unsur boyutu, Voronoi hücre büyüklüğü ve Voronoi hücre sayısına sahip modellerden oluşmaktadır. Bu değişkenler veri kümesinin gerçek veri çeşitliliğini taklit etmesine yardımcı olmaktadır. Parametrik tasarım süreci ve elde edilen verilerden bazıları Şekil 6.11’te gösterilmektedir. Veri kümesi oluşturma süreci 4. bölümde detaylı olarak açıklanmıştır. Burada ana hatları ile genel süreç özetlenmektedir.

Derin öğrenme modelinin eğitimi için 3B model veri kümesi bazı işlemlerden geçirilmiştir. İlk aşamada, hatalı veya eksik veriler tespit edilerek veri kümesinden kaldırılmıştır. Daha sonra, üretken tasarımın performansını artırmak için tüm veriler standart bir boyuta (büyüklüğe) getirilmiştir. Python üzerinde “binvox” kütüphanesi kullanılarak OBJ formatındaki modeller, bir nesneyi birim küplerin topluluğu olarak ifade eden, voksel formatına dönüştürülmüştür. Vokseller, karmaşık içyapıları temsil etme yeteneğine sahip

olduğundan, bu çalışmada üretilen yapısal iş parçası verileri için uygun veri temsil yöntemi olarak seçilmiştir. Ancak, parça çözünürlüğü vksel ızgara sayısına göre değişkenlik göstermektedir. Bu çalışma için bilgisayar işlem kapasitesine bağlı olarak ideal ızgara boyutu 128 x 128 x 128 olarak belirlenmiştir.




Şekil 6.11. Voronoi diyagramlarının parametrik tasarıma dâhil edilmesi ile oluşturulan veri kümesi

6.5.2. Üretken model eğitimi

Bu çalışmada Wu vd. tarafından geliştirilen vksel tabanlı bir 3B Derin Evrişimli Üretken Çekişmeli Ağ (İng. 3D Deep Convolutional Generative Adversial Networks, 3D DCGAN) modeli kullanılmıştır [190]. Bu model zayıf bir olasılık dağılımından gerçekçi 3B nesneler üretme kapasitesine sahiptir. Bu model eğitiminin ilk aşamasında olasılıksal nokta dağılımı bir gürültü vektörüne dönüştürülür. Daha sonra bu gürültü vektörü, üretici ağ ile gerçek nesne boyutuna yükseltilir [57]. Diğer taraftan Ayırıcı ağ ise üretilen nesne ve veri kümesinden gelen nesneleri birbirinden ayırmaya çalışır. Üretici ve Ayırıcı ağ eğitim sürecinin nihai amacı önce daha gerçekçi sahte veriler oluşturma ve sonra da bunları verileri gerçek verilerden ayırt edebilmektir [10].

Bu çalışmada 3D DCGAN mimarisi oluşturma ve eğitim süreç verimini artırmak için “PyTorch” kütüphanesi kullanılmıştır. İlk aşamada, 200 boyutlu bir gürültü vektörü 3B bir matrise dönüştürülmüştür. Bu matrisin boyutu üretici ağda mevcut 4 adet tersine konvolüsyon katmanı ile kademeli olarak genişletilir. Her katmanda bir önceki katmandan daha yüksek boyutlu bir matris oluşturulur. Üretici ağın son katmanında $128 \times 128 \times 128$ boyutlu bir matris ile temsil edilen sahte 3B model üretilir. Ayrıcıcı ağ ise 4 konvolüsyon katmanında farklı boyutlarda özellik haritaları kullanarak $128 \times 128 \times 128$ boyutlu matrisi tek boyutlu bir diziye dönüştürür. Her bir katmanda matris boyutu azaltılarak ağın genelleme kabiliyeti artırılırken hesaplama maliyeti azaltılır. Bu matris Konvolüsyon katmanların ardından Full Connected (FC) katmanların eğitimi için tek boyutlu bir diziye dönüştürülür. Ayrıcıcı ağın son aşamasında Sigmoid aktivasyon fonksiyonu kullanılarak, girdi matrisinin sınıfı (sahte veya gerçek) tahmin edilerek süreç tamamlanır. Her iki ağ mimarisinde konvolüsyon (tersine ve normal) katmanları arasında Batch Normalleştirme ve aktivasyon (yani LeakyReLU) fonksiyonları uygulanmıştır. Ağ mimarisinde kullanılan konvolüsyon katmanları sayısı, parametre sayısı, batch boyutu, gizli vektör boyutu, epoch sayısı, öğrenme hızı gibi parametreler sezgisel olarak belirlenmiştir. Bu parametrelerin belirlenmesinde ana sınırlandırıcı grafik işlemci kapasitesidir. 500 epoch (yaklaşık 14 saat) sonunda elde edilen yeni 3B modeller Şekil 6.12’te gösterilmektedir. Bu modeller organik formlar içermektedir. Bu durum yapısal analiz gerçekleştirilmesinde sınır koşullarının belirlenmesinde bir problem oluşturmaktadır. Bu problemin üstesinden gelmek için model üzerindeki delik çapları gerçek ölçüsünden daha bir küçük çapta üretilmiş ve analiz aşamasında kontrollü bir şekilde genişletilmiştir.

Bu çalışmada kullanılan 3DGAN modeli eğitim sürecinde elde edilen kayıp değerleri Şekil 6.13’de gösterilmiştir. Ayrıcıcı kayıp değerlerinin, eğitimin ilk aşamalarında hızla azaldığı ve 300. döngüden sonra stabil hale geldiği görülmektedir. Diğer taraftan üretici ağ kayıp değerlerinin eğitimin ilk döngülerinde belli bir eğimle yükseldiğini daha sonra stabil hale geldiği görülmektedir. Bu değerler eğitimin ilk kısmında ayrıcıcının üretici tarafından üretilen verileri doğru bir şekilde ayırt ettiğini daha sonra eğitimin bir dengeye ulaştığını göstermektedir. Üretici ağ eğrisinin dalgalanması eğitim kararsızlığına işaret edebilir ancak eğimin stabil olması dengeye ulaşıldığı anlamına gelir.




Şekil 6.12. 3DGAN modeli tarafından oluşturulan yeni iş parçası (mafsal) örnekleri

6.5.3. Veri (model) üretimi


Eğitilmiş 3D GAN modeli önceden belirlenmiş parametre ve ağırlık değerleri kullanarak sınırsız sayıda 3B yapılar oluşturmayı mümkün kılar. Bu süreç, genellikle belirli bir dağılımı takip eden rastgele sayılar içeren bir gürültü vektörünün oluşturulması ile başlar. Bu gürültü vektörü, üretici ağının giriş katmanına beslenir. Üretici ağ, bu girdiyi alarak eğitim süresince öğrendiği karmaşık özellikleri ve ilişkileri kullanarak yeni 3B verileri üretir. Bu üretim sürecinde ağ ağırlıkları sabit kalır, yani eğitim sırasında öğrenilen değerleri korur. Eğer üretilen veriler istenen özelliklere sahip değilse, gürültü vektöründe yapılacak küçük değişikliklerle üretim süreci tekrarlanabilir.

Ağ mimarisine bağlı olarak üretilen veriler voksel formatındadır. "binvox" uzantılı veriler, BDT ortamında düzenlenebilmesi için mesh yapılarına dönüştürülmüştür. Bu dönüşüm, Python'un "binvox_rw" ve "pymeshlab" kütüphaneleri ile bir otomasyon dahilinde gerçekleştirilmiştir. Sürecin ilk aşamasında "binvox" dosyalarından 3B voksel ızgaralar,

işlem için bir diziye aktarılır. Bu diziler, içlerindeki Voksel koordinatlarını temel alarak bir 3B mesh yapısına dönüştürülür. İkinci aşamada oluşturulan mesh üzerinde nokta sayısını azaltma, gürültüleri temizleme, yakın noktaları birleştirme, yinelenen yüzleri kaldırma, ölçeklendirme, delikleri doldurma gibi bazı düzenleme ve iyileştirme işlemi yapılır. Daha sonra, elde edilen mesh formatlı veriler STL formatında kaydedilir (Şekil 6.14). Daha sonra, elde edilen mesh formatlı veriler STL formatında kaydedilir (Şekil 6.6).



Şekil 6.13. Üretken çekişmeli ağ eğitim sürecinde kayıp değerleri (uygulama-2)




Şekil 6.14. Voksel'den mesh'e dönüşüm ve mesh iyileştirme süreci


6.5.4. Tasarım değerlendirme

Yapısal iş parçalarının fonksiyonelliğini von Mises değerleri referans alınarak değerlendirilmiştir. Von Mises gerilmesi, çok eksenli gerilme durumlarında malzemenin

mekanik tepkisini hesaplamak için kullanılır. Bu değerin malzemenin akma sınırını aşması durumunda plastik deformasyon başlar. Üretken tasarım modeli ile üretilen konsept iş parçaları CATIA V5 yazılımında kullanılan bir script ile otonom olarak analiz edilerek von Mises değerleri belirlenmiştir. Bu amaçla hazırlanan makro mesh formatlı iş parçalarını katı modele dönüştürür, sınır koşullarını tanımlayarak yapısal analizi gerçekleştirir (Şekil 6.15).



Şekil 6.15. Veri hazırlık ve yapısal analiz süreci




Şekil. 6.16. Veri düzenleme otomasyonu: Mesh modelin BDT ortamına alınması

İlk olarak, bu makro arayüzü kullanılarak mesh formatlı STL uzantılı 3B geometriler BDT ortamına alınır (Şekil 6.16). Burada, mesh yapılar sırasıyla yüzey ve katı modele

dönüştürülür. Öncelikle 0,025 mm ortalama yüzey sapma değeri ile yüksek doğrulukta yüzey modeli oluşturulur. Oluşturulan yüzey modelleri “Close Surface” komutu ile katı model dönüştürülür (Şekil 6.17).

Sonraki aşamada, orijinal parça ölçüleri korunarak katı model üzerinde delikler kontrollü bir şekilde genişletilir (gerçek ölçü). Sonlu elemanlar analizinin yapılabilmesi için bileşen malzemesi belirlenir (Şekil 6.18). Bu tasarımlar tipik olarak organik yapılar sergilediği için yalnızca katmanlı imalat teknikleri kullanılarak üretilebilmektedir. Bu nedenle, katmanlı imalat teknikleriyle uyumlu AlSi10Mg malzemesi seçilmiş ve bu malzemenin fiziksel özellikleri temel alınarak bir analiz gerçekleştirilmiştir.




Şekil 6.17. Veri düzenleme otomasyonu: Mesh yapının katı modele dönüştürülmesi


Analiz modülünde, tetrahedral elemanlarla yama uyumlu bir strateji ile mesh oluşturulur. Aynı sınır koşulları ve doğrusal bir kuvvet (150 N) altında tüm modeller analiz edilir (Şekil 6.19). Son aşamada ise modelin performans puanı (von Mises gerilimi) ve hacim değeri kaydedilir. Bu veri düzenleme ve yapısal analiz süreci her iterasyonda GAN modeli tarafından üretilen 500 adet 3B model için uygulanır. Veri ön hazırlık ve yapısal analiz süreci bir model için ortalama 36,2 saniye sürmektedir. Her iterasyonda tüm modellerin değerlendirilme süresi yaklaşık 5 saattir.

Her yapısal analiz aşamasında 500 adet 3B model değerlendirilmiş ve bunlardan görece üstün performanslı 250'si veri kümesine dahil edilmiştir. Başlangıç veri kümesinden rastgele 250 model çıkartılarak veri sayısı sabit tutulmuştur. Yeni eklenen verilerle oluşturulan eğitim veri kümesi kullanılarak GAN modeli yeniden eğitilir. Her eğitim adımının sonunda üretilen 3B modellerin mekanik performansları değerlendirilerek eğitim kümesi güncellenir.

Bu iteratif süreç altı döngü sonunda tamamlanmıştır. Son döngüde eğitim kümesinin yaklaşık %27'si GAN modeli tarafından üretilen verilerden oluşmuştur.



Şekil 6.18. Veri düzenleme otomasyonu: Deliklerin oluşturulması ve malzeme ataması







Şekil 6.19. Veri düzenleme otomasyonu: Sonlu elemanlar analizi


Çizelge 6.2, 3DGAN modeli tarafından altıncı iterasyonun sonunda üretilen yapısal bileşenlerden örnekler göstermektedir. Bu modellere ait fiziksel ve mekanik özellikler de tabloda verilmiştir. Tabloda, üretilen modellerin orijinal iş parçasının sınır koşullarını büyük ölçüde karşıladığı görülmektedir. Özellikle dairesel parçalar yüksek doğrulukla oluşturulmuştur. Diğer taraftan modelin ürettiği yapısal bileşenlerin çeşitliliği dikkat çekmektedir. Bu kullanılan veri kümesinin kalitesini ve eğitim sürecinin verimini göstermektedir.

Şekil 6.20, her bir iterasyonda elde edilen von Mises gerilmesine göre hesaplanmış emniyet faktörü değerlerini göstermektedir. Grafiklerde x eksenini üretilen tasarımların hacimlerini

gösterirken, y eksenli tasarımın emniyet faktörünü ifade etmektedir. İlk iterasyonda elde edilen ortalama (μ_{SF}) emniyet faktörü ve standart sapma (σ_{SF}) değerleri sırasıyla 0,947 ve 0,645 olur. İkinci ve üçüncü iterasyonunda belirgin bir performans değişimi görülmemiştir. Ancak dördüncü ve beşinci iterasyonlar sonunda üretilen tasarımların ortalama güvenlik faktörlerinde belirgin bir artış görülmüştür. İlk iterasyona göre ikinci iterasyon sonucu emniyet faktöründe %0,01’lik bir azalma söz konusudur. Diğer iterasyonlarda ise üretilen tasarımların ortalama mekanik performans özellikleri sırasıyla %0,5, %10,1, %14,3 ve %16,9 artış göstermektedir. Bulgular revize edilmiş veri kümesiyle üretilen 3B modellerin mekanik özelliklerinde istatistiksel olarak belirgin bir iyileşme olduğunu ortaya koymaktır. Bunun yanı sıra GAN ile üretilen 3B modellerin veri kümesine dahil edilmesi veri çeşitliliğine de etki etmektedir. Daha organik forma sahip olan 3B modeller veri kümesi derinliğini ve böylece de üretilen tasarımların hacimsel olarak çeşitliliğini artırmaktadır. Diğer yandan güvenlik faktörleri incelendiğinde standart sapma değerlerinde doğrusal bir azalma vardır.


Çizelge 6.2. Altıncı iterasyon sonunda 3DGAN modeli tarafından üretilen mafsalları örnekleri ve fiziksel özellikleri

Üretilen modeller	Özellikler
	Parça adı Malzeme Hacim (cm3) von Mises (MPa) Emniyet faktörü : P_98 : AlSi10Mg : 103,23 : 71,2 : 3,79
	Parça adı Malzeme Hacim (cm3) von Mises (MPa) Emniyet faktörü : P_137 : AlSi10Mg : 98,28 : 61,8 : 4,37
	Parça adı Malzeme Hacim (cm3) von Mises (MPa) Emniyet faktörü : P_358 : AlSi10Mg : 95,36 : 69,8 : 3,86
	Parça adı Malzeme Hacim (cm3) von Mises (MPa) Emniyet faktörü : P_475 : AlSi10Mg : 91,86 : 101 : 3,87




Şekil 6.20. Üretilen tasarımların hacim ve güvenlik faktörlerini

Şekil 6.21 her iterasyondaki ortalama emniyet faktörlerini gösterir. Grafik üzerindeki daire çapları ise veri çeşitliliğini ifade eden emniyet faktörlerine ait standart sapma değerlerine göre belirlenmiştir. İlk eğitim iterasyonu en yüksek veri çeşitliliği oluştururken, bu değer dördüncü iterasyonda beklenildiği gibi daha düşüktür. Ayrıca, her bir iterasyonda kullanılan veri setindeki GAN tarafından üretilen model oranları grafik üzerinde gösterilmektedir. Şekil 6.21 ve Şekil 6.22, GAN ile üretilen tasarımların pozitif yönde şartlanabilme / etkilenebilme durumunu göstermektedir. İterasyon sayısı arttıkça veri çeşitliliği istenilen yönde gelişmektedir.



Şekil 6.21. Eğitim iterasyonları için ortalama güvenlik faktörleri

Son iterasyonda üretilen en iyi performansa sahip iş parçasının mekanik özellikleri, Ansys yazılımında hassas bir değerlendirme ile doğrulanmıştır. Bu değerlendirmeden elde edilen sonuçlar, FEA otomasyonu ile büyük oranda benzerlik göstermektedir. Şekil 6.22, bileşenin yükleme koşulları altındaki mekanik davranışı göstermekte ve özellikle kritik kesitlere odaklanmaktadır. Burada, en yüksek gerilmenin kuvvetin uygulanma noktasına en uzak ve destek noktasına en yakın bölgede olduğu görülmektedir. Diğer kesitler ise daha düşük gerilme seviyelerine maruz kalmışlardır. Şekil ayrıca orijinal, GAN ile üretilmiş ve düzenlenmiş modellerin von Mises gerilimleri ve ağırlıklarıyla ilgili bilgi de vermektedir. İlk olarak orijinal model görece büyük bir ağırlığa (579,79 g) sahip olsa da geometrisindeki keskin köşeler gerilim birikmelerine sebep olmaktadır. Organik formlardan oluşan GAN ile üretilmiş model, görece düşük ağırlığına (266,39 g) rağmen orijinal modele benzer mekanik özellikler göstermektedir. Bu model üzerindeki ince kesitlerin manuel olarak kalınlaştırılması ve gerilime maruz kalmayan hacimlerin çıkarılması ile daha iyi mekanik performans özelliklerine (43,618 MPa) ulaşılmıştır.



Şekil 6.22. Sonlu elemanlar analiz otomasyonunun doğrulanması. a) orijinal model, b) GAN ile üretilmiş model, c) düzenlenmiş model

6.5.5. Eklemeli imalat ile parça üretimi

Eklemeli İmalat (Eİ) teknolojisindeki ilerlemeler üretken tasarım algoritmalarına motivasyon kaynağı oluşturmaktadır. Geleneksel imal usulleri ile üretilmesi mümkün olmayan karmaşık geometrili parçalar Eİ teknikleriyle üretilebilir [316]. Özellikle veri bağımlı üretken tasarım yöntemleri ile oluşturulan tasarım konseptleri herhangi bir geometri


kısıtlamasına tabii değildir. Bu nedenle oluşturulan tasarım konseptleri genelde Eİ teknikleriyle üretilebilir.

Bu araştırma kapsamında üretim ve değerlendirme döngüsü son adımında konsept tasarımlar ağırlık ve dayanım özelliklerine göre sınıflandırılmıştır. Daha sonra da en iyi performansa sahip tasarım konseptleri imal edilmiştir. Bu süreçte parça üzerindeki (varsa) olumsuzluklar BDT ortamında düzeltilir. Voksel modeli STL formatına dönüştürülür ve baskıya hazır hale getirilir. İstenilen hassasiyet ve baskı kalitesine göre yazıcı ayarları yapılarak konsept tasarımlar imal edilebilir. Eİ tekniklerinde parçaların katmalar halinde üretilmesi ortak çalışma prensibi olsa da teknikler arasında kullanılan sarf malzeme ve baskı teknolojisine göre farklılıklar bulunmaktadır [319, 320]. Bu çalışmada Eİ tekniklerinin üretken tasarım ile üretilen parçaları imal etme performansları SLA ve FDM yöntemi ile değerlendirilmiştir.

SLA yöntemiyle gerçekleştirilen eklemeli imalat sürecinde, ilk olarak dilimleyici bir yazılım aracılığıyla model 0,05 mm'lik katmanlara ayrılmıştır. Bu dilimleme işlemi, belirli bir katman kalınlığında üç boyutlu bir modelin inşasına olanak tanır. Süreçte her bir katman, iki saniye boyunca UV ışığına maruz bırakılarak sertleştirilmiştir. Ayrıca, modelin inşa platformuna daha güçlü bir yapışma sağlaması için, taban katmanları 28 saniye UV ışığına maruz bırakılmıştır ve bu taban katmanları toplamda dört katmandan oluşmaktadır. 3 saat 12 dakika süren bu üretim sürecinin sonucunda üç adet 1:2 ölçekli parça başarıyla üretilmiştir. Bu üretim aşamasının hemen ardından, parçalar kalan reçine kalıntılarından arındırılmak amacıyla bir çözeltide yıkanmıştır. Parçaların mekanik dayanımını ve boyutsal tutarlılığını artırmak için 5 dakika süresince UV ışığı altında kürlenmiştir. Son olarak destek yapılar parçadan ayrılarak imalat süreci tamamlanmıştır.

FDM yöntemiyle gerçekleştirilen eklemeli üretim sürecinde, başlangıçta dilimleyici bir yazılım kullanılarak model 0,12 mm katman kalınlığında dilimlenmiştir. Üretim sürecinde, termoplastik bir filament eritilerek ince bir nozuldan ekstrüde edilir. Modelin her katmanı, belirli bir sıcaklıkta ekstrüde edilerek sertleştirilmiştir. Bu üretim süreci yaklaşık 15 saat sonunda tamamlanmıştır. Son olarak Üretilen parçalardan destek malzemeler dikkatlice çıkarılmıştır.

Çizelge 6.3. SLA ve FDM yöntemleriyle üretim karşılaştırması

Yöntem	Parça	Özellikler
SLA		Malzeme : Sıvı reçine Malzeme miktarı : 18 ml Katman kalınlığı : 0,05 mm Üretim süresi : 175 dk Maliyet : 32 ₺
FDM		Malzeme : PLA (Polilaktik Asit) Malzeme miktarı : 22 ml Katman kalınlığı : 0,12 mm Üretim süresi : 317 dk Maliyet : 14 ₺

Çizelge 6.3, bir parçanın (GAN tarafından üretilen model) SLA ve FDM teknikleriyle üretim sonuçlarını karşılaştırmaktadır. PLA, biyobozunur bir malzeme olması nedeniyle çevresel bir avantaj sunarken, sıvı reçine kullanımı SLA'nın yüzey kalitesinde üstünlük sağlamaktadır. Dahası, SLA'nın daha ince katman kalınlığı, yüksek detay ve yüzey kalitesi talep eden bu uygulama için daha uygundur. Üretim hızı bağlamında, SLA 175 dakikalık bir sürede tamamlanırken, FDM'nin tamamlanması 317 dakika sürmektedir. Ancak, FDM'nin 14 ₺ maliyetiyle SLA'nın 32 ₺ maliyetine kıyasla daha uygun maliyetli bir seçenek olduğu görülmektedir.

6.6. Bulgular


GAN, eğitim verilerinin geometrik konfigürasyonlarına benzer yeni verileri oluşturmak için etkili bir üretken tasarım aracıdır. Mühendislik tasarımında GAN modellerinin en temel eksiği üretilen verilerde elastik modül, akma dayanımı ve enerji emilimi gibi mekanik özelliklerin kontrol edilememesidir. GAN modelinin öğreneceği özellikler kullanıcı tarafından belirlenmediğinden, bahsedilen mekanik özellikler mevcut GAN modelleriyle öğrenilmesi çok zordur. Bunun yerine, bu çalışmada mekanik özellikleri öğrenmek için dolaylı bir yaklaşım önerilmektedir. GAN modelinin veri kümesinden öğrendiği göz önüne alındığında, veri kümesini sadece yüksek yapısal performanslı iş parçalarından oluşturmak, GAN modeliyle üretilen 3B modellerin de yüksek yapısal performans göstermesini

sağlamıştır. Böylece, mekanik özellikler üretken derin öğrenme eğitim sürecine dahil edilmiştir.

Önerilen tasarım ve değerlendirme döngüsü GAN tarafından üretilen 3B modellerin mekanik özelliklerini geliştirmeyi amaçlamaktadır. İlk aşamada veri yetersizliği problemini aşmak için parametrik tasarım teknikleri kullanılarak bir sentetik veri kümesi oluşturulmuştur. İkinci aşamada bu sentetik veri kümesi ile 3DGAN modeli eğitilmiştir. Son aşamada ise 3DGAN modeli tarafından oluşturulan 3B modeller bir simülasyon yazılımında mekanik özelliklerin belirlenmesi için analiz edilir. Burada belirlenen üstün mekanik özelliklere sahip 3B modeller bir sonraki iterasyonda kullanılmak için veri kümesine dahil edilir. Eklenen yeni veri miktarı kadar veri kümesinden rastgele veri çıkarılır. Önerilen yöntem veri miktarını ve eğitim parametrelerini değiştirmeden sadece veri kalitesinin GAN performansı üzerindeki etkisini incelemektedir.

Önerilen yöntemin başlangıç eğitim veri kümesine uygulanmamasının üç nedeni vardır. Bunlardan ilki, sınırlı eğitim verisinin önceden filtrelenmesi derin öğrenme model eğitimi için yetersiz veriye sebep olmasıdır. İkincisi, veri çeşitliliğinin azalması aşırı öğrenme problemine sebep olabilir. GAN'ların bir tasarım sınıfının ortak özelliklerini öğrenmesi için veri çeşitliliği gereklidir. Son olarak tüm veri kümesinin simülasyon ortamında analiz edilmesi hesaplama açısından verimsizdir.

Üretilen 3B modellerin performansını belirlemede dikkate alınan diğer bir kriter ise tasarımın gerçek dünya uygulamalarındaki başarı durumunu ifade eden uygulanabilirliktir. GAN modeli gerçekçi veri üretme yeteneğine rağmen bazı durumlarda eksik veya hatalı geometriler oluşturmaktadır. Bu durum GAN modelinin eğitim veri kümesine benzemeyen tasarımlar oluşturma potansiyelini ortaya koymaktadır. Diğer yandan veri kümesi özelliklerini tam yansıtmayan tasarımların uygulanabilirlikleri zayıftır. Şekil 6.23'te de görüldüğü gibi 3B modeller üzerindeki çok ince kesit veya süreksizlik nedeniyle bazı modeller simülasyon ortamında analiz edilememiştir. Uygulama-1'de her iterasyonda verilerin ortalama %2'si değerlendirilememiştir. Uygulama-2'de ise analiz edilemeyen 3B modellerin oranı 6 iterasyon için sırasıyla %13,4, %12,7, %13,2, %12,4, %11,5 ve %12,9'dur. İki uygulama arasındaki bu fark örnek parçaların karmaşıklık seviyesinden kaynaklanmaktadır. Yüksek işlem kapasiteli sistemlerin kullanılması ve veri sayısının artırılmasıyla bu problem aşılabılır. Diğer taraftan, bu istatistiki sonuçlar yeniden düzenlenen verilerin uygulanabilirlik üzerine anlamlı bir etkisinin olmadığını göstermektedir.



Şekil 6.23. GAN modeli tarafından üretilen hatalı geometrilerden örnekler

Bu çalışmanın temel amacı bir yapısal iş parçasının performansını en üst düzeye çıkarmak değil sunulan yöntemin mekanik özellikleri geliştirmedeki katkısını ortaya koymaktır. Bu çalışmada iki uygulama ele alınmış olsa da mekanik özelliklerin ön planda olduğu birçok yapısal iş parçası için uygulanabilir. Benzer şekilde, iş parçalarını değerlendirmede çok eksenli gerilme durumlarında hassas tahminler sunan von Mises gerilmesi, temel performans metriği olarak ele alınmıştır. Ancak, mühendislik tasarımında ve değerlendirmesinde elastik modül, sertlik, yorulma dayanımı, akma sınırı, doğal frekans gibi birçok diğer kritik performans metriği dikkate değerdir. Diğer performans metriklerini önerilen çerçeveye entegrasyonu kapsamlı bir değerlendirme için gereklidir.

Önerilen tasarım ve değerlendirme çerçevesi, geleneksel tasarım sürecinde yürütülen; ihtiyaçları belirleme, fikir ve konsept üretme, modelleme, değerlendirme ve yeniden tasarım adımlarının otomasyonunu sağlamaktadır. Böylece ürün yaşam döngüsünün bir parçası olan ürün geliştirme süreçleri önemli oranda insan müdahalesi olmadan otomatik yapılabilmektedir. Bu insan kaynaklı hataları en aza indirir, tasarım sürecini kısaltır ve nitelikli iş gücü tasarrufu da sağlar. Ayrıca, geleneksel topoloji optimizasyonuna kıyasla bu yöntem tek bir ideal tasarım seçeneğinden ziyade çeşitli uygulanabilir tasarım seçenekleri oluşturmayı amaçlar. Bir eğitim sonunda elde edilen ağ ağırlıkları ile istenildiği zaman mekanik özellikleri yüksek tasarımlar saniyeler içerisinde üretilebilir.

Sonlu elemanlar analizinin GAN eğitim sürecine dahil edilmesi hedeflenen mekanik performanslı tasarımların oluşmasına imkân tanımaktadır. Dahası kısmen sınırlı sayıda veri ile eğitilen üretken derin öğrenme modeli sınırsız sayıda fonksiyonel 3B (tasarım)

model(leri) üretebilir. Bu üretken tasarım çerçevesi yeni veri setleri oluşturma kapasitesi sayesinde veri kıtlığı problemine karşı potansiyel bir çözüm sunmaktadır. Bu özellik veri sayısının yetersiz ve/veya gizlilik gereği veriye ulaşmanın zor olduğu başta savunma, havacılık ve otomotiv endüstrilerinde derin öğrenme çalışmaları için gerekli eğitim verilerini oluşturmak için yeni bir yol sunar. 3DGAN'ların doğrudan 3B model verileriyle eğitilmesi onları birçok farklı uygulama için uygun kılar.

Diğer yandan, bu yaklaşımın bazı potansiyel zorlukları ve sınırlılıkları da bulunmaktadır. İlk olarak, bu yaklaşımda tasarım kalitesiyle çeşitlilik arasında bir ödünleşim söz konusudur [307]. Üretilen tasarımların mekanik performansı artarken tasarım çeşitliliği azalmaktadır. Ayrıca, büyük veri setlerinde yüksek öğrenme kapasitesine ihtiyaç duyulduğundan daha kompleks GAN mimarileri geliştirmek gerekebilir. Bu durum daha fazla hesaplama gücü ve zaman gerektirecektir. Aynı zamanda, hedeflenen bazı mekanik özellikler daha zor öğrenilebilir. Buna ek olarak, gerçek dünyadaki malzeme özellikleri, üretim yöntemleri ve kullanım koşulları gibi faktörler göz ardı edilirse, üretilen tasarımlar pratik uygulamalarda beklenen performansı göstermeyebilir. Ayrıca bu yöntem geleneksel üretim kısıtlamalarını dikkate alamaz. Bu durum, GAN'lar tarafından üretilen tasarımların gerçek dünya uygulamalarında kullanım ve uygulanmasını sınırlandırabilir. Örneğin, bir tasarım 3B baskı için uygun olabilirken, döküm veya talaşlı işleme için uygun olmayabilir. Bu nedenle, gelecek çalışmalarda üretim sürecine özgü kısıtlamaların GAN modeline dahil edilmesi düşünülebilir.

3DGAN modeli, organik ve ince geometrili tasarımların oluşturulmasını mümkün kılarken, bu tasarımların geleneksel üretim yöntemleriyle imalatı zordur. Eklemeli imalatla öne çıkan SLA yöntemi, bu çalışmada 3DGAN ile elde edilen ve FEA ile doğrulanan tasarımların üretim potansiyelini araştırmak için kullanılmıştır. SLA, karmaşık geometrilerin ve ince detayların üretimini mümkün kılar. Elde edilen 3B baskılar önerilen yöntemin gerçek hayata uygulanabilme potansiyeli ortaya koymaktadır. Ancak, daha kapsamlı sonuçlar için başta metal eklemeli imalat yöntemleri olmak üzere diğer yöntemler de test edilmelidir [321].

6.7. Sonuç

Bu çalışma 3DGAN modeli ile üretilen 3B konseptlerin mekanik özelliklerini geliştirmek için yeni bir çerçeve sunmaktadır. Önerilen çerçeve parametrik tasarım, derin öğrenme

eđitimi ve sonlu elemanlar analizi ařamalarından oluřmaktadır. 3DGAN ile sonlu elemanlar analizinin entegrasyonu, mekanik zellikleri stn rnlerin otomatik bir srete retilmesine imkn sađlamaktadır. nerilen iteratif tasarım ve deđerlendirme erevesi, mhendislik tasarımında mekanik zelliklerin kontrol edilememesi ve veri kıtlıđı sorunlarını ařmayı amalamaktadır. Bu ereve hem tasarım kalitesini hem de tasarım eřitliliđini optimize etmeye alıřan bir yaklařım sunmaktadır.

Elde edilen sonular, 3DGAN'ların mhendislik tasarımında nemli bir potansiyele sahip olduđunu gstermektedir. zellikle, belirli mekanik zellikleri karřılayan yeni tasarımların otomatik olarak oluřturulması, tasarım srelerini hızlandırabilir ve rn geliřtirme srecini daha verimli hale getirebilir. Bu alıřmada yalnızca bir sentetik veri kmesi kullanılsa da nerilen ereve mhendislik tasarımında kullanılan birok yapısal paranın tasarımında ve geliřtirilmesinde yer alabilir. Bununla birlikte, bu yaklařımın tam potansiyelini ortaya ıkarmak iin mevcut sınırlılıklarının ve zorluklarının stesinden gelmek adına daha fazla arařtırma yapılması gerekebilir. zellikle, farklı mhendislik disiplinleri ve uygulama alanları iin bu yaklařımın adaptasyonu ve optimizasyonu nemli bir arařtırma konusudur.

Gelecek alıřmalarda, GAN modelinin tutarlılıđını ve dođruluđunu artırmaya ynelik optimizasyon tekniklerinin uygulanması, bu hataların minimize edilmesine yardımcı olabilir. zellikle kullanılan eđitim verilerinin boyutunun artırılması daha hassas geometrilerin retilmesine yardımcı olabilir. Diđer taraftan, geliřmiř GAN mimarilerinin nerilen ereveye dhil edilmesi retilen tasarımların ayrıntı seviyesini ve uygulanabilirliđini artıracaktır. Ayrıca, farklı malzeme zelliklerini dikkate alarak, daha karmařık mhendislik problemlerine uygulanabilirlikleri test edilmelidir.

7. SONUÇLAR VE ÖNERİLER

Bu tez çalışması üretken derin öğrenme modelleri kullanarak üretilen 3B konseptlerin mekanik özelliklerini geliştirmek için yeni ve uygulanabilir bir çerçeve sunmaktadır. Bu çerçeve, parametrik tasarımı, derin öğrenme eğitimi ve sonlu elemanlar analizini kapsayarak, otonom bir süreç içerisinde üst düzey mekanik özelliklere sahip ürünlerin tasarlanmasını mümkün kılmaktadır. 3DGAN ve sonlu elemanlar analizi entegrasyonu bu sürecin merkezindedir. Bu yaklaşımın özgün bir diğer boyutu ise, hedefe yönelik tasarımlar üretebilmek için veriye dayalı üretken tasarım modellerine yeni bir perspektif getirmesidir. Bu modeller, eğitim veri kümesinin dağılımını yansıtan veriler üretme özelliğine sahiptir. Eğitim veri kümesinin genel özelliklerini iyileştirerek, tekrarlanan tasarım ve değerlendirme adımları aracılığıyla üretilen verilerin mekanik dayanıklılık açısından üst düzeye çıkartılması hedeflenmektedir. Üretken modellerin mekanik özelliklerinin düzenlenmesi, mühendislik tasarımı alanında derin öğrenme uygulamaları için potansiyel yeni bir alan açabilir. Altı ayrı bölümden oluşan bu çalışmadan elde edilen sonuçlar aşağıda özetlenmiştir.

Tezin giriş bölümünde, ele alınan konunun önemi, araştırmanın amaç ve hedefleri, çalışmanın özgün yönleri ve genel araştırma metodolojisi ayrıntılı bir şekilde incelenmiştir.

İkinci bölümde, mühendislik ve ürün tasarımında kullanılan Yapay Zekâ (YZ) yöntemlerine dair geniş bir perspektif sunulmuştur. Klasik ve modern YZ yöntemlerinin güçlü ve zayıf yönleri ele alınarak bu yöntemlerin tasarım süreçleri ve problemlerine nasıl uyum sağlayabileceği tartışılmıştır. Son yıllarda tasarım çalışmalarında YZ teknik ve yöntemlerinin kullanımı konusunda bariz bir artış gözlemlenmiş ve bu artışın arkasında yatan temel faktörlerden biri olarak yüksek performanslı bilgisayar teknolojilerindeki gelişmeler öne çıkmaktadır. Ayrıca, YZ yöntemlerinin tasarım uygulamalarındaki kullanım oranlarına dair elde edilen veriler, bilgi tabanlı YZ yöntemlerinden veri odaklı yaklaşımlara doğru bir geçişin yaşandığını göstermiştir. Bu durum, özellikle 2015 yılından itibaren makine öğrenmesi ve derin öğrenme yöntemlerinin tasarım uygulamaları ve akademik yayınlarda giderek daha fazla yer bulmasını sağlamıştır.

Tasarımda YZ uygulamalarının ana amacı, tasarımcının iş yükünü hafifletmek, tasarım maliyetlerini düşürmek ve süreçleri hızlandırmak olarak açıklanabilir. Tasarım çalışmalarında yaygın olarak kullanılan YZ yöntemleri ve bunların avantajları ile

dezavantajları detaylı bir şekilde irdelenmiş ve tablolar halinde özetlenmiştir. Elde edilen sonuçlar, veri odaklı tasarım yöntemlerinin öznel yargılardan uzak, yaratıcılığı engelleyen psikolojik ataleti aşmada etkili olduğunu ve kişisel ön yargıları minimize ederek fikir ve kavramların değerlendirilmesine olanak tanıdığını göstermiştir. Bununla birlikte, YZ yöntemlerinin tasarım süreçlerinin tümünde kullanılamayacak kadar çeşitli olduğu, bu yöntemlerinin problemin doğasına uygun olması gerektiği vurgulanmıştır. Bu bağlamda, klasik YZ yöntemlerinin değerlendirme ve karar süreçlerinde, genetik algoritmalar ve hibrit yöntemlerin alternatif çözümler üretme ve ideal tasarım seçeneğini belirlemede, veri madenciliği ve makine öğrenimi yöntemlerinin müşteri taleplerini belirleme, duygusal ihtiyaçları ortaya çıkarma ve tasarımcılara ilham verme konularında etkili olduğu belirtilmiştir. Derin öğrenme yöntemleriyle ise 2B ve 3B modellerin dönüştürülmesi ve yeni modellerin üretilmesi mümkün olabilmektedir.

Tasarım problemi için doğru YZ yöntemini belirlemek, özellikle YZ yöntemleri konusunda yeterli bilgisi olmayan tasarımcılar için zor olabilir. Bu nedenle, başarılı uygulamalara dayanarak oluşturulan iki seviyeli bir YZ yöntemi seçim akış şeması tasarımcılara rehberlik etmek için sunulmuştur.

Üçüncü bölüm, tez kapsamında sunulan modelin uygulanabilirliğini görebilmek için bir ön çalışma içermektedir. Bu bölüm, parametrik tasarım ve üretken çekişmeli ağ (GAN) süreçlerini bir araya getirerek kafes yapılarının tasarımı için yenilikçi ve verimli bir yaklaşım sunmaktadır. Parametrik tasarım ve optimizasyon algoritmalarının entegrasyonu, veri kümesinin oluşturulmasını optimize ederken GAN model eğitimi önemli ölçüde hızlandırmış ve yüksek performanslı kafes geometrilerinin üretilmesini mümkün kılmıştır. GAN'lar, tasarım uzayını verimli bir şekilde keşfedebilmekte ve yeni kafes yapıları üretebilmektedir. Ancak, bu model anlamsız geometriler üretebilmekte ve bu da veri kalitesini etkileyebilmektedir. Bu nedenle, veri kümesinin boyutu ve çeşitliliğinin artırılması gerekmektedir.

Üretilen kafes yapılarının malzeme tüketimi ve üretim maliyeti açısından önemli avantajlar sunarken, bazı boyutsal doğruluk sorunları da bulunmaktadır. Özellikle ince diyagonal elemanlara sahip yapılar, yüksek hassasiyet gerektiren uygulamalar için uygun olmayabilir. Değişken tasarım parametrelerinin etkisi, farklı hücresel konfigürasyonlarda detaylı olarak incelenmiş ve bu konfigürasyonlar, gerilme ve eğilme baskın olmak üzere iki ana kategoriye

ayrılmıştır. GAN tarafından üretilen kafes yapıları, genel olarak yüksek mukavemet ve uzama performansı gösterirken bazı durumlarda düşük darbe emme kabiliyeti sergilemiştir. GAN ve parametrik tasarım yöntemlerinin entegrasyonu ile kafes yapılarının tasarımında önemli ilerlemeler kaydedildiği gösterilmiştir. Bu yaklaşım, malzeme ve maliyet tasarrufları sunarken, aynı zamanda mekanik performansı optimize etme potansiyeline sahiptir.

Dördüncü bölümde, tez kapsamında sunulan metodoloji için kullanılacak veri kümesinin üretilmesi için yeni bir yaklaşım önerilmiştir. Bu yaklaşımın özgün katkısı, parametrik tasarım ve Voronoi diyagramları entegrasyonu yoluyla sentetik 3B BDT verileri üretmesinde yatmaktadır. Voronoi diyagramları, veri noktaları arasındaki yakınlık ve yoğunluk ilişkilerini belirleyerek veri çeşitliliğini arttırarak derin öğrenme modelinin genel performansını ve öğrenme kabiliyetini güçlendirir.

Bu çalışma, makine öğrenmesi ve derin öğrenme tekniklerinin veriye dayalı tahmin ve çıkarım yapma yeteneklerini kullanarak, özellikle 3B nesne tanıma ve üretken tasarım çalışmalarında karşılaşılan sınırlı eğitim verisi problemine yeni bir çözüm yolu sunmaktadır. Veri kalitesi ve çeşitliliğinin modelin başarısında oynadığı kritik rol göz önüne alındığında, bu çalışmanın sunduğu sentetik veri üretme teknikleri, özellikle yapısal iş parçaları için yeterli veri bulunmadığında önemli bir alternatif oluşturabilir.

Üretilen sentetik veri kümesi, geometrik doğruluk, detay düzeyi, ölçek, dosya formatı standartları ve veri sayısı gibi ölçütlere dayanarak değerlendirilmiştir. Elde edilen veriler, gerçek modelin boyut, açı, yüzey özellikleri, delik konumu, montaj ara yüzleri ve çalışma alanı ölçüleri gibi sınır koşullarını eksiksiz olarak yansıtmaktadır. Ayrıca, parametrik tasarım aşamasında uygulanan formülasyon sayesinde veri kümesinde minimum sayıda hatalı, eksik veya uyumsuz veri bulunmaktadır.

Parametrik tasarımın modern tasarım süreçlerinde oynadığı rol, disiplinler arası iş birliğini teşvik eder ve karmaşık tasarım sorunlarına kapsamlı çözümler üretmeye olanak tanır. Aynı zamanda özelleştirilmiş tasarımlar oluşturabilir, üretim sürelerini ve maliyetlerini azaltarak sürdürülebilir ve çevre dostu çözümler sunabilir. Parametrik tasarımın sağladığı hızlı ve etkili 3B modelleme kapasitesi, derin öğrenme çalışmalarına, özellikle 3B veri analizi ve üretme bağlamında önemli katkılar sağlayabilir. Bu durum veri yetersizliği sorununu ele alarak araştırmacılara etkili model eğitimi ve doğrulama için yeterli veri sağlar. Bu da derin

öğrenme uygulamalarının genel performansını artırabilir ve belirli uygulamalar için özel çözümler geliştirme sürecini hızlandırabilir. Tasarımcılar ve mühendisler için daha karmaşık ve optimize edilmiş tasarım ve çözümler elde etme olanağı tanıyabilir.

Beşinci bölümde üretken çekışmeli ağların temel çalışma mekanizmaları ve zamanla ortaya çıkan gelişmiş GAN modelleri ele alınmıştır. 3DGAN, endüstriyel tasarım ve eklemeli imalat gibi çeşitli alanlarda benzersiz zorluklarla başa çıkabilen ve özel ihtiyaçları karşılayabilen güçlü bir araçtır. Bu yöntem, 3B modelleri hızla görselleştirmek ve iyileştirmek, tasarım optimizasyonu yapmak ve estetik, işlevsellik ile üretim kısıtları arasında ideal dengeyi bulmak için çeşitli tasarım seçenekleri sunar. Böylece performansın artırılması, malzeme kullanımının azaltılması ve maliyet tasarrufu sağlanır. Ayrıca, bu modeller bilgisayar destekli mühendislik (CAE) araçlarıyla entegre edilerek tasarım uzayı daraltılabilir ve statik, dinamik ve termal iyileştirmeler yapılabilir.

3DGAN'lar, geleneksel yöntemlerle tasarlanması zor olan geometrileri üretmek için kullanılabilir. Ayrıca özelleştirme ile kişiselleştirme konusunda önemli katkılarda bulunur. Tasarım ve üretim süreçlerini devrim niteliğinde değiştirebilir ve tasarım optimizasyonu görevlerinde kritik bir role sahip olabilir. Bu teknoloji sayesinde endüstriyel tasarım ve üretim süreçleri daha esnek ve verimli hale gelebilir.

Bu bölümde tezin ilerleyen aşamalarında kullanılan ideal 3DGAN modelini belirlemek için örnek bir çalışma da yapılmıştır. Burada çeşitli veri depolarından elde edilen 3B sandalye modelleri ile bir 3DGAN modeli eğitilmiştir. Elde edilen sonuçlara göre ideal hiperparametreler ve katman sayısı belirlenmiştir.

Altıncı ve son bölümde derin öğrenme modelleri kullanarak üretilen 3B konseptlerin mekanik özelliklerini geliştirmek için yeni bir yöntem sunulmuştur. Sunulan yöntem, üretilen tasarımların mekanik özelliklerini artırma konusunda önemli bir potansiyel göstermektedir. Çalışma sonuçları da önerilen yöntemin mekanik özellikleri geliştirme konusunda etkili olduğunu göstermektedir. Bu durum, GAN'ların sadece görsel veya estetik açıdan değil, aynı zamanda fonksiyonel ve yapısal açıdan da üretken tasarım aracı olarak kullanılabileceğini kanıtlamaktadır. Bu, özellikle mühendislik tasarım uygulamaları için önemli bir avantajdır.

Bunun yanı sıra, bu çalışma sadece von Mises gerilmesini temel alarak mekanik performansı değerlendirmiştir. Mühendislik tasarımında ve değerlendirmesinde birçok diğer kritik performans metriği de önemlidir. Bu nedenle, gelecekteki çalışmalarda farklı performans metriklerini dahil etmek, bu yöntemin uygulama alanını genişletebilir.

Yine de bu yaklaşımın bazı potansiyel zorlukları ve sınırlılıkları bulunmaktadır. Örneğin, tasarım çeşitliliğinin azalması, tasarım alanındaki farklı ihtiyaçları ve tercihleri karşılamakta zorluk oluşturabilir. Bu, tasarım çeşitliliği ve kalite arasında bir denge kurmayı zorunlu kılar. Ayrıca, büyük veri setlerini ve karmaşık GAN mimarilerini kullanmanın getirdiği hesaplama yükü, bu yöntemin uygulanabilirliğini sınırlayabilir.

3B konseptlerin mekanik özelliklerini iyileştirmeyi amaçlayan gelecekteki çalışmalar, sunulan üretken derin öğrenme modelini temel alarak çeşitli alternatif yaklaşımları araştırabilir. İlk olarak, modelin genelleme kabiliyetini artırmak amacıyla farklı endüstrilerden elde edilen veri kümelerinin test edilmesi önemlidir. Sentetik veriler dışında, gerçek dünya verilerini kullanmak da modelin pratik uygulamadaki performansını anlamak için kritik öneme sahiptir. Özel endüstriyel uygulamalara odaklanmak ve detaylı vaka çalışmaları yaparak modelin uygulanabilirliğini test etmek, bu alandaki araştırmaların geleceği için önemlidir.

Model performansını artırmak adına hiper-parametre ayarlamalarına odaklanmanın yanı sıra GAN dışında alternatif derin öğrenme modelleri sürece dahil edilebilir. Mukavemet, esneklik gibi özel mekanik özelliklere yönelik detaylı analizler yapmak model performansını önemli derecede artırabilir. Son olarak, tasarım yazılımlarıyla entegrasyon sağlayarak uygulamaların kapsamını genişletmek ve modelin kullanılabilirliğini artırmak, bu alandaki gelecek çalışmaların odak noktalarından biri olmalıdır.



KAYNAKLAR

1. Sutherland, I. E. (1964). Sketchpad a Man-Machine Graphical Communication System. *Simulation*, 2(5), 3-20.
2. Huang, Y. and Fu, J. (2019). Review on application of artificial intelligence in civil engineering. *Computer Modeling in Engineering & Sciences*, 121(3), 845-875.
3. Oh, S., Jung, Y., Kim, S., Lee, I. and Kang, N. (2019). Deep Generative Design: Integration of Topology Optimization and Generative Models. *Journal of Mechanical Design*, 141(11), 1151.
4. Alpaydın, E. (2014). *Introduction to Machine Learning* (third edition). London: MIT Press.
5. Salehi, H. and Burgueño, R. (2018). Emerging artificial intelligence methods in structural engineering. *Engineering Structures*, 171, 170-189.
6. Rebala, G., Ravi, A. and Churiwala, S. (2019). *An Introduction to Machine Learning* (first edition). Cham: Springer.
7. Houssein, E. H., Emam, M. M., Ali, A. A. and Suganthan, P. N. (2021). Deep and machine learning techniques for medical imaging-based breast cancer: A comprehensive review. *Expert Systems with Applications*, 167, 114161.
8. Gal, Y. (2016). *Uncertainty in Deep Learning*, PhD thesis, University of Cambridge Department of Engineering, Cambridge.
9. Jin, L., Tan, F. and Jiang, S. (2020). Generative Adversarial Network Technologies and Applications in Computer Vision. *Computational Intelligence and Neuroscience*, 2020, 1459107.
10. Yi, X., Walia, E. and Babyn, P. (2019). Generative adversarial network in medical imaging: A review. *Medical Image Analysis*, 58, 101552.
11. Rahman, R. (2020). *Using Generative Adversarial Networks for Content Generation in Games*, Abertay University Computer Games Technology, Dundee.
12. Yoo, S., Lee, S., Kim, S., Hwang, K. H., Park, J. H. and Kang, N. (2021). Integrating deep learning into CAD/CAE system: generative design and evaluation of 3D conceptual wheel. *Structural and Multidisciplinary Optimization*, 64(4), 2725-2747.
13. Pahl, G., Beitz, W., Feldhusen, J. and Grote, K.-H. (2007). *Engineering Design: A Systematic Approach* (Third edition). London: Springer.

14. Ertel, W. (2018). *Introduction to artificial intelligence*. Springer.
15. Liu, J., Kong, X., Xia, F., Bai, X., Wang, L., Qing, Q. and Lee, I. (2018). Artificial Intelligence in the 21st Century. *IEEE Access*, 6, 34403-34421.
16. Liao, J., Hansen, P. and Chai, C. (2020). A framework of artificial intelligence augmented design support. *Human-Computer Interaction*, 35(5-6), 511-544.
17. Allison, J. T., Cardin, M.-A., McComb, C., Ren, M. Y., Selva, D., Tucker, C., Witherell, P. and Zhao, Y. F. (2022). Artificial intelligence and engineering design. *Journal of Mechanical Design*, 144(2).
18. Lu, P., Chen, S. and Zheng, Y. (2012). Artificial intelligence in civil engineering. *Mathematical Problems in Engineering*, 2012, 145974.
19. Saridakis, K. M. and Dentsoras, A. J. (2008). Soft computing in engineering design – A review. *Advanced Engineering Informatics*, 22(2), 202-221.
20. Youssef, A., El-Telbany, M. and Zekry, A. (2017). The role of artificial intelligence in photo-voltaic systems design and control: A review. *Renewable and Sustainable Energy Reviews*, 78, 72-79.
21. Chang, C.-W., Lee, H.-W. and Liu, C.-H. (2018). A Review of Artificial Intelligence Algorithms Used for Smart Machine Tools. *Inventions*, 3(3), 41.
22. Abualigah, L. and Diabat, A. (2020). A comprehensive survey of the Grasshopper optimization algorithm: results, variants, and applications. *Neural Computing and Applications*, 32(19), 15533-15556.
23. Giri, C., Jain, S., Zeng, X. and Bruniaux, P. (2019). A Detailed Review of Artificial Intelligence Applied in the Fashion and Apparel Industry. *IEEE Access*, 7, 95376-95396.
24. Verganti, R., Vendraminelli, L. and Iansiti, M. (2020). Innovation and Design in the Age of Artificial Intelligence. *Journal of Product Innovation Management*, 37(3), 212-227.
25. Nasiri, S. and Khosravani, M. R. (2021). Machine learning in predicting mechanical behavior of additively manufactured parts. *Journal of Materials Research and Technology*, 14, 1137-1153.
26. Lee, K. (2021). A Systematic Review on Social Sustainability of Artificial Intelligence in Product Design. *Sustainability*, 13(5), 2668.

27. Pan, Y. and Zhang, L. (2021). Roles of artificial intelligence in construction engineering and management: A critical review and future trends. *Automation in Construction*, 122, 103517.
28. Blessing, L. and Chakrabarti, A. (2009). *DRM, a Design Research Methodology*. London: Springer.
29. Neapolitan, R. E. and Jiang, X. (2018). *Artificial Intelligence: With an Introduction to Machine Learning* (2 edition). Boca Raton: Chapman and Hall/CRC. 480.
30. Ertel, W. (2017). *Introduction to Artificial Intelligence* (second edition). Cham: Springer.
31. Shehab, M., Abualigah, L., Jarrah, M. I., Alomari, O. A. and Daoud, M. S. (2020). (AIAM2019) Artificial Intelligence in Software Engineering and inverse: Review. *International Journal of Computer Integrated Manufacturing*, 33(10-11), 1129-1144.
32. Nti, I. K., Adekoya, A. F., Weyori, B. A. and Nyarko-Boateng, O. (2021). Applications of artificial intelligence in engineering and manufacturing: a systematic review. *Journal of Intelligent Manufacturing*.
33. Rich, E. (1983). *Artificial Intelligence*. Hill: McGraw.
34. Zhang, Y., Xu, T., Chen, C., Wang, G., Zhang, Z. and Xiao, T. (2021). A hierarchical method based on improved deep forest and case-based reasoning for railway turnout fault diagnosis. *Engineering Failure Analysis*, 127, 105446.
35. Vassiliades, A., Bassiliades, N. and Patkos, T. (2021). Argumentation and explainable artificial intelligence: a survey. *The Knowledge Engineering Review*, 36, e5.
36. Minh, D., Wang, H. X., Li, Y. F. and Nguyen, T. N. (2022). Explainable artificial intelligence: a comprehensive review. *Artificial Intelligence Review*, 55(5), 3503-3568.
37. Lucci, S. and Kopec, D. (2016). *Artificial Intelligence in the 21ST Century* (2 edition). New Delhi: Mercury Learning and Information.
38. Harman, G. and Kulkarni, S., *Statistical Learning Theory as a Framework for the Philosophy of Induction*, in *Philosophy of Statistics*, Bandyopadhyay, P. S. and Forster, M. R., Editors. Amsterdam: North-Holland. 833-847.
39. Han, Y. and Moghaddam, M. (2020). Eliciting Attribute-Level User Needs From Online Reviews With Deep Language Models and Information Extraction. *Journal of Mechanical Design*, 143(6), 1-34.

40. Zhou, F., Ayoub, J., Xu, Q. and Jessie Yang, X. (2019). A Machine Learning Approach to Customer Needs Analysis for Product Ecosystems. *Journal of Mechanical Design*, 142(1).
41. Singh, A. and Tucker, C. S. (2017). A machine learning approach to product review disambiguation based on function, form and behavior classification. *Decision Support Systems*, 97, 81-91.
42. Chan, K. Y., Kwong, C. K., Wongthongtham, P., Jiang, H., Fung, C. K. Y., Abu-Salih, B., Liu, Z., Wong, T. C. and Jain, P. (2020). Affective design using machine learning: a survey and its prospect of conjoining big data. *International Journal of Computer Integrated Manufacturing*, 33(7), 645-669.
43. Mukherjee, S., Lu, D., Raghavan, B., Breitkopf, P., Dutta, S., Xiao, M. and Zhang, W. (2021). Accelerating Large-scale Topology Optimization: State-of-the-Art and Challenges. *Archives of Computational Methods in Engineering*.
44. Hügler, M., Omoumi, P., van Laar, J. M., Boedecker, J. and Hügler, T. (2020). Applied machine learning and artificial intelligence in rheumatology. *Rheumatology Advances in Practice*, 4(1).
45. Jovel, J. and Greiner, R. (2021). An introduction to machine learning approaches for biomedical research. *Frontiers in Medicine*, 8, 2534.
46. Brynjolfsson, E. and Mitchell, T. (2017). What can machine learning do? Workforce implications. *Science*, 358(6370), 1530-1534.
47. Alanis, A. Y., Arana-Daniel, N. and López-Franco, C. (2019). *Artificial Neural Networks for Engineering Applications*. Mara Conner: St. Louis.
48. Kumar, A., Kumar, P. and Singh, V. K. (2019). Evaluating Different Machine Learning Models for Runoff and Suspended Sediment Simulation. *Water Resources Management*, 33(3), 1217-1231.
49. Dongare, A., Kharde, R. and Kachare, A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189-194.
50. Faul, A. C. (2020). *A Concise Introduction to Machine Learning*. Boca Raton: CRC Press.
51. Herzog, V. and Suwelack, S. (2021). Data-Efficient Machine Learning on Three-Dimensional Engineering Data. *Journal of Mechanical Design*, 144(2).
52. Closs, D. J., Jacobs, M. A., Swink, M. and Webb, G. S. (2008). Toward a theory of competencies for the management of product complexity: Six case studies. *Journal of Operations Management*, 26(5), 590-610.

53. Chen, W. and Chiang, Y. (2010). A study on the product design of hair dryer using neural network method, in *2010 International Symposium on Computer, Communication, Control and Automation (3CA)*. 396-399.
54. Lin, Y. and Yeh, C. (2015). Grey relational analysis based artificial neural networks for product design: A comparative study, in *2015 12th International Conference on Informatics in Control, Automation and Robotics (ICINCO)*. 653-658.
55. Feldhusen, J. and Nagarajah, A. (2009). Artificial Neural Networks to Optimize the Conceptual Design of Adaptable Product Development, in *Proceedings of the 19th CIRP Design Conference–Competitive Design*. Cranfield University Press.
56. Kutschenreiter-Praszkievicz, I. (2013). Application of neural network in QFD matrix. *Journal of Intelligent Manufacturing*, 24(2), 397-404.
57. Singh, R. D., Mittal, A. and Bhatia, R. K. (2019). 3D convolutional neural network for object recognition: a review. *Multimedia Tools and Applications*, 78(12), 15951-15995.
58. Ray, S. (2019). A Quick Review of Machine Learning Algorithms, *International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*. 35-39.
59. Bertolini, M., Mezzogori, D., Neroni, M. and Zammori, F. (2021). Machine Learning for industrial applications: A comprehensive literature review. *Expert Systems with Applications*, 175, 114820.
60. Meng, L., McWilliams, B., Jarosinski, W., Park, H.-Y., Jung, Y.-G., Lee, J. and Zhang, J. (2020). Machine Learning in Additive Manufacturing: A Review. *JOM*, 72(6), 2363-2377.
61. Abdi, H. and Williams, L. J. (2010). Principal component analysis. *WIREs Computational Statistics*, 2(4), 433-459.
62. Kramer, O. (2017). *Genetic Algorithm Essentials Studies in Computational Intelligence*. Cham: Springer Nature.
63. Kumar, M., Husain, M., Upreti, N. and Gupta, D. (2010). Genetic algorithm: Review and application. *Journal of Information & Knowledge Management*, 2(2), 451-454.
64. Tam, J. H., Ong, Z. C., Ismail, Z., Ang, B. C. and Khoo, S. Y. (2019). A new hybrid GA–ACO–PSO algorithm for solving various engineering design problems. *International Journal of Computer Mathematics*, 96(5), 883-919.
65. Gen, M., Cheng, R. and Lin, L. (2008). *Network Models and Optimization Decision Engineering* London: Springer.

66. Roy, S. and Chakraborty, U. (2013). *Introduction To Soft Computing*. New Delhi: Pearson.
67. Lin, C. D., Anderson-Cook, C. M., Hamada, M. S., Moore, L. M. and Sitter, R. R. (2015). Using Genetic Algorithms to Design Experiments: A Review. *Quality and Reliability Engineering International*, 31(2), 155-167.
68. Kanagaraj, G., Ponnambalam, S. G., Jawahar, N. and Nilakantan, J. M. (2014). An effective hybrid cuckoo search and genetic algorithm for constrained engineering design optimization. *Engineering Optimization*, 46(10), 1331-1351.
69. Khuat, T. T. and Le, M. H. (2017). A genetic algorithm with multi-parent crossover using quaternion representation for numerical function optimization. *Applied Intelligence*, 46(4), 810-826.
70. Zheng, H., Feng, Y.-x., Tan, J.-r., Zhang, Z.-f. and Zhang, Z.-x. (2016). An integrated cognitive computing approach for systematic conceptual design. *Journal of Zhejiang University-SCIENCE A*, 17(4), 286-294.
71. Han, J.-X., Ma, M.-Y. and Wang, K. (2021). Product modeling design based on genetic algorithm and BP neural network. *Neural Computing and Applications*, 33(9), 4111-4117.
72. Fung, K. Y., Kwong, C. K., Siu, K. W. M. and Yu, K. M. (2012). A multi-objective genetic algorithm approach to rule mining for affective product design. *Expert Systems with Applications*, 39(8), 7411-7419.
73. Trautmann, L., Piros, A. and Botzheim, J. (2020). Application of the Fuzzy System for an Emotional Pattern Generator. *Applied Sciences*, 10(19), 6930.
74. Hooda, D. S. and Raich, V. (2017). *Fuzzy Logic Models and Fuzzy Control* Oxford: Alpha Science. 408.
75. de Aguiar, J., Scalice, R. K. and Bond, D. (2018). Using fuzzy logic to reduce risk uncertainty in failure modes and effects analysis. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 40(11), 516.
76. Bělohlávek, R., Dauben, J. W. and Klir, G. J. (2017). *Fuzzy Logic and Mathematics: A Historical Perspective*. New York: Oxford University Press.
77. Sutono, S. B., Abdul-Rashid, S. H., Aoyama, H. and Taha, Z. (2016). Fuzzy-based Taguchi method for multi-response optimization of product form design in Kansei engineering: a case study on car form design. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, 10(9), 0108-0108.

78. Babaei, M. and Sheidaii, M. R. (2017). Desirability-Based Design of Space Structures Using Genetic Algorithm and Fuzzy Logic. *International Journal of Civil Engineering*, 15(2), 231-245.
79. Lanzotti, A., Carbone, F., Grazioso, S., Renno, F. and Staiano, M. (2018). A new interactive design approach for concept selection based on expert opinion. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 12(4), 1189-1199.
80. Huang, H.-Z., Liu, Y., Li, Y., Xue, L. and Wang, Z. (2013). New evaluation methods for conceptual design selection using computational intelligence techniques. *Journal of Mechanical Science and Technology*, 27(3), 733-746.
81. Bajaras, M. and Agard, B. (2015). A methodology to form families of products by applying fuzzy logic. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 9(4), 253-267.
82. Sousa-Zomer, T. T. and Miguel, P. A. C. (2017). A QFD-based approach to support sustainable product-service systems conceptual design. *The International Journal of Advanced Manufacturing Technology*, 88(1), 701-717.
83. Meng, Q., Li, F.-y., Zhou, L.-r., Li, J., Ji, Q.-q. and Yang, X. (2015). A rapid life cycle assessment method based on green features in supporting conceptual design. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 2(2), 189-196.
84. Ko, Y.-T. (2010). A dynamic planning method for new product development management. *Journal of the Chinese Institute of Industrial Engineers*, 27(2), 103-120.
85. Han, J., Shi, F., Chen, L. and Childs, P. R. N. (2018). The Combinator – a computer-based tool for creative idea generation based on a simulation approach. *Design Science*, 4, e11.
86. Vasconcelos, L. A. and Crilly, N. (2016). Inspiration and fixation: Questions, methods, findings, and challenges. *Design Studies*, 42, 1-32.
87. Jansson, D. G. and Smith, S. M. (1991). Design fixation. *Design Studies*, 12(1), 3-11.
88. Goldschmidt, G. and Smolkov, M. (2006). Variances in the impact of visual stimuli on design problem solving performance. *Design Studies*, 27(5), 549-569.
89. Goldschmidt, G. and Sever, A. L. (2011). Inspiring design ideas with texts. *Design Studies*, 32(2), 139-155.

90. Jiang, S., Luo, J., Ruiz-Pava, G., Hu, J. and Magee, C. L. (2021). Deriving Design Feature Vectors for Patent Images Using Convolutional Neural Networks. *Journal of Mechanical Design*, 143(6).
91. Fu, K., Cagan, J., Kotovsky, K. and Wood, K. (2013). Discovering Structure in Design Databases Through Functional and Surface Based Mapping. *Journal of Mechanical Design*, 135(3).
92. Mukherjea, S., Bamba, B. and Kankar, P. (2005). Information retrieval and knowledge discovery utilizing a biomedical patent semantic Web. *IEEE Transactions on Knowledge and Data Engineering*, 17(8), 1099-1110.
93. Sarica, S., Luo, J. and Wood, K. L. (2020). TechNet: Technology semantic network based on patent data. *Expert Systems with Applications*, 142.
94. Hao, J., Zhou, Y., Zhao, Q. and Xue, Q. (2019). An evolutionary computation based method for creative design inspiration generation. *Journal of Intelligent Manufacturing*, 30(4), 1673-1691.
95. Liu, L., Li, Y., Xiong, Y. and Cavallucci, D. (2020). A new function-based patent knowledge retrieval tool for conceptual design of innovative products. *Computers in Industry*, 115, 103154.
96. Luo, J., Song, B., Blessing, L. and Wood, K. (2018). Design opportunity conception using the total technology space map. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 32(4), 449-461.
97. Liu, Q., Wang, K., Li, Y. and Liu, Y. (2020). Data-Driven Concept Network for Inspiring Designers' Idea Generation. *Journal of Computing and Information Science in Engineering*, 20(3).
98. Han, J., Hua, M., Park, D., Wang, P. and Childs, P. R. N. (2020). Computational conceptual distances in combinational creativity. *Proceedings of the Design Society: DESIGN Conference*, 1, 177-186.
99. Boden, M. A. (2004). *The Creative Mind: Myths and Mechanisms*. London, UK: Routledge.
100. Ward, T. B. and Kolomyts, Y., *Cognition and Creativity*, in *The Cambridge Handbook of Creativity*. Cambridge: Cambridge University Press. 93-112.
101. Yilmaz, S., Daly, S. R., Seifert, C. M. and Gonzalez, R. (2016). Evidence-based design heuristics for idea generation. *Design Studies*, 46, 95-124.
102. Jin, X. and Dong, H. (2020). New design heuristics in the digital era. *Proceedings of the Design Society: DESIGN Conference*, 1, 607-616.

103. Shi, F., Chen, L., Han, J. and Childs, P. (2017). A Data-Driven Text Mining and Semantic Network Analysis for Design Information Retrieval. *Journal of Mechanical Design*, 139(11).
104. Han, J., Park, D., Forbes, H. and Schaefer, D. (2020). A computational approach for using social networking platforms to support creative idea generation. *Procedia CIRP*, 91, 382-387.
105. Bell, S. and Bala, K. (2015). Learning visual similarity for product design with convolutional neural networks. *ACM Transactions on Graphics*, 34, 98:1-98:10.
106. Yu, S., Dong, H., Wang, P., Wu, C. and Guo, Y. *Generative Creativity: Adversarial Learning for Bionic Design*. in *International Conference on Artificial Neural Networks*. 2019. Springer.
107. Chen, L., Wang, P., Dong, H., Shi, F., Han, J., Guo, Y., Childs, P. R. N., Xiao, J. and Wu, C. (2019). An artificial intelligence based data-driven approach for design ideation. *Journal of Visual Communication and Image Representation*, 61, 10-22.
108. Börklü, H. R., Yüksel, N., Çavdar, K. and Sezer, H. K. (2018). A practical application for machine design education. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, 12(2), JAMDSM0036-JAMDSM0036.
109. Childs, P. R. N. (2014). *Mechanical Design Engineering Handbook*., Oxford: Butterworth-Heinemann.
110. Yuan, C. and Moghaddam, M. (2020). Attribute-Aware Generative Design With Generative Adversarial Networks. *IEEE Access*, 8, 190710-190721.
111. Zhao, T., Yang, J., Zhang, H. and Siu, K. W. M. (2021). Creative idea generation method based on deep learning technology. *International Journal of Technology and Design Education*, 31(2), 421-440.
112. Matei, O. D. (2015). Using Genetic Algorithms for Exploring the Solution Space in the Case of Automated Product Design. *Applied Mechanics and Materials*, 809-810, 1516-1521.
113. Matei, O. and Contras, D. (2016). Automated product design and development using evolutionary ontology, in *Advances in Intelligent Systems and Computing*, 47-57.
114. Lin, Y., Yeh, C. and Wang, C. (2009). *Applying Neural Networks to Consumer-Oriented Product Design*. *International Conference on Artificial Intelligence and Computational Intelligence*, Shanghai.
115. Shen, H.-C. and Wang, K.-C. (2016). Affective product form design using fuzzy Kansei engineering and creativity. *Journal of Ambient Intelligence and Humanized Computing*, 7(6), 875-888.

116. Lin, Y. and Chen, Y. (2016). Artificial Intelligent Models for New Product Design: An Application Study. *International Conference on Computational Science and Computational Intelligence (CSCI)*, Hong Kong.
117. Camburn, B., He, Y., Raviselvam, S., Luo, J. and Wood, K. (2019). Evaluating Crowdsourced Design Concepts With Machine Learning, *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, Anaheim.
118. Soni, S., Khanna, P. and Tandon, P. (2013). Knowledge Support System for Aesthetics in Product Design. *Journal of Computing and Information Science in Engineering*, 13(1).
119. Bae, J. K. and Kim, J. (2011). Product development with data mining techniques: A case on design of digital camera. *Expert Systems with Applications*, 38(8), 9274-9280.
120. Yonekura, K. and Suzuki, K. (2021). Data-driven design exploration method using conditional variational autoencoder for airfoil design. *Structural and Multidisciplinary Optimization*, 64(2), 613-624.
121. Raina, A., McComb, C. and Cagan, J. (2019). Learning to Design From Humans: Imitating Human Designers Through Deep Learning. *Journal of Mechanical Design*, 141(11).
122. Mirza, M. and Osindero, S. (2014). Conditional generative adversarial nets (2014). *arXiv preprint arXiv:1411.1784*.
123. Chen, W. and Ahmed, F. (2020). PaDGAN: Learning to Generate High-Quality Novel Designs. *Journal of Mechanical Design*, 143(3).
124. Wang, P., Wang, S., Peng, D., Chen, L., Wu, C., Wei, Z., Childs, P., Guo, Y. and Li, L. (2020). Neurocognition-inspired design with machine learning. *Design Science*, 6.
125. Gu, Z., Hou, X., Saafi, M. and Ye, J. (2022). A Novel Self-Updating Design Method for Complex 3D Structures Using Combined Convolutional Neuron and Deep Convolutional Generative Adversarial Networks. *Advanced Intelligent Systems*, 2100186.
126. Oman, S. K., Tumer, I. Y., Wood, K. and Seepersad, C. (2013). A comparison of creativity and innovation metrics and sample validation through in-class design projects. *Research in Engineering Design*, 24(1), 65-92.
127. Wu, J., Xing, B., Si, H., Jian, D., Wang, J., Zhu, Y. and Liu, X. (2020). Product Design Award Prediction Modeling: Design Visual Aesthetic Quality Assessment via DCNNs. *IEEE Access*, 8, 211028-211047.

128. Romeo, L., Loncarski, J., Paolanti, M., Bocchini, G., Mancini, A. and Frontoni, E. (2020). Machine learning-based design support system for the prediction of heterogeneous machine parameters in industry 4.0. *Expert Systems with Applications*, 140.
129. Sharif Ullah, A. M. M. (2005). A fuzzy decision model for conceptual design. *Systems Engineering*, 8(4), 296-308.
130. Ayağ, Z. (2005). A fuzzy AHP-based simulation approach to concept evaluation in a NPD environment. *IIE Transactions (Institute of Industrial Engineers)*, 37(9), 827-842.
131. Sarfaraz Khabbaz, R., Dehghan Manshadi, B., Abedian, A. and Mahmudi, R. (2009). A simplified fuzzy logic approach for materials selection in mechanical engineering design. *Materials & Design*, 30(3), 687-697.
132. Ko, Y.-T. (2010). A fuzzy logic-based approach to idea screening for product design. *International Journal of Management Science and Engineering Management*, 5(2), 149-160.
133. Yüksel, N. and Börklü, H. (2021). Yapay Zeka Destekli Kavramsal Tasarım: Tekerlekli Sandalye Tasarım Seçenekleri Değerlendirmede Bulanık Mantık Kullanımı. *Gazi Journal of Engineering Sciences*, 7, 309-316.
134. Wang, K.-C. (2011). A hybrid Kansei engineering design expert system based on grey system theory and support vector regression. *Expert Systems with Applications*, 38(7), 8738-8750.
135. Toh, C. A., Starkey, E. M., Tucker, C. S. and Miller, S. R. *Mining for creativity: Determining the creativity of ideas through data mining techniques*. in *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*. 2017. American Society of Mechanical Engineers.
136. Li, Z., Tian, Z. G., Wang, J. W., Wang, W. M. and Huang, G. Q. (2018). Dynamic mapping of design elements and affective responses: a machine learning based method for affective design. *Journal of Engineering Design*, 29(7), 358-380.
137. Hao, J., Xu, L., Wang, G., Jin, Y. and Yan, Y. (2019). A Knowledge-Based Method for Rapid Design Concept Evaluation. *IEEE Access*, 7, 116835-116847.
138. Camburn, B., He, Y., Raviselvam, S., Luo, J. and Wood, K. (2020). Machine Learning-Based Design Concept Evaluation. *Journal of Mechanical Design*, 142(3).
139. Wang, L. and Liu, Z. (2021). Data-driven product design evaluation method based on multi-stage artificial neural network. *Applied Soft Computing*, 103, 107117.

140. Han, J., Forbes, H., Shi, F., Hao, J. and Schaefer, D. (2020). A data-driven approach for creative concept generation and evaluation. *Proceedings of the Design Society: DESIGN Conference*, 1, 167-176.
141. Gatys, L. A., Ecker, A. S. and Bethge, M. (2016). Image Style Transfer Using Convolutional Neural Networks, in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2414-2423.
142. Shu, D., Cunningham, J., Stump, G., Miller, S. W., Yukish, M. A., Simpson, T. W. and Tucker, C. S. (2020). 3D Design Using Generative Adversarial Networks and Physics-Based Validation. *Journal of Mechanical Design*, 142(7).
143. Yoo, S. and Kang, N. (2021). Explainable artificial intelligence for manufacturing cost estimation and machining feature visualization. *Expert Systems with Applications*, 183, 115430.
144. Johnvictor, A. C., Durgamahanthi, V., Pariti Venkata, R. M. and Jethi, N. (2022). Critical review of bio-inspired optimization techniques. *Wiley Interdisciplinary Reviews: Computational Statistics*, 14(1), e1528.
145. Skinner, S. N. and Zare-Behtash, H. (2018). State-of-the-art in aerodynamic shape optimisation methods. *Applied Soft Computing*, 62, 933-962.
146. Shelokar, P. S., Siarry, P., Jayaraman, V. K. and Kulkarni, B. D. (2007). Particle swarm and ant colony algorithms hybridized for improved continuous optimization. *Applied Mathematics and Computation*, 188(1), 129-142.
147. Engelbrecht, A. P. (2007). *Computational intelligence: an introduction*. John Wiley & Sons.
148. Zhengtong, H., Zhengqi, G., Xiaokui, M. and Wanglin, C. (2019). Multimaterial layout optimization of truss structures via an improved particle swarm optimization algorithm. *Computers & Structures*, 222, 10-24.
149. Jafari, M., Salajegheh, E. and Salajegheh, J. (2021). Optimal design of truss structures using a hybrid method based on particle swarm optimizer and cultural algorithm. *Structures*, 32, 391-405.
150. Samma, H., Mohamad-Saleh, J., Suandi, S. A. and Lahasan, B. (2020). Q-learning-based simulated annealing algorithm for constrained engineering design problems. *Neural Computing and Applications*, 32(9), 5147-5161.
151. Samma, H., Lim, C. P. and Mohamad Saleh, J. (2016). A new Reinforcement Learning-based Memetic Particle Swarm Optimizer. *Applied Soft Computing*, 43, 276-297.

152. Talbi, E.-G. (2009). *Metaheuristics: from design to implementation*. John Wiley & Sons.
153. Nadimi-Shahraki, M. H., Taghian, S., Mirjalili, S. and Faris, H. (2020). MTDE: An effective multi-trial vector-based differential evolution algorithm and its applications for engineering design problems. *Applied Soft Computing*, 97, 106761.
154. Leylek, E. A., Manzo, J. E. and Garcia, E. (2010). Bat-Inspired Wing Aerodynamics and Optimization. *Journal of Aircraft*, 47(1), 323-328.
155. Chen, A. L. and Martinez, D. H. (2012). A heuristic method based on genetic algorithm for the baseline-product design. *Expert Systems with Applications*, 39(5), 5829-5837.
156. Jiao, J., Zhang, Y. and Wang, Y. (2007). A generic genetic algorithm for product family design. *Journal of Intelligent Manufacturing*, 18, 233-247.
157. Brintrup, A. M., Ramsden, J. and Tiwari, A. (2007). An interactive genetic algorithm-based framework for handling qualitative criteria in design optimization. *Computers in Industry*, 58(3), 279-291.
158. Dou, R., Zong, C. and Nan, G. (2016). Multi-stage interactive genetic algorithm for collaborative product customization. *Knowledge-Based Systems*, 92, 43-54.
159. Yildiz, A. R. (2013). Comparison of evolutionary-based optimization algorithms for structural design optimization. *Engineering Applications of Artificial Intelligence*, 26(1), 327-333.
160. Zha, X. F. (2005). Soft computing in engineering design: a hybrid dual cross-mapping neural network model. *Neural Computing & Applications*, 14, 176-188.
161. Nguyen, N. V. (2015). Repetitively enhanced neural networks method for complex engineering design optimisation problems. *Aeronautical Journal -New Series-*, 119.
162. Zhang, Y., Jin, Z. and Chen, Y. (2020). Hybrid teaching-learning-based optimization and neural network algorithm for engineering design optimization problems. *Knowledge-Based Systems*, 187, 104836.
163. Sharpe, C., Wiest, T., Wang, P. and Seepersad, C. C. (2019). A Comparative Evaluation of Supervised Machine Learning Classification Techniques for Engineering Design Applications. *Journal of Mechanical Design*, 141(12).
164. Yu, Y., Hur, T., Jung, J. and Jang, I. G. (2019). Deep learning for determining a near-optimal topological design without any iteration. *Structural and Multidisciplinary Optimization*, 59(3), 787-799.

165. Burnap, A., Liu, Y., Pan, Y., Lee, H., Gonzalez, R. and Papalambros, P. Y. (2016). Estimating and Exploring the Product Form Design Space Using Deep Generative Models, in *ASME 2016 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*.
166. Umetani, N. (2017). Exploring generative 3D shapes using autoencoder networks, in *SIGGRAPH Asia 2017 Technical Briefs*. Association for Computing Machinery: Bangkok, Thailand. Article 24.
167. Sasaki, H., Hidaka, Y. and Igarashi, H. (2021). Explainable Deep Neural Network for Design of Electric Motors. *IEEE Transactions on Magnetics*, 57(6), 1-4.
168. Du, X. and Zhu, F. (2018). A new data-driven design methodology for mechanical systems with high dimensional design variables. *Advances in Engineering Software*, 117, 18-28.
169. Zheng, K., Hu, J. and Yang, R.-J. (2015). A New Variable Screening Method for Design Optimization of Large-Scale Problems. *SAE International Journal of Materials and Manufacturing*, 8(3), 693-696.
170. Shi, L., Fu, Y., Yang, R.-J., Wang, B.-P. and Zhu, P. (2013). Selection of initial designs for multi-objective optimization using classification and regression tree. *Structural and Multidisciplinary Optimization*, 48(6), 1057-1073.
171. Echeverria, F., Mallor, F. and San-Miguel, U. (2018). Design exploration prior to blade multi-disciplinary optimisation. *Journal of Physics: Conference Series*, 1037(4), 042014.
172. Shan, S. and Wang, G. G. (2010). Survey of modeling and optimization strategies to solve high-dimensional design problems with computationally-expensive black-box functions. *Structural and Multidisciplinary Optimization*, 41(2), 219-241.
173. Wang, G. G. and Shan, S. (2006). Review of Metamodeling Techniques in Support of Engineering Design Optimization. *Journal of Mechanical Design*, 129(4), 370-380.
174. Fu, Z. and Zhou, Y. (2020). Research on human–AI co-creation based on reflective design practice. *CCF Transactions on Pervasive Computing and Interaction*, 2(1), 33-41.
175. Kaljun, J. and Dolsak, B. (2011). Artificial intelligence in aesthetic and ergonomic product design process, in *MIPRO 2011 - 34th International Convention on Information and Communication Technology, Electronics and Microelectronics - Proceedings*. 959-964.
176. Bickel, S., Spruegel, T. C., Schleich, B. and Wartzack, S. (2019). How Do Digital Engineering and Included AI Based Assistance Tools Change the Product

- Development Process and the Involved Engineers. *Proceedings of the Design Society: International Conference on Engineering Design*, 1(1), 2567-2576.
177. Zarandi, M. H. F., Mansour, S., Hosseinijou, S. A. and Avazbeigi, M. (2011). A material selection methodology and expert system for sustainable product design. *The International Journal of Advanced Manufacturing Technology*, 57(9), 885-903.
 178. Akbari, F., Saberi, M. and Hussain, O. K. (2020). Social network structure-based framework for innovation evaluation and propagation for new product development. *Service Oriented Computing and Applications*, 14(3), 189-201.
 179. Ferrero, V. J., Alqseer, N., Tensa, M. and DuPont, B. *Using decision trees supported by data mining to improve function-based design*. in *Proceedings of the ASME Design Engineering Technical Conference*. 2020.
 180. Saxby, D. J., Killen, B. A., Pizzolato, C., Carty, C. P., Diamond, L. E., Modenese, L., Fernandez, J., Davico, G., Barzan, M., Lenton, G., da Luz, S. B., Suwarganda, E., Devaprakash, D., Korhonen, R. K., Alderson, J. A., Besier, T. F., Barrett, R. S. and Lloyd, D. G. (2020). Machine learning methods to support personalized neuromusculoskeletal modelling. *Biomechanics and Modeling in Mechanobiology*, 19(4), 1169-1185.
 181. Bryant, C. R., Bohm, M., Stone, R. B. and McAdams, D. A. (2008). An interactive morphological matrix computational design tool: A hybrid of two methods, in *2007 Proceedings of the ASME International Design Engineering Technical Conferences and Computers and Information in Engineering Conference, DETC2007*. 249-261.
 182. Newstetter, W. C. and Svinicki, M. D., *Learning theories for engineering education practice*, in *Cambridge Handbook of Engineering Education Research*. 29-46.
 183. Gologlu, C. and Mizrak, C. (2011). An integrated fuzzy logic approach to customer-oriented product design. *Journal of Engineering Design*, 22(2), 113-127.
 184. Saxby, D. J., Killen, B. A., Pizzolato, C., Carty, C. P., Diamond, L. E., Modenese, L., Fernandez, J., Davico, G., Barzan, M., Lenton, G., da Luz, S. B., Suwarganda, E., Devaprakash, D., Korhonen, R. K., Alderson, J. A., Besier, T. F., Barrett, R. S. and Lloyd, D. G. (2020). Machine learning methods to support personalized neuromusculoskeletal modelling. *Biomech Model Mechanobiol*, 19(4), 1169-1185.
 185. Nobari, A. H., Chen, W. and Ahmed, F. (2021). Range-Constrained Generative Adversarial Network: Design Synthesis Under Constraints Using Conditional Generative Adversarial Networks. *Journal of Mechanical Design*, 144(2).
 186. Dosovitskiy, A., Springenberg, J., Tatarchenko, M. and Brox, T. (2016). Learning to Generate Chairs, Tables and Cars with Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39, 1-1.

187. Sun, X., Wu, J., Zhang, X., Zhang, Z., Zhang, C., Xue, T., Tenenbaum, J. B. and Freeman, W. T. (2018). Pix3d: Dataset and methods for single-image 3d shape modeling, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2974-2983.
188. Zhou, L., Du, Y. and Wu, J. (2021). 3D Shape Generation and Completion through Point-Voxel Diffusion. *ArXiv*, abs/2104.03670.
189. Wu, J., Wang, Y., Xue, T., Sun, X., Freeman, W. T. and Tenenbaum, J. B. (2017). Marnet: 3d shape reconstruction via 2.5 d sketches. *arXiv preprint arXiv:1711.03129*.
190. Wu, J., Zhang, C., Xue, T., Freeman, W. T. and Tenenbaum, J. B. (2016). Learning a probabilistic latent space of object shapes via 3d generative-adversarial modeling, in *Proceedings of the 30th International Conference on Neural Information Processing Systems*. 82-90.
191. Gadelha, M., Maji, S. and Wang, R. (2017). 3D Shape Induction from 2D Views of Multiple Objects, in *2017 International Conference on 3D Vision (3DV)*. 402-411.
192. Zhang, C., Zhou, G., Yang, H., Xiao, Z. and Yang, X. (2020). View-Based 3-D CAD Model Retrieval With Deep Residual Networks. *IEEE Transactions on Industrial Informatics*, 16(4), 2335-2345.
193. Nguyen, T. A. and Zeng, Y. (2017). A theoretical model of design fixation. *International Journal of Design Creativity and Innovation*, 5(3-4), 185-204.
194. Su, Z., Yu, S., Chu, J., Zhai, Q., Gong, J. and Fan, H. (2020). A novel architecture: Using convolutional neural networks for Kansei attributes automatic evaluation and labeling. *Advanced Engineering Informatics*, 44, 101055.
195. Bonanno, D., Nock, K., Smith, L., Elmore, P. and Petry, F. (2017). *An approach to explainable deep learning using fuzzy inference* SPIE Defense + Security. Vol. 10207. SPIE.
196. Majak, J., Pohlak, M., Küttner, R., Eerme, M. and Karjust, K. (2008). Artificial neural networks and genetic algorithms in engineering design, in *International Conference on Engineering Optimization–Eng Opt*. Citeseer.
197. Yan, X., Liu, H., Zhu, Z. and Wu, Q. (2017). Hybrid genetic algorithm for engineering design problems. *Cluster Computing*, 20(1), 263-275.
198. Top, N., Şahin, İ., Gökçe, H. and Gökçe, H. (2021). Computer-aided design and additive manufacturing of bone scaffolds for tissue engineering: state of the art. *Journal of Materials Research*, 36(19), 3725-3745.

199. Wang, X., Qin, R., Chen, B., Niu, X. and Zhou, J. (2022). Multi-scale collaborative optimization of lattice structures using laser additive manufacturing. *International Journal of Mechanical Sciences*, 222, 107257.
200. Beyer, C. and Figueroa, D. (2016). Design and Analysis of Lattice Structures for Additive Manufacturing. *Journal of Manufacturing Science and Engineering*, 138(12).
201. Wu, Y., Fang, J., Wu, C., Li, C., Sun, G. and Li, Q. (2023). Additively manufactured materials and structures: A state-of-the-art review on their mechanical characteristics and energy absorption. *International Journal of Mechanical Sciences*, 246, 108102.
202. Ali, M., Sajjad, U., Hussain, I., Abbas, N., Ali, H. M., Yan, W.-M. and Wang, C.-C. (2022). On the assessment of the mechanical properties of additively manufactured lattice structures. *Engineering Analysis with Boundary Elements*, 142, 93-116.
203. Caiazzo, F., Alfieri, V., Campanelli, S. L. and Errico, V. (2022). Additive manufacturing and mechanical testing of functionally-graded steel strut-based lattice structures. *Journal of Manufacturing Processes*, 83, 717-728.
204. Eren, O., Sezer, H. K. and Yalçın, N. (2022). Effect of lattice design on mechanical response of PolyJet additively manufactured cellular structures. *Journal of Manufacturing Processes*, 75, 1175-1188.
205. Chen, L.-Y., Liang, S.-X., Liu, Y. and Zhang, L.-C. (2021). Additive manufacturing of metallic lattice structures: Unconstrained design, accurate fabrication, fascinated performances, and challenges. *Materials Science and Engineering: R: Reports*, 146, 100648.
206. du Plessis, A., Razavi, N., Benedetti, M., Murchio, S., Leary, M., Watson, M., Bhate, D. and Berto, F. (2022). Properties and applications of additively manufactured metallic cellular materials: A review. *Progress in Materials Science*, 125, 100918.
207. Siegkas, P. (2022). Generating 3D porous structures using machine learning and additive manufacturing. *Materials & Design*, 220, 110858.
208. Grasso, M., Laguzza, V., Semeraro, Q. and Colosimo, B. M. (2016). In-Process Monitoring of Selective Laser Melting: Spatial Detection of Defects Via Image Data Analysis. *Journal of Manufacturing Science and Engineering*, 139(5).
209. J, J. A., Schneider, J., Schiffer, A., Hafeez, F. and Kumar, S. (2022). Dynamic crushing of tailored honeycombs realized via additive manufacturing. *International Journal of Mechanical Sciences*, 219, 107126.
210. Tao, W. and Leu, M. C. *Design of lattice structure for additive manufacturing*. in *2016 International Symposium on Flexible Automation (ISFA)*. 2016. IEEE.

211. Sun, Z. P., Guo, Y. B. and Shim, V. P. W. (2021). Characterisation and modeling of additively-manufactured polymeric hybrid lattice structures for energy absorption. *International Journal of Mechanical Sciences*, 191, 106101.
212. Gibson, L. J. (1989). Modelling the mechanical behavior of cellular materials. *Materials Science and Engineering: A*, 110, 1-36.
213. Vaissier, B., Pernot, J.-P., Chougrani, L. and Véron, P. (2019). Parametric design of graded truss lattice structures for enhanced thermal dissipation. *Computer-Aided Design*, 115, 1-12.
214. Lucklum, F. and Vellekoop, M. J. (2015). Rapid Prototyping of 3D Phononic Crystals using High-resolution Stereolithography Fabrication. *Procedia Engineering*, 120, 1095-1098.
215. McGregor, D. J., Tawfick, S. and King, W. P. (2019). Automated metrology and geometric analysis of additively manufactured lattice structures. *Additive Manufacturing*, 28, 535-545.
216. Liu, W., Song, H. and Huang, C. (2020). Maximizing mechanical properties and minimizing support material of PolyJet fabricated 3D lattice structures. *Additive Manufacturing*, 35, 101257.
217. Sathishkumar, N., Vivekanandan, N., L.Balamurugan, Arunkumar, N. and Ahamed, I. (2020). Mechanical Properties of Triply Periodic Minimal Surface based lattices made by Polyjet Printing. *Materials Today: Proceedings*, 22, 2934-2940.
218. Nguyen, L. C. and Nguyen-Xuan, H. (2020). Deep learning for computational structural optimization. *ISA Transactions*, 103, 177-191.
219. Mao, Y., He, Q. and Zhao, X. (2020). Designing complex architected materials with generative adversarial networks. *Science Advances*, 6(17), eaaz4169.
220. Kumar, S., Tan, S., Zheng, L. and Kochmann, D. M. (2020). Inverse-designed spinodoid metamaterials. *Computational Materials*, 6(1), 73.
221. Hassanin, H., Alkendi, Y., Elsayed, M., Essa, K. and Zweiri, Y. (2020). Controlling the Properties of Additively Manufactured Cellular Structures Using Machine Learning Approaches. *Advanced Engineering Materials*, 22(3), 1901338.
222. Ma, C., Zhang, Z., Luce, B., Pusateri, S., Xie, B., Rafiei, M. H. and Hu, N. (2020). Accelerated design and characterization of non-uniform cellular materials via a machine-learning based framework. *Computational Materials*, 6(1), 40.
223. Bhuwal, A. S., Pang, Y., Ashcroft, I., Sun, W. and Liu, T. (2023). Discovery of quasi-disordered truss metamaterials inspired by natural cellular materials. *Journal of the Mechanics and Physics of Solids*, 175, 105294.

224. Zheng, X., Chen, T.-T., Guo, X., Samitsu, S. and Watanabe, I. (2021). Controllable inverse design of auxetic metamaterials using deep learning. *Materials & Design*, 211, 110178.
225. Wang, J., Chen, W., Da, D., Fuge, M. and Rai, R. (2022). IH-GAN: A conditional generative model for implicit surface-based inverse design of cellular structures. *Computer Methods in Applied Mechanics and Engineering*, 396, 115060.
226. Gerber, D. (2009). *The Parametric Affect: Computation, Innovation and Models for Design Exploration in Contemporary Architectural Practice*.
227. Gerber, D. and Lin, E. (2012). *Designing-in performance through parameterization, automation, and evolutionary algorithms: 'H.D.S. BEAGLE 1.0'*. 141-150.
228. Bushra, N. (2022). A comprehensive analysis of parametric design approaches for solar integration with buildings: A literature review. *Renewable and Sustainable Energy Reviews*, 168, 112849.
229. Shin, J., Kim, Y., Kim, D.-Y., Yoon, G. H. and Seo, T. (2023). Parametric Design Optimization of a Tail Mechanism Based on Tri-Wheels for Curved Spoke-Based Stair-Climbing Robots. *International Journal of Precision Engineering and Manufacturing*, 24(7), 1205-1220.
230. Yu, C., Chen, M., Cheng, K., Zhao, X., Ma, C., Kuang, F. and Chen, H. (2022). SGOA: annealing-behaved grasshopper optimizer for global tasks. *Engineering with Computers*, 38(5), 3761-3788.
231. Creswell, A., White, T., Dumoulin, V., Arulkumaran, K., Sengupta, B. and Bharath, A. A. (2018). Generative Adversarial Networks: An Overview. *IEEE Signal Processing Magazine*, 35(1), 53-65.
232. Kirkpatrick, S., Gelatt Jr, C. D. and Vecchi, M. P. (1983). Optimization by simulated annealing. *Science*, 220(4598), 671-680.
233. Huiyong, W., Shuchun, J. and Zhu, J. (2022). Simulation model and fault analysis of air circulation system of the aircraft based on grasshopper optimization algorithm: support vector machine. *Soft Computing*.
234. Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1-48.
235. Toshpulatov, M., Lee, W. and Lee, S. (2021). Generative adversarial networks and their application to 3D face generation: A survey. *Image and Vision Computing*, 108, 104119.

236. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.
237. Zhang, L., Song, B., Fu, J. J., Wei, S. S., Yang, L., Yan, C. Z., Li, H., Gao, L. and Shi, Y. S. (2020). Topology-optimized lattice structures with simultaneously high stiffness and light weight fabricated by selective laser melting: Design, manufacturing and characterization. *Journal of Manufacturing Processes*, 56, 1166-1177.
238. Wallach, J. C. and Gibson, L. J. (2001). Mechanical behavior of a three-dimensional truss material. *International Journal of Solids and Structures*, 38(40), 7181-7196.
239. Cheng, L., Zhang, P., Biyikli, E., Bai, J., Robbins, J. and To, A. (2017). Efficient design optimization of variable-density cellular structures for additive manufacturing: Theory and experimental validation. *Rapid Prototyping Journal*, 23.
240. Li, D., Liao, W., Dai, N., Dong, G., Tang, Y. and Xie, Y. M. (2018). Optimal design and modeling of gyroid-based functionally graded cellular structures for additive manufacturing. *Computer-Aided Design*, 104, 87-99.
241. Ayres, D. J. (1976). Dynamic plastic analysis of ductile fracture — the charpy specimen. *International Journal of Fracture*, 12(4), 567-578.
242. Gibson, L. J., Ashby, M. F., Schajer, G. and Robertson, C. (1982). The mechanics of two-dimensional cellular materials. *Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences*, 382(1782), 25-42.
243. Zohdi, N. and Yang, R. (2021). Material Anisotropy in Additively Manufactured Polymers and Polymer Composites: A Review. *Polymers*, 13(19).
244. Kim, G. D. and Oh, Y. T. (2008). A benchmark study on rapid prototyping processes and machines: Quantitative comparisons of mechanical properties, accuracy, roughness, speed, and material cost. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 222(2), 201-215.
245. Larson, E. R. (ed. Larson, E. R.) (2015). 5 - *Material Selection Based on Performance*, ed. Larson, E. R.: William Andrew Publishing. 145-205.
246. Mueller, J. and Shea, K. (2018). Buckling, build orientation, and scaling effects in 3D printed lattices. *Materials Today Communications*, 17, 69-75.
247. Liverani, E. and Fortunato, A. (2021). Stiffness prediction and deformation analysis of Cobalt-Chromium lattice structures: From periodic to functionally graded structures produced by additive manufacturing. *Journal of Manufacturing Processes*, 68, 104-114.

248. Sim, E.-A., Lee, S., Oh, J. and Lee, J. (2021). GANs and DCGANs for generation of topology optimization validation curve through clustering analysis. *Advances in Engineering Software*, 152, 102957.
249. Yüksel, N., Börklü, H. R., Sezer, H. K. and Canyurt, O. E. (2023). Review of artificial intelligence applications in engineering design perspective. *Engineering Applications of Artificial Intelligence*, 118, 105697.
250. Wang, H. and Wei, W. (2023). *Machine Learning for Synthetic Data Generation: a Review*.
251. Figueira, A. and Vaz, B. (2022). Survey on Synthetic Data Generation, Evaluation Methods and GANs. *Mathematics*, 10(15), 2733.
252. El Emam, K., Mosquera, L. and Hoptroff, R. (2020). *Practical synthetic data generation: balancing privacy and the broad availability of data*. O'Reilly Media.
253. Hsu, W. N., Zhang, Y. and Glass, J. (2017). Unsupervised domain adaptation for robust speech recognition via variational autoencoder-based data augmentation, in *2017 IEEE Automatic Speech Recognition and Understanding Workshop (ASRU)*. 16-23.
254. Lu, P.-H., Wang, P.-C. and Yu, C.-M. (2019). Empirical Evaluation on Synthetic Data Generation with Generative Adversarial Network, in *Proceedings of the 9th International Conference on Web Intelligence, Mining and Semantics*. Association for Computing Machinery: Seoul, Republic of Korea. Article 16.
255. Planche, B., Wu, Z., Ma, K., Sun, S., Kluckner, S., Chen, T., Hutter, A., Zakharov, S., Kosch, H. and Ernst, J. (2017). *DepthSynth: Real-Time Realistic Synthetic Data Generation from CAD Models for 2.5D Recognition*.
256. Ibrahim, A. and Kashef, R. (2012). Statistical vs. visual data generation in hand gesture recognition, in *2012 Seventh International Conference on Computer Engineering & Systems (ICCES)*. 163-169.
257. Siu, C., Wang, M. and Cheng, J. C. P. (2022). A framework for synthetic image generation and augmentation for improving automatic sewer pipe defect detection. *Automation in Construction*, 137, 104213.
258. Mursalin, M. and Islam, S. M. S. (2021). Deep Learning for 3D Ear Detection: A Complete Pipeline From Data Generation to Segmentation. *IEEE Access*, 9, 164976-164985.
259. Baimukashev, D., Zhilisbayev, A., Kuzdeuov, A., Oleinikov, A., Fadeyev, D., Makhataeva, Z. and Varol, H. A. (2019). Deep Learning Based Object Recognition Using Physically-Realistic Synthetic Depth Scenes. *Machine Learning and Knowledge Extraction*, 1(3), 883-903.

260. Salas, A. J. C., Meza-Lovon, G., Fernández, M. E. L. and Raposo, A. (2020). Training with synthetic images for object detection and segmentation in real machinery images, in *2020 33rd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. 226-233.
261. Gezawa, A. S., Zhang, Y., Wang, Q. and Yunqi, L. (2020). A Review on Deep Learning Approaches for 3D Data Representations in Retrieval and Classifications. *IEEE Access*, 8, 57566-57593.
262. Gao, M., Ruan, N., Shi, J. and Zhou, W. (2022). Deep Neural Network for 3D Shape Classification Based on Mesh Feature. *Sensors*, 22(18), 7040.
263. Feng, Y., Feng, Y., You, H., Zhao, X. and Gao, Y. *Meshnet: Mesh neural network for 3d shape representation*. in *Proceedings of the AAAI conference on artificial intelligence*. 2019.
264. Xu, Y., Tong, X. and Stilla, U. (2021). Voxel-based representation of 3D point clouds: Methods, applications, and its potential use in the construction industry. *Automation in Construction*, 126, 103675.
265. Poux, F. and Billen, R. (2019). Voxel-based 3D Point Cloud Semantic Segmentation: Unsupervised Geometric and Relationship Featuring vs Deep Learning Methods. *ISPRS International Journal of Geo-Information*, 8(5), 213.
266. Camuffo, E., Mari, D. and Milani, S. (2022). Recent Advancements in Learning Algorithms for Point Clouds: An Updated Overview. *Sensors*, 22(4), 1357.
267. Caetano, I., Santos, L. and Leitão, A. (2020). Computational design in architecture: Defining parametric, generative, and algorithmic design. *Frontiers of Architectural Research*, 9(2), 287-300.
268. Ahlquist, S. and Menges, A. (2011). *Computational design thinking*. London: Wiley.
269. Coenders, J. L. (2021). Next generation parametric design. *Journal of the International Association for Shell and Spatial Structures*, 62(2), 153-166.
270. Estrada Meza, M. G., González Meza, E., Chi Pool, D. A. and McNamara Trujillo, J. S. (2022). Design Exploration of Bamboo Shells Structures by Using Parametric Tools. *Applied Sciences*, 12(15), 7522.
271. Bolognini, F., Shea, K. and Seshia, A. (2011). Advanced applications of a computational design synthesis method, in *DS 68-9: Proceedings of the 18th International Conference on Engineering Design (ICED 11), Impacting Society through Engineering Design, Vol. 9: Design Methods and Tools pt. 1, Lyngby/Copenhagen, Denmark, 15.-19.08. 2011*.

272. Cristie, V. and Joyce, S. C. (2021). Versioning for parametric design exploration process. *Automation in Construction*, 129, 103802.
273. Turrin, M., Yang, D., D'Aquilio, A., Sileryte, R. and Sun, Y. (2016). Computational Design for Sport Buildings. *Procedia Engineering*, 147, 878-883.
274. Ng, W. L., Chan, A., Ong, Y. S. and Chua, C. K. (2020). Deep learning for fabrication and maturation of 3D bioprinted tissues and organs. *Virtual and Physical Prototyping*, 15(3), 340-358.
275. As, I., Pal, S. and Basu, P. (2018). Artificial intelligence in architecture: Generating conceptual design via deep learning. *International Journal of Architectural Computing*, 16(4), 306-327.
276. Price, M., Zhang, W., Friel, I., Robinson, T., McConnell, R., Nolan, D., Kilpatrick, P., Barbhuiya, S. and Kyle, S. (2022). Generative design for additive manufacturing using a biological development analogy. *Journal of Computational Design and Engineering*, 9(2), 463-479.
277. Drezner, T. and Drezner, Z. (2013). Voronoi diagrams with overlapping regions. *OR Spectrum*, 35(3), 543-561.
278. Danielsson, P.-E. (1980). Euclidean distance mapping. *Computer Graphics and image processing*, 14(3), 227-248.
279. Wang, Y. C., Xing, Y. and Zhang, J. (2023). Voronoi treemap in Manhattan distance and Chebyshev distance. *Information Visualization*, 14738716231167181.
280. Park, J. j. and Jun, H. (2009). A Study on the Process of the Architectural Design Generation based on the 3D Voronoi Diagram. *Korean Journal of Computational Design and Engineering*, 14, 306-313.
281. Friedrich, C. (2008). SmartVolumes - Adaptive Voronoi Power Diagramming for Real-Time Volumetric Design Exploration, in *Virtual Systems and Multimedia*, Wyeld, T. G., Kenderdine, S. and Docherty, M., Editors., Springer Berlin Heidelberg: Berlin, Heidelberg. 132-142.
282. Laaroussi, F.-E., Nouh, B. and Bakkali, M. (2020). *Parametric Building Design Options Within Voronoi Diagram Based Urban Fabric* Intelligent Environments 2020. IOS Press. 278-288.
283. Lei, H.-Y., Li, J.-R., Xu, Z.-J. and Wang, Q.-H. (2020). Parametric design of Voronoi-based lattice porous structures. *Materials & Design*, 191, 108607.
284. Li, H., Li, J., Guan, X., Liang, B., Lai, Y. and Luo, X. (2019). Research on Overfitting of Deep Learning, in *2019 15th International Conference on Computational Intelligence and Security (CIS)*. 78-81.


285. Bello, S. A., Yu, S., Wang, C., Adam, J. M. and Li, J. (2020). Review: Deep Learning on 3D Point Clouds. *Remote Sensing*, 12(11), 1729.
286. Liu, T., He, S., Kumaran Jayakumar, V. and Wang, W. (2022). A Cloud 3D Dataset and Application-Specific Learned Image Compression in Cloud 3D, in *Computer Vision – ECCV 2022*, Avidan, S., Brostow, G., Cissé, M., Farinella, G. M. and Hassner, T., Editors., Springer Nature Switzerland: Cham. 268-284.
287. Zeng, Q., Zhao, Z., Lei, H. and Wang, P. (2023). A deep learning approach for inverse design of gradient mechanical metamaterials. *International Journal of Mechanical Sciences*, 240, 107920.
288. Zhu, S., Hrnjica, B., Ptak, M., Choiński, A. and Sivakumar, B. (2020). Forecasting of water level in multiple temperate lakes using machine learning models. *Journal of Hydrology*, 585, 124819.
289. Sang, J., Pan, X., Lin, T., Liang, W. and Liu, G. R. (2021). A data-driven artificial neural network model for predicting wind load of buildings using GSM-CFD solver. *European Journal of Mechanics - B/Fluids*, 87, 24-36.
290. Rebala, G., Ravi, A. and Churiwala, S. (2019). *An Introduction to Machine Learning* (1 edition). Switzerland: Springer. 263.
291. Bendale, S. (2020). A Study of 3D-GANs and their Implementation Challenges. 194.
292. Qi, S., Ning, X., Yang, G., Zhang, L., Long, P., Cai, W. and Li, W. (2021). Review of multi-view 3D object recognition methods based on deep learning. *Displays*, 69, 102053.
293. Yang, Q., Xu, F. and Leng, J. (2022). Abnormal actions detection of robotic arm via 3D convolution neural network and support vector data description. *Journal of Intelligent & Fuzzy Systems*, 42, 5931-5937.
294. Verma, V., Chauhan, H., Gupta, D. and Gupta, S. (2020). Different Convolution Neural Network Based Models for Garbage Detection: A Review, in *2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering (WIECON-ECE)*. 117-121.
295. Fırat, H. and Hanbay, D. (2022). 3 Boyutlu Evrişimsel Sinir Ağı Kullanılarak Hiperspektral Görüntülerin Sınıflandırılması. *Türk Doğa ve Fen Dergisi*, 11(1), 19-28.
296. Liu, X., Wang, K., Liu, F., Zhao, W. and Liu, J. (2022). 3D Convolution neural network with multiscale spatial and temporal cues for motor imagery EEG classification. *Cognitive Neurodynamics*.

297. Zheng, S., Lan, F. and Castellani, M. (2023). A competitive learning scheme for deep neural network pattern classifier training. *Applied Soft Computing*, 146, 110662.
298. Kim, B., Ryu, K. H. and Heo, S. (2022). Mean squared error criterion for model-based design of experiments with subset selection. *Computers & Chemical Engineering*, 159, 107667.
299. Lei, X., Liu, C., Du, Z., Zhang, W. and Guo, X. (2018). Machine Learning-Driven Real-Time Topology Optimization Under Moving Morphable Component-Based Framework. *Journal of Applied Mechanics*, 86(1).
300. Han, J., Shi, F., Chen, L. and Childs, P. R. N. (2018). A computational tool for creative idea generation based on analogical reasoning and ontology. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 32(4), 462-477.
301. Regenwetter, L., Nobari, A. H. and Ahmed, F. (2022). Deep generative models in engineering design: A review. *Journal of Mechanical Design*, 144(7), 071704.
302. Burnap, A., Liu, Y., Pan, Y., Lee, H., Gonzalez, R. and Papalambros, P. Y. *Estimating and Exploring the Product Form Design Space Using Deep Generative Models*. in *Design Automation Conference*. 2016.
303. Yu, S., Dong, H., Wang, P., Wu, C. and Guo, Y., *Generative Creativity: Adversarial Learning for Bionic Design*. Cham: Springer. 525-536.
304. Nie, Z., Lin, T., Jiang, H. and Kara, L. B. (2020). TopologyGAN: Topology Optimization Using Generative Adversarial Networks Based on Physical Fields Over the Initial Domain. *ArXiv*, abs/2003.04685.
305. Chen, W. and Fuge, M. (2019). Synthesizing Designs With Interpart Dependencies Using Hierarchical Generative Adversarial Networks. *Journal of Mechanical Design*, 141(11).
306. Chen, W. and Ahmed, F. (2021). MO-PaDGAN: Reparameterizing Engineering Designs for augmented multi-objective optimization. *Applied Soft Computing*, 113, 107909.
307. Nobari, A. H., Chen, W. and Ahmed, F. (2021). PcDGAN: A Continuous Conditional Diverse Generative Adversarial Network For Inverse Design, in *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*. Association for Computing Machinery: Virtual Event, Singapore. 606–616.
308. Giannone, G., Regenwetter, L., Srivastava, A., Gutfreund, D. and Ahmed, F. (2023). Learning from Invalid Data: On Constraint Satisfaction in Generative Models. *ArXiv*, abs/2306.15166.

309. Behzadi, M. M. and Ilieş, H. T. (2021). Real-Time Topology Optimization in 3D via Deep Transfer Learning. *Computer-Aided Design*, 135, 103014.
310. Rawat, S. and Shen, M. H. (2019). Application of Adversarial Networks for 3D Structural Topology Optimization. SAE International.
311. Achlioptas, P., Diamanti, O., Mitliagkas, I. and Guibas, L. J. *Learning Representations and Generative Models for 3D Point Clouds*. in *International Conference on Machine Learning*. 2017.
312. Li, C.-L., Zaheer, M., Zhang, Y., Poczos, B. and Salakhutdinov, R. (2018). Point cloud gan. *arXiv preprint arXiv:1810.05795*.
313. Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X. and Xiao, J. *3d shapenets: A deep representation for volumetric shapes*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015.
314. Yi, G., Sui, Y. and Du, J. (2011). Application of python-based Abaqus preprocess and postprocess technique in analysis of gearbox vibration and noise reduction. *Frontiers of Mechanical Engineering*, 6(2), 229-234.
315. Standard, A. (2012). Standard terminology for additive manufacturing technologies, in *ASTM International F2792-12a*. 1-9.
316. Diegel, O., Nordin, A. and Motte, D. (2019). *A practical guide to design for additive manufacturing*. Springer.
317. Rahim, T. N., Abdullah, A. M. and Md Akil, H. (2019). Recent developments in fused deposition modeling-based 3D printing of polymers and their composites. *Polymer Reviews*, 59(4), 589-624.
318. Bikas, H., Stavropoulos, P. and Chryssolouris, G. (2016). Additive manufacturing methods and modelling approaches: a critical review. *The International Journal of Advanced Manufacturing Technology*, 83, 389-405.
319. Gibson, I. (2015). Additive manufacturing technologies 3D printing, rapid prototyping, and direct digital manufacturing. Springer.
320. Frazier, W. E. (2014). Metal additive manufacturing: a review. *Journal of Materials Engineering and performance*, 23, 1917-1928.




EK 1. İdeal 3DGAN mimarisini belirleme denemeleri




Deneme 1

Havuz boyutu : 32
 Gürültü vektörü : 200
 Gürültü dağılımı : Normal
 Üretici öğr. oranı : 0,00015
 Ayırıcı öğr. oranı : 0,00001
 Bias : yok
 Katman sayısı : 3




Deneme 2

Havuz boyutu : 32
 Gürültü vektörü : 200
 Gürültü dağılımı : Normal
 Üretici öğr. oranı : 0,00015
 Ayırıcı öğr. oranı : 0,00001
 Bias : Yok
 Katman sayısı : 4



Deneme 3


Havuz boyutu : 32
 Gürültü vektörü : 200
 Gürültü dağılımı : Düzenli
 Üretici öğr. oranı : 0,00015
 Ayırıcı öğr. oranı : 0,00001
 Bias : yok
 Katman sayısı : 5



Deneme 4


Havuz boyutu : 32
 Gürültü vektörü : 200
 Gürültü dağılımı : Düzenli
 Üretici öğr. oranı : 0,00015
 Ayırıcı öğr. oranı : 0,00001
 Bias : Yok
 Katman sayısı : 5

Şekil 1.1. İdeal GAN mimarisini belirlemede hiper-parametre ayarları ve kayıp değerleri




Deneme 5

Havuz boyutu : 48
 Gürültü vektörü : 200
 Gürültü dağılımı : Düzenli
 Üretici ögr. oranı : 0,00015
 Ayırcı ögr. oranı : 0,00001
 Bias : Yok
 Katman sayısı : 5




Deneme 6

Havuz boyutu : 64
 Gürültü vektörü : 200
 Gürültü dağılımı : Düzenli
 Üretici ögr. oranı : 0,00015
 Ayırcı ögr. oranı : 0,00001
 Bias : Yok
 Katman sayısı : 5



Deneme 7


Havuz boyutu : 64
 Gürültü vektörü : 100
 Gürültü dağılımı : Düzenli
 Üretici ögr. oranı : 0,00015
 Ayırcı ögr. oranı : 0,00001
 Bias : Yok
 Katman sayısı : 5



Deneme 8


Havuz boyutu : 64
 Gürültü vektörü : 200
 Gürültü dağılımı : Düzenli
 Üretici ögr. oranı : 0,00015
 Ayırcı ögr. oranı : 0,00001
 Bias : Var
 Katman sayısı : 5

Şekil 1.1. (devam) İdeal GAN mimarisini belirlemede hiper-parametre ayarları ve kayıp değerleri




Deneme 9

Havuz boyutu : 64
 Gürültü vektörü : 100
 Gürültü dağılımı : Normal
 Üretici öğr. oranı : 0,00015
 Ayırcı öğr. oranı : 0,00001
 Bias : Var
 Katman sayısı : 5




Deneme 10

Havuz boyutu : 64
 Gürültü vektörü : 50
 Gürültü dağılımı : Normal
 Üretici öğr. oranı : 0,00015
 Ayırcı öğr. oranı : 0,00001
 Bias : Var
 Katman sayısı : 5



Deneme 11


Havuz boyutu : 32
 Gürültü vektörü : 200
 Gürültü dağılımı : Normal
 Üretici öğr. oranı : 0,00015
 Ayırcı öğr. oranı : 0,00001
 Bias : Var
 Katman sayısı : 5



Deneme 12


Havuz boyutu : 32
 Gürültü vektörü : 200
 Gürültü dağılımı : Normal
 Üretici öğr. oranı : 0,0002
 Ayırcı öğr. oranı : 0,0002
 Bias : Var
 Katman sayısı : 5

Şekil 1.1. (devam) İdeal GAN mimarisini belirlemede hiper-parametre ayarları ve kayıp değerleri




Deneme 13

Havuz boyutu : 64
 Gürültü vektörü : 200
 Gürültü dağılımı : Normal
 Üretici ögr. oranı : 0,0003
 Ayıncı ögr. oranı : 0,0003
 Bias : Var
 Katman sayısı : 5




Deneme 14

Havuz boyutu : 64
 Gürültü vektörü : 200
 Gürültü dağılımı : Normal
 Üretici ögr. oranı : 0,00025
 Ayıncı ögr. oranı : 0,00015
 Bias : Var
 Katman sayısı : 5



Deneme 15

Havuz boyutu : 64
 Gürültü vektörü : 200
 Gürültü dağılımı : Normal
 Üretici ögr. oranı : 0,0001
 Ayıncı ögr. oranı : 0,00001
 Bias : Var
 Katman sayısı : 5




Deneme 16

Havuz boyutu : 64
 Gürültü vektörü : 200
 Gürültü dağılımı : Normal
 Üretici ögr. oranı : 0,0002
 Ayıncı ögr. oranı : 0,00001
 Bias : Var
 Katman sayısı : 5

Şekil 1.1. (devam) İdeal GAN mimarisini belirlemede hiper-parametre ayarları ve kayıp değerleri

EK-2. GAN model eğitimi için veri boyutlandırma



Şekil 2.1. 3DGAN eğitiminde kullanılan 3B model boyutu ve veri sayına göre üretilmiş veriler



Gazili olmak ayrıcalıktır