



İSLAMİ GEOMETRİK DESENLERDE DERİN ÖĞRENME
ALGORİTMALARI İLE GÖRÜNTÜ RESTORASYONU

Makbule ÖZDEMİR

DOKTORA TEZİ
MİMARLIK ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TEMMUZ 2025

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.

İmza

Makbule ÖZDEMİR

11/07/2025

İSLAMİ GEOMETRİK DESENLERDE DERİN ÖĞRENME ALGORİTMALARI İLE GÖRÜNTÜ RESTORASYONU

(Doktora Tezi)

Makbule ÖZDEMİR

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2025

ÖZET

Dijitalleşmenin etkisiyle, kültürel mirasın korunmasında modern teknolojilerin kullanımı giderek önem kazanmaktadır. İslami Geometrik Desenlerin (İGD) dijital analizi alanındaki mevcut çalışmalar, ağırlıklı olarak grup teorisine dayalı sınıflama yöntemlerine ve vektörel üretim yaklaşımlarına odaklanmaktadır. Bu yöntemler, çoğunlukla desenlerin geometrik yapısının anlaşılmasına ve tanımlanmasına yöneliktir. Bu tez, İslami geometrik desenlerin dijital görüntü restorasyonu bağlamında, derin öğrenme temelli bir metodoloji geliştirerek geleneksel mimari süsleme sanatlarının korunması ve yeniden üretimi konusunda katkı sunmayı amaçlamaktadır. Bu doğrultuda teorik düzeyde, geleneksel desen analiz yaklaşımlarından farklı olarak veri odaklı bir çerçeve oluşturulmuş; yöntemsel olarak ise hem sınıflandırma hem de görüntü tamamlama algoritmalarının aynı kültürel veri seti üzerinde bütüncül biçimde test edildiği disiplinlerarası bir yapı geliştirilmiştir. Tez kapsamında, verinin hazırlanması, doğruluğunun test edilmesi ve eksik desen parçalarının tamamlanması görevlerinde derin öğrenme temelli algoritmalar uygulanmış; üretilen sonuçların hem nicel hem de nitel analizi gerçekleştirilmiştir. Ayrıca, İGD'ye özgü simetrik yapı ve süreklilik gibi biçimsel özellikler değerlendirme kriterleri olarak ele alınmış, elde edilen çıktıların başarısı bu niteliksel ölçütler üzerinden analiz edilmiştir. Çalışmanın veri toplama aşamasında, çeşitli kaynaklardan temin edilen yüksek çözünürlüklü desen görselleri kullanılarak üç ayrı sınıf oluşturulmuştur. Bu ayrım, hem görsel bozulmanın hem de algoritmaların sınıflandırma ve tamamlama performanslarının analizinde belirleyici bir faktör olarak kullanılmıştır. Derin ağlar aracılığıyla gerçekleştirilen sınıflandırma sürecinde elde edilen doğruluk oranları, İGD'lerin kendi içinde ayrışabilir yapısal özelliklere sahip olduğunu doğrulamıştır. Bu bulguların ardından, eksik desenlerin tamamlanmasına yönelik üretici algoritmalar ve derin görüntü boyama yöntemleri uygulanmış, performansları karşılaştırmalı olarak değerlendirilmiştir. Sonuç olarak, önerilen metodolojik yapı, İGD'lerin yapısal özelliklerini gözeterek restorasyon kalitesini ölçebilen ve yeniden kullanılabilir bir çerçeve ortaya koymaktadır.

Bilim Kodu : 80126
Anahtar Kelimeler : İslami geometrik desenler, derin öğrenme, görüntü restorasyonu, kültürel mirasın dijitalleştirilmesi, çekişmeli üretici ağlar
Sayfa Adedi : 229
Danışman : Prof. Dr. Semra ARSLAN SELÇUK

IMAGE RESTORATION OF ISLAMIC GEOMETRIC PATTERNS WITH DEEP LEARNING ALGORITHMS

(Ph. D. Thesis)

Makbule ÖZDEMİR

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2025

ABSTRACT

With the impact of digitalization, the use of modern technologies in the preservation of cultural heritage is becoming increasingly significant. Existing studies on the digital analysis of Islamic Geometric Patterns (IGPs) mainly focus on classification methods based on group theory and vector-based generative approaches. These methods are predominantly oriented toward understanding and describing the geometric structure of the patterns. This dissertation aims to contribute to the preservation and reproduction of traditional architectural ornamentation by developing a deep learning-based methodology for the digital restoration of Islamic geometric patterns. In this context, a data-driven framework has been established at the theoretical level, differing from traditional pattern analysis approaches; methodologically, a multidisciplinary structure has been developed in which both classification and image inpainting algorithms are tested comprehensively on the same cultural dataset. Deep learning-based algorithms have been applied to tasks such as data preparation, accuracy verification, and the completion of missing pattern segments. The generated outputs have been analyzed using both quantitative and qualitative methods. Moreover, formal characteristics specific to IGPs, such as symmetrical structure and rhythmic continuity, have been employed as evaluation criteria, and the success of the outputs has been examined based on these qualitative measures. During the data collection stage, three distinct categories were formed using high-resolution pattern images obtained from various sources. This categorization has been used as a determining factor in analyzing both the degree of visual degradation and the performance of classification and inpainting algorithms. Classification using deep neural networks yielded accuracy rates that confirm the presence of distinguishable structural characteristics within IGPs. Based on these findings, generative algorithms and deep image inpainting methods were applied to the completion of missing pattern regions, and their performances were evaluated comparatively. In conclusion, the proposed methodological framework provides a reusable approach that assesses restoration quality while taking into account the structural properties of Islamic geometric patterns.

Science Code : 80126

Key Words : Islamic geometric patterns, deep learning, image restoration, cultural heritage digitization, adversarial generative networks

Page Number : 229

Supervisor : Prof. Dr. Semra ARSLAN SELÇUK

TEŞEKKÜR

İlk olarak, tezimin her aşamasında desteği, anlayışı ve engin bilgi birikimiyle bana yol gösteren; karşılaştığım her zorlukta bana güven vererek, çözüm odaklı yaklaşımıyla hem akademik hem de kişisel olarak gelişmeme büyük katkı sağlayan değerli danışmanım Semra ARSLAN SELÇUK'a en içten teşekkürlerimi sunarım.

Doktora çalışmam süresince katkılarını esirgemeyen, detaylı geri bildirimleriyle araştırmamın niteliğini artıran tez izleme komite üyelerim Ali AKÇAYOL ve Sema ALAÇAM'a detaylı geri bildirimleri için teşekkür ederim.

Bu süreçte çalışmalarımı destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na "TÜBİTAK 2211-C Yurtiçi Öncelikli Alanlar Bursu" desteği için teşekkür ederim.

Tez çalışma sürecimde deneyimlerini paylaşarak yardımlarını esirgemeyen Hasan Fevzi ÇÜĞEN'e ve bu süreçte beni teşvik eden arkadaşlarıma, verdikleri değerli destek ve tavsiyeler için teşekkür ederim.

Son olarak, her zaman çabalamam için beni motive eden aileme; gösterdikleri sabır, destek ve anlayış için sonsuz sevgilerimi sunar tüm içtenliğimle teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	xi
RESİMLERİN LİSTESİ.....	xviii
SİMGELER VE KISALTMALAR.....	xix
1. GİRİŞ	1
2. LİTERATÜR İNCELEMESİ VE KURAMSAL ÇERÇEVE	11
2.1. İslam Sanatı ve İslami Geometrik Desenler	11
2.1.1. İGD’de tarihsel kaynaklar ve geometrik yapım ilkeleri	15
2.1.2. İGD’ de simetri tabanlı yaklaşım	20
2.1.3. İGD’ de ızgara yapıları ve üretim yöntemleri	28
2.1.4. İGD’de modüler sistem tasarımı	36
2.2. Yapay Zeka ve Makine Öğrenmesi	45
2.3. Derin Öğrenme	51
2.3.1. Yapay sinir ağları.....	52
2.3.2. Evrişimli sinir ağları	54
2.3.3. Çekişmeli üretici ağlar	56
2.3.4. Yapay sinir ağı hiperparametreleri	58
2.3.5. İGD’ de YZ algoritmaları ile yapılmış çalışmalar	61
2.4. Görüntü Tamamlama	66
2.5. Uygulama Değerlendirme Yöntemleri.....	75

	Sayfa
2.5.1. Görüntü kalite metrikleri.....	75
2.5.2. Topolojik veri analizi.....	78
2.5.3. Fourier tabanlı simetri analizi ve Gaussian yoğunluk haritası	81
3. ARAŞTIRMA METODOLOJİSİ	83
3.1. Araştırma Yaklaşımı	83
3.2. Uygulama Süreci ve Değerlendirme	85
3.3. Veri Kaynakları ve Toplama Süreci	87
4. ALAN ÇALIŞMASI	95
4.1. İGD’ de Veriye Dayalı Yeniden Yapılandırma	95
4.2. İGD’ de Veriye Dayalı Sınıflandırma	100
4.3. İGD’ de Veriye Dayalı Tamamlama.....	111
4.3.1. Kenar bağlantı algoritması ile görüntü restorasyonu.....	113
4.3.2. Derin Füzyon ağı ile görüntü restorasyonu	121
4.3.3. Filtreleme tabanlı görüntü restorasyonu	129
4.4. Uygulama Sonuçlarının Ölçüm ve Analizi	137
4.4.1. Görüntü kalite metriklerinin karşılaştırılması	138
4.4.2. Topolojik yapısal analiz	147
4.4.3. Yoğunluk haritası analizi ve frekans alanlı simetri	154
4.5. Tartışma.....	158
5. SONUÇ VE ÖNERİLER	161
KAYNAKLAR	169
EKLER	187
EK-1. AlexNet ağ mimarisi	188
EK-2. VGG19 ağ mimarisi.....	189

	Sayfa
EK-3. EfficientNetB3 ağ mimarisi.....	190
EK-4. Resnet50 ağ mimarisi.....	199
EK-5. DCGAN ağ mimarisi	203
EK-6. Kenar bağlantı algoritması ağ mimarisi	204
EK-7. Derin Füzyon ağı ile görüntü restorasyonu DfNet ağ mimarisi	206
EK-8. Filtreleme tabanlı görüntü restorasyonu MISF ağ mimarisi	207
EK-9. Simetri tespiti, tepe noktalarının belirlenmesi.....	208
EK-10. %10 ve %10-%20 kayıp görüntüde tamamlanmış doğrudan görüntülerin karşılaştırması	212
EK-11. %20-%30 ve %30-%40 kayıp görüntüde tamamlanmış doğrudan görüntülerin karşılaştırması	213
EK-12. %40-%50 ve %50-%60 kayıp görüntüde tamamlanmış doğrudan görüntülerin karşılaştırması	214
EK-13. %10 ve %10-%20 kayıp görüntüde tamamlanmış açılı görüntülerin karşılaştırması	215
EK-14. %20-%30 ve %30-%40 kayıp görüntüde tamamlanmış açılı görüntülerin karşılaştırması	216
EK-15. %40-%50 ve %50-%60 kayıp görüntüde tamamlanmış açılı görüntülerin karşılaştırması	217
EK-16. %10 ve %10-%20 kayıp görüntüde tamamlanmış yapı bileşeni içeren görüntülerin karşılaştırması	218
EK-17. %20-%30 ve %30-%40 kayıp görüntüde tamamlanmış yapı bileşeni içeren görüntülerin karşılaştırması	219
EK-18. %40-%50 ve %50-%60 kayıp görüntüde tamamlanmış yapı bileşeni içeren görüntülerin karşılaştırması	220
EK-19. %10-20, %20-30 kayıp görüntüde tamamlanmış doğrudan görüntülerin analizi.....	221
EK-20. %30-40, %50-60 kayıp görüntüde tamamlanmış doğrudan görüntülerin analizi.....	222
EK-21. %10-20, %20-30 kayıp görüntüde tamamlanmış yapı bileşeni görüntülerin analizi.....	223

Sayfa

EK-22. %30-40, %50-60 kayıp görüntüde tamamlanmış yapı bileşeni görüntülerin analizi.....	224
EK-23. %10-20, %20-30 kayıp görüntüde tamamlanmış açılı görüntülerin analizi.....	225
EK-24. %30-40, %50-60 kayıp görüntüde tamamlanmış açılı görüntülerin analizi.....	226
EK-25. Uygulama nicel değerlendirmeleri.....	227
ÖZGEÇMİŞ.....	228



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. İzzettin Keykavus Türbesi'ne ait desenlerin İGD modüler sistem analizleri	43
Çizelge 2.2. Geometrik desenler konusunda yapılan sınıflandırma çalışmaları.....	66
Çizelge 2.3. İç boyama algoritmalarının karşılaştırılması.....	71
Çizelge 3.1. Anahtar kelime analizi	90
Çizelge 3.2. Veri filtreleme kriterleri	91
Çizelge 4.1. Farklı Epok değerlerinde Dijital ortamda üretilmiş görüntülerin eğitim sonuçları	97
Çizelge 4.2. Farklı epok değerlerinde fotoğraf görüntülerinin eğitim sonuçları	98
Çizelge 4.3. VGG19 modeli farklı epok sayıları için doğruluk ve kayıp değerleri.....	102
Çizelge 4.4. Farklı epok sayıları için modelin EfficientNet değerleri	106
Çizelge 4.5. Farklı epok sayıları için modelin AlexNet değerleri	106
Çizelge 4.6. Farklı epok sayıları için modelin ResNet değerleri.....	108
Çizelge 4.7. Modellerin değerlendirilmesi	110
Çizelge 4.8. Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı)	117
Çizelge 4.9. %10 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar	118
Çizelge 4.10. %10-%20 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar.....	119
Çizelge 4.11. %20-%30 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar.....	119
Çizelge 4.12. %30-%40 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar.....	120
Çizelge 4.13. %40-%50 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar.....	120
Çizelge 4.14. %50-%60 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar.....	121

Çizelge	Sayfa
Çizelge 4.15. Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı).....	125
Çizelge 4.16. %10 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar ..	126
Çizelge 4.17. %10-%20 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar.....	126
Çizelge 4.18. %20-%30 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar.....	127
Çizelge 4.19. %30-%40 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar.....	127
Çizelge 4.20. %40-%50 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar.....	128
Çizelge 4.21. %50-%60 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar.....	128
Çizelge 4.22. Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı).....	133
Çizelge 4.23. %10 maske boyutlarına göre karşılık gelen sonuçlar	134
Çizelge 4.24. %10-%20 maske boyutlarına göre karşılık gelen sonuçlar	134
Çizelge 4.25. %20-%30 maske boyutlarına göre karşılık gelen sonuçlar	135
Çizelge 4.26. %30-%40 maske boyutlarına göre karşılık gelen sonuçlar	135
Çizelge 4.27. %40-%50 maske boyutlarına göre karşılık gelen sonuçlar	136
Çizelge 4.28. %50-%60 maske boyutlarına göre karşılık gelen sonuçlar	136
Çizelge 4.29. İGD' de değerlendirme kriterleri.....	137
Çizelge 4.30. Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı).....	139
Çizelge 4.31. Görüntü kalitesi sonuçlarının değerlendirmesi.....	146
Çizelge 4.32. Doğrudan görüntülerin İGD kriterlerine göre değerlendirmesi	150
Çizelge 4.33. Açılı görüntülerin İGD kriterlerine göre değerlendirmesi	152
Çizelge 4.34. Yapı bileşeni içeren görüntülerin İGD kriterlerine göre değerlendirmesi.....	154
Çizelge 4.35. Tamamlanan görüntülerin İGD kriterlerine göre değerlendirmesi.....	158

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Tez akış şeması.....	10
Şekil 2.1. Altıgen bir yapı kullanılarak tekrarlanan bir birimden İGD'in oluşturulması	14
Şekil 2.2. Üç birim kareden bir karenin oluşturulması (a), İsfahan'daki Cuma Camii'nden paneller (b).....	16
Şekil 2.3. Yıldız ve çokgen motiflerinin tekrarlanan birimleri.	17
Şekil 2.4. Kök iki oran sistemi (a), kök üç oran sistemi (b)	18
Şekil 2.5. Altın oran sistemi (Critchlow, 1976).....	19
Şekil 2.6. Dönme (a) öteleme (b), yansıma (c), ve kayma yansıma (d) simetrileri	20
Şekil 2.7. Desenin alternatif öteleme yönleri.....	21
Şekil 2.8. İzzettin Keykavus Türbesi'ne ait öteleme simetrisi ile çoğaltılmış desen.....	21
Şekil 2.9. Desenin dönme merkezleri.....	22
Şekil 2.10. İzzettin Keykavus Türbesi kemer yüzeyi 60° dönme simetrisi.....	23
Şekil 2.11. İzzettin Keykavus Türbesi kemer yüzeyi yansıma simetrisi	23
Şekil 2.12. Kayma yansıma simetrisi ile desen çoğaltımı	24
Şekil 2.13. Kemer yüzeyleri kayma yansıma simetrisi	25
Şekil 2.14. Broug'a göre İslami geometrik desenlerin soy ağacı; dört, beş ve altı katlı simetri gruplarına göre sınıflandırma.....	26
Şekil 2.15. On köşeli (üstte) ve altı köşeli (altta) motifin uygulama adımları	26
Şekil 2.16. 17 duvar kağıdı grubu için birim kafesler.....	27
Şekil 2.17. On yedi simetri grubu akış diyagramı	28
Şekil 2.18. Bir yüzeyin yinelemeli alt bölümünün dairesel ızgara ile oluşturulması (Sol) Dairesel ızgara ile üretilen yüzey (Orta) Altıgen ve üçgenlere dönüşüm (Sağ) Üçgenlerden yıldız motiflere dönüşüm.....	29
Şekil 2.19. Dairesel ızgara ile motif oluşumu, (A) Altıgene dayalı yıldız deseni oluşumu (B) Kareye dayalı dört köşeli yıldız oluşumu (C) On iki köşeli yıldız oluşumu için adımlar	30
Şekil 2.20. Nokta birleştirme tekniği ile üretilmiş model	31

Şekil	Sayfa
Şekil 2.21. Geometrik desenin izometrik ızgara üzerinde gösterimi	32
Şekil 2.22. İzometrik ızgara tasarımları	33
Şekil 2.23. 4 katlı modeli oluşturmak kullanılan ortogonal ızgara yöntemi	34
Şekil 2.24. İzzettin Keykavus Türbesi ortogonal ızgara örneği)	34
Şekil 2.25. Eşkenar dörtgen bir ızgara modelleri ve ilişkileri	35
Şekil 2.26. Bir yıldız deseni için eşkenar dörtgen ızgara modeli	35
Şekil 2.27. Temel altıgen hücrelerin farklı yönelimlerdeki çizgi uygulamalarıyla şekillenen geometrik kompozisyonlar	36
Şekil 2.28. Modüler sistem tasarımı için model çerçevesi	37
Şekil 2.29. Modüler sistem oluşumunda tüm olası çapraz referanslar	37
Şekil 2.30. Kareler, altıgenler ve onikigenlerden oluşan bir döşeme üzerinde çizgi açıları değiştiğinde çıkan çeşitli desen tasarımları	38
Şekil 2.31. Aynı temel mozaikleme sistemi ve farklı üretici çizgi kurgularıyla elde edilen dört desen.....	38
Şekil 2.32. İGD P6 desenleri temel birim hücrelerden (temel etki alanı) yineleme modülünün üretim aşamaları.....	39
Şekil 2.33. İzzettin Keykavus Türbesi süsleme detayının temel birimi	40
Şekil 2.34. Dar eşkenar dörtgen temel etki alanı ve tekrarlayan birim ilişkileri	40
Şekil 2.35. Geniş eşkenar dörtgen temel etki alanı ve tekrarlayan birim ilişkileri	41
Şekil 2.36. Ortogonal temel etki alanı ve tekrarlayan birim ilişkileri	41
Şekil 2.37. Süsleme detayının analizi.....	42
Şekil 2.38. Yapay zeka disiplinleri arasındaki ilişki diyagramı	47
Şekil 2.39. ML algoritmasının çalışma prensibi	48
Şekil 2.40. Makine öğrenimi algoritmalarının kategorileri	49
Şekil 2.41. Yapay sinir ağlarında bir nöronun şematik görüntüsü.....	52
Şekil 2.42. İki gizli katmana ve tek bir çıkış katmanına sahip bir ANN algoritmasının genel yapısı	53
Şekil 2.43. Genel bir CNN mimarisi	55

Şekil	Sayfa
Şekil 2.44. U-Net mimarisi.....	56
Şekil 2.45. Standart GAN model mimarisi.....	57
Şekil 2.46. Solda, sınıflandırma şeması, Sağda, etiketli görüntü ve çıkarma bölgesi Sağ alt, çıkarılan bölgede yapılan dönüşüm işlemleri	62
Şekil 2.47. Üstte, deseninin en küçük temsili bölgesi bulunma adımları, altta (a) tamamlanacak orijinal rozet görüntüsü ve (b) rozetin tespit edilen merkezi ve tamamlanma sonucu.....	63
Şekil 2.48. Boyama görevi	67
Şekil 2.49. Kalıcı homoloji süreçleri.....	79
Şekil 2.50. LBP sıralama ilişkisi.....	80
Şekil 2.51. LBP kodlarının geometrik gösterimi	80
Şekil 3.1. Çalışma metodolojisinin aşamaları.....	84
Şekil 3.2. Verilerin elde edildiği coğrafi konumlar	88
Şekil 3.3. Verilerin elde edilme süreci	88
Şekil 3.4. Fiziksel kaynaklardan elde edilen verilerden örnekler	89
Şekil 3.5. Bir anahtar kelimeyi bağlam içinde keşfetmek için kullanılan kelime ağaçları.....	91
Şekil 3.6. Geometrik desen kategorisi ile ilgisiz görüntüler.....	92
Şekil 4.1. Dijital ortamda üretilmiş görüntüler (solda), fotoğraf görüntüleri (sağda)....	96
Şekil 4.2. Dijital ortamda üretilmiş görüntülerin 1500 epok eğitim sonucu üretici ve ayırıcı kayıp değerleri	98
Şekil 4.3. Fotoğraf görüntülerinin 1500 epok eğitim sonucu üretici ve ayırıcı kayıp değerleri	99
Şekil 4.4. 3 sınıfa ayrılmış veri seti.....	100
Şekil 4.5. Çalışma şeması.....	102
Şekil 4.6. VGG19 her bir epoktaki doğruluk ve kayıp değerlerinin grafikleri.....	103
Şekil 4.7. EfficientNet her bir epoktaki doğrulama doğruluğu ve kayıp değerlerinin grafikleri.....	104
Şekil 4.8. AlexNet mimarisi 100 epok doğrulama doğruluğu ve kayıp değerlerinin grafikleri.....	107

Şekil	Sayfa
Şekil 4.9. ResNet mimarisi 100 epok doğrulama doğruluğu ve kayıp değerlerinin grafikleri.....	109
Şekil 4.10. Veri setine ait görsellerden örnekler.....	112
Şekil 4.11. Maske verilerine ait görseller.....	112
Şekil 4.12. Ağ akış şeması.....	114
Şekil 4.13. Eşik değerlerinin kenar tespitine etkisi.....	115
Şekil 4.14. (a) Orijinal görüntü, (b) %20-%30 maskelenmiş görüntü ve tamamlanan görüntü, (c) %30-%40 maskelenmiş görüntü ve tamamlanan görüntü, (d) %40-%50 maskelenmiş görüntü ve tamamlanan görüntü, (e) %50-%60 maskelenmiş görüntü ve tamamlanan görüntü.....	115
Şekil 4.15. Algoritma akış şeması.....	123
Şekil 4.16. Algoritma akış şeması.....	130
Şekil 4.17. (a) Orijinal görüntü, (b) %20-%30 maskelenmiş görüntü ve tamamlanan görüntü, (c) %30-%40 maskelenmiş görüntü ve tamamlanan görüntü, (d) %40-%50 maskelenmiş görüntü ve tamamlanan görüntü, (e) %50-%60 maskelenmiş görüntü ve tamamlanan görüntü.....	131
Şekil 4.18. Değerlendirme bağlantı şeması	138
Şekil 4.19. %0-10 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması.....	141
Şekil 4.20. %10-20 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması.....	142
Şekil 4.21. %20-30 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması.....	143
Şekil 4.22. %30-40 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması.....	144
Şekil 4.23. %40-50 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması.....	145
Şekil 4.24. %50-60 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması.....	146
Şekil 4.25. Orijinal görüntü ve DFNet modeli ile tamamlanmış görüntü	147
Şekil 4.26. Orijinal görüntünün G6 geometrisinin R1 dönüşünün diyagramları.....	147
Şekil 4.27. Tamamlanmış görüntünün G6 geometrisinin R1 dönüşünün diyagramları.	148

Şekil	Sayfa
Şekil 4.28. Toplojik yapısal analiz için seçilen desenler.....	148
Şekil 4.29. Farklı maske oranına göre doğrudan görüntülerin kullanılan algoritmalarda orijinal ve tamamlanmış görüntü topolojik analiz sonuçları	149
Şekil 4.30. Farklı maske oranına göre açılı görüntülerin kullanılan algoritmalarda orijinal ve tamamlanmış görüntü topolojik analiz sonuçları	151
Şekil 4.31. Farklı maske oranına göre yapı bileşeni içeren görüntülerin kullanılan algoritmalarda orijinal ve tamamlanmış görüntü topolojik analiz sonuçları	153
Şekil 4.32. Desenin gri tonlamalı görüntüsü (a), Gaussian yoğunluk haritası (b) ve tepe noktaları tespiti (c).....	155
Şekil 4.33. Fouier dönüşümü ile simetri tespiti aşamaları	156
Şekil 4.34. Geometrik bir desenin orijinal hali ile %30-40 boşluğunda tamamlanmış görüntünün bir karşılaştırılması.....	157

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 2.1. Şeyh Lütfullah Mescidi'nde Arapça hat sanatının Kufi üslubu kullanılarak resmedilmesi	12
Resim 2.2. Solda: Özbekistan, Şāh-ı Zindah, Şād-ı Mülk Aqa Türbesi'nden seramik pano, (14. YY), Sağda: Bursa, Yeşil Cami'den duvar çinisi (1420)	13
Resim 2.3. IGP tasarımlar. Solda: Karatay Medresesi'nden geometrik desen tasarımı Sağda: Konya'dan tasarım	13



SİMGELER VE KISALTMALAR

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

Kısaltmalar	Açıklamalar
ANN	Yapay Sinir Ağları (<i>Artificial Neural Networks</i>)
CNN	Evrişimli Sinir Ağı (<i>Convolutional Neural Network</i>)
DL	Derin Öğrenme (<i>Deep Learning</i>)
DFNet	Derin Füzyon Ağı (<i>Deep Fusion Network</i>)
GAN	Çekişmeli Üretici Ağ (<i>Generative Adversarial Network</i>)
İGD	İslami Geometrik Desenler
LBP	Yerel İkili Örüntüler (<i>Local Binary Pattern</i>)
LPIPS	Öğrenilmiş algısal görüntü yama benzerliği (<i>Learned Perceptual Image Patch Similarity</i>)
KNN	K-En Yakın Komşu (<i>K-Nearest Neighbors</i>)
MISF	Çok Düzeyli İnteraktif Siyam Filtreleme (<i>Multi-level Interactive Siamese Filtering</i>)
ML	Makine Öğrenmesi (<i>Machine Learning</i>)
MSE	Ortalama Kare Hatası (<i>Mean Square Error</i>)
PSNR	Tepe Sinyal-Gürültü Oranı (<i>Peak Signal to Noise Ratio</i>)
SSIM	Yapılandırılmış benzerlik endeksi ölçüsü (<i>Structural Similarity Index Measure</i>)
SVM	Destek Vektör Makineleri (<i>Support Vector Machine</i>)
TVA	Topolojik Veri Analizi
YZ	Yapay Zeka

1. GİRİŞ

İslam sanatı yüzyıllar boyunca benzersiz estetik yapısıyla tanınmış ve İslam kültürünü yansıtan geometrik desenler, mimaride önemli bir rol oynamıştır. Bu desenler, geometrik şekillerin bir düzen içinde bir araya gelmesiyle oluşmakta ve kültürel bir dil olarak kendine has bir yapı sergilemektedir. Kültürel mirasın sürekliliği için; İslam sanatının estetik, kültürel ve tarihsel zenginliğini anlamak, İslami geometrik desenlerin yapısal özelliklerini detaylı bir şekilde kavramak ve bu özellikleri modern tekniklerle analiz etmek yüzyıllar boyunca süregelen bu yapıların bozulmadan, korunarak yaşatılmasına katkı sağlamaktadır. Bu sebeple geçmişten günümüze birçok araştırmacı, bu desenlerin altında yatan ilkeleri ve kuralları keşfetmeye çalışmıştır.

İslami desenlerin matematiksel ve simetrik analizine yönelik ilk önemli girişimler 19. yüzyıla kadar uzanmaktadır. Jones'un ilk olarak 1856'da yayımlanan çalışması doğrudan yalnızca İslam sanatına odaklanmasa da İslami mimari ve dekoratif motifleri kapsamlı biçimde belgelemiştir. Jones, desenlerdeki simetri ve karmaşıklığı vurgulayarak bu tasarımlarda gömülü olan matematiksel bilgiyi ortaya koymuş ve farklı kültürlerin tasarım ilkelerini ayrıntılı biçimde analiz ederek önemli bir kaynak oluşturmuştur. Ardından, İslami geometrik desen yapılarının simetriye dayalı sistematik organizasyonunu inceleyen ilk akademisyenlerden biri olan Müller (1944), desenleri grup teorisi merceğinden analiz ederek kuramsal bir matematiksel çerçeve ortaya koymuştur. Müller'in çalışması, İslami geometrik kalıpların anlaşılması ve sınıflandırılmasında, ayrıca simetrik örüntülerin tanımlanması ve çoğaltılmasında teorik bir temel görevi görmüştür. Bu temel sayesinde daha sonraki hesaplamalı analiz ve sınıflandırma çalışmalarına zemin hazırlanmıştır (Chorbachi, 1989). Benzer bir yaklaşımla Abas ve Salman (1994) da grup teorisine dayalı bir sistem kullanarak İslami desenleri simetri gruplarına göre sınıflandırmıştır. Bu çalışma, İslam sanatı eserlerinde mevcut matematiksel temelleri ve çeşitli simetri türlerini ortaya çıkararak desenleri farklı kategoriler altında düzenlenmesi için sağlam bir çerçeve sunmuştur. Simetrik özelliklere dayalı bu sınıflandırma, desenlerin daha iyi anlaşılmasını, karşılaştırılmasını ve algoritmik olarak üretilmesini kolaylaştırdığı için, Abas ve Salman'ın bulguları hesaplamalı modeller ve desen veri tabanları için de bir altyapı sağlamıştır.

Literatürde bazı çalışmalar, İslami geometrik desenleri yalnızca matematiksel kurallar ile değil, estetik ve sembolik ilkeler açısından da ele almıştır. Örneğin Keith Critchlow (1976), geometri ile kozmoloji arasında bir köprü kurarak zanaatkârların geometriyi pratik bir araç olmanın ötesinde manevi ve metafizik ilkelerin ifadesi olarak yorumlamış olabileceğini öne sürmüştür. Critchlow'un analitik ve yorumlayıcı yaklaşımı, hesaplamalı modelleme ile ilgilenen araştırmacılara sadece matematiksel ilişkileri değil, aynı zamanda desenlerin kültürel ve sembolik boyutlarını da dikkate alma gerekliliğini göstermiştir (Critchlow, 1976). Diğer taraftan, El-Said ve El-Bouri (1993) İslami tasarımda matematiksel oranların tekrar eden özelliklerini inceleyerek İslami görsel kültürün temelinde yatan orantısal ve estetik çerçeveyi vurgulamışlardır. Çeşitli İslami sanat formlarında tutarlı biçimde ortaya çıkan oranların izini süren bu çalışma, İslami geometrik desenlerin katı orantısal sistemleri takip ettiğini göstermiştir. El-Said ve El-Bouri, desenlerin farklı boyutlar arasında ölçeklendirilmesi için gereken temel oran yönergelerini ortaya koyarak, bu alandaki tasarımların doğru ve tutarlı bir şekilde yeniden üretilebilmesi için önemli bilgiler sunmuştur (El-Said, El-Bouri ve Critchlow, 1993).

İslami geometrik desenlerin yeniden üretimi konusunda da literatürde hem geleneksel hem modern yaklaşımlar bulunmaktadır. Wasma Al-Chorbachi (1989) İslam geometrisinin üretken yönlerini incelemiş ve desen oluşturmak için kullanılan formüllerdeki parametre değişimlerinin nasıl farklı desen sonuçları verebileceğini ortaya koymuştur. Al-Chorbachi'nin yaklaşımı, geleneksel formlara sadık kalarak yeni varyasyonların üretilebileceğini göstermiş ve algoritmik tasarımın modern uygulamaları için özel bir önem taşımıştır. Diğer taraftan, Broug (2008), İslam geometrisinin kuralları üzerine yaptığı kapsamlı çalışmalarla, desenlerin üretimi için pratik uygulamalar sağlamaktadır. Çalışmalarında geometrik desenlerin nasıl oluşturulduğunu adım adım açıklamakta ve İslami desenlerin üretiminde kullanılan temel geometrik yapıların detaylı bir analizini sunmaktadır. Otomatik tasarım veya dijital yeniden yapılanma için desen çözümlemesi daha anlaşılır hale gelmekte ve geleneksel yapı kurallarına bağlı kalarak algoritmalar geliştirmek için kaynak sağlamaktadır. Bonner (2017) ise İslami desenlerin tarihsel evrimini ve bu desenlerde kullanılan mozaikleme tekniklerini derinlemesine incelemiştir. Bonner, tekrar eden birimlerin oluşturulmasında kullanılan yöntemlerin zaman içinde nasıl geliştiğine ışık tutarken, oransal ilişkilere odaklanarak doğru desen inşası için gerekli hassas geometrik prensipleri detaylandırmıştır. Bu sayede, iki ve üç boyutlu alanlarda karmaşık desenlerin

otomatik olarak oluşturulabilmesine yönelik tasarım araçları için teknik bir temel sağlamıştır (Bonner, 2017).

Yapılan çalışmalarda, İslami geometrik desenlerin anlaşılması, sınıflandırılması ve üretilmesi konusunda kapsamlı bir birikim oluşturulmuştur. Bu çalışmalar, desenlerin matematiksel yapısını ve estetik prensiplerini ortaya koyarak, karmaşık desenlerin anlaşılabilir ve tekrar üretilabilir hale gelmesini sağlamıştır. Ancak, bu yaklaşımların ortak noktası, desenlerin incelenmesi ve oluşturulmasında kural tabanlı ve insan uzmanlığına dayalı yöntemler olmasıdır. Bir başka deyişle, desenlerin üretimi genellikle önceden tanımlanmış geometrik kural setlerinin takip edilmesiyle veya zanaatkarların ustalık ve bilgisine dayanarak gerçekleştirilmiştir.

Son yıllarda ise, hesaplamalı tasarım ve yapay zeka alanlarındaki gelişmeler, uygulamalardaki yönelimde değişime yol açmıştır. Otomatik tasarım sistemleri, konuya bağlı araçlar geliştirerek çoğu karmaşık ortamda bile verimlilik ve değişiklik yapma özgürlüğünü sağlama potansiyelleri sunmuştur. Bu bağlamda, makine öğrenmesinin (*Machine Learning - ML*) son gelişimleri dikkate alınarak, büyük veri işleme potansiyeline sahip derin öğrenme (*Deep Learning - DL*) algoritmalarının, desenlerin keşfi ve üretimi için çözümler üretme potansiyeline sahip olduğu düşünülmektedir.

Problemin tanımı

İslami geometri alanındaki araştırmaların temelini oluşturan çalışmalar desenlerin yeniden inşasını veya geliştirilmesini amaçlayanlar için bir zemin sağlamaktadır. Ancak bu çalışmalar teorik bir temel ve kural setleri sunmuş olsa da bu süreç büyük ölçüde manuel müdahaleye ve insan uzmanlığına ihtiyaç duymaktadır. Mevcut bilgisayar destekli yaklaşımlar ise genellikle önceden belirlenmiş matematiksel modellere ve algoritmik kurallara dayanmaktadır. Bu algoritmalar deneyim ve verilerden ziyade, çoğunlukla programlandıkları sınırların içinde kalarak tanımlı görevlerde sonuçlar vermektedir. Bu bağlamda, bilgisayar uygulamaları aracılığıyla yeni yöntemler geliştirilse de araştırmalarda güncel tekniklerin kısıtlı bir şekilde kullanıldığı görülmektedir. Bu güncellemeleri ele almak için derin öğrenme sistemleri, İslami geometrik desenlerin keşfedilmesi ve üretilmesi için otomatik bir sistem oluşturması açısından etkin bir yol olarak ortaya çıkmıştır. Böylelikle çalışmada, kural tabanlı klasik yöntemlerden ziyade, veri odaklı modeller kullanılmakta ve

örüntüleri tanımlamak, yapıları analiz etmek ve eğitim verilerine dayalı üretimler oluşturmak için bütüncül bir araştırma önerisi sunulmaktadır.

Araştırmanın amacı ve kapsamı

İslami geometrik desenlerde gözlenen tahribatların giderilmesi ve bu desenlerin dijital ortamda yeniden canlandırılması, estetik bir kazanım olmanın ötesinde, kültürel mirasın korunması açısından da öneme sahiptir. Bu gerçekten hareketle, yapay zeka tekniklerinin sunduğu imkanlar da düşünüldüğünde; eksik desenlerin otomatik olarak yeniden oluşturulması ve bütünlüğün sağlamasına yönelik yaklaşımların kullanımı hedeflenmektedir. Bu yaklaşımlar, veri odaklı yöntemler bütünü olarak etkinliği değerlendirilebilir uygulanmalardan oluşmaktadır.

Araştırmanın kapsamı, belirtilen amaçlar doğrultusunda geniş bir alanı kaplamakta ve hem tarihsel hem de veriye dayalı yaklaşımları birleştirerek, İslami geometrik desenlerin üretimini ve analizini ele almaktadır. Çalışma, yalnızca desenlerin tamamlanmasını değil, aynı zamanda uygulama tabanlı bir çalışma olarak desenlerin yeniden oluşturulması ve sınıflandırma aşamaları ile süreçleri aynı iş akışı içinde bütünleştirerek yeni yöntemlerin uygulamasını kapsamaktadır.

Bu doğrultuda ilk olarak, İslami geometrik desenlerin tarihsel gelişimi ve altında yatan matematiksel ilkeler incelenmektedir. Bu kapsamda, geleneksel desen çizim teknikleri, simetri kuralları ve üretim prensipleri literatür taraması ile ortaya konmaktadır. Daha sonra, veriye dayalı yöntemlerin desenlerin yapısal özelliklerini anlamada ve üretmede ne derece etkili olduğunu anlamak için araştırmalar sunulmaktadır.

Uygulama sürecinde, desen örneklerinin üretilmesi ve sınıflandırılmasının desenlerin karakteristik özelliklerini ne derece ortaya çıkaracağı ve bu özelliklerin sınıflandırma ve üretim süreçlerinde nasıl kullanılabileceğini anlamayı hedeflemektedir. Bu kapsamda sinir ağları ve derin öğrenme teknikleri kullanılarak, desenlerin veri tabanlarından öğrenilen temsilleri oluşturulmaktadır.

Araştırmanın diğer aşamasında, eksik kısımların tamamlanması için derin öğrenme tabanlı yaklaşımlar kullanılmaktadır. Bu bölümde, üretici algoritmalar ve görüntü boyama

teknikleriyle, desenlerin kaybolan parçalarının orijinal yapıya sadık kalarak yeniden oluşturulması hedeflenmektedir. Bu süreç, yalnızca görsel bir bütünlük sağlamakla kalmayıp, aynı zamanda desenin kültürel ve estetik değerini koruma amacını da taşımaktadır.

Çalışmanın son aşamasında, tamamlanan desenlerin orijinal desenlerle olan benzerlikleri ve kurallara uygunluğu topolojik analiz, haritalama ve görüntü kalite metrikleri kullanılarak söz konusu desenlerin üretimine katkının incelenmesi amaçlanmaktadır. Çıktılar; simetri, kenar sürekliliği ve motif bütünlüğü gibi yapısal ölçütlerle birlikte topolojik analiz ve görüntü kalite metrikleri ile nicel olarak değerlendirilerek ve karşılaştırmalı analiz yoluyla veri odaklı yöntemlerin hangi bağlamlarda üstünlük veya sınırlılık gösterdiğini ortaya koymaktadır. Burada amaç, görsel bütünlüğün ötesine geçerek, desenlerin ilkeleriyle uyumlu yapısal özelliklerin korunmasını da içerecek şekilde tanımlanmasıdır.

Böylece, İslam coğrafyasındaki tarihi eserlerde yer alan geometrik desenlerin eksik kısımlarının, özgünlüğünün ve uyumunun ne ölçüde sağlandığını tartışılmaktadır. Bunların yanı sıra, araştırma mevcut geleneksel yöntemler de kullanılan özellikleri de ortaya koyarak güncel yaklaşımlarla bir kıyaslama yapmayı hedeflemektedir. Bu çalışma, her iki yaklaşımın da güçlü ve zayıf yönlerini değerlendirerek, literatürdeki boşluğu dolduracak bir köprü kurmayı amaçlamaktadır.

Belirtilen amaç ve kapsam çerçevesinde; bu çalışma, İslam sanatının zengin mirasını korumaya ve onu modern teknolojilerle desteklemeye yönelik yenilikçi modellerin kullanımını ortaya koymaktadır. Derin öğrenme algoritmalarının kullanımıyla, İslami geometrik desenlerin yeniden oluşturulması, otomatik olarak sınıflandırılması, tamamlanması ve değerlendirilmesi süreçlerinde katkı sağlanması hedeflenmektedir. Kurgulanan yöntemin, yalnızca kültürel mirasın korunmasına hizmet etmekle kalmaması; aynı zamanda mimarlık, restorasyon ve sanat tasarımı gibi alanlarda da yeni uygulamalara imkân tanınması amaçlanmaktadır.

Araştırma sorusu ve hipotez

Yukarıda tanımlanan problem ve hedefler doğrultusunda çalışma, “Kısmen bozulmuş İslami geometrik desenlerde eksik bölümlerin, derin öğrenme yaklaşımlarıyla otomatik olarak

tamamlanması mümkün müdür?” sorusuna cevap aramaktadır. Bu doğrultuda, kısmen bozulmuş desenlerin veri odaklı derin öğrenme yöntemleriyle, desen özellikleri gözetilerek otomatik biçimde tamamlanmasının mümkün olabileceği hipotezi ileri sürülmektedir.

Alt araştırma soruları şu şekilde yapılandırılmaktadır:

- İslami geometrik desenlerin oluşturulmasına yönelik temel özellikler ve mevcut yaklaşımlar nelerdir?
- Günümüzde etkin bir rol oynayan yapay zeka uygulamalarının desen oluşumunda kullanılabilirliği ne ölçüdedir?
- İGD üretimi için veriye dayalı yöntemlerin kullanılması ile aşamalı bir sistem kurgulanması mümkün müdür?
- İGD veriye dayalı yeniden yapılandırma yöntemleri ile üretilebilir ve ölçülebilir mi?
- İGD veriye dayalı tamamlama yöntemleri ile üretilebilir ve ölçülebilir mi?

Araştırma metodolojisi

Çalışma amacı doğrultusunda sürdürülen metodoloji, dört ana aşamada ilerlemektedir. İlk aşamada, desenlerin doğrudan yapay olarak üretilmesi hedeflenmiştir. Bu amaçla Çekişmeli Üretici Ağ (GAN) gibi üretici derin öğrenme algoritmaları kullanılarak, eğitim verilerinden yeni desenler oluşturma mümkün olup olmadığı değerlendirilmiştir. GAN tabanlı modeller, veri kümesindeki örneklerden öğrendikleri dağılıma benzer özgün desenler üretmeyi amaçlamaktadır. Bu modeller bazı temel desen özelliklerini yakalayabilse de, karmaşık detayları ve eksik bölgeleri doldurma konusunda istenilen düzeyde doğruluk ve tutarlılığı sağlamadığı görülmüştür. Bu nedenle araştırmanın odak noktası, diğer aşamada farklı bir yaklaşıma dönüştürülmüştür.

İkinci aşamada, veriler fotoğraf görüntüleri ile sınırlandırılmış ve test gruplarına ayrılmıştır. Bu test sınıflarının görüntü algılama ve tanıma aşamasındaki başarısının ölçülmesi için ilk olarak derin öğrenme algoritmaları ile sınıflandırılmakta ve doğrulukları ölçülmektedir. Bu aşama, test için ayrılan desenlerin yapısal bütünlüğünü anlamak ve eksik kısımların nasıl tamamlanması gerektiğine dair ipuçları elde etmek için önem taşımaktadır. Çalışmanın üçüncü aşamasında, kısmen eksik desenlerin orijinal bütünlüğüne kavuşturulması için

görüntü boyama algoritmaları kullanılmıştır. Bu adımda, üç farklı tamamlama yöntemi seçilmiş ve her biriyle eksik desen parçalarını tamamlama denemeleri yapılmıştır. Amaç, desenin geri kalan kısmıyla uyumlu ve gerçeğe uygun bir şekilde boşlukları doldurabilen bir model ortaya koymaktır.

Çalışmanın son aşamasında, uygulanan algoritmalar karşılaştırmalı olarak değerlendirilmiş; hangisinin desenin özgün simetrik yapısını ve estetik detaylarını en iyi koruduğu analiz edilmiştir. Bu karşılaştırmada, topolojik analiz yöntemleri, görüntü kalite metrikleri, frekans analizi ve haritalama değerlendirme yöntemleri kullanılarak her bir yöntemin çıktıları, orijinal desenlerle kıyaslanmıştır. Elde edilen sonuçlar, tamamlanan desenlerin orijinal desenlere benzerlik oranları üzerinden nicel olarak değerlendirilmiş ve anlaşılır olması için tablolar ve diyagramlar ile görselleştirilmiştir. Böylece, her bir yöntemin desen tamamlama performansı (görsel benzerlik ve yapısal uyum açısından) somut verilerle ortaya konmuştur.

Bu araştırma genel olarak veri odaklı bir yaklaşımı benimsemektedir; zira derin öğrenme ve görüntü tamamlama yöntemlerinin etkin çalışabilmesi için çeşitli desen verilerine ihtiyaç duyulmaktadır. Tez kapsamında hem teorik çerçeveyi hem de uygulamalı deneyleri içeren bütüncül bir yöntem izlenmiştir. Bu yönüyle çalışma, kısmen uygulamaya dayalı bir araştırma metodolojisi barındırmaktadır. Elde edilen bilgilerin önemli bir kısmı, geliştirilen modelin uygulanması ve sonuçlarının değerlendirilmesi yoluyla kazanılmıştır.

Sonuç olarak geliştirilen metodoloji, İslami geometrik desenlerin otomatik olarak yeniden üretilmesi ve eksik parçalarının tamamlanması için ardışık bir model önermektedir. Bu modelde, önce desen üretimine dair bir deneme çalışması gerçekleştirilmiş, sonrasında verinin türüne karar verilmiştir. Daha sonra verinin doğruluğu test edilmiş ve tamamlama algoritmaları kullanılmıştır. Son olarak da desenlerin üretiminde izlenen özellik kategorilerine göre değerlendirilmiştir.

Tezin önemi

Geliştirilen metodoloji, İslami geometrik desenlerin kendine özgü yapısını ve simetrik özelliklerini dikkate alarak, eksik kısımları en doğru şekilde yeniden oluşturmak için güncel modelleri sunmayı amaçlamaktadır. Bu bağlamda, desenlerin hem görsel hem de topolojik benzerliğini koruyan algoritmalar üzerinde yapılan karşılaştırmalar, çalışmanın yenilikçi

yönlerinden biridir. Ayrıca, İslami geometrik desenlerin yapısal ve estetik özelliklerine sadık kalınarak yapılan bu tamamlamalar, yalnızca kültürel mirasın korunmasına katkı sağlamakla kalmayıp; aynı zamanda bilgisayar destekli tasarım, restorasyon ve mimari alanlarında yeni yöntemlerin geliştirilmesine de olanak tanımaktadır. Sonuç olarak, bu çalışmanın sunduğu metodoloji, İslami geometrik desenlerin tamamlanmasına yönelik yenilikçi modellerin kullanılmasını hedeflemekte ve bu alandaki literatür açığını doldurmayı amaçlamaktadır. Çalışmanın bulguları, kültürel mirasın korunmasına yönelik bilgisayar tabanlı çözümler geliştirilmesi ve eksik desenlerin özgün yapıya uygun olarak yeniden oluşturulması açısından önemli katkılar sunacaktır.

Tezin strüktürü

Tez, çalışması beş ana bölümden oluşmaktadır. Birinci bölüm, araştırmanın dayandığı kavramsal çerçeveyi, problem tanımını ve çalışma bağlamını sunmaktadır. Bu bölümde İslami geometrik desenlerin tarihsel, estetik ve yapısal önemi açıklanmakta; çalışmanın dayandığı temel problemler tanımlanmaktadır. Ayrıca, çalışmanın temel amacı, özgün katkısı ve araştırma soruları bu bölümde tanımlanarak tezin genel yönelimi belirlenmektedir.

İkinci bölüm, İslami geometrik desenlerin tarihsel ve matematiksel temellerine ilişkin mevcut literatürü incelemektedir. Desenlerin simetrik özellikleri, tekrarlama sistemleri ve geometrik yapılarına dair yapılan çalışmalar özetlenmektedir. İslam sanatı desenlerine genel bir bakış sağlayarak ve çeşitli bilgisayar programlarının dahil edilen matematiksel süreçleri kullanarak bu desenleri dönüştürmek için müdahale adımlarının günümüze kadar olan kullanımları tartışılmıştır. Bunun yanı sıra, güncel yaklaşımlar olarak makine öğrenmesi yöntemlerine değinilmektedir. Derin öğrenme algoritmaları ve görüntü boyama gibi güncel algoritmaların bu alanda nasıl uygulandığına dair güncel araştırmalar ele alınır. Literatürdeki bilgi boşlukları ve mevcut yaklaşımların sınırlamaları tartışılarak, tezin bu eksikleri doldurmadaki katkısı açıklanmaktadır.


Üçüncü bölüm olan araştırma metodolojisi bölümünde, veri setinin oluşturulması, GAN modelleriyle desen üretimi, evrişimli sinir ağı (Convolutional Neural Network-CNN) tabanlı sınıflandırma ile verinin testi, görüntü boyama algoritmaları ile eksik parçaların tamamlanması için kullanılan yöntemler detaylı bir şekilde açıklanmaktadır. Derin öğrenme algoritmalarının eğitimi, GAN modellerinin uygulanması ve görüntü boyama tekniklerinin

seçimi gibi süreçler sunulmuştur. Ayrıca, topolojik veri analizi, frekans analizi ve görüntü kalite metriklerinin neden ve nasıl kullanıldığına dair gerekçeler sağlanmaktadır.

Dördüncü bölüm, metodolojinin uygulandığı süreçleri ve elde edilen bulguları içermektedir. Veri setlerinin hazırlanması, modellerin uygulanması ve sonuçların analiz aşamaları açıklanmakta, farklı algoritmaların performansları karşılaştırmalı olarak sunulmaktadır. Eksik kısımların tamamlanmasına yönelik yöntemlerin başarı düzeyleri, ilgili görseller, tablolar ve grafiklerle desteklenerek gösterilmektedir.

Aynı bölümde, çalışmada kullanılan modellerin çıktıları sistematik biçimde değerlendirilmektedir. GAN tabanlı yaklaşımların sınırlılıkları tartışılmakta; CNN tabanlı sınıflandırmanın başarı düzeyi değerlendirilmekte; üç ayrı görüntü tamamlama (inpainting) modelinin sonuçları ise nicel ve görsel düzeyde karşılaştırılmaktadır. Değerlendirme sürecinde yapısal benzerlik, algısal fark ve genel piksel hatası gibi ölçütler kullanılmakta; SSIM, PSNR, LPIPS ve L1 metrikleriyle desteklenmektedir. Buna ek olarak, topolojik analizler aracılığıyla geometrik süreklilik ve yapısal bütünlük ölçülmekte; frekans yönelimi ile yoğunluk haritası analizleri üzerinden simetrik uyum ve motif sürekliliği değerlendirilmektedir.

Son bölüm olan sonuç ve öneriler, tezin genel çıktılarının özetlendiği, özgün katkıların vurgulandığı ve gelecekte yürütülebilecek araştırmalara yönelik önerilerin sunulduğu bölümdür. Çalışmanın İslami geometrik desenlerin dijital ortamda korunması, yeniden inşası ve sınıflandırılması konularına sağladığı katkılar açıklanmakta; kullanılan yöntemlerin disiplinler arası potansiyeli değerlendirilmektedir. Ayrıca, veri çeşitliliğinin artırılması, model ölçeklenebilirliği, farklı yapay zeka mimarilerinin denenmesi ve restorasyon pratiklerine doğrudan entegrasyon gibi konularda ileriye dönük önerilere yer verilmektedir. Tez akış şeması Şekil 1.1.' de görülmektedir.



Şekil 1.1. Tez akış şeması

2. LİTERATÜR İNCELEMESİ VE KURAMSAL ÇERÇEVE


Bu bölümde, İslami geometrik desenler (İGD) alanında literatür bilgileri verilmekte; çalışmanın yöntemsel kararlarını besleyecek kuramsal dayanaklar derlenmektedir. Öncelikle İslam sanatı bağlamında İGD'nin tarihi kaynakları ve geometrik yapım ilkeleri özetlenmekte; ardından simetri kuralları ekseninde desenlerin sınıflandırılmasına ve çözümlemesine imkan veren yaklaşımlar ele alınmaktadır. Devamında, üretim süreçlerinde belirleyici olan ızgara türleri ve ilişkili yöntemler tartışılmakta; modüler sistem tasarımıyla tekrar eden birimlerin ve bileşenler arası hiyerarşinin nasıl kurgulandığı açıklanmaktadır. Böylelikle İGD'nin mevcut biçimlenme mantığı ortaya konulmakta ve sonraki bölümlerde yer alacak veri odaklı analiz, üretim ve tamamlama süreçlerinin dayandığı ilkesel yapı netleştirilmektedir.

2.1. İslam Sanatı ve İslami Geometrik Desenler

İslam kültürünün yedinci yüzyılda yükselişi, sanat ve mimarlıkta köklü bir dönüşümün başlangıcını teşkil etmektedir (Stierlin, 1996). Bu yükseliş, Emevi Halifeliği'nden başlayarak Safevi, Babür ve Osmanlı gibi büyük imparatorluklar boyunca süregelen ve Güney Asya'dan Avrupa ile Afrika'ya kadar geniş bir coğrafyayı kapsayan on üç yüzyılı aşkın bir dönemi ifade eder (Kaplan ve Salesin, 2004). Bu süreçte İslam sanatı, yalnızca dini bir temsil biçimi olarak değil, aynı zamanda bilgi üretimi ve estetik anlayışın da taşıyıcısı olarak kültürel kimliğin yapı taşlarından biri haline gelmiştir (Critchlow, 1976). İslam kültürleri boyunca görülen İslam sanatı ve mimarisi çeşitli şekil ve türlerde ortaya çıkmaktadır (Kaplan ve Salesin, 2004). Bunlar; geometrik desenler, hat sanatı ve arabesk motifler gibi kendine özgü özelliklerle kategorilere ayrılmaktadır. Bu sanatsal formlar, hem dini hem de dünyevi yapıların dekorasyonunda kullanılarak, İslam medeniyetinin zenginliğini ve çeşitliliğini yansıtmaktadır (Critchlow, 1976). Özellikle geometrik süslemeler, İslam sanatının ayırt edici yönlerinden biri olarak; matematiksel düzene dayalı kurguları ve doğayla uyumlu motifleriyle dikkat çeker. Bu düzenlemeler, bağımsız öğelerden ziyade bütünsel ve ritmik bir organizasyonla, görsel denge ve uyumun ifadesi hâline gelmiştir (Cromwell, 2016).


Hat sanatı, İslam medeniyetinin estetik anlayışını yansıtan ve farklı etnik grupların kültürel mirasını taşıyan önemli bir yazı sanatıdır (Burckhardt, 2009). Erken dönemlerde dini ve manevi bir sembol ve ifade aracı olarak gelişen hat sanatı, farklı kültür ve topraklardan gelen dillerin kaynaşması ve kültürel birleşme unsuru olarak kullanılmıştır (Bakhsh, 2021). Bu yönüyle İslami hat sanatı, sanat eserlerine sembolik, kutsal ve kültürel katmanlar ekleyerek, biçim ve içerik arasında bütüncül bir uyum oluşturmaktadır (Fraser ve Kwiatkowski, 2006).

Hat sanatının en erken ve karakteristik biçimlerinden biri olan Kufi yazısı, özellikle mimari süslemelerde kullanılan geometrik yapısıyla öne çıkar (Resim 2.1). Sekizinci yüzyıl civarında geliştirilen bu kaligrafik stil, erken İslam döneminde kullanılan en eski yazı türlerinden biri olarak kabul edilmektedir. Zaman içinde farklı bölgelerde çeşitli varyasyonlara uğrayan Kufi yazısı, yalnızca kutsal metinlerde değil, aynı zamanda el yazmaları, mimari yüzeyler ve dekoratif sanat nesnelerinde de görsel ve estetik bir unsur olarak benimsenmiştir (Abas, 2001; Etikan, 2008).




Resim 2.1. Şeyh Lütfullah Mescidi'nde Arapça hat sanatının Kufi üslubu kullanılarak resmedilmesi (Burckhardt, 2009)

İslam sanatının ayırt edici öğelerinden biri olan arabesk ise, genellikle stilize edilmiş bitkisel motiflerin ritmik ve iç içe geçmiş hatlar oluşturacak şekilde düzenlenmesiyle tanımlanmaktadır (Abas ve Salman, 1994). Bu süsleme biçimi, stilize bitki formları gibi organik öğelerin geometrik düzende soyutlanarak yeniden kurgulanmasıyla oluşur (Burckhardt, 2009). Arabesk, aynı zamanda İslam sanatında mimari yüzeylerin süslenmesinde İslam kültüründe birlik işlevi gören soyut bir sanat formu olarak İslam sanatında figüratif temsile alternatif bir görsel sistem sunmaktadır.



Resim 2.2. Solda: Özbekistan, Şāh-ı Zindah, Şād-ı Mülk Aqa Türbesi'nden seramik pano, (14. YY), Sağda: Bursa, Yeşil Cami'den duvar çinisi (1420) (Burckhardt, 2009)


İslam kültürlerinde zengin bir çeşitliliğe sahip olan İslami geometrik desenler ise, İslam sanat mirasına ayırt edici bir kimlik kazandıran başlıca özelliklerden biridir (Kaplan, 2005). Bu desenler, genellikle çokgen temelli kurgular, yıldız sistemleri ve simetrik bölünmelerle oluşturulan karmaşık geometrik örgülerden meydana gelir (Bier, 2015). Dokuzuncu yüzyıldan itibaren gelişen bu yapılar, ilk dönemlerde basit yıldız gibi motiflerle temsil edilirken, on altıncı yüzyılda 14 ve 16 kollu yıldız sistemlerini içeren çokgen yapılar İslam mimarisinde yaygın biçimde uygulanmıştır (Abdullahi ve Embi, 2013).



Resim 2.3. IGP tasarımlar. Solda: Karatay Medresesi'nden geometrik desen tasarımı (Kasraei, Nourian ve Mahdavinejad, 2016). Sağda: Konya'dan tasarım (Broug, 2013)

İslami geometrik desenler belirli yapısal ilkelere göre şekillenmektedir. Bunlardan biri, iç içe geçme özelliğidir. Desen yapıları, tekrarlanan kareler ve daireler gibi basit şekillerin

birbirleriyle bağlanması ve iç içe geçirilmesi kompozisyonları üzerine kurulmaktadır. Bu özellik, cetvel ve pergel yardımıyla oluşturulan oranlı bileşenlerin, düğüm benzeri yapı formlarıyla birbirine bağlanmasıyla ortaya çıkmaktadır (Necipoğlu, 1996). Bu görsel yapı, desenin sürekliliğini ve bütünselliğini pekiştirir. “Tekrar” ilkesi ise geometrik desenlerin oluşturulmasında merkezi bir rol oynamaktadır. Temel geometrik şekillerin (kare, üçgen, beşgen, altıgen ve ongen gibi) tekrarlanmasıyla oluşturulan bu desenler, karmaşık ve göz alıcı süslemeler oluşturmaktadır (El-Said ve diğerleri, 1993). Bu tekrar mekanizması, desenin hem modülerliğini hem de yüzeydeki görsel ritmi sağlamaktadır (Şekil 2.1).



Şekil 2.1. Altıgen bir yapı kullanılarak tekrarlanan bir birimden İGD'in oluşturulması (Yazar tarafından oluşturulmuştur)


İGD' in bir diğer belirleyici özelliği ise “simetri”dir. Bu desenler, yalnızca görsel düzen açısından değil, matematiksel grup teorisi bağlamında da yüksek düzeyde simetrik yapılardan oluşmaktadır (Grünbaum, Grünbaum ve Shephard, 1986; Pérez-Gómez, 1987).

İGD, elemanlarının sürekliliği ve yönlü akışıyla, yapının tamamına yayılan bütüncül bir geometri inşa eder. Bu süreklilik, İslam sanatında kutsallık, sonsuzluk ve tekillik gibi felsefi kavramların görsel karşılığı olarak yorumlanmaktadır. Bu sebeple bu yaklaşımlar, yalnızca estetik analizi değil, aynı zamanda İslam sanatının içsel kavramsal çerçevesini de anlamaya yöneliktir. Nitekim “çoklukta birlik ve birlik içinde çokluk” anlayışı, İslami desenlerin altında yatan ontolojik ve metafiziksel düşünce sisteminin önemli bir parçası olarak görülmektedir (Jones, 2016). Bu düşünce, evrendeki ideal düzenlerin, geometrik biçimler aracılığıyla temsili olarak görselleştirilmesini amaçlar (Mostafa, 1979).

2.1.1. İGD’de tarihsel kaynaklar ve geometrik yapım ilkeleri


desen sistemlerinin temelini oluşturmuştur (Koliji, 2016). Abu al-Wafa 'nın üçgenler aracılığıyla kareleri nasıl böldüğü ve dönüştürdüğü üzerine geliştirdiği teknikler, zanaatkârlar için hem yapısal hem estetik açıdan etkili çözümler sunmuştur (Şekil 2.2 a) (Bonner, 2017). Bu kesik kare motiflerin İslam süslemelerinde kullanılan bir örneği, İsfahan'daki Cuma camisinin 17. yüzyıl karo panelidir (Şekil 2.2 b). Ayrıca Abu al-Wafa'nın çalışmaları, çemberlerle ilgili bir dizi prosedürü içermektedir. Bu prosedürler arasında, çemberlerin merkez noktalarını tespit etme, onları eşit parçalara ayırma, belirlenen noktalardan çemberlere teğet çizgiler çekme ve çemberlerin içerisine düzgün çokgenler yerleştirme yer Ortaçağ İslam sanatında geometrik desenlerin tasarım süreçleri hakkında çok fazla bilgi günümüze ulaşmamış olsa da, bazı önemli metinler bu konuda kaynak oluşturmaktadır (Necipoğlu, 1996). Bu metinler, zanaatkârların geometrik prensiplerle olan etkileşimlerini ve dönemin matematiksel bilgisinin sanat üretimine nasıl yansıdığını ortaya koymaktadır. Söz konusu etkileşim, yalnızca pratik tasarım süreçlerini değil, aynı zamanda matematikçilerin zanaatkârlarla kurduğu bilgi alışverişini de yansıtır (Özdural, 2000).

İranlı matematikçi ve astronom Abu al-Wafa al-Buzjani' nin (940-998) Kitāb fī mā yahtāj ilayh al-şāni' min al-a' māl al-handasiyya (Zanaatkâr için Gerekli Geometrik Yapılar Üzerine Bir Kitap) eseri geometrik desenlerin tasarımını sistematik bir şekilde ele alan ilk kaynaklardan biridir. Bu el yazması, zanaatkârların çeşitli geometrik desenleri dikkatle nasıl şekillendireceklerini ve bu süreçte karşılaşılabilecekleri engelleri anlatan, tarih boyunca kaleme alınmış kıymetli rehberlerden birini temsil etmektedir (Necipoğlu, 1996). Özellikle çokgenlerin çizimi, bölünmesi ve genişletilmesi gibi konulara dair geliştirdiği yöntemler, mimarlık ve süsleme sanatlarında tekrar edilebilir ve modüler almaktadır (Bodner, 2012; Necipoğlu, 1996). Bu el yazması genel olarak, geometrik problemlerin çözümüne ve bu çözümlerin pratikte nasıl uygulanacağına dair kapsamlı bir rehber olarak hizmet etmektedir (Koliji, 2016).



Şekil 2.2. Üç birim kareden bir karenin oluşturulması (a) (Özdural, 2000), İsfahan'daki Cuma Camii'nden paneller (b) (Necipoğlu, 2017)

13. yüzyıla ait olduğu tahmin edilen ve geometri konusunda uygulamalı bir bilgi birikimine sahip bir zanaatkar tarafından hazırlandığına inanılan “Fî tadâkhul al-ashkâl al-mutashâbiha aw al-mutawâfiqa” (On interlocking similar or congruent figures) ise geometrik desenin tekrar birimlerini oluşturmak için talimatlar içeren anonim bir el kitabıdır. Bu metin pratik geometri alanında rehberlik eden metinler barındıran 25 eserlik bir koleksiyon sunmaktadır (Özdural, 1996). Chorbachi'nin analizleri, bu el yazmasında yer alan geometrik yapıların, Abu al-Wafa'nın çalışmalarındaki temel geometrik formlar ve çokgenlerle karşılaştırıldığında, daha karmaşık bir matematiksel düzlemde inşa edildiğini ve gelişmiş matematiksel kavrayışı sergilediğini ortaya koymaktadır (Chorbachi, 1989). Necipoğlu'nun ifadelerine göre, bu yapıt, geometrik desenlerin uyumlu ve estetik bir şekilde iç içe geçtiği “giriş modu” tekniğinin bir örneğini sunmaktadır. Onuncu yüzyılın sonlarına doğru pratik geometrinin yükselen bir ilgi görmesi, Abu al-Wafa gibi matematikçilerin eserleriyle bağlantılıdır ve bu yapıt, o dönemle sonraki parşömen geleneği arasında önemli bir bağlantı kurmaktadır (Necipoğlu, 1996). Şekil 2.3’ te eserde ifade edilen bir tekrar birimi görülmektedir.




Şekil 2.3. Yıldız ve çokgen motiflerinin tekrarlanan birimleri. “On interlocking similar or congruent figures” adlı eserden, Fotoğraf: Bibliothèque Nationale de France, Paris (Necipoğlu, 1996)

Topkapı Sarayı Müzesi'nin önemli koleksiyonlarından biri olan Topkapı Parşömeni, 15. yüzyılın sonları ve 16. yüzyılın başlarında İranlı zanaatkarlara atfedilmektedir. Parşömen, mimari süslemelerde kullanılmak üzere tasarlanmış 114 farklı geometrik desen içermekte olup, bu desenlerin dönemin yapılarında mozaik kompozisyonları oluşturmak amacıyla referans olarak kullanıldığı düşünülmektedir. Modüler tasarım yaklaşımı ve ızgara sistemi ile bu çizimler, tasarımcılara tekrar eden öğelerin entegrasyonu ve simetri ilkeleri aracılığıyla yüzeylerin geometrik desenlerle nasıl zenginleştirilebileceğine dair uygulamalı bilgiler sunar (Necipoğlu ve Al-Asad, 1995; Sarhangi, 2012) Bu sebeple, Ortaçağ İslam dünyasının estetik anlayışını ve geometrik desenlerin mimarideki rolünün anlaşılması açısından değerli bir kaynaktır.

Benzer nitelikteki bir başka belge olan Taşkent Parşömenleri ise, Taşkent kentinde bulunan Doğu Araştırmaları Enstitüsü'nde korunmakta ve 16. yüzyıl zanaatkârları ile mimarlarına atfedilmektedir (Bodner, 2011). Topkapı Parşömeni'ndeki çizimlerle benzerlik taşıyan bu eskizler, geometrik tasarımların nasıl oluşturulduğuna dair herhangi bir ölçü veya yazılı açıklama içermemektedir (Bodner, 2012). Her iki parşömen de, hem iki hem de üç boyutlu desenlerin üretimi için kullanılan çeşitli ızgara sistemlerini barındırmaktadır. Bu belgeler üzerinde kapsamlı bir analiz gerçekleştiren Rempel (1961), Taşkent Parşömenleri'nde yer alan desenleri farklı türlere göre sınıflandırmış ve bu desenlerin, karmaşık hesaplamalara


başvurmadan, temel geometrik formüller aracılığıyla üretildiğini öne sürmüştür (Necipoğlu, 1996; Rempel, 1961).

19. ve 20. yüzyıldan itibaren literatüre yakından bakıldığında, matematiksel ve biçimsel olarak iki yaklaşım açıkça görülebilmektedir. Matematiksel yaklaşımlar genellikle desenleri simetri gruplarına göre sınıflandırırken; biçimsel yaklaşımlar, bu desenlerin görsel düzen, tekrar birimi ve oran sistemine dayalı yapısal özelliklerine odaklanmaktadır. İslami geometrik desenlerde kullanılan oran sistemleri, belirli tekrar birimlerine göre sınıflandırılmaktadır. Bunlardan ilki, kare tekrar birimine ve "kök iki" oranına dayalı sistemdir. Bu sistemde, dairenin dört eşit parçaya bölünmesiyle başlayan yapı, dördün katlarıyla oluşturulan kompozisyonlara dönüşür. Bu tip desenler genellikle kare içinde kare yapısıyla ilerleyen simetrik yapılar üretir (Critchlow, 1976; El-Said ve diğerleri, 1993) (Şekil 2.4.a). İkinci sistem, altıgen tekrar birimi ve "kök üç" oranı üzerine kuruludur. Dairenin üç veya altı eşit parçaya bölünmesiyle başlayan bu sistem, altı ve on iki köşeli yıldız motiflerinin üretiminde temel alınır (Al Ajlouni, 2005; El-Said ve diğerleri, 1993) (Şekil 2.4.b).



Şekil 2.4. Kök iki oran sistemi (a), kök üç oran sistemi (b) (Al Ajlouni, 2005)

Üçüncü sistem ise, beşgen tekrar birimi ve Altın Oran ilkesine dayalı olarak yapılandırılmıştır. Bu sistemde, dairenin beş eşit parçaya bölünmesiyle başlayan kompozisyonlar, beş ve onun katları ile elde edilen çokgen ve yıldız motiflerine dönüşmektedir (Critchlow, 1976) (Şekil 2.5).




Şekil 2.5. Altın oran sistemi (Critchlow, 1976)

Yapılan diğer çalışmalarda, Lee (1987) ve Bonner (2017) matematiksel yapılarını inceleyerek desen tasarımlarının sistematik taksonomilerini sunmaktadır Lee (1987), yapım ilkelerini keşfederek yıldız ve rozet motiflerinin tanımlarını ortaya koymakta ve farklı türleri sınıflandırmaktadır. Bonner (2017) 'in sınıflandırmaları ise, çeşitli desen tasarımlarını oluşturan üretken çokgen mozaiklere ve çizgi eğimlerine dayanmaktadır. Çalışma, belirli geometrik tasarımlar ile bunların altında yatan üretken mozaikler arasındaki ilişkiyi göstermeyi amaçlamıştır Sınıflandırma, mozaikler oluşturmak için uçtan uca konfigürasyonlarda bir araya gelen ilişkili desen çizgileri ile sınırlı bir poligonal modül setine dayanmaktadır. Her sistemi oluşturan modüllerin sayısız şekilde birleştirilebileceği ve dört model ailesinin her birinin her bir mozaiklemeye uygulanabileceği düşünülürse, her sistem için sınırsız sayıda geometrik model mevcuttur. (Bonner, 2016). Başka bir yaklaşımda, Bourgoïn (1879) kalıpları tekrar eden birimlerin poligonal doğasına göre sınıflandırır. Bourgoïn'in (1879) yaklaşımında, altıgen desenler altı kat simetriye sahip desenlere atıfta bulunurken, on iki köşeli grup on iki kat simetriye sahip motifler içerir. Öte yandan Lee (1987) ve Bonner (2017), matematiksel yapılarını daha açık bir şekilde inceleyerek desen tasarımlarının daha sistematik taksonomilerini ortaya koymaktadır Lee (1987), yapım ilkelerini keşfederek yıldız ve rozet motiflerinin tanımlarını ortaya koyar ve farklı türleri sınıflandırır.

2.1.2. İGD' de simetri tabanlı yaklaşım


İslami geometrik desenler üzerine yapılan çalışmalarda geleneksel yaklaşım daha çok pratik geometri ve klasik tasarım araçlarına odaklanırken, bilimsel yaklaşım ise matematik ve simetri üzerine yoğunlaşmıştır. Bu desenlerin geniş çeşitliliği, erken dönem İslam desen sanatçılarının geometri ve simetriye dair derin bir anlayışa sahip olduklarını göstermektedir. Bu anlayış, farklı desen modelleri, simetri stratejileri ve üretim yöntemlerinin gelişimine yol açmıştır (Bonner, 2017; Kappraff, 2001). Simetrik stratejilerde desen tasarımının sınıflandırılması, iki ve üç boyutlu izometrik dönüşümlerin kombinasyonu ile elde edilen simetri grupları üzerinden gerçekleştirilmektedir (Knight, 1998). Geometrik sanatın görsel gelişimi ve stil çeşitliliği, bu kuralların uygulanmasına büyük ölçüde dayanır. Simetri, basit bir ifadeyle, bir nesnenin şeklini kendisiyle örtüşecek şekilde değiştiren ve görünümünü koruyan dönüşümlerdir. Geometride yüzeyi düzenli kaplayan sürekli desenler; öteleme, yansıma, dönme ve kayma yansıması gibi temel izometrik dönüşümlerle analiz edilir (Grünbaum ve Shephard, 1987) (Şekil 2.6).



Şekil 2.6. Dönme (a) öteleme (b), yansıma (c), ve kayma yansıma (d) simetrisi (Grünbaum ve Shephard, 1987).


Tekrar eden bir desendeki en temel simetri türleri öteleme simetrisidir. Eğer bir desen, belirli bir yönde kaydırıldığında boyut ve biçim olarak değişmiyorsa, bu desen öteleme simetrisine sahiptir (Grünbaum ve Shephard, 1987). Bu durum, desenin farklı yönlerde kaydırılabileceği çeşitli seçeneklerin olduğunu gösterir. Her bir yönde minimal bir öteleme bulunur ve bu ötelemenin tam sayı katları da desenin simetrisini oluşturur. Sonsuz sayıda öteleme arasında en küçük iki öteleme öne çıkar. Bu ötelemeler kalın oklarla gösterilmiş ve “u” ve “v” olarak adlandırılmıştır (Şekil 2.7). Bu iki minimal ötelemenin, diğer tüm ötelemeler için bir temel oluşturduğu düşünülmektedir. Diyagramda görüldüğü üzere, diğer

tüm öteleme simetrisi temel birimin ardışık uygulamalarıyla elde edilebilir (Abas ve Salman, 1994).




Şekil 2.7. Desenin alternatif öteleme yönleri (Abas ve Salman, 1994)

Şekil 2.8’de İzzettin Keykavus Türbesi’ne ait bir desen öteleme simetrisi ile çoğaltılmıştır.




Şekil 2.8. İzzettin Keykavus Türbesi’ne ait öteleme simetrisi ile çoğaltılmış desen (sol üstte, Hasan Fevzi Çüngen Arşivi’ne ait fotoğraf) (Yazar tarafından oluşturulmuştur)

Dönme simetrisinde, bir geometrik desende dönme kat simetrisi $a = 360/n$ derecesinde n olarak gösterilmektedir. Burada “a” dönme simetrisinin açısını tanımlanmaktadır. “n” ise ortaya çıkan şeklin simetri katını ifade eder (Grünbaum ve Shephard, 1987). Şekil 2.9 bir desendeki birimlerin dönme simetri merkezlerini göstermektedir. Merkezde yer alan yıldız, altı eşit bölüme ayrılarak dönme simetrisi gösterirken, her bir altıgenin ortası üç katlı simetriye işaret etmektedir. İki katlı simetri merkezleri ise 180 derecelik bir dönüşle tamamlanmaktadır. Abas ve Salman (1994), bu tür tekrar eden desenlerdeki dönme simetrilerini sistematik olarak incelemiş ve simetri merkezlerini ikili, üçlü, dördü ve altılı olmak üzere sınıflandırmıştır (Abas ve Salman, 1994).




Şekil 2.9. Desenin dönme merkezleri (Abas ve Salman, 1994)

Dönme simetrisi, geometrik desenlerin tasarımında önemli bir rol oynamaktadır ve genellikle konumları çokgenlerin merkezleri veya yıldız şekillerinin odak noktaları gibi belirli noktalar etrafında gerçekleşmektedir. Diğer olası noktalar ise köşeler ve kenarların orta noktalarıdır. Şekil 2.10’da İzzettin Keykavus Türbesi’nde kullanılan desen, bu prensibi kullanarak 60 derecelik bir dönme simetrisi ile oluşturulmaktadır. Bu simetri, altıgen şekillerin dönüşümlü olarak yerleştirilmesiyle elde edilmektedir. Bir tekrar birimin çizimi için, 30 derecelik açılarla 12 kata ayrılan daire, daha sonra 60°’lik açılarla her iki noktadan bir doğru geçirmek üzere iki adet eş merkezli altı katlı altıgen biçimler oluşturmaktadır. İlk altıgenin tekrarlayan birimi A kat, ikinci altıgenin tekrarlayan birimi B kat dönme simetrisi oluşturmaktadır.




Şekil 2.10. İzzettin Keykavus Türbesi kemer yüzeyi 60° dönme simetrisi (sol üstte, Hasan Fevzi Çüngen Arşivi'ne ait fotoğraf) (Özdemir, Selçuk ve Çüngen, 2022)

Yansıma simetrisi, bir nesnenin ayna karşısındaki görüntüsü gibi eşit ve ters yönde oluşturulduğu bir simetri çeşidi olarak açıklanmaktadır. (Grünbaum ve Shephard, 1987, s. 26). Bu simetri türü, belirli bir eksen boyunca şeklin katlanıp özdeş bir yansıma yarattığı durumlarda gözlemlenmektedir. Şekil 2.11' de desenin yansıma simetrileri sergilediği ayna çizgileri gösterilmektedir. Örnek, sekiz köşeli yıldızların uçlarını birleştiren sekizgenler ve daha küçük altı köşeli yıldızlardan oluşan ve yansıma simetrisi sergileyen bir kompozisyonu ifade eder. Bu desen aynı zamanda, dört katlı motiflerinden meydana gelmektedir ve hem 90° hem de 180° dönme noktalarına sahiptir.




Şekil 2.11. İzzettin Keykavus Türbesi kemer yüzeyi yansıma simetrisi (solda, Hasan Fevzi Çüngen Arşivi'ne ait fotoğraf) (Özdemir ve diğerleri, 2022)

Kayma simetrisi, bir nesnenin aynası olarak düşünölebilecek bir kopyasının, belirli bir doğrultuda ve mesafede kaydırılmasıyla oluşmaktadır (Grünbaum ve Shephard, 1987, s. 26). Bu simetri türü, yansıma ve öteleme işlemlerinin ardışık olarak uygulanmasıyla her noktanın, desenin farklı bir konumundaki eşleniğine taşınmasını sağlar. Böylece nesnenin tüm noktaları, özgün şeklin simetrik bir yansıması olarak konumlandırılır (Abas ve Salman, 1994) Şekil 2.12’de birimin özgün hali ile yansıtılmış ve kaydırılmış hali arasındaki ilişki gösterilmektedir. Böylece bu matematiksel düzen ve simetri anlayışı ile görsel bir bütünlük ve düzen sağlanmaktadır.




Şekil 2.12. Kayma yansıma simetrisi ile desen çoğaltımı (Abas ve Salman, 1994)

Şekil 2.13’ de kemer iç yüzeyi çok kollu şerit örgü süslemelerden elde edilen modüler bir bileşimden oluşur. Desen kompozisyonu ritmik biçimde dengeleyen sekiz kollu yıldız hücreleriyle tanımlanır. Desen oluşumu, kare tabanlı bir tekrar ızgarası üzerinde düzenlenmiş tekil bir modülün, doğrultusal ötelemelerle yüzeye dağıtılmasının yanı sıra, yatay eksenlere paralel kayma yansıma işlemleriyle genişletilmesi sonucu elde edilir. Simetri merkezleri incelendiğinde, örgü düğümünün yer aldığı modüler hücrelerin kaydırmalı eşlenikleri boyunca süreklilik sağlandığı, yıldız arakesitlerinin de aynı simetri dizilimini izleyerek yüzey bütünlüğünü elde ettiği görölmektedir.




Şekil 2.13. Kemer yüzeyleri kayma yansıma simetrisi (sol üstte, Hasan Fevzi Çüngen Arşivi'ne ait fotoğraf) (Özdemir ve diğerleri, 2022)

Simetri gruplarının sınıflandırılması ve analizine yönelik çalışmalar, İslami geometrik desenlerin yapısal temellerini anlamada önemli katkılar sunmuştur. Bu alandaki ilk sistematik yaklaşımlardan biri, 1944 yılında Edith Müller tarafından gerçekleştirilmiştir. Muller, Elhamra Sarayı'ndaki süsleme üzerine bir tez yazmış ve kalıpları açıklamak için grup teorisi ve kristalografiyi kullanmıştır. Simetri analizi yaparak ve 11 çeşit simetri keşfetmiştir (Müller, 1944; akt. Necipoğlu, 1996). Ayrıca, Gaganov (1958), girih desenlerini simetrik özelliklerine göre sistematik biçimde sınıflandırarak; doğrusal, yüzeye eşit yayılmış ve radyal örüntüler olmak üzere üç ana kategori önermiştir (Gaganov, 1958; akt. Necipoğlu, 1996). 1986'da Branko Grünbaum, Zdenka Grünbaum ve G.C. Shepard, Elhamra Sarayı'nı incelemiş ve 13 tür simetri grubunun varlığını ortaya koymuştur (Grünbaum ve diğerleri, 1986). Bu tür çalışmalar, yüzyıllar boyunca İslam dünyasında yayılan geometrik estetiğin yalnızca görsel değil, aynı zamanda matematiksel olarak da anlaşılabilir bir temele sahip olduğunu ortaya koymaktadır. Son dönem araştırmalarında ise Broug (2008), dönme simetrisi esasına dayalı bir sınıflandırma önererek, dairenin belirli sayıda eşit parçaya bölünmesiyle elde edilen açısız oranlara göre desenleri kategorize etmiş ve bu yaklaşım üzerinden üretim stratejileri geliştirmiştir (Broug, 2008) (Şekil 2.14).



Şekil 2.14. Broug'a göre İslami geometrik desenlerin soy ağacı; dört, beş ve altı katlı simetri gruplarına göre sınıflandırma (Broug, 2008)


Bu sınıflandırmalar, genellikle desen kompozisyonlarına gömülü temel motiflerin geometrik yapılarına dayanmaktadır. Örneğin bir yıldız veya rozet motifi, merkezden çevreye doğru uzanan ışınların ya da katların sayısına göre tanımlanır. Altı, sekiz, on, on iki ve on altı kollu yıldız motifleri en yaygın türleri oluştururken; sekizden başlayıp doksan altıya kadar değişen daha yüksek simetri derecelerine sahip çeşitlere de rastlanmaktadır (Abas ve Salman, 1994). Benzer biçimde, yalnızca çokgen temelli süslemeler içeren örneklerde ise tasarım, kullanılan ana çokgenlerin kenar sayısına göre sınıflandırılmaktadır (Lee, 1987). Örnek olarak, Şekil 2.15'te görseller, farklı köşe sayılarına dayalı iki desenin üretim sürecini göstermektedir. Her iki örnekte de merkezden radyal olarak yayılan çizgiler ve ara bağlantılar, belirli bir rotasyonel simetriyi temel alarak görsel bütünlük sağlamaktadır.



Şekil 2.15. On köşeli (üstte) ve altı köşeli (altta) motifin uygulama adımları (Özdemir ve diğerleri, 2022)

Simetri sınıflandırmaları arasında en kapsamlı sistemlerden biri düzlemdeki tüm periyodik simetrileri kapsayan 17 duvar kağıdı grubu modelidir. Bu sınıflandırma ilk olarak 19.


yüzyılın sonlarında ve 20. yüzyılın başlarında kristalograflar ve matematikçiler tarafından ortaya konmuştur (Fedorov, 1891; Polya, 1924'dan akt. Bonner, 2017). Hermann Weyl ise kavramsal çerçeveyi derinleştirerek farklı kompozisyonlara uzanan geniş bir uygulama alanı sunmaktadır (Weyl, 1952). İslami geometrik desenlerin sınıflandırılmasında ise Abas ve Salman (1994) 17 düzlem simetri grubunu temel alan sistematik bir yaklaşım sunmuştur (Abas ve Salman, 1994). Hem yatay hem de dikey yönlerde birden çok tekrar ile genişletilen periyodik birimlerden oluşan bu sistemde her bir grup, dikdörtgen, eşkenar dörtgen, kare veya paralelkenar gibi geometrik şekillerden oluşan kafeslerle karakterize edilmektedir (Schattschneider, 1978). Şekil 2.16, 17 farklı Duvar Kağıdı Grubu'nun simetrik özelliklerini barındıran birim hücrelerin görsel bir temsilini sunmaktadır. Burada, tek çizgi ile ifade edilen alanlar, bu birim hücrelerin temel bölgelerini işaret ederken iki çizgi ile gösterim yansıma eksenini, kesikli çizgi ise kayma yansıma eksenini ifade etmektedir (Liu, Collins ve Tsin, 2004).



Şekil 2.16. 17 duvar kağıdı grubu için birim kafesler (Schattschneider, 1978)'den uyarlanmıştır.

Simetri grubunda yer alan harfler, grubun özelliklerini ifade ederken; kare, dikdörtgen ve paralelkenar birim hücrelerini temsil eden 'p' harfi, ardından gelen sayı ile birlikte, desenin sahip olduğu en yüksek dönme simetrisinin derecesini belirtmektedir. Bu harften sonra gelen rakamlar (1, 2, 3, 4 ya da 6 kat) döndürme simetrisinin derecesine göre kat sayısını göstermektedir. Bu sayılar, desenin 360°'lik bir tam dönüşün kaç eşit parçaya bölündüğünün bir ifadesidir. "c" harfi ise, merkezi bir tekrar özelliği gösteren eşkenar dörtgen şeklindeki

birim hücreleri ifade etmektedir. Harflerin ardından gelen sayılar, desenin dönme simetrisinin maksimum derecesini temsil ederken, "m" ve "g" harfleri ise sırasıyla ayna yansıması ve kayma simetrisini tanımlamaktadır. Grubun ikinci ve üçüncü pozisyonlarında herhangi bir sembol bulunmaması, bu grubun yansıma veya kayma gibi reaksiyonları barındırmadığını ifade etmektedir. Bu durum, grubun bu tür dönüşümlere karşı dirençli olduğunu göstermektedir (Asha, Nagabhushan ve Bhajantri, 2012) Şekil 2.17' de simetri gruplarının bir akış diyagramı gösterilmektedir.




Şekil 2.17. On yedi simetri grubu akış diyagramı (Ostromoukhov, 1998)'dan uyarlanmıştır.

2.1.3. İGD' de ızgara yapıları ve üretim yöntemleri

İslami geometrik desenler, tek bir ögenin sürekli tekrarlanmasıyla düzlemi tamamen kaplayabilmektedir. Bu tekrar birimleri, desenin uçtan uca öteleme simetrisi sayesinde düzlemi kesintisiz bir şekilde doldurmasını sağlayan minimum yapıyı oluşturur. Bu nedenle, tekrar birimi, bir desenin iki boyutlu bir alanı eksiksiz kaplama yeteneği açısından temel bir unsurdur. Tekrarlanan iki boyutlu boşluk doldurma veya döşeme bilimini yöneten kurallar, İslami geometrik tasarım için olduğu kadar diğer herhangi bir desen yönelimli süsleme geleneği için de geçerlidir (Bonner, 2017).


Izgara sistemlerinde ise her desen, yüzeylerin bölünmesi ile oluşan belirli şablonlar üzerine kurulmakta ve tekrarlayan öğeler yüzeye uygulanarak çoğaltılmaktadır. Bu yaklaşım, yüzey mozaikleme yöntemlerinde alt bölümlerin yapısını temel alır. Yüzey üzerinde desen üretimi sağlamak amacıyla, belirli bir aralık belirlenmekte ve bu aralık üzerinden yüzey düzenli biçimde bölünmektedir. Bu işlem, yüzeyin yinelemeli olarak değerlendirilmesiyle tüm alanın desenle kaplanmasını mümkün kılar. Ayrıca bu sistemler, kompozisyon planlamayı ve ölçeğini değiştirmeyi kolaylaştırmasından dolayı, yeni tasarımlar oluşturmanın bir yolunu da sunmaktadırlar (Özgan, 2018). Şekil 2.18’ de gösterilen görüntüler, dairesel veya üçgen ızgara sistemi ile elde edilen desen oluşumunu örneklemektedir. Soldaki görüntü, eşit aralıklarla elde edilen düzenli yüzey bölünmesini; ortadaki ve sağdaki görseller ise bu bölünmüş yüzeylerin üçgen ızgara yapısına dönüştürülmesini ifade etmektedir. Örnek bağlamında, dairesel yüzeylerin diyagonal çizgilerle bölünmesiyle iki farklı ızgara yapısının türetildiği görülmektedir.



Şekil 2.18. Bir yüzeyin yinelemeli alt bölümünün dairesel ızgara ile oluşturulması (Sol) Dairesel ızgara ile üretilen yüzey (Orta) Altıgen ve üçgenlere dönüşüm (Sağ) Üçgenlerden yıldız motiflere dönüşüm (Yazar tarafından oluşturulmuştur)

Geometrik desenlerin üretiminde yaygın olarak benimsenen yöntemlerden biri de, iç içe geçen ve tekrarlayan dairelerin birleşimiyle elde edilen temel birimlerin düzenlenmesine dayanmaktadır (Broug, 2008; Critchlow, 1976; Gonzalez, 2001; Wade, 1976). Bu yöntem, karmaşık desen kompozisyonlarının, daha basit dairesel yapıların detaylandırılmasıyla inşa edilmesini mümkün kılar (Critchlow, 1976; El-Said ve diğerleri, 1993). Bonner (2017) bu yaklaşımı “nokta birleştirme tekniği” olarak adlandırmakta ve geleneksel desen üretiminde sıklıkla başvuru alan bir yöntem olarak tanımlamaktadır (Bonner, 2017). Uygulama süreci,


pergel yardımıyla bir dairenin çizilmesi ve bu dairenin eşit açılarla bölünmesiyle başlar. Elde edilen referans noktaları ise, çevresel olarak konumlandırılmış yeni dairelerin yerleştirilmesinde kılavuz görevi görmektedir. Bu aşamalar sonucunda oluşan dairesel kurgular, desenin iskeletini oluşturan düzenli ızgaraların temelini meydana getirmektedir. Şekil 2.19, bu yöntemle elde edilen üç farklı geometrik yapının (A, B ve C) adım adım oluşumunu sunarken; her bir yapının, eş merkezli veya kesişen daireler temelinde kurulan dairesel ızgara sistemine dayandığı görülmektedir.



Şekil 2.19. Dairesel ızgara ile motif oluşumu, (A) Altıgene dayalı yıldız deseni oluşumu (B) Kareye dayalı dört köşeli yıldız oluşumu (C) On iki köşeli yıldız oluşumu için adımlar (Broug, 2013)’ten uyarlanmıştır.

Nokta birleştirme yapılarının temel özelliği, çizim sürecinin adım adım ilerlemesi ve her bir desenin kendine özgü bir üretim sırasına sahip olmasıdır. Bu süreç, genellikle dairesel bir


formun belirli oranlarla alt bölümlere ayrılmasıyla başlamaktadır. Dairenin çevresine yerleştirilen eşit aralıklı noktaların kesişimlerine çizilen doğrular, bir desenin tekrar biriminin referans noktalarını ve sıralarını tanımlamaktadır (Şekil 2.20). Bu sayede, karmaşık görünen desenler dahi sistematik bir yaklaşımla yeniden inşa edilebilmektedir. Bu yöntemin karakteristik yönlerinden biri, her desenin kendine özgü bir yapım aşaması içermesidir. Ancak, bu yöntem özellikle karmaşık bileşik simetrilere sahip desenlerin yeniden inşasında zahmetli bir süreç olarak kalmaktadır. Özgün desenlerin üretiminden ziyade, daha çok mevcut motiflerin yeniden üretiminde etkili bir araçtır (Demiriz, 2017).



Şekil 2.20. Nokta birleştirme tekniği ile üretilmiş model (sol üstte, Hasan Fevzi Çüçen Arşivi'ne ait fotoğraf) (Özdemir ve diğerleri, 2022)

Birçok desen tasarımını türeten ve bir alt yapı olarak çalışılan bölümlmeleri ifade eden ızgara sistemlerinde, dairesel ızgara yönteminin iç içe geçme özelliğinden farklı bir şekilde, çokgen mozaikler çakışma olmaksızın sonsuz bir düzlemi kaplayabilmektedir. Bu yöntemdeki farklılıklardan biri, dairesel ızgaranın kaybolması ve yerine, çokgenlerin belirli noktalardan birleşmesi ile ızgara sistemlerini meydana getirmesidir (Kaplan, 2002). Craig Steven Kaplan (2002)'ın yaptığı çalışmalar, özellikle geometrik desenler ve ızgara sistemleri üzerinde yoğunlaşmıştır. Kaplan, bilgisayar grafikleri ve hesaplamalı geometri alanlarında,


çokgenlerin temas noktalarını kullanarak İslami yıldız desenler gibi karmaşık geometrik yapıları oluşturma yöntemlerini incelemiştir. Bu yöntemler, geleneksel dairesel ızgara yerine belirli noktaların birleştirilmesiyle oluşturulan çokgen tabanlı ızgaralar kullanılarak, daha esnek ve çeşitli desenlerin üretilmesini sağlamıştır (Kaplan, 2002). Ayrıca, Grünbaum ve Shephard "Tilings and Patterns" adlı kitabı ile düzlem kaplamaları ve mozaiklerin oluşturduğu desenler, matematiksel özellikleri hakkında ayrıntılı bilgi sunmaktadır (Grünbaum ve Shephard, 1987). Matematiksel olarak bu ızgaralar, temel bir ögeyi ifade eden çokgenlerin tekrarlı kullanımı ile düzlemi doldurabilmektedir. Bu ızgara çeşitleri; eşkenar üçgenlere ve katlarına dayalı ızgaralar, karelere ve katlarına dayalı ızgaralar, beşgen ve katlarına dayalı ızgaralar, temel kategorilerin bir kombinasyonuna dayalı ızgaralar olarak sınıflandırılmıştır (Al Ajlouni, 2005). Desenler çoğunlukla izometrik ve ortogonal ızgaralar ile bir düzlemde sonsuz olarak kaplanabilmektedir. Eşkenar üçgenlerden oluşan izometrik ızgaralar, altı kat dönme simetrisiyle altıgenlere dönüşmektedir. Şekil 2.21'de oluşturulan geometrik desen, izometrik ızgara üzerine çoğaltılmıştır. Kırmızı çizgiler düzenli üçgenlerden yapılmış altıgen ızgarayı göstermektedir. İzometrik ızgara ile çoğaltılan geometrik desenlerde ızgara birleşim noktalarının 60 derece dönme simetrisi gösterirken her altıgen birim 120 derece ile 3 katlı dönme simetrisi sergilemektedir (Bonner, 2018).



Şekil 2.21. Geometrik desenin izometrik ızgara üzerinde gösterimi (Yazar tarafından oluşturulmuştur)


İzometrik ızgara, geometrik desenlerin oluşturulmasında önemli bir araç olarak kabul edilirken, özellikle İslami sanatın karmaşık desenlerini tasarlamak için uygun bir altlıktır. Daha basit üç katlı desenler doğrudan izometrik ızgaradan türetilebilirken, daha karmaşık modeller için ızgara yönünde ve ızgara çizgilerine dik olarak desen çizgilerine

yerleşebilmektedir (Bonner, 2017) Şekil 2.22, Bonner'in üç izometrik ızgara tasarımını göstermektedir. Bonner'in tasarımları, ızgara sistemiyle uyumlu bir şekilde üç ve altı katlı dönme simetri merkezlerine sahip birbirine kenetlenen (solda) , iç içe geçmiş desenler (orta) ve hem ızgaraya paralel hem de dik olan çizgiler kullanarak oluşturulmuştur (solda) (Bonner, 2017). Bu tasarımlar, düzgün çokgenler sisteminden de üretilebilmekte ve desen çizgileri öteleme simetrisi ile genişleterek artırılabilir.




Şekil 2.22. İzometrik ızgara tasarımları (Bonner, 2017)

Ortogonal ızgaralar ise, tasarım alanında yaygın olarak kullanılan güçlü bir diğer geometrik yapı olarak öne çıkmaktadır. Bu ızgaralar, her biri köşe noktalarından bağlanan 90 derecelik iç açılarla dört katlı simetriye sahiptir. Kare tekrar birimleri kullanan dört katlı desenler, üç katlı desenlere benzer şekilde simetri bölgelerini kullanmaktadır. Bu desenler, özellikle İslami sanatın karmaşık döşemelerinde sıkça görülmektedir (Bonner, 2017). Şekil 2.23 tasarımı oluşturmak için ortogonal ızgaranın kullanımını göstermektedir. Solda ortogonal ızgaranın (kırmızı) çizgi hizalarından ve orta noktalarının çapraz birleşimlerinden bir mozaik oluşturulmuştur. Sağa doğru desenin tamamlama aşamaları üç adımla gösterilmektedir. Bu dörtlü düğüm, motifleri tekrar eden bir kompozisyonla birbirine bağlanarak kesintisiz desen görünümünü oluşturur.



Şekil 2.23. 4 katlı modeli oluşturmak kullanılan ortogonal ızgara yöntemi (Yazar tarafından oluşturulmuştur)


Ortogonal ızgaradan üretilen tasarımlar sıklıkla dört katlı sistemin karakterine sahiptir. Şekil 2.24, yaygın olarak kullanılan dört katlı sistemden oluşturulan bir tasarımın ortogonal ızgara türevini göstermektedir. Şekil iç içe geçmiş sekizgenlerden oluşturulmuştur. Böylece, birbirine kenetlenen sekizgenler arasında kareler oluşturarak düzenli bir örgü yapısı elde edilmektedir. Bu anlamda ortogonal ızgara, hem tasarım seçeneklerini keşfetmek hem de belirli geometrik ilkeleri test etmek için pratik bir yöntem sunmaktadır.



Şekil 2.24. İzzettin Keykavus Türbesi ortogonal ızgara örneği (sol üstte, Hasan Fevzi Çüngen Arşivi'ne ait fotoğraf) (Özdemir ve diğerleri, 2022)


İzometrik ızgara ve ortogonal ızgaradan farklı olarak eşkenar dörtgenden oluşan ızgaralarla deseni oluşturmak mümkündür. Her eşkenar dörtgen, iki eşkenar üçgen oranına sahip bir tekrar birimi oluşturmaktadır. Bu yaklaşım, kenar uzunlukları ve açılarda yapılan

değişikliklerle, doğal oranları muhafaza ederek veya yeni oranlar oluşturarak, simetri ve orantısal özellikler açısından zengin, estetik ve işlevsel tasarımlar geliştirmeyi mümkün kılmaktadır. Ayrıca, birden fazla yerel simetri merkezine sahip olabilen ve geleneksel yöntemlerle uyumlu olmayan daha karmaşık yapıların oluşturulmasına olanak tanımaktadır. Bu esneklik, tasarımcılara belirli bir estetik veya işlevsel gereksinimi karşılayan özgün tasarımlar yaratma konusunda daha fazla esneklik sunmaktadır. Bonner, eşkenar dörtgen şemayı kullanan ızgaraları, 10 katlı dairelerin kat sayıları köşe açılarına denk gelecek şekilde sınıflandırmıştır. Şekil 2.25, A geniş eşkenar dörtgeni B ise dar eşkenar dörtgeni tanımlamaktadır. Böylelikle 10 kat dönme simetrisine sahip geometrik desenler için oluşturulan dörtgen ızgaralar tekrar birimini oluşturmaktadır (Bonner, 2017).




Şekil 2.25. Eşkenar dörtgen bir ızgara modelleri ve ilişkileri (Bonner, 2017)

Şekil 2.26 beş köşeli iç içe geçmiş iki yıldız desenin ızgara yapısını göstermektedir. Desen beşin katlarına dayalı bir altyapıya sahiptir. Tekrar birimi oluşturan eşkenar dörtgen dairenin 1/10'luk bölümü dar açı ve 3/10'luk bölümü geniş açıdan oluşmaktadır. Tekrar birimi kendi içinde 4 yönde ayna simetrisi özelliği taşımaktadır.



Şekil 2.26. Bir yıldız deseni için eşkenar dörtgen ızgara modeli (Yazar tarafından oluşturulmuştur)


Bununla birlikte, düzenli çokgen sisteminden oluşturulan bazı örnekler, altıgen ızgaralara dayanmaktadır. Düzgün altıgenlerin birbirine kenetlenmesiyle oluşturulan bu sistem, yüzeyin kesintisiz bir biçimde doldurulmasına olanak tanırken, aynı zamanda yıldız, rozet ve örgü motiflerinin üretimine uygun bir altyapı sağlamaktadır. Şekil 2.27’de yer alan üçlü desen dizisi, aynı altıgen ızgara temelinden yola çıkarak geliştirilen üç farklı desenin yapısını göstermektedir. Üst kısımlarda altıgen ızgara yapısı ve uygulanan desen çizgileri görülürken, alt kısımlar bu çizgiler doğrultusunda elde edilen sonuç desenleri sunmaktadır (Bonner, 2017).



Şekil 2.27. Temel altıgen hücrelerin farklı yönelimlerdeki çizgi uygulamalarıyla şekillenen geometrik kompozisyonlar (Bonner, 2017)


2.1.4. İGD’de modüler sistem tasarımı

Geometrik desenlerin biçimlenişi, büyük ölçüde uygulanan yapım yöntemine bağlıdır. Belirli bir desen, farklı üretim teknikleriyle benzer biçimde elde edilebilse de, tarihsel örneklerde hangi yöntemin tercih edildiğini kesin olarak saptamak her zaman mümkün değildir. Özellikle daha az karmaşık desenlerin birden fazla yolla inşa edilebilmesi bu durumu açıklamaktadır. Ayrıca, İslam sanatı geleneğinde üretim yöntemlerinde bilgilerin çoğunlukla ustadan çırağa aktarılarak korunması, günümüze ulaşan kaynakların sınırlı olmasına neden olmuştur (Bonner, 2017). Desen üretiminde kullanılan yöntemlerin anlaşılabilmesi için süreci; temel geometrinin belirlenmesi, taşıyıcı yapının kurulması ve uygulanan üretim tekniğiyle desenin ortaya çıkarılması olarak bileşenlere ayırmak mümkündür (Şekil 2.28) (Wang, 2012).




Şekil 2.28. Modüler sistem tasarımı için model çerçevesi

İslami geometrik desenlerin oluşturulma süreci, belirli özelliklere sahip formların, tanımlanmış değişkenler aracılığıyla sistematik biçimde işlenmesiyle yürütülür. Bu süreçte geometrik desenlere uygulanan değişkenler, tasarımın farklı aşamalarında yapının analizine ve varyasyon üretimine olanak tanımaktadır. Geometrik desen üretiminde, kalıplar içinde yer alan tekrarlayıcı kuralların tanımlanması, desenin mantıksal yapısını anlamada kritik bir rol oynamaktadır. Şekil 2.29'da, görsel ve yapısal kurallara dayalı desen üretim teknikleri değerlendirilmekte; özellikle tekrar eden modüller ve çoğalma stratejileri sınıflandırılmaktadır.




Şekil 2.29. Modüler sistem oluşumunda tüm olası çapraz referanslar

İslami geometrik desenlerin üretiminde, ızgara sistemleri motiflerin yönelimini ve yerleşim düzenini belirlemede önemli bir rol oynarken, modüler tekrar yapıları ayrıca altında yatan mozaikleme yapılandırmalarıyla ilişkilidir. Şekil 2.30 parametrik bir modülasyon sürecine dayalı olarak farklı temas açılarıyla elde edilen desen varyasyonlarını göstermektedir. İlk sütunda yer alan temel mozaikleme düzeni, giriş verisi olarak kullanılan üretici bir ızgara sistemini temsil eder. Bu iskelet yapısı, modül üretim sürecinde tekrarlamalı dönüşüm kurallarına tabi tutularak farklı geometrik çıktılar üretmektedir. Aynı çokgen mozaik yapısından türeyen desenler, yalnızca birleşim açılarındaki (45° , 60° , 75°) değişimlerle biçimsel çeşitlilik kazanmaktadır (Kaplan, 2002).



Şekil 2.30. Kareler, altıgenler ve onikigenlerden oluşan bir döşeme üzerinde çizgi açıları değiştirilerek elde edilen çeşitli desen tasarımları (Kaplan, 2002).


Bu bağlamda, poligonal teknik, belirli çokgen yapıların üretici desenlere dönüştürülmesini sağlayan etkili bir yöntem olarak öne çıkmaktadır (Bonner, 2003). Şekil 2.31, poligonal teknikle üretilen desenlerde çizgi yerleşiminin belirleyici rolünü ortaya koymaktadır. Süreç, üretici mozaikleme yapısındaki her bir çokgenin belirli kenar noktalarına desen çizgilerinin yerleştirilmesiyle başlar ve bu çizgiler, desen organizasyonunu sağlayan çokgen yapı üzerine sistematik olarak uygulanır. Çizgiler kimi zaman kenarların orta noktalarına, kimi zaman ise belirli oranlarda bölünmüş alt noktalarına yerleştirilmiştir. Bu temas açıları, desenin genel yapısını ve estetik karakterini doğrudan etkilemektedir.



Şekil 2.31. Aynı temel mozaikleme sistemi ve farklı üretici çizgi kurgularıyla elde edilen dört desen (Bonner, 2016)

Yüzeyin modüler parçalara ayrılarak yürütülmesi, üretkenliğe dayalı desen tasarımı sürecinin sistematik ve esnek bir biçimde ilerlemesini mümkün kılmaktadır. Bu yaklaşımda her bir modül, belirli bir geometrik birimi tanımlamakta ve dönüşüm işlemleri ile çoğaltılarak yüzey üzerinde yayılmaktadır.


Şekil 2.32, bir üçgen birimin sistemli biçimde döndürülmesi ve yansıtılmasıyla nasıl karmaşık yüzey mozaiklerinin üretilbildiğini göstermektedir. Başlangıçta temel biçimle başlayan süreç, her adımda artan çizgisel karmaşıklıkla birlikte daha yoğun geometrik yapıların ortaya çıkmasına neden olur. Bu yapıların her biri, üretici modülün sistematik dönüşümüne ve yeniden yerleştirilmesine dayanır. Modüler üretim süreci yalnızca tekrarlayan yapılar oluşturmakla kalmaz, aynı zamanda geometri kurallarının tanımlanmasına olanak tanır. Bu bağlamda, geometrik bilgilerin dönüşümüyle elde edilen her modül, yüzeydeki bütünsel yapıya katkı sunan ilişkisel bir bileşene dönüşmektedir.



Şekil 2.32. İGD P6 desenleri temel birim hücrelerden (temel etki alanı) yineleme modülünün üretim aşamaları (Yazar tarafından oluşturulmuştur)


Temel etki alanı, bir tasarımın minimal temel tekrarlayan bileşenidir. Dönme, yansıma ve kayma yansımasının tekil veya birleşik işlevleriyle, temel etki alanı tekrar birimini oluşturmaktadır. Daha basit geometrik kurgulara dayansa da birçok temel etki alanının oldukça sınırlı görsel bilgi içermesine rağmen başarılı sonuçlar üretmesi dikkat çekmektedir. Şekil 2.33, altıgen ızgaranın köşeleri üzerinde yer alan 6 köşeli yıldızlardan oluşan modeli göstermektedir. Bu desen için temel alan, tek bir desen çizgisi uygulanmış bir dik üçgendir (sağ alt). Bu temel birim alanı yansıtılır ve ardından tekrar birimini tamamlamak için

döndürülür. Tüm desen, altıgenin her bir kenarına dayalı olarak öteleme simetrisi alınarak oluşturulmuştur.



Şekil 2.33. İzzettin Keykavus Türbesi süsleme detayının temel birimi (sol üstte, Hasan Fevzi Çüngen Arşivi'ne ait fotoğraf) (Yazar tarafından oluşturulmuştur)


Tekrar birimlerinin oranları, düzenli çokgenlerle daha yaygın olarak ilişkilendirilen simetrilere de uyabilir. Bu şekilde, izometrik ve ortogonal ile sınırlı olmayan, daha yüksek dereceli yıldız formlarına sahip desenler oluşturmak mümkün olmuştur. Şekil 2.34 on köşeli yıldızlar yerleştirilerek bu eşkenar dörtgen tekrarlayan şemayı kullanan bir model sınıfının başarılı bir örneğini göstermektedir. Bu tasarımın temel alanı, öteleme simetrisine sahip eşkenar dörtgen tekrar birimini (mavi) oluşturmak için yansıtılan bir üçgendir (orta üst).



Şekil 2.34. Dar eşkenar dörtgen temel etki alanı ve tekrarlayan birim ilişkileri (solda, Hasan Fevzi Çüngen Arşivi'ne ait fotoğraf) (Yazar tarafından oluşturulmuştur)


Şekil 2.35, tekrar birimi geniş eşkenar dörtgene sahip deseni göstermektedir. Ortadaki birim hücre, iki dik yönde yansıma simetrisiyle çoğaltılarak tüm yüzeye yayılmıştır. Sağdaki şematik çizim, altta yatan üretici yapıyı ve yansıma eksenlerinin desendeki düzenleyici

rolünü ortaya koymaktadır. Böylece, tekrarlayan hücrelerin bir araya gelmesiyle hem görsel süreklilik hem de yapısal denge sağlanmaktadır.



Şekil 2.35. Geniş eşkenar dörtgen temel etki alanı ve tekrarlayan birim ilişkileri (solda, Hasan Fevzi Çüngen Arşivi'ne ait fotoğraf) (Yazar tarafından oluşturulmuştur)


Şekil 2.36, ortogonal ızgaranın köşelerine ve dört katlı çaprazları bu ızgaranın ikilisinin köşelerine yerleştiren klasik dört katlı yıldız modelini göstermektedir. Temel birim, yalnızca iki karenin tek bir birimidir. Temel alanın iki farklı ekseninde aynalanması, kare tekrar birimi tamamlamaktadır.



Şekil 2.36. Ortogonal temel etki alanı ve tekrarlayan birim ilişkileri (Yazar tarafından oluşturulmuştur)

İslami geometrik desenlerde modül üretiminin yolu, onların yaygın sayısal niteliklerini hesaba katmaktır. Bu tasarım geleneğindeki değişkenler nedeniyle, bu tür bir üretim kategorize edilirken, n-kat dönüş simetrisine sahip karakteristik yıldız formlarında bulunan

noktaların sayısı özellikle önemlidir. Şekilde kompozisyonun merkezinde ve alt iki köşede turkuaz renkli beş köşeli yıldızlar görülür. Desen beşin katlarına dayalı bir altyapıya sahiptir. Desen bir 10 köşeli bir poligonun merkez aksından ışımsal ızgara sistemiyle genişlemektedir. Desenin oluşum aşamaları altı adımda ifade edilmektedir. Bir ongen merkez aksını takip edecek şekilde 36° açıyla ayna görüntüleri alınarak çoğaltılmıştır. İkinci aşamada ise her birleşim noktasından aynı açı derecesi ile doğrular çizilir. Desenler daha karmaşık hale geldikçe, sayısal niteliklerinin tanımlanması, belirli bir tasarımın belirli niteliklerini ayırt etmek ve bu geleneğin genel olarak kapsamını ve potansiyelini nitelendirmek için yararlı bir araç haline gelir. Yıldız formlarına ek olarak, birçok desen, düzenli çokgenleri içerecektir. Bu, özellikle düzenli çokgen özellikler ile n-katlı yıldızlar arasında ayırım yapılmasına yardımcı olmaktadır.














Şekil 2.37. Süsleme detayının analizi (Yazar tarafından oluşturulmuştur)






İGD'in alt yapılarını ve geometrik tasarım yöntemlerini takip etmek için İzzettin Keykavus Türbesi'ne ait desenlerin analizleri bir çizelge halinde (Çizelge 2.1) sunulmuştur. Böylelikle çalışmada modelin yapılandırılması; alt yapılar, tekrarlayan birimler ve modelin

geniřletilmesi ile incelenmekte ve karřılařtırılmaktadır. Ayrıca, desenlerin oluřturulmasında uygulanan adımların daha kapsamlı bir řekilde algılanmasını saęlamak için, motiflerin simetri yönleri, tekrar eden birimler gösterilmiřtir.











Çizelge 2.1. İzzettin Keykavus Türbesi'ne ait desenlerin İGD modüler sistem analizleri (solda, Hasan Fevzi Çüçen Arřivi'ne ait fotoęraflar) (Özdemir ve dięerleri, 2022)

	Geometrik desen	Temel birim	Tekrarlayan birim	Simetri özellikleri
1				Desenin düzenli tekrarı yoktur. (Penrose) Tekrarlayan birimler alternatif iki kafese aittir.
2				Desen 60 ° dönüş merkezine sahiptir. Ayrıca yansıma simetrileri görülür.
3				Tekrarlayan birim alternatif desene aittir. İki dik yönde yansımaları mevcuttur.
4				Desen 60 ° dönüş merkezine sahiptir. Ayrıca yansıma simetrileri görülür.
5				Desende iki yöne dik yansıma görülür. 180 ° dönüş merkezine sahiptir.

Çizelge 2.1. (devam) İzzettin Keykavus Türbesi'ne ait desenlerin İGD modüler sistem analizleri (solda, Hasan Fevzi Çüngen Arşivi'ne ait fotoğraflar) (Özdemir ve diğerleri, 2022)

Geometrik desen	Temel birim	Tekrarlayan birim	Simetri özellikleri
6			Desende iki yöne dik yansıma görülür. 180 ° dönüş merkezine sahiptir.
7			Desen 60 ° dönüş merkezine sahiptir. Ayrıca yansıma simetrisi görülür.
8			Desen 60 ° dönüş merkezine sahiptir. Ayrıca yansıma simetrisi görülür.
9			Desen 60 ° dönüş merkezine sahiptir. Ayrıca yansıma simetrisi görülür.
10			Desen 60 ° dönüş merkezine sahiptir. Ayrıca yansıma simetrisi görülür.

Çizelge 2.1. (devam) İzzettin Keykavus Türbesi'ne ait desenlerin İGD modüler sistem analizleri (solda, Hasan Fevzi Çüçen Arşivi'ne ait fotoğraflar) (Özdemir ve diğerleri, 2022)


	Geometrik desen	Temel birim	Tekrarlayan birim	Simetri özellikleri
11				Desen 60 ° dönüş merkezine sahiptir.
12				Dört yönlü yansıma simetrileri görülür.
13				Desen 90 ° dönüş merkezine sahiptir.
14				Desen 60 ° dönüş ile altı kattan oluşur. Yansıma ve kayma simetrisi bulunmaz.
15				Desen yalnızca kayma yansımaları içerir.

2.2. Yapay Zeka ve Makine Öğrenmesi

Yapay zeka (YZ), insan zekası ile bağdaştırılan görevleri gerçekleştirebilen makinelerin geliştirilmesini ifade etmektedir. Başka bir açıdan, yapay zeka, çevresini anlayıp hedeflerine ulaşmak için stratejik eylemler gerçekleştiren ve akıllı davranışlar sergileyen yapay varlıkların tasarlanması süreci olarak tanımlanabilir (Poole ve Mackworth, 2010). Bu doğrultuda, makinelerin insanlar gibi anlama, hareket etme, konuşma, düşünme ve öğrenme yeteneğine sahip olmalarını sağlamak amacıyla yapay zeka yazılımları geliştirilmiştir.

Bilgisayarların hayatımıza girmesiyle birlikte ortaya çıkan ‘yapay zeka’ terimi ilk olarak, 1956 yılında John McCarthy tarafından Dartmouth Konferansı’nda ortaya atılmıştır (Moor, 2006). Bu kavram, Alan Turing’in 1950’de yayımladığı “*Computing Machinery and Intelligence*” adlı çalışmasında (Turing, 1950) ortaya koyduğu makine zekâsı üzerine temel fikirlerden yaklaşık altı yıl sonra şekillenmiştir. Turing’in çalışmaları, makinelerin düşünme kapasitesine sahip olup olamayacağı sorusunu gündeme getirerek, insan benzeri sohbet sistemleri ve daha ileri yapay zekâ araştırmaları için bir temel oluşturmaktadır. “Makineler düşünebilir mi?” sorusunun çıkış noktası, insan özelliklerini taklit edebilmesi, örneklerden öğrenebilmesi, yeni bilgilere dayalı muhakeme yapabilmesi ve verilere dayalı sonuçlar çıkarabilmesi fikrine dayanmaktadır. Bu bağlamda YZ, yalnızca insanlar gibi düşünen ve davranan sistemleri değil, aynı zamanda bilgiyi rasyonel biçimde işleyen ve insan zekâsı gerektiren görevleri yerine getiren sistemleri de kapsamaktadır. Kaplan ve Haenlein (2019) yapay zekayı, olası çözümleri hızlı ve kapsamlı bir şekilde değerlendirme, aşamalar arasında yeni ilişkiler kurma ve tahmin yürütme kapasitesiyle, sistemlerin esnek adaptasyon yeteneği üzerinden tanımlamaktadır (Haenlein ve Kaplan, 2019).

1950’li yıllardan itibaren geliştirilmeye başlanan yapay zeka uygulamaları, 1960’lı yıllarda yapay sinir ağları ile yapılan çalışmalarla birlikte önemli bir gelişme kaydetmiştir. Bu gelişmeler devamında, 1990’lı yıllarda insan zekası seviyesindeki performansa ulaşan ve giderek daha karmaşık problemlerin çözümünde kullanılan makine öğrenmesi (Machine Learning/ ML) çalışmaları takip etmiştir (Belém, 2019). 2010’larda ise çok katmanlı derin sinir ağlarının geliştirilmesiyle birlikte derin öğrenme modellerine giriş yapılmıştır (Krizhevsky, Sutskever ve Hinton, 2017). Yapay zekanın bir alt dalı olan makine öğrenimi (ML), istatistiksel algoritmalar kullanarak talimatları yerine getirmektedir. Makine öğrenmesinin bir parçası olan temsil öğrenimi ise, makinenin veri özelliklerini doğrudan öğrenmesine ve kullanmasına olanak tanırken; temsil öğreniminin alt kümesi olan derin öğrenme bu özellik çıkarımını çok katmanlı yapılar aracılığıyla gerçekleştirmektedir (Deng ve Yu, 2014). Bu ilişkileri ifade eden yapay zeka teknolojisi diyagramı Şekil 2.38’de gösterilmektedir.



Şekil 2.38. Yapay zeka disiplinleri arasındaki ilişki diyagramı (Goodfellow, Bengio ve Courville, 2016)’ dan uyarlanmıştır.


Bir yapay zeka dalı olarak makine öğrenmesi, son yıllarda kaydedilen gelişmelerle beraber daha çok dikkat çekmektedir. Literatürde farklı tanımları bulunan bu alan, ilk kez Arthur Samuel tarafından “bilgisayarlara açıkça programlanmadan öğrenme yeteneği kazandıran bir çalışma alanı” olarak tanımlanmıştır (Samuel, 1959). Ethem Alpaydın ise makine öğrenmesini "örnek verileri veya geçmiş deneyimleri kullanarak bir performans kriterini optimize etmek için bilgisayarları programlama" olarak ifade etmektedir (Alpaydın, 2009). Donald Michie, makinelerin yürütme sırasında programdan öğrenerek verimliliği artırmak için yararlı bilgileri otomatik olarak keşfedebileceğini belirtmiştir (Michie, Spiegelhalter, Taylor ve Campbell, 1994).

Makine öğrenimi süreci, verilerdeki kalıpları analiz ederek başlar ve bu bilgiler gelecekteki kararlar için kullanılır. Veriden öğrenebilen algoritmalar üzerine odaklanan makine öğrenmesi, bu yönüyle “istatistiksel öğrenme” olarak da adlandırılmaktadır (Hastie, Tibshirani, Friedman ve Franklin, 2009). Çoğu durumda, bir sistemin istenen girdi ve çıktı davranışlarını örneklerden öğrenmesi, girdiden çıktıya ulaşmanın tam mantığını manuel olarak tanımlamaktan daha kolay kabul edilmektedir. Bu özellik, makine öğrenmesini geleneksel istatistiksel yöntemlerden ayıran temel unsurlardan biridir (Liu, 2019).

Yapay zekanın geleneksel yaklaşımlarının aksine, makine öğrenmesindeki veri odaklı yaklaşımlar, bilgisayar sistemlerinin belirli görevleri gerçekleştirmek için programlanmasına gerek kalmadan çalışmasını sağlamaya odaklanmıştır. ML, eğitim verisi olarak bilinen örneklenmiş verilerden öğrenmek için matematiksel algoritmalara ihtiyaç

duymaktadır. Böylece geçmiş deneyimlerden öğrenerek anlamlı çıkarımlar yaparak müdahale gerektirmeden belirli görevlerdeki performansını zamanla iyileştirmektedir (Belém, 2019). Makine öğrenimi algoritmaları, her bir bilgi parçası bir özellik olarak adlandırılan veri temsiline büyük ölçüde bağımlıdır. Böylelikle doğru özellik kümelerini tasarlamak birçok problemi çözmek için kullanılabilir (Aggarwal, 2018). Eğitimde kullanılan veriler, sadece mevcut girdilerle sunulduğunda beklenen sonuçları elde edemeyebilir, ancak yapılandırılmış ve optimize edilmiş veriler istenen sonuçlara ulaşma potansiyeli taşıyabilmektedir (Naqa, Li ve Murphy, 2015).


Sonuç olarak, bir ML sisteminin başarısı, verilen bir eğitim setine dayanarak doğru bir şekilde öngörmesine veya karar vermesine bağlıdır (Hastie ve diğerleri, 2009). Şekil 2.39 'ta gösterildiği üzere, genel ML iş akışında model önce bir eğitim veri seti üzerinde eğitilmekte, ardından yeni veriler üzerinden tahmin ve karar verme süreçlerinde kullanılmaktadır (Alpaydin, 2009). Eğitim için toplanan veriler, uygun bir modelde belirlenmiş sayıda giriş özelliği ile çalıştırılmaktadır. Eğitim aşamasında sistem, model üzerinde çalıştırılarak çıktıları tahmin etmeyi öğrenir. Değerlendirme aşamasında ise modelin ürettiği tahminler, ayrı bir test verisi ile karşılaştırılarak doğruluk kontrolü yapılır. Böylece sistem, istatistiksel hesaplamalar yoluyla kendi kendine öğrenme kapasitesi kazanmaktadır.



Şekil 2.39. ML algoritmasının çalışma prensibi

Sorunun karmaşıklığı ve içerdiği özelliklerin sayısı arttıkça, makine öğrenimi sürecinde bağlantıları izlemek ve doğru modelleme yapmak güçleşmektedir. Bu noktada, çıktının değerlendirilmesi kullanıcı tarafından belirlenen performans kriterlerine ve görevi oluşturan özelliklerin doğru seçimine bağlıdır (Özgenel, 2018). Problemin özellikleri ve sahip

olunmak istenen deneyim ML yaklaşımının tipini belirlemektedir. Bu kapsamda makine öğrenme sürecinde sistem, görevlere ve eğitim verilerinin yapılarına göre farklı kategorilerde tanımlanmıştır. Şekil 2.40'ta görüldüğü gibi ML yöntemleri, denetimli öğrenme, yarı pekiştirmeli öğrenme ve denetimsiz öğrenme olarak alt kategorilere ayrılmaktadır. Her kategori farklı görevlerde kullanılan algoritmalarından oluşmaktadır.



Şekil 2.40. Makine öğrenimi algoritmalarının kategorileri (Singh, Kumar, Payra ve Singh, 2023)'ten uyarlanmıştır.

Denetimli öğrenme, en yaygın kullanılan makine öğrenimi yöntemidir (Hastie ve diğerleri, 2009). Bu yaklaşımda algoritmalar, girdi ile çıktı arasında bir eşleme kurabilmek için, her girdinin uzmanlar tarafından etiketlendiği bir eğitim seti ile eğitilmektedir. Böylece, her biri ilgili kategoriyle etiketlenmiş, çeşitli nesnelere sahip bir görüntü koleksiyonu ile girdi ve çıktı arasında doğru bir eşleme yapabilmesi için gerekli bilgi sağlanır (Hasan, 2023). Daha sonra algoritma, tahmin edilen çıktıları doğru etiketlerle karşılaştırarak hataları bulup bunları bir kayıp fonksiyonu aracılığıyla ölçer. Kayıp fonksiyonu, öngörülen çıktılar ile gerçek etiketler arasındaki farkı hesaplar ve algoritma, bu hataları minimize ederek ve performans ölçütlerini artırarak, girdileri etiketleriyle doğru bir şekilde eşleştiren kalıpları öğrenir. Bu süreç, algoritmanın daha doğru tahminler yapabilmesi için sürekli olarak kendini geliştirmesini sağlamaktadır (Liu, 2019). Denetimli öğrenmede regresyon ve sınıflandırma gibi görevler yerine getirilmektedir. Sınıflandırmada, algoritmanın girdilerin hangi sınıfa ait olduğunu tahmin etmesi beklenirken; regresyonda, çıktılar sayısal değerler olarak öngörülür (Goodfellow ve diğerleri, 2016). Bu görevler kapsamında Destek Vektör Makineleri, Bayes

ağları, K-en yakın komşu, Lineer Regresyon, Lojistik Regresyon, Karar Ağaçları gibi modeller yaygın olarak kullanılmaktadır.

Yarı denetimli öğrenme, hem etiketli hem de etiketsiz verileri birleştirerek modelin genel performansını iyileştirmeyi amaçlayan bir makine öğrenmesi türüdür (Chapelle, Scholkopf ve Zien, 2009). Bu yaklaşım, denetimli öğrenme algoritmalarına bir alternatif olarak, etiketsiz verilerden elde edilen ek bilgilerden yararlanmakta ve karar sınırının yüksek yoğunluklu bölgelerden kaçınmasına olanak tanımaktadır. Denetimli algoritmalarda etiketli veriler, veri noktalarını düşük yoğunluklu bölgelerle ayırabilme özelliğine sahiptir. Ancak yarı denetimli algoritmalar, etiketlenmemiş verilerden yararlanarak iki sınıf arasındaki karar sınırının şekli hakkında ek bilgi sağlayabilmektedir (Hasan, 2023). Yarı denetimli öğrenme sürecinde, etiketli veriler üzerinde yapılan eğitimin ilerleyen aşamalarında veri modeline göre etiketsiz verilerin bir kısmı etiketlenmekte ve ardından bu yeni etiketli veriler kullanarak yeniden eğitilmektedir (Chapelle ve diğerleri, 2009). Böylelikle, etiketlenmemiş verilerin etiketlerini tahmin etmek için mevcut etiketli model kullanılmış olur. Bu yöntem, büyük veri setlerini manuel olarak etiketleme gereksinimini ortadan kaldırarak, zaman ve maliyet tasarrufu sağlamakta ve modelin performansını artırmaktadır (Abed jooy Divshali, 2022).

Denetimsiz öğrenme, veri kümelerindeki bilgi çıkarmaya yönelik örüntüleri sınıflandırılmış veya etiketlenmiş veri noktalarına ihtiyaç duymadan bulabilen bir makine öğrenmesi türü olarak ifade edilmektedir. (Barlow, 1989). Bu algoritmalar, verileri gruplandırmak veya etiketlemek için herhangi bir denetim gerektirmemektedir. Bu nedenle, algoritmalar girdi setindeki yapıyı kendi başlarına tanıyarak benzerliklere ve farklılıklara dayalı olarak veri noktalarını kümeleyecek şekilde çalışır. Böylelikle bir eğitim sürecinde verilere ilişkin herhangi bir hedef bulunmaksızın veri kümesindeki ortak özellikleri belirlemeye çalışır (Goodfellow ve diğerleri, 2016). Denetimsiz öğrenme yöntemleri, etiketlerin gözlemlenemez veya elde edilmesinin mümkün olmadığı durumlarda algoritmanın daha önce düşünülmemiş kalıpları aramasını sağladığı için avantajlı olmaktadır. Bu öğrenme görevi verilerin belirli gruplar halinde organize etme, kümeleme, verileri arındırma ve sonuç olarak öngörülemeyen veri noktaları için öngörülerde bulunmayı amaçlamaktadır. Hiyerarşik kümeleme, K-ortalamlar ve Temel bileşen analizi modelleri gibi algoritmalar, denetimsiz öğrenmede verilerin yapısını anlamak ve bu verilerdeki yararlı özellikleri ortaya çıkarmak için yaygın teknikler olarak kullanılmaktadır (Gupta ve Chandra, 2020). Buna ek

olarak, pekiştirmeli öğrenme gibi yaklaşımlar, ödül-ceza mekanizmaları ile karar verme süreçlerini yönlendirmektedir. Her bir öğrenme tipi, farklı veri yapıları ve problem türleri için uygun algoritmalar sunarak, makine öğreniminin geniş bir uygulama yelpazesine sahip olmasını sağlamaktadır (Shakya, Pillai ve Chakrabarty, 2023).


2.3. Derin Öğrenme

Derin öğrenme (DL), makine öğrenmesinin bir alt dalı olarak, verilerden temsilleri hiyerarşik olarak türeterek öğrenmeyi amaçlamaktadır. Bu yaklaşım, bilgisayarların basit kavramlardan daha karmaşık kavramlar inşa etmesini sağlayarak hem tahmin doğruluğunu artırmakta, hem de büyük veri kümelerinden etkin bir şekilde öğrenme olanağı sunmaktadır (Goodfellow ve diğerleri, 2016). Geleneksel ML teknikleri ise, verilerin temsiline bağlı olarak sınırlı işleme kapasitesine sahiptir. Görevler için hangi özelliklerin çıkarılması gerektiğinin belirlenmesi, algoritmaların performansı açısından kritik bir aşamayı oluşturmakta ve bu durum önemli ölçüde alan uzmanlığı gerektirmektedir (LeCun, Bengio ve Hinton, 2015). Derin öğrenme yaklaşımlarının avantajı, öğrenilen temsillerin genellikle elle tasarlanmış temsillere göre hem performans hem de süre açısından üstünlük sağlamasıdır. Bir temsil öğrenme algoritması, görev için kısa süre içinde iyi bir özellik kümesi bulabilirken bunun manuel olarak elde edilmesi çok daha fazla zaman almaktadır.

Derin öğrenme algoritmaları ise, ML yaklaşımlarından farklı olarak çoklu temsil seviyelerine sahip olan ve otomatik olarak özellik çıkarımı sağlayan yöntemlerdir. Bu yöntemlerde dönüşüm katmanları, verilerin altında yatan özellik faktörlerini her katmanın çıktısı bir sonraki katmana öğrenme verisi olarak iletilecek şekilde çıkarmaya çalışır. Son katmanın çıktısı olan temsiller ise farklı görevler için bilgi olarak kullanılmaktadır. Böylelikle DL, yalnızca karmaşık veri temsilleri oluşturabilen değil, aynı zamanda insan müdahalesine daha az bağımlı, yarı otonom bir öğrenme yaklaşımı olarak tanımlanabilmektedir (Najafabadi ve diğerleri, 2015). Büyük miktarda veri söz konusu olduğunda; derin ağlar görüntü tamamlama, üretme, sınıflandırma gibi alanlarda kullanıldığında önemli sonuçlar elde edilebilmektedir. Bu bağlamda, derin otokodlayıcılar, evrişimli sinir ağları ve çekişmeli üretici ağlar gibi ağ mimarileri yaygın bir biçimde kullanılmaktadır.

2.3.1. Yapay sinir ağıları


Yapay sinir ağıları (ANN), biyolojik organizmaların öğrenme süreçlerini kavramsal düzeyde taklit ederek öğrenme yeteneğini simüle eden önemli hesaplama yöntemlerinden biridir. Bu kapsamda; insan benzeri problem çözme becerilerine sahip makineler geliştirme çabaları, beynin işlevlerinin matematiksel ve hesaplamalı modeller aracılığıyla modellenmesini sağlamıştır. 1943 yılında McCulloch ve Pitts ANN araştırmalarının ilerlemesine katkı sağlayan ilk hesaplama modelini önermişlerdir. ANN'ler insan beyninin işleyişini modellemek amacıyla nöron adı verilen bağlı birimlerden oluşan matematiksel ve hesaplamalı modellerden oluşmaktadır. Tipik bir ANN, girdi katmanını, bir veya daha fazla gizli katman ve çıkış katmanından meydana gelmektedir. Şekil 2.41'de, en solda girdi katmanının özellikleri çıkış katmanına ilettiği bir temel ANN mimarisi gösterilmektedir (Abed jooy Divshali, 2022). İki nöron arasındaki bağlantı, önceki nöronun diğerini ne kadar etkileyeceğini tanımlayan bir ağırlığa sahiptir. Girdi katmanındaki x_1, x_2, x_3 gibi özellikler, bu girdilere karşılık gelen w_1, w_2, w_3 ağırlıkları ile çarpılarak işlenmektedir. Tek katmanlı bir ağ, sadece bir hesaplama katmanını içerir ve aktivasyon fonksiyonu ile hesaplanarak çıkış düğümüne bağlanır. Bu değer bağımlı değişken girdi özelliklerini tahmin etmek için kullanılmaktadır (Aggarwal, 2018).



Şekil 2.41. Yapay sinir ağlarında bir nöronun şematik görüntüsü (Liu, 2019)' dan uyarlanmıştır

Çok katmanlı sinir ağlarında ise nöronlar katmanlı bir şekilde düzenlenmekte ve birden fazla hesaplama katmanını içermektedir. Girdi ve çıktı katmanlarına ilave olarak bir grup gizli ara katman bulundurulur. Her nöron, bir önceki katmandaki tüm nöronlarla tamamen bağlantılıdır. Tek katmanlı sinir ağından farklı olarak, çok katmanlı ağlarda ağırlıklar karmaşık bir birleşim fonksiyona sahiptir. Bu nedenle, hata gradyanının hesaplanmasında geri yayılım algoritmasından yararlanılmakta; böylece bağlantılar arasındaki yollar üzerinde

gradyanların dinamik programlama yöntemleriyle verimli biçimde hesaplanması sağlanmaktadır (Aggarwal, 2018). Sinir ağının bu katman bazlı mimari tasarımı ileri ve geri aşamalı ağ olarak iki aşama içermektedir. İleri besleme aşamasında, girişler ilgili ağırlıklarla çarpılarak ve sapma parametresi eklenerek gizli katmanlardan geçirilir. Her katmanda elde edilen ağırlıklı toplam, aktivasyon fonksiyonları aracılığıyla dönüştürülerek çıkış katmanına iletilir. Böylece ağ, girdi özelliklerinden hedef çıktıları üretir (Liu, 2019). Geri yayılma aşamasında ise (Linnainmaa, 1970) kayıp fonksiyonu aracılığıyla öngörülen çıktılar ile gerçek değerler arasındaki fark hesaplanır. Bu hata, gradyan inişi yöntemi ile ağın ağırlıklarını güncellemek üzere geriye doğru dağıtılır. Böylelikle kayıp fonksiyonunu minimuma ulaşıncaya kadar geriye doğru ilerlemektedir (Liu, 2019). Şekil 2.42’de iki gizli katmana ve tek bir çıkış katmanına sahip tipik bir ANN algoritmasının genel yapısı gösterilmektedir.




Şekil 2.42. İki gizli katmana ve tek bir çıkış katmanına sahip bir ANN algoritmasının genel yapısı (Liu, 2019)’ dan uyarlanmıştır.

Genel olarak bahsetmek gerekirse ANN’ler, bilgi özelliklerini toplayarak, öğrenme sürecinde girişler ile çıkışlar arasındaki ilişkileri keşfetmektedir. Hesaplamalar ileri doğru ilerledikten sonra, çıkış katmanında kayıplar hesaplanmakta ve geri yayılım ile giriş katmanına doğru iletilmektedir. Böylece, ağırlıklar kayıp fonksiyonlarını optimize etmek amacıyla güncellenip ve sonuçlar iyileştirilmektedir.

2.3.2. Evriřimli sinir aęları

Evriřimli sinir aęları (CNN), konvolüsyonel katmanları kullanan yapay sinir aęları olarak, derin öğrenme mimarilerinin temelini oluşturmaktadır. Geleneksel yapay sinir aęlarından farklı olarak, CNN'ler veriden otomatik özellik çıkarımı yapabilme kapasitesiyle, görüntü analizi ve desen tanıma alanlarında yaygın bir şekilde kullanılmaktadır (Shen, 2021). 1980'li yıllarda ilk olarak sınıflandırma amacıyla kullanılan CNN'ler (LeCun ve dięerleri, 1989), 2012 yılında, Krizhevsky öncülüęünde AlexNet (Krizhevsky, Sutskever ve Hinton, 2012) derin öğrenme modeli ile daha yaygın bir şekilde benimsenmiştir. CNN mimarileri, nesne tanıma gibi karmařık görevlerde farklı veri setlerine uyum sağlayabilmeleri için ön bilgiye dayalı özellikleri öğrenme kapasitesiyle öne çıkmaktadır. Önemli avantajlarından biri ise, tam baęlantılı yapılar yerine yalnızca küçük yerel bölgeler üzerinde işlem yapmalarındır. Evriřim katmanları, giriş verisinin tamamı yerine sınırlı alanlardan bilgi çıkararak hem parametre sayısını azaltmakta hem de öğrenme sürecini daha verimli hale getirmektedir (Krizhevsky ve dięerleri, 2012).


CNN mimarileri, evriřimsel katmanlar, tam baęlantılı katmanlar, ReLU (Rectified Linear Unit) katmanları, havuzlama katmanları olarak ana katmanlardan oluşmaktadır (Krizhevsky ve dięerleri, 2012; LeCun ve dięerleri, 2015). Evriřimli katmanlar, CNN modelindeki hesaplamaların büyük kısmını oluşturmaktadır. Bu katmanlar yükseklik, genişlik ve derinliğe sahip bir ızgara yapısı ile ifade edilir (Aggarwal, 2018). Her katmanda, görsel örüntüleri tespit etmek üzere öğrenebilir çeřitli filtreler yer alır. Bu filtreler, giriş görüntüsü üzerinde farklı bölgelerde kayarak belirli görsel özellikleri yakalamaktadır (Zhou, 2017). Filtrelerin boyutu genellikle görüntünün tamamından çok daha küçüktür ve aynı filtre görüntünün farklı alanlarında tekrar tekrar uygulanır. Bu işlem sırasında, filtre ile görüntünün ilgili bölgesinin deęerleri çarpılır ve elde edilen sonuçlar toplanarak yeni bir özellik deęeri oluşturulur. Her adımda elde edilen bu deęerler, aktivasyon fonksiyonları yardımıyla işlenir. Bu fonksiyonlardan evriřimli katmanda genelde ReLU (Nair ve Hinton, 2010) ve Leaky ReLU (Maas, Hannun ve Ng, 2013) kullanılmaktadır. CNN iş akışının temsili Şekil 2.43'te gösterilmektedir.



Şekil 2.43. Genel bir CNN mimarisi (Hasan, 2023)’ten uyarlanmıştır.

Evrişim ve aktivasyon katmanlarının ardından gelen, havuzlama katmanları temsillerin uzamsal boyutunu azaltmak için kullanılmaktadır. Bu işlem, modeldeki parametre sayısını önemli ölçüde düşürerek hem hesaplama yükünü azaltır hem de öğrenilen özelliklerin daha verimli bir şekilde aktarılmasını sağlar (Dumoulin ve Visin, 2016; Goodfellow ve diğerleri, 2016). CNN mimarisinin sınıflandırma aşamasında ise tam bağlantılı katmanlar, her nöronun bir önceki katmandaki nöronlara bağlı olduğu geleneksel yapay sinir ağlarına benzer şekilde çalışmaktadır. Evrişim ve havuzlama katmanlarından elde edilen çıktılar, giriş görüntüsünün özelliklerini yakalamakta ve bu özellikler tam bağlantılı katmandaki nöronlara iletilmektedir. Böylece, sınıflandırma görevlerinde model bu özellikleri kullanarak görüntüyü sınıflara ayırmaktadır (Zhou, 2017).

CNN’ler yalnızca sınıflandırma görevlerinde değil, aynı zamanda görüntü tamamlama, yeniden yapılandırma ve dönüşüm odaklı görevlerde de kullanılmaktadır (Badrinarayanan, Kendall ve Cipolla, 2017; Pathak, Krahenbuhl, Donahue, Darrell ve Efros, 2016; Ronneberger, Fischer ve Brox, 2015). Bu kapsamda, kodlayıcı–kodçözücü mimariler öne çıkmaktadır. Encoder kısmı, giriş görüntüsünden çok katmanlı evrişimsel işlemler ile öznitelik çıkarımı yaparken; decoder kısmı bu öznitelikleri kullanarak görüntüyü yeniden üretmekte veya dönüştürmektedir (Badrinarayanan ve diğerleri, 2017). U-Net gibi yapılar, görüntüleme ve segmentasyon alanlarında yaygın olarak kullanılan kodlayıcı–kodçözücü tabanlı CNN mimarilerine örnektir (Ronneberger ve diğerleri, 2015). İki aşamadan oluşan U-Net ağ yapısı, önce görüntüyü kademeli olarak küçülterek genel düzeni ve ilişkileri öğrenmekte, ardından çözünürlüğü artırılarak piksel düzeyinde çıktı üretmektedir. Aşamalar arasındaki bağlantılar, ilk kısımda zayıflayabilecek kenar ve sınır bilgisini karşı tarafa taşımakta; böylece hem bütünlük hem ayrıntı korunmaktadır (Şekil 2.44).




Şekil 2.44. U-Net mimarisi (Ronneberger ve diğerleri, 2015)

2.3.3. Çekişmeli üretici ağlar

Çekişmeli üretici ağlar (GANs), evrimsel sinir ağlarının kullanımında yeni bir gelişmeyi temsil eden derin öğrenme algoritmaları içerisinde yer almaktadır. 2014 yılında Goodfellow ve diğerleri (Goodfellow ve diğerleri, 2014), sinir ağlarını kullanarak farklılaştırılabilir bir üretici ağına dayanan ve karmaşık veri dağılımlarından rastgele örnekler üretmeyi amaçlayan bir çerçevede GAN'ları önermiştir. Denetimsiz öğrenme teknikleri arasında yer alan GAN'lar, görüntü üretiminde CNN'lerden yararlanarak geleneksel sınıflandırma görevlerine kıyasla yenilikçi bir uygulama sunmaktadır (Radford, Metz ve Chintala, 2016).

Mevcut verilerden öğrenerek yeni örnekler oluşturmak için kullanılan ağlar üretici ve ayırıcı olarak iki derin ağ yapısından oluşmaktadır. Eğitim sürecinde, üretici orijinal veriyi taklit eden algılanabilir sahte örnekler üretirken, ayırıcı ağ ise orijinal veri ile üretici tarafından üretilen sahte veri arasında ayırım yapmaya çalışmaktadır. Şekil 2.45'te gösterildiği gibi üretici (G) giriş olarak bir gürültü vektörü (Z) almaktadır. Çıkışta ise sentezlenmiş sinyaller ile sahte örnekler oluşturur. Ayırıcı (D) ise hem üreticiden sahte hem de eğitim verilerinden orijinal verilerle karşılaşır. Sinyaller ayırıcı tarafından gerçeklik oranına göre 1.0 (gerçek) ya da 0.0 (sahte) olarak işaretlenmektedir (Liu, 2020). Daha sonra ayırıcının üreticiye verdiği puanlar doğrultusunda yeni veriler üretilir. Böylece üretici ve ayırıcı dönüşümlü olarak eğitilmektedir. Eğitim sırasında, ayırıcı doğru etiketi atama olasılığını maksimize etmek için çalışırken, üretici de aynı anda kayıp değerini minimize etmeye odaklanır (Creswell ve

diğerleri, 2018). Böylelikle üreticinin gittikçe daha gerçekçi örnekler üretmeyi, ayırıcının da ayırmada daha iyi öğrendiği bir süreç elde edilmiş olur. Modelin başarıya ulaşabilmesi için, üreticinin, eğitim verileriyle aynı dağılımdan gelen ve ayırt edilemeyen örnekler oluşturmayı öğrenmesi gerekmektedir.



Şekil 2.45. Standart GAN model mimarisi (Iglesias, Talavera ve Díaz-Álvarez, 2023)’ten uyarlanmıştır.

Tüm bu sistem aşağıdaki denklem (Goodfellow ve diğerleri, 2014) ile optimize edilir:

$$\min_G \max_D V(G, D) = \mathbb{E}_{x \sim P_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim P_Z(z)} [\log (1 - D(G(z)))] \quad (2.1)$$

Burada, $V(G;D)$ değer fonksiyonu iki oyunculu bir oyun olarak tanımlanmaktadır. G fonksiyonu, rastgele sayılardan oluşan bir z vektörünü girdi olarak almakta ve $G(z)$ ile sahte görüntüler üretmektedir. $D(x)$, girdinin gerçek veri dağılımı P_{data} ’dan mı yoksa üreticinin oluşturduğu dağılım P_z ’den mi geldiğini tahmin etmektedir. Üretici, $D(G(z))$ ’yi maksimize edecek şekilde; ayırt edici ise $D(x)$ ’i doğru sınıflandıracak şekilde eğitilmektedir. Böylece üretici, gerçek verilerden ayırt edilemeyen örnekler üretme kapasitesini geliştirir (Goodfellow ve diğerleri, 2014; Liu, 2019).

Özetle, çekişmeli üretici ağlar, karmaşık dağılımları taklit eden veri örnekleri üretmek için sinir ağlarını kullanmaktadır. Bu da özellikle görüntü işlemede veri artırma ve örnekleme (Wu, Chen ve Meng, 2020; Zhao, 2020), sentetik veri üretimi (Torfi, 2020), görüntüden görüntüye çeviri (Hoffman ve diğerleri, 2018; Tseng, 2021), görüntü iyileştirme (Perez, 2021), görüntü tamamlama (Ghiro, 2022; Jam, 2021) grafik temsillerinden görüntü üretme (Han, 2022) gibi çok çeşitli görevlere uyarlanmalarına olanak tanımaktadır.

2.3.4. Yapay sinir ağı hiperparametreleri

Yapay sinir ağlarının yapı ve performansı, genellikle uygulayıcı tarafından eğitim öncesinde belirlenen bazı parametrelere bağlıdır. Bu hiperparametreler, ağı eğitim sürecini, eğitim süresini ve elde edilen modelin doğruluğunu doğrudan etkileyerek öğrenme çıktıları üzerinde önemli bir rol oynamaktadır (Aggarwal, 2018). Bu parametreler arasında aktivasyon fonksiyonları, öğrenme oranı, devir sayısı, yığın boyutu, iterasyon, toplu normalleştirme ve optimizasyon algoritmaları yer almaktadır.

Aktivasyon fonksiyonları

Aktivasyon Fonksiyonları, yapay sinir ağlarında nöronların çıktılarını hesaplamak ve herhangi bir fonksiyona yaklaşma kapasitesine sahip olmasını sağlamak için kullanılan matematiksel işlemlerdir. Bir nöronun girişleri ile ağırlıklarının birleşiminden elde edilen toplam, bu fonksiyonlar aracılığıyla doğrusal olmayan bir dönüşüme tabi tutulur. Böylece belirli bir girdi ile sonuçta elde edilen çıktı arasında bir dönüştürücü görevi görmektedir (Sharma, Sharma ve Athaiya, 2017). Aktivasyon fonksiyonlarının birçok farklı türü vardır. Sıklıkla kullanılan fonksiyonlar ise genellikle tam bağlı katmanlarda bulunan Sigmoid ve Tanh ve evrişimli katmanlarda bulunan ReLU ve Leaky aktivasyon fonksiyonlarıdır (Zhou, 2017). Aşağıda bu fonksiyonların bazıları ve uygulamalara dahil edilenler açıklanmaktadır.

Sigmoid fonksiyonu, çıktıyı 0 ile 1 aralığında normalize eden doğrusal olmayan bir aktivasyon fonksiyonudur (Sibi, Jones ve Siddarth, 2013). Bu fonksiyon çok katmanlı CNN ağlarında ve ikili sınıflandırmalarda pratik bir kullanıma sahiptir (Nagarajan, 2021). Sigmoid fonksiyonu Eş. 2.2’de tanımlanmıştır.

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.2)$$

Hiperbolik tanjant (Tanh) fonksiyonu sigmoid aktivasyon fonksiyonuna benzemekle beraber aralığı (-1,+1) olarak sınırlandırılmaktadır. Bu daha hızlı öğrenme ve sınıflama işlemi için daha geniş aralığa sahip olmasından dolayı daha verimli olabilmektedir (Zhou, 2017). Tahn fonksiyonu Eş. 2.3’te tanımlanmaktadır.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$

Rectified Linear Unit (ReLU) (Nair ve Hinton, 2010) derin öğrenme modellerinde yaygın olarak kullanılan fonksiyonlardan biridir. İşlem esnasında herhangi bir negatif girdi için sıfır çıktısı, herhangi bir pozitif girdi için girdinin kendisini vermektedir. Bu doğrusal olmayan yapı, hesaplama maliyetini düşürürken öğrenme sürecini hızlandırmaktadır. Fonksiyon Eş. 2.4'de görülmektedir.

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.4)$$

Leaky ReLU, derin öğrenme modellerinde kullanılan ölü nöron problemini düzeltmek için geliştirilmiş bir aktivasyon fonksiyonudur. $x < 0$ olduğunda işlevin sıfır çıktı olması yerine, küçük bir eğim bırakmaktadır. Bu da, uygulamalarda ağı performansını etkileyen önemli bir unsurdur. Leaky ReLU Eş. 2.5'teki formüle sahiptir.

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0.01, & x < 0 \end{cases} \quad (2.5)$$

Softmax fonksiyonu, çok sınıflı sınıflandırma problemlerinde kullanılan, her bir sınıf için olasılık dağılımı üreten bir aktivasyon fonksiyonudur. Birden fazla sigmoid fonksiyonun birleşiminden oluşmaktadır (Sharma ve diğerleri, 2017). CNN'ler gibi çok katmanlı ağların son katmanlarında etkin kullanımı görülmektedir. Softmax fonksiyonu Eş. 2.6.'da bulunan formül ile tanımlanır.

$$f(x)_i = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}}, i = 1, \dots, k \quad (2.6)$$

Swish fonksiyonu, GOOGLE'daki araştırmacılar tarafından önerilen ve diğer fonksiyonlara kıyasla yeni bir aktivasyon fonksiyonudur (Sharma ve diğerleri, 2017). ReLU fonksiyonuna benzemekle birlikte, doğrusal fonksiyon ile ReLU fonksiyonu arasında farklı bir yapı sergilemektedir (Ramachandran, Zoph ve Le, 2017). Swish fonksiyonunun performans avantajları bazı durumlarda diğer aktivasyon fonksiyonlarından daha tercih edilebilir hale getirmektedir. Swish fonksiyonu Eş. 2.7'de tanımlanmıştır.

$$f(x) = x * sigmoid(x) = \frac{x}{1+e^{-x}} \quad (2.7)$$

Devir sayısı, yığın boyutu ve iterasyon

Devir sayısı (Epok), eğitim sürecinde modelin tüm eğitim veri setini işleme sayısını ifade eden temel bir kavramdır. Bir epok, eğitim veri setinin tamamından tek bir geçişi temsil eder ve her yeni epokta modelin ağırlıkları güncellenerek öğrenme süreci devam eder (Song, 2025). Devir sayısı modelin doğruluğunun hesaplanmasında önemli bir etkidir. Değerin az olması öğrenme verimliliğini düşürebilir ya da istenilen değerden yüksek olması modelin eğitim verilerine aşırı uyum sağlamasına sebep olabilir. Bu da istenmeyen sonuçları ortaya çıkarmaktadır. Modelin iyi bir performans sağlaması için doğru epok değeri performansın gözlenmesiyle belirlenebilir (Afaq ve Rao, 2020).

Yığın boyutu (batch size) ise modelin verimliliğini ve süreci etkileyen bir unsur olarak verinin parçalar halinde hesaplanmasını sağlamaktadır. Derin öğrenme sürecinde, yığın boyutu eğitim etkinliği ile hesaplama verimliliğini ve süresini doğrudan etkilemesi sebebiyle kritik bir hiper parametre olarak öne çıkmaktadır. Büyük yığın boyutları hızlı eğitim imkanı sunarken, düşük doğruluk ve genelleme yeteneğinin kaybına yol açabilir (Keskar, Mudigere, Nocedal, Smelyanskiy ve Tang, 2017). Diğer taraftan, küçük yığın boyutları yüksek doğruluk sunabilir fakat hesaplama maliyeti ve zamanı artırabilir (Smith, Kindermans, Ying ve Le, 2018). Veri setinin büyüklüğü, modelin karmaşıklığı ve kullanılabilir hesaplama kaynakları gibi faktörler ideal yığın boyutunu belirlerken göz önünde bulundurulması gereken faktörlerdir. Bir deviri tamamlamak için gereken toplam yığın sayısı ise iterasyon olarak ifade edilmektedir. Yığın boyutunun toplam örnek sayısına bölünmesi iterasyon değerini vermektedir. Bu değer her devirde işleme ve hesaplama fonksiyonlarının sayısını belirlemesi sebebiyle önemli bir rolü bulunmaktadır.

Toplu normalleştirme

Toplu normalleştirme (Ioffe, 2015) yapay sinir ağlarında her katmandaki çıktıları belirli bir ortalama ve standart sapmaya göre yeniden ölçeklendirerek eğitimi daha kararlı ve hızlı hale getiren bir yöntemdir (Goodfellow ve diğerleri, 2016). Bu yöntem, gradyanların doygunluk bölgelerinde takılıp kalmasını önleyerek, daha yüksek öğrenme oranlarının güvenle

kullanılabilmesine imkân tanımaktadır. Böylece ağı eğitim süreci hızlanır, genelleme başarısı artar ve öğrenme daha verimli hale gelmektedir (Bjorck, Gomes, Selman ve Weinberger, 2018).

Öğrenme oranı

Öğrenme oranı, algoritmanın kayıp fonksiyonunu minimuma ulaşmak için attığı adımların boyutunu belirleyen bir ayar parametresidir. Her iterasyonda ağı şimdiye kadar öğrendiği kavramları yeni verilere dayanarak bilgisini güncellemektedir. Öğrenme oranı öğrenilen bilgilerin optimum ağırlıklara doğru ilerleme hızını belirleyerek ağı parametrelerini büyük ölçüde değiştirmektedir. Kısaca, yeni bilginin etkisi ile önceki bilginin kalıcılığı arasındaki dengeyi yönetmektedir. Büyük bir öğrenme oranı, çözümü atlayabilecek daha büyük adımlarla sonuçlanabilirken, küçük bir öğrenme oranı en iyi değerlere yakınsamak için temkinli bir yaklaşımla atlama riskini azaltır ancak potansiyel olarak öğrenimin uzun sürmesine neden olmaktadır (Belcic ve Stryker, 2024) .


Optimizasyon algoritmaları

Optimizasyon algoritmaları, modellerde bir amaç fonksiyonunu en aza indirmek veya maksimuma ulaştırmak için giriş parametrelerini sistematik şekilde ayarlayan temel yöntemlerdir. En yaygın kullanımlardan biri, gradyan inişidir. Bu yöntem, her iterasyonda parametreleri küçük veri alt kümeleri üzerinden güncelleyerek büyük veri kümeleriyle çalışabilme esnekliği sunar (Ruder, 2016). Ek olarak, Adam ve RMSProp gibi varyantları, özellikle büyük veri kümeleriyle çalışma ve optimizasyon zorluklarının üstesinden gelme konusunda derin öğrenme modellerini eğitmek için yaygın olarak kullanılmaktadır.

2.3.5. İGD' de YZ algoritmaları ile yapılmış çalışmalar

İGD'de yöntemler genellikle özelleştirilmiş çizim algoritmaları veya şekil gramerleri kullanırken, yeni yaklaşımlar üretici yapay zekâ ile özgün desenler oluşturmayı hedeflemektedir. Bu gelişmelerle birlikte desenlerin bilgisayar destekli üretimi, tasarımı ve sınıflandırılması gibi işlemlerde de son yıllarda yapay zeka tekniklerinden faydalanmaktadır. İGD'lerin otomatik tanınması ve sınıflandırılması için veriye dayalı sınıflandırma yöntemleri, desenlerin görüntülerini arşivlemek, analiz etmek ve yeniden


oluşturmak gibi görüntü işleme görevlerinden oluşmaktadır (Rasouli, Bastanfard, Rezvanian ve Jalilian, 2008). Bu çalışmalardan Ahadian ve Bastanfard (2011b) İGD'lerin temsil ve tanınma aşamalarında geometrik merkez momentleri şekil betimleri olarak kullanmıştır. Bu çalışmada ikili (siyah-beyaz) desen görüntülerinden çıkarılan merkez momentler, K-En yakın komşu ve çok katmanlı ileri beslemeli sinir ağı olmak üzere iki farklı sınıflandırıcı kullanılarak şekle dayalı bir sınıflandırılma oluşturmayı amaçlanmıştır. Özellikle yıldız motifleri içeren desenlere odaklanan çalışmada; çevrilmiş, döndürülmüş ve ölçeklenmiş desenlerin ikili görüntüleri üzerinde farklı deneyler yapılmış ve sonuçları sunulmuştur. Yapılan deneylerde bu dönüşüm işlemleriyle bozulan desenlerde dahi yüksek tanıma oranları elde edilmiştir (Şekil 2.46).



Şekil 2.46. Solda, sınıflandırma şeması, Sağda, etiketli görüntü ve çıkarma bölgesi. Sağ alt, çıkarılan bölgede yapılan dönüşüm işlemleri (Ahadian ve Bastanfard, 2011b)

Başka bir örnek olarak Djibril, İGD görüntülerini friz, duvar kağıdı ve rozet olmak üzere üç ana simetri sınıfına ayıran bir model sunmuştur. (Djibril, Hadi ve Thami, 2006; Djibril ve Thami, 2008). Her desenin temel simetri özellikleri çıkarılarak bir özellik vektörü oluşturulmuş ve dönme açısını, yıldız ışınlarının sayısı hesaplanarak, rozet dönme merkezi tespit edilmiştir. Sonrasında, simetri işlemleri uygulanarak tüm rozetin yeniden oluşturulabileceği rozetin en küçük temsili bölgesi bulunmuş ve simetri sergileyen rozet şeklini tamamlamak için yeni görüntü boyutları hesaplanabilmiştir. Böylelikle uygulama, görüntüyü merkez noktası üzerinde ortalayarak, hem merkez hem de simetri bilgilerine göre görüntüye bilgi kopyalama yoluyla tam yıldız şekli için uygun bir aday görüntü üretebilmektedir (Şekil 2.47). Önerilen yöntem, görüntü veritabanında desen arama ve eşleştirmede başarılı sonuçlar vermiştir. Ancak, yapılan çalışma desenlerden yalnızca yıldız

modellerinin tanınması ve sınıflandırılmasına ve dönme simetrisine bağlı olarak özellik çıkarmaya odaklıdır.



Şekil 2.47. Üstte, deseninin en küçük temsili bölgesi bulunma adımları, altta (a) Tamamlanacak orijinal rozet görüntüsü ve (b) rozetin tespit edilen merkezi ve tamamlanma sonucu (Djibril ve Thami, 2008)

Çok az çalışma İslami geometrik desenleri oluşturmak için algoritmalar sağlarken, diğerleri İslami geometrik desenlerin görüntülerini indekslemek, analiz etmek ve yeniden oluşturmak gibi görüntü işleme alanındadır (Rasouli ve diğerleri, 2008). Önceki başlıklarda bahsedildiği gibi İGD modellerini sınıflandırmak için yapılan birçok girişim, çok çeşitli yapım grupları ve sınıflandırmalarıyla sonuçlanmıştır. İGD'leri sınıflandırmak için benzersiz bir özellik bulmak, farklı yapılarının çeşitliliği nedeniyle güç olmuştur.

Albert ve diğerleri (2015) çalışmasında matematiksel simetri grupları kuramını İGD mozaiklerinin analizi için uygulanmıştır. Geliştirilen yöntem, bir desendeki temel motifleri ve kafes yapısını çıkararak desenin ait olduğu duvar kağıdı grubu simetri tipini otomatik olarak belirlemektedir. Yöntem yalnızca desenin simetri yapısını tanımakla kalmayıp, deseni oluşturan öğeleri nesne tabanlı bir seviyede tanımlayarak her bir öğenin nokta grubu simetrilerini de çıkarabilmektedir. Yöntem, görüntünün bölümlere ayrıldığı görüntü veya piksel odaklı aşama, elde edilen bölgelerin çıkarılan nesnelere, kontur ve nokta grubu özelliklerine karşılık geldiği nesne yönelimli aşama ve öteleme, dönme ve simetri özelliklerine sahip duvar kağıdı grubunun bulunduğu yapı aşamasından oluşmaktadır (Albert, Gómis, Blasco, Valiente ve Aleixos, 2015). Bu bilgi sayesinde desenlerin sınıflandırılması, kataloglanması, desen tasarımı ve farklı kültürlerle ait motiflerin karşılaştırılması gibi uygulamalara imkan sağlanabileceği düşünülmektedir.

Aoulalay, El Makhfi, Abounaima ve Massar (2020) çalışmasında Fas mimarisindeki genellikle İGD motifleri içeren dekoratif desenleri doku ve renginin analizine dayalı olarak makine öğrenmesiyle sınıflandırmıştır. Desen görüntülerinden doku (seramik, alçı, kumaş, cam ve ahşap) ve renk özellikleri çıkarılmış; özellikle gri-seviyeli eş oluşum matrisi, Yerel İkili Örüntüler (LBP) ve renk histogramı gibi özellikler kullanılmıştır. Elde edilen özellik vektörleri, K-En Yakın Komşu (KNN) ve Destek Vektör Makineleri (SVM) gibi gözetimli öğrenme algoritmaları ile sınıflandırılmıştır. Çalışma, 5 farklı malzeme türüne ait desenlerle yapılan denemelerde özelliklerin başarılı şekilde ayrılabilirdiğini göstermektedir

Aoulalay ve diğerleri (2022) bir başka çalışmasında, İGD görüntüleri üç temel simetri sınıfına (Friz, Duvar Kağıdı, Rozet) ayrılarak sınıflandırılmıştır. Bu çalışmada filtreler ile elde edilen öznitelikler ve önceden eğitilmiş bir CNN modelinden çıkarılan derin özellikler ile iki farklı özellik çıkarım stratejisi karşılaştırılmıştır. Sınıflandırma aşamasında ise Rastgele Orman (RF) ve SVM algoritmaları kullanılmıştır. Sonuçlar, derin ağdan öğrenilen özelliklerin filtreler ile elde edilen özelliklere göre daha başarılı olduğunu göstermiştir: Bu çalışma, derin özelliklerin İGD'lerin simetri tabanlı sınıflandırmasında daha iyi performans sağladığını, klasik doku analizinin ise daha sınırlı kaldığını ortaya koymaktadır (Aoulalay, El Mhouthi ve Massar, 2022).

Nasri ve Benslimane (2014) makalesinde, otomatik periyodik desen tespiti için otomatik korelasyon fonksiyonu ve SIFT öznitelik çıkarımı birleştirmiştir. Bu yöntemde, periyodik desenler için kafes noktaları ve tekrarlayan birimi temsil eden öteleme vektörü birbiriyle ilişkili bir biçimdedir. Yapılan testler, karmaşık çoklu renk ve gürültü şartlarında bile İGD görüntülerindeki periyodik motifleri ve kafes yapısını ortaya çıkarabilmektedir. Bu da önerilen yöntemin otomatik periyodik motif çıkarma kabiliyetini göstermektedir Benzer şekilde, El Ouazizi, Nasri ve Benslimane (2015) İslami yıldız desenlerindeki dönel simetri merkezini ve derecesini bulmaya yönelik bir yöntem geliştirilmiştir. Önerilen yöntem, yıldız motifin merkezini tespit ettikten sonra Friz genişlemesi adı verilen bir yaklaşım uygulayarak desenin dönel simetri grubunu otomatik olarak karakterize etmektedir. Bu sayede, bir rozet deseninin kaç kollu yıldız simetrisine sahip olduğu belirlenebilmektedir

Ghosh, Obaidullah, Gherardini ve Zdimalova (2021) çalışmasında tarihi bir İslami mozaik eserinden elde edilen görüntüler kullanılarak, mozaikte tekrar eden geometrik şekiller (daire, sekizgen, kare, üçgen, yaprak motifi) bir derin sinir ağı ile otomatik sınıflandırılmıştır.

Yazarlar, özel olarak hafif yapıda bir CNN mimarisi tasarlayarak 5 sınıftaki şekilleri yüksek doğrulukla tanımıştır

Hajebi ve Hajebi (2024) farklı dönem ve bölgelere özgü tarihi mimari üslupların ortak geometrik karakteristiklerinden yola çıkarak, süsleme desenlerinin otomatik sınıflandırılması ve dokümantasyonu üzerine odaklanmaktadır. Bu nedenle çalışmada, görüntü işleme ve makine öğrenmesi teknikleri kullanılarak, geometrik desenlerin türlerinin tespiti ve desen sayısının tahmini gibi işlemler hızlı ve etkili bir şekilde gerçekleştirilmiştir. Bunun yanı sıra çalışmada, zamanla tahrip olmuş desenlerin tanınması ve yeniden inşası da ele alınmıştır. Böylece, desenlerin kategorik olarak ayrıştırılması, görsel mirasın dijital ortamda sınıflandırılması ve bozulmuş örüntülerin tanınması için yapay zekâ destekli bir yaklaşımla desteklenmiştir

Tekrar modelin çıkarılması ile doku periyodunun tamamlanması şeklinde uygulanan çalışmalar; birçok yerde karşımıza çıkan tekrar modellerini, oluşturdukları öğelerin yapısı hakkında fikir verme ve güçlü geometrik veya anlamsal ipuçları sağlama açısından önem kazanmaktadır. Bu nedenle, tekrar birimin algılanması birçok sınıflandırma ve görüntü çoğaltma problemine çözüm sağlayabilmektedir. Bu alanda İslami Geometrik Desenler özelinde olmasa da tekrar eden desenlere odaklı periyodiklik ve simetri problemlerini ele alan çalışmalar mevcuttur. Bu çalışmalardan birinde Adonova ve Tari (2019) tekrar eden desenler için otomatik bir yöntem sunmaktadır. Bu çalışmada süsleme parçalarını 13 duvar kağıdı grubundan birine sınıflandırmak ve yeniden inşa etmek için yeterli olan minimum bölge olan temel alanı çıkarmak için bir yöntem sunmaktadır

Qu, Zhou, Chau ve Mok (2020) tekrar kalıplarının otomatik olarak çıkarılması için CNN'e dayalı bir yaklaşım önermiştir. Yöntem, AlexNet'in evrişim katmanlarından öğrenilen filtrelerle VGG16'nın sınır algılama çıktılarının birleştirilmesi üzerine kuruludur. Bu sayede tek görüntüler üzerinde filtreler hızlı biçimde uygulanabilmektedir

Liu, Collins ve Tsin, (2004) kristalografik grupların matematiksel teorisine dayanan periyodik desen algısı için hesaplamalı bir model sunmaktadır. Belirli bir periyodik modelin temsili motiflerini çıkaran bir dizi bilgisayar algoritması geliştirmiştir. Yöntemin adımları; desenin altta yatan kafesini çıkarmak, modelin simetri grubunu sınıflandırmak ve modeli algısal olarak karakterize eden temsili bir motifi tanımlamak olarak sıralanmıştır. Çalışmada,

translasyonel simetriyi ölçmek için otokorelasyon ve kafes vektörlerini belirlemek amacıyla Hough dönüşümü kullanılmıştır (Liu ve diğerleri, 2004). Yapılan çalışmaların değerlendirmeleri Çizelge 2.2’de görülmektedir.

Çizelge 2.2. Geometrik desenler konusunda yapılan sınıflandırma çalışmaları


Referans	Amaç	Odak noktası	Metodoloji
(Ahadian ve Bastanfard, 2011a)	Sınıflandırma	Merkez momentlerle yıldız tanıma	KNN ve ANN
(Albert ve diğerleri, 2015)	Sınıflandırma	Simetri grubu ve nesne sınıflama	Mean Shift Hu moments
(Aoulalay ve diğerleri, 2020)	Sınıflandırma	Doku ve renk analizi	KNN ve SVM
(El Ouazizi ve diğerleri, 2015)	Simetri derecesi tespiti	Dönme simetri ve merkez algılama	Frieze-Expansion, simetri algoritması
(Nasri ve Benslimane, 2014)	Periyodik desen çıkarımı	Simetri algılama	SIFT + Otokorelasyon
(Ghosh ve diğerleri, 2021)	Sınıflandırma	Mozaik geometrik şekil tanıma	CNN
(Liu ve diğerleri, 2004)	Sınıflandırma	Simetri algılama	Otokorelasyon
(Nasri ve Benslimane, 2017)	Sınıflandırma	Simetri algılama	Otokorelasyon
(Djibril ve Thami, 2008)	Sınıflandırma	Simetri algılama	Otokorelasyon
(Qu ve diğerleri, 2020)	Tekrar eden modellerin çıkarılması	Simetri algılama	CNN
(Adanova ve Tari, 2019)	Sınıflandırma	Simetri algılama	KNN ve ANN
(Hajebi ve Hajebi, 2024)	Bozulmuş desen tanıma	karar birleştirme	Füzyon modeli (CNN + klasik yöntemler)

2.4. Görüntü Tamamlama

Görüntü tamamlama, eksik ya da bozulmuş bölgelerin uygun içerikle doldurularak görüntünün görsel bütünlüğünün korunmasını amaçlamaktadır. Bu kapsamda, literatürde yaygın olarak kullanılan yöntemlerden biri görüntü boyama (inpainting) tekniğidir. Görüntü boyama, eksik veya hasarlı kısımları tahmin ederek yeniden yapılandırma işlevi görür ve bu nedenle görüntü tamamlama uygulamalarında temel bir yaklaşım olarak değerlendirilmektedir.

Görüntü boyama

Görüntü boyama, eksik veya hasarlı bölümleri tamamlayarak görüntünün genel bütünlüğünü görsel olarak daha gerçekçi hale getirmeyi amaçlayan bir süreçten oluşmaktadır. Bu süreç, eksik alanlar için makul içerik tahmin ederek görüntü restorasyonunda önemli bir görevi temsil etmektedir. Boyama görevi bozulmuş bölgelerin yapılandırılması (Cao, Li, Zhang ve Cui, 2019; Cao, Zhang, Zhao, Cui ve Zhang, 2020; Zhou ve diğerleri, 2022), istenmeyen veya dikkat dağıtıcı öğelerin kaldırılması (Criminisi, Pérez ve Toyama, 2004; Suvorov ve diğerleri, 2022) gibi işlevleri üstlenmektedir. Şekil 2.48’de örnek bir boyama görevi görselleştirilmiştir. *B* eksik bölgeyi, *G* hasarsız görüntü alanını; *Q* ise görüntü bütünlüğünün sağlanması boyama görevini ifade eder.



Şekil 2.48. Boyama görevi (Chan ve Shen, 2002)’den uyarlanmıştır

Görüntü boyama tekniklerinde ilk yıllarda eksik görüntüleri doldurmak için genellikle çevresindeki piksellerin değerlerini doğrudan kullanarak tamamlamayı amaçlayan basit interpolasyon teknikleri ya da yama tabanlı yöntemler kullanılmıştır. Yama tabanlı yöntem, bilinen bölgelerden en iyi eşleşen yamaları bulup bunları eksik bölgelere entegre etmeye odaklanmaktadır (Barnes, Shechtman, Finkelstein ve Goldman, 2009; Cao ve diğerleri, 2019; Criminisi, Perez ve Toyama, 2003; Drori, Cohen-Or ve Yeshurun, 2003; Efros ve Leung, 1999; Huang, Kang, Ahuja ve Kopf, 2014; Kwatra, Essa, Bobick ve Kwatra, 2005). Ancak, bu çalışmalar genellikle eksik alanların daha uygun şekilde doldurulmasını sağlamak için daha fazla yapısal bilgiye ihtiyaç duyan sınırlı uygulamalardır.

Görüntü boyama alanında ilk sistematik ve matematiksel adımlarını atan çalışmada ise Bertalmio ve diğerleri (2000), sanat eserlerinin restorasyonu için daha matematiksel ve

model bazlı bir yaklaşım sunmuşlardır Bu yöntemde, eksik bölgelerin etrafındaki sınır bölgelerden bilgi yayılmakta ve bu bilgi, kaybolan kısımların tamamlanmasına yardımcı olmaktadır. Matematiksel olarak, bu süreç kısmi türevli denklemler kullanılarak modellenmiştir. Böylece, eksik bir bölgeyi çevresindeki bilinen bölgeden elde edilen özellikleri yaymak için bilinen bölgelerin yama benzerliklerini eşleştirerek ve çoğaltarak bilinmeyen bölgeleri yeniden oluşturmaktadır (Ballester, Bertalmio, Caselles, Sapiro ve Verdera, 2001; Bertalmio ve diğerleri, 2000; Osher, Burger, Goldfarb, Xu ve Yin, 2005). Ardından, Shen, Hu, Zhang ve Zhang, (2009) benzer yaklaşımlarla örüntü aktarımını kullanarak küçük alanlı renkli görüntü hasarlarını onarmıştır Bu geleneksel yöntemler, çizik veya nokta kusurları gibi küçük ölçekli hasarları gidermede başarılı olmuş, onarılan bölgede komşu piksel uyumunu koruyabilmiştir. Ancak tamamlanacak bölgenin büyümesi veya bu bölgelerde beklenen içeriklerin karmaşık yapılar, dokular veya derinlik özellikleri içermesi, genellikle bulanık sonuçlara sebep olmaktadır. Bu sınırlılıklar, iç boyama problemine öğrenmeye dayalı yaklaşımların gerekliliğini ortaya koymuştur (Xu ve diğerleri, 2023).

2010'ların ortasından itibaren, derin öğrenmenin başarısı görüntü iç boyama alanına da taşınmıştır. Derin sinir ağları, veriden anlamsal özellik çıkarımı konusunda yüksek performans göstererek hem küçük hem de büyük ölçekli hasarlar için daha etkili çözümler sunma potansiyeli elde edilmiştir. Bu yaklaşımda, evrimsel sinir ağları, veri içerisinden anlamlı özellikleri çıkarma konusunda oldukça başarılıdır. Diğer yandan, GAN'lar ise gerçekçi veri üretme yetenekleri sayesinde yaygın olarak tercih edilmektedir. Görüntü tamamlama problemini ele alan ilk çalışmalardan biri olarak Pathak ve diğerleri (2016) kodlayıcı-kod çözücü ağ kullanarak bir model önermektedir (Pathak ve diğerleri, 2016). Bu modelde, eksik bölümleri doldurabilmek için bir CNN mimarisi kullanılırken, tamamlanacak görüntünün yapısal ve bağlamsal özelliklerini anlama problemine karşı bir kodlayıcı (*encoder*) ile kayıp kısımları sentezleyen bir kod çözücü (*decoder*) entegre edilmiştir (Iizuka, Simo-Serra ve Ishikawa, 2017). Bu uygulama, CNN tabanlı derin modellerin ilk defa görüntü iç boyamaya uygulanması olarak görülür ve geleneksel yöntemlerin etiketli veri ihtiyacı ve sınırlı semantik anlayışına yönelik önemli bir adım olmuştur. Derin ağların kullanılmaya başlanması, geleneksel yaklaşımların eksikliklerini gidermeye yönelik bir adım olarak, eksik verinin tamamlanması sürecinde modelin hem mevcut bilgiyi anlamasına hem de gerçekçi tahminler üretebilmesine olanak tanımıştır. Bu doğrultuda yapılan araştırmalar, yalnızca yüzeysel doku bilgilerini değil, aynı zamanda derin anlamsal ilişkileri de yakalayarak daha gerçekçi ve bağlamsal açıdan tutarlı sonuçlar

üretmeyi amaçlamışlardır (Yang ve diğerleri, 2017; Yeh ve diğerleri, 2017). Örneğin, geleneksel yöntemler bir boşluğu doldururken çevre dokusunu kopyalarken, bir derin ağ sahnenin genel bağlamı da kavrayarak o boşluktaki eksik nesneleri veya anlamlı detayları ekleyebilmektedir. Bu sayede derin öğrenme tabanlı iç boyama algoritmaları, özellikle nesne kaldırma, eski fotoğraf onarımı, hasarlı tarihi eserlerin düzeltilmesi gibi senaryolarda öne çıkarak alanın ana araştırma yönü haline gelmiştir (Qin, Zeng, Zong ve Xu, 2021). Ayrıca çalışmalarda, düşük çözünürlükteki görüntüler yüksek kalitede boyama görevleri için kullanılmaktadır (Sidorov ve Yngve Hardeberg, 2019; Zeng, Fu, Chao ve Guo, 2019).

Derin öğrenme yaklaşımlarında, iç boyama probleminin tekil bir doğru çözümü olmadığı gibi bazı çalışmalar varyasyonel kodlayıcılar gibi üretici modellerle birden fazla olası çözüm üretebilen yöntemler geliştirmiştir. Örneğin, Zheng ve diğerleri (2019)'nin çalışması, eksik bölgenin farklı olası içeriklerini üretebilen bir varyasyonel kodlayıcı tabanlı çerçeve sunarak, iç boyamada belirsizliğin üstesinden gelmeyi hedeflemiştir (Zheng, Cham ve Cai, 2019). Bu yaklaşımlar, iç boyamada çeşitlilik sağlarken, modelin gerçekçi örnekler üretme kapasitesi genellikle doğrudan çekişmeli öğrenim (GAN) kullanan yöntemler kadar yüksek değildir. Üretici çekişmeli ağlar gerçekçi veri üretmedeki başarısı sayesinde iç boyama alanında önemli gelişmeler sağlamıştır. İlk başarılı GAN tabanlı çalışmalardan biri, Iizuka ve diğerleri (2017)'nin geliştirdiği iç boyama modelidir. Bu modelde, bir üretici ağ ile birlikte ikili bir ayırt edici ağ yapısı kullanmıştır. GAN ve CNN birleşimiyle tasarlanan bu mimari, önceki yöntemlere kıyasla iç boyama kalitesini belirgin biçimde artırmıştır (Iizuka ve diğerleri, 2017). Model, çevresel tutarlılığı hem global sahne düzeyinde hem de lokal doku düzeyinde kontrol ederek sonuçların hem genel anlamda mantıklı hem de bölgesel olarak gerçeğe yakın olmasını sağlamıştır (Liu, Li, Hussain Bukhari ve Ullah, 2022). GAN tabanlı yaklaşımlarda, eğitim sürecinin kararsızlığı ve eksik bölgelerin genişliği gibi sorunlar da ele alınmıştır. Yeh ve diğerleri (2017), eksik görüntü alanlarını doldururken sahnenin genel yapısıyla ve anlamıyla uyumlu içerikler üretmeyi hedeflemiştir. Yang ve diğerleri (2017) ise tamamlanan bölgenin yalnızca yüzeysel olarak benzemesine ek olarak, hem dokular, çizgiler gibi küçük detaylar hem de nesne biçimleri, sınırlar gibi genel şekiller açısından doğru ve gerçekçi görünmesini sağlayacak kurallar eklemiştir. Bu çalışmalar, modelin yalnızca pikselleri değil anlamlı nesne ve sahne bütünlüğünü de öğrenerek tamamlaması yönünde önemli adımlar atmaktadır. Ancak, GAN tabanlı modeller dahi başlangıçta düzensiz şekilli maskeler veya çok büyük boşluklar karşısında zorluk yaşayabilmektedir.

İlerleyen çalışmalarda, tek bir ağın tek adımda yaptığı tamamlamanın yetersiz kaldığı durumlar için çok aşamalı iç boyama mimarileri ortaya çıkmıştır. Bu yaklaşımlar, önce kaba bir tahmin yapıp ardından detayı zenginleştiren aşamalı doldurma stratejileri izlemektedir. Örneğin, Nazeri, Ng, Joseph, Qureshi ve Ebrahimi (2019) geliştirdikleri EdgeConnect yönteminde ilk aşamada eksik bölgelerin kenar çizgilerini tahmin eden bir ağ, ikinci aşamada ise bu tahmini kenar bilgisini kullanarak görüntüyü dolduran bir GAN kullanmaktadır. Benzer şekilde, Yu ve diğerleri (2018) iki aşamalı bir model ile önce düşük çözünürlüklü taslak bir içerik, ardından yüksek çözünürlüklü ince ayrıntılar üreterek daha tutarlı sonuçlar elde etmiştir. Bu aşamalı öğrenme, tek seferde karmaşık bir problemi çözmek yerine alt problemlere bölerek her adımda daha yönetilebilir bir görev çözme fikrine dayanmaktadır. Literatürde çok aşamalı yaklaşımın başka bir örneği, Zamir ve diğerleri (2021) tarafından önerilen ilerlemeli iç boyama ağıdır. Bu üç aşamalı modelde ilk iki aşama, kodlayıcı-kod çözücü tabanlı alt ağlar ile geniş görüş alanında sahnenin bağlamını öğrenirken, üçüncü aşama orijinal çözünürlükte çalışarak ince doku detaylarını işlemektedir. Bu görüntü boyama tekniklerinde uygulamalar; ek girdiler ile kenar haritaları (Li, L. ve diğerleri, 2022; Nazeri ve diğerleri, 2019), yapı haritaları (Ren ve diğerleri, 2019) ve segmentasyon haritaları (Song ve diğerleri, 2018) gibi bilgileri kullanmaktadır. Ayrıca aşamalar arası özellik füzyonu mekanizmalarıyla, önceki adımlarda öğrenilen çok ölçekli bağlamsal özellikler sonradan zenginleştirilerek kademeli bir iyileştirme elde edilir. Bu çalışmalarda (Qin ve diğerleri, 2019; Zeng, Fu, Chao ve Guo, 2022) önceki adımlarda öğrenilen çok-ölçekli bağlamsal özellikler sonradan zenginleştirilerek kademeli bir iyileştirme elde edilmektedir. Bu sayede ağ, ilk aşamada genel yapıyı, son aşamalarda ayrıntıları daha isabetli şekilde restore edebilmektedir. Nitekim, çok aşamalı yaklaşımlar büyük boşlukların veya yüksek çözünürlüklü görüntülerin tamamlanmasında tek aşamalı modellere kıyasla daha başarılı ve kararlı bulunmaktadır (Qin ve diğerleri, 2021; Zheng ve diğerleri, 2019).

Görüntü üretiminde son dönemde önemli gelişmeler elde eden difüzyon modelleri, iç boyama problemine de uygulanmaya başlamıştır. Difüzyon modelleri, bir görüntüye kademeli olarak gürültü ekleyip daha sonra bu süreci tersine çevirerek yeni görüntüler üretmeyi temel almaktadır (Ho, Jain ve Abbeel, 2020). Bu alanda ümit verici çalışmalardan Lugmayr, Danelljan, Romero, Yu, Timofte ve Van Gool (2022) RePaint isimli çalışmalarında difüzyonun ters süreç adımlarını modifiye ederek, her adımda hasarsız bölge piksellerini geri ekleme stratejisiyle serbest biçimli maskelerde dahi üst düzey başarı elde

etmişlerdir Yine Rombach, Blattmann, Lorenz, Esser ve Ommer (2022) difüzyon işlemini hızlandıran ve gerçekçi sonuçlar veren yöntemi tanıtmışlardır Çizelge 2.3' te algoritmaların iç boyama yöntemlerinin temel özellikleri, uygulama alanları da dahil olmak üzere çeşitli yönleri ile ele alınmaktadır. Bu karşılaştırmalar, bu tekniklerin çalışma prensiplerini ve uygulama alanlarını daha iyi anlaşılmasına yardımcı olarak, alan çalışması için öngörüler ve referanslar sunmaktadır.

Çizelge 2.3. İç boyama algoritmalarının karşılaştırılması

Yöntem Adı	Yöntem Türü	Temel Özellikler	Uygulama Alanı	Uygunluk (İGD ile ilişkilendirme)
Texture Synthesis (Efros ve Leung, 1999)	Geleneksel	Örnekleme tabanlı doku sentezi	Doku tamamlama	Düşük (küçük ölçekli dokular için elverişlidir)
Image Inpainting (Bertalmio ve diğerleri, 2000)	Geleneksel	PDE tabanlı bilgi yayılımı, kenar ve yapı devamlılığı için matematiksel model	Sanat restorasyonu (küçük hasarlar)	Düşük (karmaşık desenlerde yetersiz, bulanık sonuç)
Local nontexture inpaintings (Chan ve Shen, 2002)	Geleneksel	Varyasyonel model, doku olmayan alanların matematiksel onarımı	Doku içermeyen bölgeler	Düşük (sadece düz renk/kenar, desenli alanlarda başarısız)
Fragment-Based Completion (Drori ve diğerleri, 2003)	Geleneksel	Yama tabanlı tamamlama	Genel görüntü tamamlama	Orta (Benzersiz motiflerde eşleşme ve desen süreksizliği oluşabilir)
Exemplar-Based Inpainting (Criminisi ve diğerleri, 2003)	Geleneksel	Örnek yama kopyalama, öncelik fonksiyonu ile yapısal çizgileri önleme	Obje kaldırma, genel	Orta (mevcut desen parçalarını kopyalayabilme düzeyi)
Fast Marching Inpainting (Telea, 2004)	Geleneksel	Hızlı boyama yöntemine dayalı, bilinen pikselleri komşu boşluklara yayma	Küçük boşluklar	Düşük (büyük boşluklarda başarısız)
Texture Optimization (Kwatra ve diğerleri, 2005)	Geleneksel	Yama birleştirme, aşamalı doku sentezi optimizasyonu	Doku sentezi, görüntü tamamlama	Orta (doku devamlılığı iyi, fakat simetri üretimi belirsiz)
PatchMatch (Barnes ve diğerleri, 2009)	Geleneksel	Rastgeleleşmiş algoritma kullanarak en yakın yama arama komşu eşleşmeleri, etkileşimli onarım	İçerik duyarlı doldurma	Yüksek (tekrarlayan motiflerde eşleşme ihtimali)
Planar Structure Guidance (Huang ve diğerleri, 2014)	Geleneksel	Orta seviye yapısal ipuçları ile yama seçimi, düzlemsel perspektif ve düzen yakalama	Yapı barındıran sahneler	Orta (karmaşık motiflerde sınırlı olabilir)
CE (Pathak ve diğerleri, 2016)	CNN	İlk derin otoenkoder yaklaşımı, tek adımlı eksik bölge tahmini, özellik öğrenimi için GAN kullanımı	Genel görüntü tamamlama, ImageNet Paris Streetview	Düşük (sonuçlar bulanık/ortalama)

Çizelge 2.3. (devam) İç boyama algoritmalarının karşılaştırılması

Yöntem Adı	Yöntem Türü	Temel Özellikler	Uygulama Alanı	Uygunluk (İGD ile İlişkilendirme)
Global&Local GAN (Iizuka ve diğerleri, 2017)	GAN	İki ayırık ayırmacı (genel ve yerel) ile tutarlılık sağlama, çevre ve delik bölgesinde eşzamanlı doğruluk	Doğal sahneler, Places2	Orta (genel uyumu iyi, ancak özel desen simetrisine odaklanmayabilir)
GAN Prior Optimization (Yeh ve diğerleri, 2017)	GAN	Önceden eğitilmiş bir GAN modeline dayalı, eksik kısımları gizli görüntü aramasıyla doldurma	Anlamsal tamamlama, CelebA Cars	Düşük (uygun üretici model yoksa zorlanabilir)
Multi-Scale Neural Patch (Yang ve diğerleri, 2017)	CNN	Çok ölçekli ağ + yama sentezi: önce CNN ile kaba doldurma, sonra özellik uzayında yama eşleştirme ile ince detay onarımı	Yüksek çözünürlüklü görüntüler, ImageNet Paris Streetview	Yüksek (büyük boşluklarda detaylar eksik kalabilir)
CA (Yu ve diğerleri, 2018)	GAN	İki aşamalı (kaba + ince) model, bilinen bölgelerden benzer yamaları dikkatle çekerek doldurma	ImageNet, CelebA-HQ, Places2	Yüksek (büyük boşluklarda detaylar eksik kalabilir)
Partial Convolutions (Liu ve diğerleri, 2018)	CNN	Maskeye duyarlı evrişim, çoklu katmanlı doldurma	Düzensiz boşluklar, ImageNet, CelebA-HQ, Places2	Düşük (içeriği semantik olarak anlamakta zorlanabilir)
SPG-Net (Song ve diğerleri, 2018)	GAN	Segmentasyon (anlamsal bölütleme) öngörüsü ve rehberliği: ilk aşamada eksik bölgenin sınıf etiketlerini tahmin etme, ikinci aşamada bu segmente dayalı iç boyama	Karma sahneler, yüz verileri	Düşük (karmaşık desenlerde yetersiz)
Gated Convolution (Yu ve diğerleri, 2019)	GAN	Serbest biçimli maskeler için öğrenilebilir geçitli konvolüsyonlara dayanan sistem	Obje kaldırma, serbest biçimli görüntü	Orta (desen tutarlılığı için özel bileşen yok)
LBAM (Xie ve diğerleri, 2019)	CNN + Attention	Öğrenilebilir ileri ve geri dikkat haritaları	Düzensiz boşluklar ve yapısal eksiklikler içeren görüntüler, Paris StreetView, Places	Yüksek (Özel bir motif bilgisi içermediği için özgün detaylarda hata üretebilir.)
EdgeConnect (Nazeri ve diğerleri, 2019)	GAN	İki aşamalı model: önce kenar haritası tahmini, ardından bu kenarla yönlendirilen içerik üretimi	Yapısal sahneler, CelebA, Places2, Paris StreetView	Yüksek (desenin kenarları belirlenebilirse eksik motifler simetrik biçimde tamamlanabilir)

Çizelge 2.3. (devam) İç boyama algoritmalarının karşılaştırılması

Yöntem Adı	Yöntem Türü	Temel Özellikler	Uygulama Alanı	Uygunluk (İGD ile İlişkilendirme)
DFNet (Ren ve diğerleri, 2019)	GAN	Yapı-odaklı çift aşamalı ağ: yapı yeniden yapılandırma ve doku oluşturma. Bilinmeyen bölgeleri birleştirmek için bir füzyon bloğu kullanımı	Geniş boşluklar, belirgin yapılar, CelebA, Places2, Paris StreetView	Yüksek (Kenar sürekliliğini ve dokusal bütünlüğü korumada başarılıdır)
Foreground-Aware (Xiong ve diğerleri, 2019)	GAN	Ön-plan farkındalığı: Maske alanında nesne ve arka planı ayırt edip ayrı yollarla tamamlama	Obje kaldırma, doğal görüntüler, Places2	Düşük (özgün detaylarda hata üretme olasılığı)
PICNet (Zheng ve diğerleri, 2019)	VAE	Çeşitlilik odaklı VAE (varyasyonel oto kodlayıcılar) tabanlı çift yönlü ağ: aynı girdi için birden çok tutarlı çıktı üretebilir	Alternatif tamamlamalar, CelebA-HQ, Places2, Paris, ImageNet	Düşük (orijinal motife sadık kalmak yerine olası varyasyonlar üretir)
RFR-Net (Li, Wang, Zhang, Du ve Tao, 2020)	CNN	Tekrarlı özellik yinelemesi: eksik bölgeyi kademeli olarak doldurmak için alan tanımlama, özellik çıkarma, özellik haritalarını birleştirme modüllerinden oluşur.	Farklı senaryolar, CelebA, Places2, Paris StreetView	Orta (tekrarlı yaklaşım yapıları özellikleri korur lokal özelliklere bağlıdır.)
HiFill / CFGI (Zeng ve diğerleri, 2020)	CNN	Geri bildirim mekanizmasına dayalı yinelemeli boyama yöntemi, düşük çözünürlükte başlanıp kademeli yükseltilebilir çözünürlük	Yüksek çözünürlük, büyük maskeler, Places2	Orta (büyük alanları doldurabilir, ancak dokusal bütünlüğü sağlamayabilir)
MEDFE (Liu, Jiang, Song, Huang ve Yang, 2020)	GAN + CNN	Derin kodlayıcı (encoder)-kod çözücü (decoder) tabanlı CNN'lerin kullanımı	Paris StreetView, CelebA, Places2	Yüksek (Yapı ve doku ayrımı simetrik desenler için faydalı)
UCTGAN (Zhao ve diğerleri, 2020)	GAN	Denetimsiz <i>cross-space</i> çeviri: eşleştirilmemiş veriyle eğitim, CycleGAN benzeri yapıyla çeşitlilik sağlayan iç boyama; tek bir girdi için birden fazla olası çıkış üretebilir	Eiketsiz veriyle geniş uygulama, CelebA-HQ, Places2, ImageNet, Paris StreetView	Düşük (çıktılar çeşitli ancak özgün deseni aynen koruma garantisi yok)
Co-Mod GAN (Zhao ve diğerleri, 2021)	GAN	Koşullu ve stokastik stil temsillerinin birlikte modülasyonu, büyük ve yüksek çözünürlüklü görüntülerde güçlü sentez kabiliyeti, eğitim sırasında stabilite için stil modülasyon kullanımı	Yüksek çöz. sahneler, portreler, Places2	Orta (Stil öğrenimi güçlü olsa da motif düzenine odaklanmayabilir)

Çizelge 2.3. (devam) İç boyama algoritmalarının karşılaştırılması

Yöntem Adı	Yöntem Türü	Temel Özellikler	Uygulama Alanı	Uygunluk (İGD ile İlişkilendirme)
DE-GAN (Zhang ve diğerleri, 2022)	GAN	Etki alanı (domain) gömülü GAN: Özellikle yüz görüntüleri için, yüz özelliklerini koruyan ve yüksek kaliteli onarım yapan model	Yüz onarımı, CelebA, CelebA-HQ	Düşük (Özellikle yüz gibi belirli alanlarda başarılıdır)
ICT (Wan, Zhang, Chen ve Liao, 2021)	Transformer + CNN	Hasarlı görüntülerin eksik yapısını geri yüklemek için transformatörleri kullanır	Genel (ImageNet, Places2)	Orta (Transformer ile küresel yapısal ilişkileri güçlü şekilde öğrenir. İşlem yükü yüksektir)
BAT (Yu ve diğerleri, 2021)	Transformer	Hasarlı görüntülerin eksik yapısını geri yüklemek için transformatörlerin kullanımı	Çeşitli sahneler, Paris StreetView, CelebA, Places2	Orta (Çok büyük eksik alanlarda dahi anlamlı içerikler üretebilir. İşlem yükü yüksektir)
LaMa (Suvorov ve diğerleri, 2022)	CNN	Fourier konvolüsyon tabanlı geniş algı alanı: görüntü boyutundan bağımsız büyük maskeleri doldurmada başarılı, parametre verimliliği yüksek; dikkat mekanizması yerine Fourier dönüşümü kullanımı	Yüksek çözünürlüklü görüntüler büyük boşluklar, Places, CelebA-HQ	Orta (genel tutarlılık iyi ve büyük bölgelerde başarılı, ancak özgün detaylarda hata üretebilir)
ZITS (Dong, Cao ve Fu, 2022)	Transformer	Artan transformer ile yapısal onarım: düşük çözünürlükte kenar/çizgi restorasyonu için Transformer, ardından maskeli birleştirme ile CNN doku doldurma	Karmaşık yapı dokular, Indoor, Places2	Yüksek (Kenar + içerik uyumu sağlar, ancak işlem yükü yüksektir)
MISF (Li, X. ve diğerleri, 2022)	CNN+ Dinamik filtreleme	İki dallı yapı (semantik & görüntü filtreleme), dinamik konvolüsyon, detaylı yapı koruma	Doğal sahneler, sanat restorasyonu, Dunhuang	Yüksek (çok seviyeli yapı ve detaylı yapı koruma ile karmaşık desenlerde etkili olabilir)
MAT (Li, W. ve diğerleri, 2022)	Transformer	Maske-farkındalığı olan Transformer: Konvolüsyon ve tam dikkat mekanizmasını birleştirerek doğrudan yüksek çözünürlükte büyük boşlukları işler	Büyük hasarlı görüntüler, CelebA, Places2	Yüksek (tüm görüntü üzerinde dikkat sağlar, ancak eğitim süreci karmaşıktır)

2.5. Uygulama Değerlendirme Yöntemleri

Bu bölümde, görüntü tamamlama algoritmalarının performansını değerlendirmek amacıyla kullanılan yöntemler ele alınmaktadır. Öncelikle sayısal ölçütler sağlayan değerlendirme metrikleri tanıtılmakta, ardından desenlerin yapısal özelliklerini inceleyen topolojik veri analizi açıklanmaktadır. Son olarak, simetri ve düzenlilik ölçümlerine odaklanan Fourier tabanlı simetri analizi ile Gaussian yoğunluk haritası yöntemleri sunulmaktadır.

2.5.1. Görüntü kalite metrikleri

Görüntülerin ve işlevlerinin önemli bir yönü kalitesidir. Görüntü kalitesi değerlendirmesi bir görüntünün karakteristik bir özelliği olarak kabul edilmektedir. İnsan görsel algısı, görsel benzerlikleri kolaylıkla algılayabilir ve değerlendirebilir. Ancak, bilgisayar görme ve görüntü işleme alanındaki uzmanlar, bilgisayar tabanlı bir görüntü kalite (benzerlik) metriğinin insan görsel algısıyla uyumlu olmasını sağlamak için büyük çaba harcamışlardır. Bu metriklerin geliştirilmesi zorlu bir süreçtir çünkü insan görsel algısı, yüksek düzeyde yapısal bilgilerle ve belirli bağlam bağımlılıklarıyla ilişkilidir (Wang, Bovik ve Lu, 2002). Performans metrikleri, algılanan görüntü kalitesini değerlendirmek için nicel bir yöntem sağlamaktadır (Sara, Akter ve Uddin, 2019). Bu değerlendirme, bir görüntünün algılanan kalitesindeki bozulmayı değerlendirmek için kullanılmaktadır. Bozulma genellikle referans görüntü veya ideal bir görüntüye kıyasla hesaplanmaktadır (Wang, Bovik, Sheikh ve Simoncelli, 2004). İnsanların algısal olarak daha iyi görüntüleri ayırt etmesi kolay olsa da, algoritmaların bunu algılaması görev güçlüğü olarak ortaya çıkmıştır (Crump, McDonnell ve Gureckis, 2013). Bu bölümde, görüntü restorasyon modellerinin performansını değerlendirmek için sıklıkla kullanılan kalite değerlendirme teknikleri ve yöntemleri açıklanmaktadır.

Ortalama Kare Hatası (Mean Square Error-MSE)

Ortalama kare hatası (MSE), gözlemlenen değeri alarak, öngörülen değerin çıkarılmasıyla ve sonra farkın karesi ile hesaplanmaktadır (Allen, 1971). Bu metrik, derin üretken modellerde bir rekonstrüksiyon kaybı olarak yaygın olarak kullanılan bir performans metriğidir (Chai ve Draxler, 2014). Şu şekilde tanımlanmıştır:

$$MSE = \frac{1}{M \times N \times O} \sum_{i=1}^M \sum_{j=1}^N \sum_{k=1}^O (y_{(i,j,k)} - \hat{y}_{(i,j,k)})^2 \quad (2.7)$$

y orijinal görüntü, $\hat{y}$ geliştirilmiş görüntüyü, M ve N görüntü çözünürlüğünü, O ise görüntü kanalı sayısını ifade etmektedir. i, j ; görüntünün yükseklik ve genişliği (görüntünün boyutu) ve k değeri renkli görüntüdeki kanal sayısı (RGB kanalı) olarak temsil edilmektedir (Setiadi, 2021).

Tepe sinyal-gürültü oranı (Peak Signal to Noise Ratio-PSNR)

Görüntü işleme literatüründe tepe sinyal-gürültü oranı, genellikle bir maksimum sinyalin doğruluğu etkileyen gürültü oranı ile ölçülmektedir. Bu oran, sinyal gücü taşıyan bilgi seviyesinin gürültü gücü seviyesine bir ölçüsünü vermektedir (Gonzalez ve Woods, 2008). PSNR aşağıdaki gibi ifade edilmektedir:

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX^2}{MSE} \right) \quad (2.8)$$

MAX, görüntünün mümkün olan maksimum piksel değerini ifade etmektedir. PSNR değeri, MSE değeri sıfıra yaklaştıkça sonsuzluğa yaklaşmaktadır. İki görüntü arasındaki piksel değerindeki farkın fazlalığı, daha küçük bir değere sahip bir PSNR üretmektedir. Bu, daha yüksek bir PSNR değerinin daha yüksek bir görüntü kalitesi sağladığını gösterir. PSNR, görüntü restorasyon algoritmalarının performansını karakterize etmek için yaygın olarak kullanılmaktadır (Eskicioglu ve Fisher, 1995).

L1 kayıp fonksiyonu

L1 Kayıp fonksiyonu, tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını hesaplamak için kullanılmaktadır. Matematiksel olarak aşağıdaki gibi gösterilmektedir:

$$L1 = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.9)$$

Formülde; n , toplam örnek sayısını y_i gerçek değerleri $\hat{y}_i$ ise tahmin edilen değerleri ifade etmektedir. L1 metriği; görüntü işlemede, piksel düzeyindeki hataları indirmede, regresyon görevlerinde ve üretken modellerde görüntü oluşturma görevlerinde kullanılmakta ve kararlı sonuçlar verebilmektedir (Hastie ve diğerleri, 2009). Bu sebeple algoritmaların karşılaştırmasında sıklıkla kullanılan değerlendirme yöntemlerinden biridir.

Yapılandırılmış benzerlik endeksi ölçüsü (Structural Similarity Index Measure-SSIM)

Wang ve diğerleri (Wang ve diğerleri, 2004) tarafından geliştirilen bu yöntem, iki görüntü arasındaki benzerliği ölçmek için kullanılan önemli metriklerden bir diğeridir. SSIM, MSE ve PSNR benzerlik metriklerine göre insan gözü ile algılanan faktörlere dayanmaktadır. Herhangi bir görüntü bozulmasını ölçümlemek için orijinal ve üretilen görüntüler arasındaki yapı kaybı, parlaklık bozulması ve kontrast bozulması olarak üç faktörün bir kombinasyonunu kullanmaktadır (Setiadi, 2021). Her bir faktör ayrı olarak hesaplanmakta ve karşılaştırmaların sonuçları nihai bir puanda birleştirilmektedir. SSIM değeri matematiksel olarak şu şekilde tanımlanmıştır:

$$SSIM(x, y) = \frac{(2\mu_x \cdot \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2.10)$$

Bir referans veya orijinal görüntü x ile geliştirilmiş bir görüntü olan y arasındaki SSIM değeri hesaplanırken μ_x ve μ_y terimleri sırasıyla ilgili görüntülerin ortalama parlaklık değerlerini temsil etmektedir. σ_x ve σ_y değerleri ise görüntüdeki kontrast düzeyini belirlemede kullanılır. Yapısal benzerlik ise iki görüntü arasındaki yapısal benzerlik (σ_{xy}) ile ölçülür (Ghiro, 2022). SSIM formülündeki C_1 ve C_2 sabitleri ise $\mu_x^2 + \mu_y^2$ yada $\sigma_x^2 + \sigma_y^2$ değerleri sıfıra çok yakın olduğunda bölmeyi dengelemek ve kararsız sonuçlardan kaçınmak için stabilize sabitleri olarak kullanılmaktadır. SSIM değeri 1 olduğunda, karşılaştırılan iki görüntü tamamen benzer kabul edilir; benzerlik azaldıkça SSIM değeri de düşer ve tamamen farklı iki görüntü için bu değer 0'a yaklaşır (Maiti, Kumar, Jain ve Bhatnagar, 2021). Ancak SSIM'in bir dezavantajı, görüntü edinme cihazlarının hareketinin neden olduğu çeviri, ölçekleme, dönme gibi geometrik çarpıklıkları düzgün bir şekilde ele almamasıdır (Wang ve Bovik, 2006).

Öğrenilmiş algısal görüntü yama benzerliği (*Learned Perceptual Image Patch Similarity-LPIPS*)

Öğrenilmiş algısal görüntü yama benzerliği (LPIPS), Zhang ve diğerleri (2018) tarafından önerilen iki görüntü arasındaki algısal benzerliği hesaplamak için kullanılan derin sinir ağı temelli bir karşılaştırma yöntemidir (Zhang, Isola, Efros, Shechtman ve Wang, 2018). Bu metrik, önceden eğitilmiş bir evrişimli sinir ağından (Simonyan ve Zisserman, 2015) çıkarılan özellikleri görüntü benzerliğini ölçümleme görevleri için kullanmaktadır (Naeini, 2019). Düşük LPIPS puanı, görüntü yamalarının algısal olduğu anlamına gelir. Daha yüksek değer iki karşılaştırma arasında farkı artırırken düşük değer benzerliği artırmaktadır (Jam, 2021).

$$LPIPS(x, y) = \sum_l \frac{1}{H_1 W_1} \sum_{h,w} \|w_1 \odot (\hat{f}_l^x - \hat{f}_l^y(h, w))\|_2^2 \quad (2.11)$$


LPIPS değeri hesaplanırken x ve y karşılaştırılan iki görüntüyü temsil etmektedir. l derin ağın katmanını, $\hat{f}$ normalize edilmiş özellik haritasını, w_1 her kanal için öğrenilmiş ağırlık vektörünü ifade etmektedir.

2.5.2. Topolojik veri analizi

Nesnelerin şekillerini ve bu şekillerin süreklilik gibi özelliklerini inceleyen matematiksel disiplin topoloji olarak tanımlanmaktadır. Bu alandaki önemli bir gelişme ise, çeşitli ölçeklerde topolojik değişmezlerin kalıcılığını yakalayan Topolojik Veri Analizi (TVA)'dir. Bu yöntem, özellikle büyük ölçekli veri kümelerindeki örüntüleri ve ilişkileri keşfetmek için daha sağlam ve güçlü araçlar sunmaktadır (Carlsson, 2009; Edelsbrunner, 2012; Ghrist, 2008). Ayrıca verilerdeki örüntüleri ve ilişkileri belirlemek; dokusal, görsel bozulma ve görüntü kalitesi gibi konularda bilgi edinmek için bağlantılılık ve boşluklar gibi temel özelliklere odaklanarak araçlar sağlamaktadır (Asaad, 2020). Böylece TVA, çoğunlukla gözden kaçırılan yapısal bilgileri ortaya çıkararak verilerin daha derinlemesine anlaşılmasına katkı sunmaktadır.


TVA yönteminde kullanılan temel kavramlar arasında topolojik yapıları modelleyen basit kompleksler ve boşlukların veya bağlantılı bileşenlerin sayısını ölçmek için bir yöntem olan

kalıcı homoloji yer almaktadır. Bu yaklaşım, farklı ölçeklerdeki topolojik değişmezlerin sürekliliğini yakalayarak veri içindeki önemli yapıları tanımlamaya yardımcı olmaktadır. Basit kompleksler, veri noktaları arasındaki bağlantıları modellemek için kullanılan temel yapıları oluşturmakta ve verinin topolojik özelliklerini koruyarak analiz edilmesini sağlamaktadır. Bu süreçte, özellikle görüntü içerisindeki bağlantılı bileşenler ve boşluklar tanımlanmakta (Edelsbrunner, 2012), sonrasında kalıcı diyagramlar gibi yapılar aracılığıyla temsil edilmektedir (Zomorodian ve Carlsson, 2004). Görüntü tamamlama uygulamalarında, bağlı bileşen sayısı hem tamamlanmış hem de orijinal görüntü üzerinde hesaplanmakta; tamamlanmış bölgenin bağlı bileşen sayısının orijinaline yakınlığı, kullanılan algoritmanın kalitesini değerlendirmek için ölçüt olarak kullanılmaktadır. Yöntemin uygulanmasında, topolojik veri analizini görselleştirmek için geliştirilmiş DAAR Topology (Ali ve Asaad, 2020) arayüzü kullanılmaktadır. Bu yazılım, özellikle görüntü analizinde homolojik değişkenleri hesaplamak ve veri içindeki topolojik özellikleri belirlemek için analiz sürecini daha erişilebilir hale getirmektedir. Kalıcı homoloji aracının uygulama adımları şekilde görülmektedir (Şekil 2.49).




Şekil 2.49. Kalıcı homoloji süreçleri (Asaad, 2020)'dan uyarlanmıştır

TVA sürecinde görüntüler ilk olarak algoritmaya doku tanımlayıcıları kullanılarak tanıtılmakta ve bu kapsamda yerel ikili örüntüler (Local Binary Patterns-LBP) kullanılmaktadır. Ojala ve diğerleri (Ojala, Pietikäinen ve Harwood, 1996) tarafından önerilen LBP pikseller arasındaki sıralama ilişkisini dikkate alarak görüntülerin yerel dokusunu temsil eden bir kodlama tekniğidir. Kodlama işlemi, merkezi bir pikselin yoğunluk değerini eşik olarak belirler ve çevresindeki komşu piksellerle karşılaştırır. Süreç Şekil 2.50'deki gibi merkez piksel değerinin komşu değerlerden belirli bir noktadan başlayıp saat yönünde çıkarılmasıyla ilerlemektedir. Değerin merkezi piksele eşit ya da daha yüksek olduğu durular 1, düşük olduğu durumlar ise 0 ile ifade edilmektedir. Sonuç olarak bu değerler dairesel bir ikili dizilim oluşturularak yeniden etiketlenmektedir (Al-Jaberi, 2019; Ke-Chen, Yun-Hui, Wen-Hui ve Zhang, 2013).



Şekil 2.50. LBP sıralama ilişkisi (Al-Jaberi, 2019)

Yerel ikili örüntüler (LBP), bir desenin farklı döndürme durumlarını geçişler şeklinde göstermektedir (Şekil 2.51). Şekilde G0'dan G8'e kadar olan satırlar, belirli bir LBP desenini temsil etmektedir. Aynı gruptaki desenler aynı sayıda "1" ve "0" değerlerine sahiptir. Her sütun ise, belirli bir desenin farklı açılarla döndürülmesiyle elde edilen dönüşüm versiyonlarını gösterir. Yoğunluk ilişkisinin hesaplanmasında, bir görüntü döndüğünde aynı doku deseni farklı bir konumda görünebilir. Bu tür dönüşlere bağlı olarak, LBP histogramları da değişmektedir (Al-Jaberi, 2019).



Şekil 2.51. LBP kodlarının geometrik gösterimi (Qi, Shen, Zhao, Li ve Pietikäinen, 2015)'dan uyarlanmıştır.

Ojala ve diğerleri (2002) LBP desenlerinin, parlak nokta, koyu nokta/düz alan ve çeşitli eğriliklerde kenarlar gibi temel mikro yapıları yakaladığını göstermiştir. Asaad (2020) çalışmasında ise karakterize edilen doğal görüntü eşleşmelerine göre;

- G0 ve G8 geçiş içermeyen geometrileri içermektedir. G0, düz yüzeyleri ve G8 ise noktasal, leke bölgeleri temsil etmektedir.

- G2 ve G4 türü geometriler görüntüdeki kenarları ve konturları temsil etmektedir.
- G3 ve G5 türü geometriler görüntüdeki köşeleri temsil etmektedir.
- G6 doğal görüntülerde çizgi sonlarını temsil etmektedir. Bu tür desenler karmaşık ve yoğun doku bölgeleriyle ilişkilendirilmektedir
- G1 veya G7'nin doğal görüntüler bağlamında özel bir tanımı yoktur. Yüz görüntüleri bağlamında alternatif eşlemede çizgi uçlarını tanımlamak için kullanılmıştır. (Chan, Kittler ve Messer, 2007'den aktaran Al-Jaberi, 2019; Asaad, 2020).

2.5.3. Fourier tabanlı simetri analizi ve Gaussian yoğunluk haritası

Fourier dönüşümü, karmaşık sinyalleri oluşturan farklı frekans bileşenlerini ayrıştırarak temsil eden temel bir matematiksel yöntemdir. Bu yöntem, herhangi bir sinyalin farklı frekanslarda bulunan bileşenlerini ortaya çıkararak çeşitli bilimsel alanlarda geniş bir kullanım alanı sunmaktadır (Bracewell, 1989). Keller ve Shkolnisky (2006) Fourier dönüşümü kullanarak elde ettiği açısal korelasyon fonksiyonunun, n -katlı döner simetriye sahip desenin periyodik bir sinyal verdiğini ve temel frekansın n ile ilişkili olduğunu göstermiştir (Keller ve Shkolnisky, 2006). Benzer şekilde, Lomov ve diğerleri (2023), şekillerin simetri derecesini üzerinde Fourier analizi yaparak belirlemişlerdir (Lomov, Seredin, Kushnir ve Liakhov, 2023). Bu yöntemler, desenin genel düzeninin (örn. tekrar eden motifler, örgü yapısı) ve simetrisinin değerlendirilmesine katkı sağlamaktadır. Simetri bozulmalarının ölçümünde ise, Fourier tabanlı analiz önem taşımaktadır. Fourier dönüşümünün açısal profili, simetri eksenlerine karşılık gelen yönlerdeki enerji piklerini ortaya çıkararak; bu piksellerin şiddeti ve düzeni, desenin ne kadar simetrik olduğunu göstermektedir. Örneğin bir desen on katlı simetriye sahipse, Fourier spektrumunda merkez etrafında on simetrik tepe noktası görülmesi beklenir. Böylelikle görüntü tamamlama sırasında simetri ekseninin kayması, tepe konumlarının ufak bir açı farkıyla yer değiştirmesine yol açabilmektedir. Dolayısıyla açısal sapma, simetri bozulması nicel bir gösterge olarak kullanılabilir.

Gaussian yoğunluk haritası, desenin temel geometrik elemanlarının konum dağılımını gösteren yoğunluk görüntülerini görselleştirmektedir. Bu harita, desen üzerindeki özellik noktalarına iki boyutlu Gauss çekirdekleri uygulayarak oluşturulmaktadır. Örneğin, Lin ve diğerleri (1997) düzenli bir dokunun otokorelasyon fonksiyonunu en uygun Gauss filtresiyle

süzerek ortaya çıkan pikleri vurgulamışlardır (Lin, Wang ve Yang, 1997). Gauss filtresiyle oluşturulmuş yoğunluk haritası, desenin elemanlarının kümelenmesini görselleştirmekte; yüksek yoğunluk bölgeleri motiflerin bir araya geldiği yerleri göstermektedir. Bu sayede desenin yapısal bütünlüğü, elemanların ne kadar düzenli ve yoğun yerleştiği gibi özellikler anlaşılabilir hale gelmektedir.

Gaussian yoğunluk haritası üzerinde tepe noktası tespiti işlemi ise, desenin öne çıkan motiflerinin belirgin noktalarını ortaya çıkarmaktadır. Yoğunluk haritasındaki her bir zirve, desenin belirgin bir geometrik elemanına karşılık gelir. Böylece orijinal ve tamamlanmış desenler için hesaplanan yoğunluk haritalarında bulunan tepe noktalarının sayısı ve konumları karşılaştırılır. Tamamlama işleminin yapısal elemanlarının tepe noktalarının konumlarının orijinal desenle olan tutarlılığı başarı durumunu ölçmektedir. Aksi durumda, yeni zirve noktaları oluşabilir veya beklenen bazı zirveler eksik kalabilir. Bu sayede Gaussian yoğunluk haritaları ve tepe tespiti, desenlerin öğeler düzeyindeki yapısal bütünlüğü hakkında nicel bilgi sağlamaktadır. Bu bilgiler, desen içerisindeki motif yoğunluğu, eleman sayısı ve konumlarındaki tutarlılık gibi kriterleri ölçmektedir.


3. ARAŞTIRMA METODOLOJİSİ

Literatür bölümünde değindiğimiz gibi, geleneksel yöntemlerle oluşturulmuş çok sayıda İslami geometrik desen tasarımı bulunmaktadır. Bu tasarımlar, özellikle çeşitli bilgisayar programları ve dijital çizim teknolojileri kullanılarak geliştirilmiştir. Buna ek olarak çalışmada mevcut yaklaşımların iyileştirilmesi ve yeni yöntemlerin ortaya çıkarılması için, İslami geometrik desenlerin üretim süreçlerini anlamaya yönelik yenilikçi ve otomatik yaklaşımlar benimsenmiştir. Ayrıca bu otomatik yöntemler, zaman kısıtlamaları karşısında hızlı ve etkili sonuçlar üretebilme yetenekleri sebebiyle araştırma sürecinde hem verimlilik hem de uygulanabilirlik açısından önemli bir avantaj sağlamaktadır. Bu bağlamda, metodoloji kapsamında, kullanılan yaklaşım, kapsam bilgisi, veri toplama süreci, uygulanan yöntemler ve değerlendirme teknikleri sunulmaktadır.

3.1. Araştırma Yaklaşımı

Çalışmanın akışında uygulamaya yönelik bir araştırma metodolojisi kullanılmıştır. Bu süreçte uygulamaların sadece bir çıktı aracı değil, yöntemin bir parçası olması; uygulamaların izlerini takip eden bir araştırma akışını ortaya çıkarmaktadır (Skains, 2018). Böylece İslami geometrik desenlerin oluşum sürecinin incelenmesi, veriye dayalı yaklaşımların bu sürece katkılarının tartışılması ve uygulama çıktılarının yeni bilgileri türetmesi ile bir sonraki adımlar için karar girdisi olarak kullanılması sağlanmıştır.

Desenlerin üretim sürecini oluşturmak ve veriye dayalı yöntemlerin bu süreçteki etkilerini değerlendirmek amacıyla farklı uygulamaların dahil olduğu bir akış kullanılmaktadır. Bu akış ile İslami geometrik desenlerde dijital analiz, sınıflandırma ve eksik parça tamamlama problemlerini, yinelemeli denemeler ve karşılaştırmalı değerlendirmeler yoluyla çözümleyen bir süreç oluşturulmuştur. Süreç; veri toplama, veri bütünlüğünü değerlendirmek için sınıflandırma ile ön doğrulama, üretim (GAN) denemesi ve karar, görüntü tamamlama (inpainting) için model seçimi ve uygulanması, nicel ve nitel değerlendirme ile yapısal ve topolojik analiz adımlarından oluşmaktadır. Bu yaklaşımda desen oluşturma sürecine entegre edilen algoritmalar ile elde edilen yeni bilgiler, desenlerin geometrik yapılarının daha iyi anlaşılması için geri besleme döngüsü oluşturmaktadır. Metodolojinin aşamaları Şekil 3.1’de gösterilmektedir.



Şekil 3.1. Çalışma metodolojisinin aşamaları

3.2. Uygulama Süreci ve Değerlendirme

Bu çalışmada, İslami geometrik desenlerin analiz edilmesi, sınıflandırılması ve tamamlanmasına yönelik derin öğrenme teknikleri kullanılmaktadır. Araştırmanın metodolojisi; veri setinin hazırlanması, GAN modelleriyle desenlerin yeniden yapılandırılması, desenlerin görüntü gruplarına göre sınıflandırılması ve görüntü boyama algoritmaları ile eksik desenlerin tamamlanması ve tamamlanan desenlerin değerlendirilmesi olarak beş ana aşamada ele alınmıştır. Bu başlıklar uygulama adımlarını, elde edilen bulguları ve değerlendirmeleri içermektedir.

İlk bölümde İslami geometrik desenlere dair görüntü işleme aşamasına uygun bir veri seti oluşturularak sınıflandırma ve tamamlama modellerinin eğitimi için bir temel hazırlanmıştır. Veri seti oluşturma aşamasında, farklı kaynaklardan derlenen görseller belirli kategorilere ayrılmış ve filtreleme işlemleri uygulanmıştır. Bu adım, çalışmanın sonraki bölümlerinde kullanılacak girdi verisinin tutarlı olmasını sağlamaktadır. İkinci aşamada, desen üretimi ve keşfine yönelik olarak GAN tabanlı bir deneme yürütülmüş, fotoğraf ve sentetik görüntüler üzerinde eğitilen DCGAN algoritması ile yeni desenler oluşturulmuştur; ancak çıktılarda morfolojik tutarlılık ve gerçeğe yakınlık açısından yetersizlikler gözlemlenmiştir.

Çalışmanın devamında, desen tamamlamaya uygun bir yöntem olarak görüntü boyama algoritmalarına geçiş yapılmaktadır. Bu uygulamalarda sadece fotoğraf görüntüleri kullanılmış ve bu görüntüler fotoğraf özelliklerine göre üç kategoriye ayrılmıştır. Buna göre sınıflar; doğrudan (frontal) çekimler (perspektif bozunumu minimal olan örnekler), açılı çekimler (farklı bakış doğrultuları nedeniyle perspektif/ölçek değişimi içeren örnekler) ve yapı bileşeni içeren görseller (desenin çevresinde kemer, bordür, yazı vb. mimari unsurlar bulunan örnekler) olarak tanımlanmaktadır. Bu kategorilerin dijital görüntü formatında uygunluğunun ölçülmesi için ilk aşamada derin öğrenme modelleri ile sınıflandırma yapılmış, CNN tabanlı sınıflandırma algoritmaları kullanılarak modellerin performansı ve veri setinin uygunluğu değerlendirilmiştir. Bu aşamada algoritmaların sınıfları belirleme konusunda başarılı performans göstermesi ile görüntü tamamlama algoritmalarında aynı veriler ile teste devam edilmiştir. Bu uygulamalarda görüntü restorasyonunun karmaşıklık ve bozulma seviyelerine karşı yeterince duyarlı ve etkili bir şekilde sağlaması beklenmektedir. Bu sebeple geleneksel optimizasyon tabanlı yöntemlere kıyasla, bozulmalara maruz kalmış veri setlerinde yüksek performansı sayesinde derin öğrenme

tabanlı restorasyon modelleri tercih edilmiştir. Görüntü tamamlama başlığında yapılan analiz kapsamında uygulama sonuçlarında başarılı olan üç farklı algoritma seçilmiştir. Bu seçim, yalnızca genel başarıya değil, aynı zamanda algoritmaların veri setine uygunluğuna dayanmaktadır. Seçilen algoritmalar, İslami geometrik desenlerin tekrar eden motif yapısını koruyabilme, eksik bölgeleri doğal bir şekilde tamamlayabilme ve kenar sürekliliğini başarılı bir şekilde sağlayabilme kapasitelerine göre değerlendirilmiştir. Kullanılan modellerden ilki eksik desenleri kenar haritası çıkararak tamamlayan EdgeConnect modelidir. Model, görüntüyü kenar haritasına dönüştürülerek eksik bölgelerde tahmini kenarlar oluşturmaya ve eksik bölge piksel yoğunluklarını tamamlamaya odaklanmaktadır. İkincisi düşük seviyeli detayları koruyarak eksik alanları tamamlamak için çok aşamalı özellik haritaları kullanan DFNet modelidir. Modelde kod çözücü katmanlarına eklenen füzyon blokları, çevredeki bağlamı ince detaylarla birleştirerek özellikle boşluk sınırlarında doku ve kenar sürekliliğini güçlendirmektedir. Üçüncü model ise eksik bölgeleri doldururken farklı ölçeklerde bilgi toplayarak doğal tamamlamalar sağlayabilen MISF modelidir. Bu model, çoklu ölçekli özelliklerin birleştirilmesi sayesinde eksik bölgelerde bütünlük sağlayabilmektedir. Uygulamalar veri seti kısıtlılıklarından dolayı önceden eğitilmiş ağırlıkları kullanmaya odaklanmaktadır. Görüntüler 512x512 ve 256x256 olmak üzere boyutlandırılmıştır. Yapılan uygulamaların başarı düzeyleri, hem görüntü kalite metrikleri hem de görsel çıktılar aracılığıyla sağlanmıştır. Değişkenler arasındaki ilişkileri anlamak ve kullanılan algoritmaların diğer yöntemlere kıyasla performansını değerlendirmek için nicel analiz yöntemlerinden faydalanılmaktadır. Elde edilen sonuç görselleri ile başlangıç verileri arasında karşılaştırmalı bir analiz gerçekleştirilerek algoritmaların etkinliği ve doğruluğu incelenmiştir.

Uygulama sonuçlarının ölçüm ve analizinde ayrıca topolojik yapı özelinde, görsel benzerlikten bağımsız bir doğrulama katmanı kurulmuştur. Bu kapsamda, desenlerin kenar haritaları üzerinden üretilen bağlantı grafikleri kullanılarak; bağlı bileşen sayıları ile kenar geçiş bütünlüğü gibi ölçütler çıkarılmıştır. Ölçütler, orijinal ve tamamlanmış görüntü çiftleri arasında mutlak fark ve oransal sapma olarak raporlanmış; böylece piksel-temelli metriklerin kaçırabildiği yapısal kopmalar ve desen ağının yeniden bağlanma hataları nicel olarak görünür kılınmıştır. Bu topolojik katman, özellikle motif sınırlarının korunumu ve kenar sürekliliği açısından, görsel kalite metriklerini tamamlayıcı bir yapısal doğruluk göstergesi olarak kullanılmıştır.

Son bölümde ise tamamlanan desenlerin geometrik bütünlüğünü ve süregelen desen bütünlüğünü ve simetrisini koruyup koruyamadığını incelemek için topolojik analiz frekans yönelimi ve yoğunluk haritası analizi yapılmıştır. Analizde her algoritma tarafından üretilen desenlerin kenar sürekliliği, motif bütünlüğü ve genel simetri korunumu değerlendirilmiştir. Bu süreçte algoritmaların eksik bölgeleri tamamlamadaki başarısı sayısal metriklerin yanı sıra topolojik analizle de desteklenmiş ve detaylandırılmıştır.

3.3. Veri Kaynakları ve Toplama Süreci

Çalışmada İslami geometrik desenler için bir veri seti oluşturmak, tarihi kaynaklardan çeşitli geometrik desen ve tasarımları bir araya getirmek için önemli bir aşamayı kapsamaktadır. İslam sanatı ve mimarisini incelemek ve tarihi yapılardan örnekler elde etmek amacıyla elde edilen fotoğraflar ve çizimler, analiz ve çoğaltma için zengin bir veri kaynağı sağlamaktadır. Fiziksel koleksiyonlara ek olarak, çevrimiçi veri tabanları, sanal koleksiyonlar ve dijital arşivler gibi kaynaklardan yararlanmak veri setinin kapsamını daha da genişletmektedir. Bu yaklaşım, daha geniş kapsam ve çeşitlilikte örneklerin toplanmasını sağlamaktadır. Veri seti, tarihten gelen çeşitli örnekleri derleyerek, çeşitli bağlamlarda İslami geometrik desenleri incelemek, anlamak ve oluşturmak için bir kaynak olarak hizmet etmektedir. Bu kapsamda kullanılan veri kaynakları üç çeşittir:

- 1) Fiziksel kaynaklardan elde edilen veriler
- 2) Google görseller aracılığıyla toplanan veriler
- 3) İlgili internet arşivlerinden toplanan veriler

Literatür çalışmalarında geometrik desenler, erken dönemler ve sonrasında hüküm süren hanedanlar açısından ele alınmakta ve bazı anıtlardan örnek olarak bahsedilerek belirli tasarımlar tartışılmaktadır (Abdullahi ve Embi, 2013; Berggren, 2017; Bier, 2015; Bonner, 2017; Cromwell, 2016; Makovicky, 2017; Rajabi ve Khosravi, 2019). Broug ve Necipoğlu çalışmalarında anıtları orijinal isimleri, hanedanları ve coğrafi konumlarına göre tanımlamaktadır (Broug, 2013; Necipoğlu ve Al-Asad, 1995). Bölgelere göre desenlerin elde edilmesi, İslam sanatında kullanılan geometrik yapılara, simetrilere ve motiflere daha kapsamlı bir şekilde ulaşmayı ve desen tipolojisini artırmanın çalışmanın sonuçlarına etki edeceği düşünülmüştür. Bunun sonucunda, verinin geniş kapsamda toplanmasına aracılık

etmesi sebebiyle coğrafi konuma göre arama şekli ile kaynaklar incelenmiştir. Veri toplama sürecinde verilerin elde edildiği coğrafi konumlar Şekil 3.2’de gösterilmektedir.



Şekil 3.2. Verilerin elde edildiği coğrafi konumlar

Veri toplama süreci ilk olarak konu ile ilgili kaynakların toplanmasından oluşmaktadır. Bu kaynaklar yukarıda bahsedildiği gibi üç aşamadan oluşmaktadır. Sürecin ilerleyen aşamalarında ise bu kaynaklardan verilerin alınması ve düzenlenmesi gelmektedir. Toplanan veriler çalışma kapsamında kullanılacak düzeye getirilmesi için filtreleme aşamasından geçmektedir. Sonrasında ise kategorilere ayrılmaktadır. Şekil 3.3’te verinin oluşturulma süreci görülmektedir.



Şekil 3.3. Verilerin elde edilme süreci

Fiziksel kaynaklardan elde edilen veriler

Fiziksel kaynaklardan elde edilen veriler bireysel araştırmacı arşivlerinden ve ilgili yazarların kitaplarını da içeren kütüphane kaynaklarından (Bonner, 2017; Sönmez, 2020; Burckhardt, 2009) oluşmaktadır. Bu kaynaklardan hem fotoğraf tabanlı hem de dijital ortamda üretilmiş İslami geometrik desenler temin edilmiştir. Desen fotoğrafları

olabildiğince yüksek çözünürlüklü ve anlaşılabilir görüntülerden elde edilmeye çalışılmıştır. Veri filtreleme aşamasında bu kapsama uymayan görüntüler çıkarılmıştır. Fotoğraflanma şekillerine dayalı olarak veriler kategorilere ayrılmıştır. Görüntüler dik açı ile doğrudan çekilen fotoğraflar, açılı yani farklı açılardan çekilen fotoğraflar ve yapı bileşeni içeren fotoğraflar olarak farklı sınıflardan oluşmaktadır. Görüntü örneklerinin bazıları Şekil 3.4'te görülmektedir.



Şekil 3.4. Fiziksel kaynaklardan elde edilen verilerden örnekler

Google görseller aracılığıyla toplanan veriler

Google Görsel Aramalar görsel veri kümesi oluşturmak için kullanılan bir diğer arama yöntemidir. Daha iyi sonuçlar elde etmek için görsel arama kriterleri detaylandırılmıştır. Bunun için öncelikle arama için kullanılacak anahtar kelimeler belirlenmiş ve görseller indirilmiştir. Arama sonuçlarında mimari miras, müzeler, kütüphaneler ve sanatla ilgili alanlar yer almaktadır. Oluşan listeleri farklı coğrafi bölgelere göre yenileyerek görsel olarak ayırt edici bir unsur haline getirilmeye çalışılmıştır. Geometrik desenlerin tespitini farklı bölgelere göre ele alınması, elde edilen görsellerde geleneksel kaynaklardan faydalanılmasını sağlamıştır. İslami geometrik desenlerin geniş bir alanı kapsadığı düşünüldüğünde kültürel mirasın sınırlarının içinde olması, ayırma işlemi gerektirmektedir. Bu sebeple İslami geometrik desenlerin kültürel miras olarak tanımlanmayan modern yorumlamaları ve sentetik veriler dahil edilmemiştir. Veri toplama sürecindeki arama yöntemi aşağıdaki adımlardan oluşmaktadır:

1. Veri kümesi için manuel olarak bir ön sorgu anahtar kelimeleri kümesi oluşturma (Ön arama kategorilerini oluşturmak için anahtar kelimelerin analizi)
2. Sorgu anahtar kelimelerinin kelime ağacı yardımıyla sorgu anahtar kelimelerinin genişletilmesi
3. Verinin toplanması
4. İlgisiz verilerin ayrıştırılması

5. Aramaların temel bilgiler yardımıyla incelenmesi, ilgilenilen unsurların ve kategorilerin tanımı

Anahtar kelimeler, geometrik desenler konusunda paylaşılan verilerin doğasına ilişkin bir anlayış sağlamak, ayrıca bu alanda elde edilen görseller ile geniş bir kaynak oluşturmak amacıyla oluşturulmuştur. Sorgu için bir dizi anahtar kelime elde etmek ve ön kategorileri belirlemek amacıyla genel bir arama terimi kullanılmıştır. “*İslamic geometric pattern*” başlığı altında ön sorgu anahtar kelimesi ile analiz edilmiştir. Böylece, arama sonucunda çıkan otomatik önerileri ve ilişkili terimler incelenerek ön anahtar kelime listesi oluşturulmuştur. Benzer kelimeler daha sonra manuel olarak Çizelge 3.1’deki gibi sıralanmaktadır.


Çizelge 3.1. Anahtar kelime analizi

Kategori	Detay
Anahtar kelimeler	Islamic art, Islamic design, Islamic geometry, Geometric motifs, Islamic ornamentation, Islamic architecture, Moorish patterns, Islamic tile patterns, Islamic calligraphy, Islamic motifs, Islamic tile design, Islamic decorative art, Geometric Islamic art, Islamic pattern design, Persian geometric patterns, Islamic tessellation, Islamic manuscript illumination

Sonuçta ortaya çıkan sık kullanılan kelimeler özetlenmiş ve sıklıklarına göre sıralanmıştır. En sık kullanılan kelimeler arasında “*Islamic art*” anahtar kelimesi bulunmaktadır. İslam sanatı, geniş bir coğrafi ve kültürel yelpazeye yayılan İslam dünyasında üretilen çeşitli sanat formlarını ve stillerini kapsayan geniş bir terimdir. İslami geometrik tasarım, özellikle İslam sanatı ve mimarisinde yaygın olan karmaşık geometrik desenlere ve tasarımlara odaklanmaktadır. Bu sebeple veri kümesi oluşturmak amacıyla daha geniş bir çerçeve sunduğu görülen “*islamic art*” anahtar kelimesi sorgularda ana terim olarak kullanılarak kelime ağacı oluşturulmuştur.

Anahtar kelimelerin kelime ağacı yöntemi ile genişletilmesi aşamasında, İslami geometrik desenlerle ilgili görsel çeşitliliği artırmak amacıyla her bir sorgu anahtar kelimesinin alt kümeleri elde edilmiştir. Şekil 3.5’te “*Islamic art*” terimi temel alınarak oluşturulan ve alt başlıklarda geometrik desenlere ulaşılacak kelime ağacı yer almaktadır. Bu kelime

ağaçları, arama stratejisini optimize etmek açısından önemli bir adımı oluşturmaktadır. Kaynakların daha çeşitlendirilebilir olması için İngilizce ifade dilleri kullanılmıştır.



Şekil 3.5. Bir anahtar kelimeyi bağlam içinde keşfetmek için kullanılan kelime ağaçları

Veri toplama aşamasında, kelime ağaçları aracılığıyla belirlenen anahtar ve alt anahtar kelimeler kullanılarak Google Görsel Arama üzerinden sorgular gerçekleştirilmiştir. Her bir kategoriye ait görseller indirilmiş, yinelenen görseller ayıklanmıştır. Bu aşamada, içerik türüne yönelik bir ön eleme yapılmaksızın, geometrik desen içeren ve içermeyen fotoğraflar ile dijital ortamda üretilmiş görseller toplanmıştır.


Çizelge 3.2. Veri filtreleme kriterleri

Kategori	Tanım
İslami geometrik desen fotoğrafları	Kültürel miras alanlarına ait tüm görüntüler (hasarlı ya da hasarsız) bu kategoride sınıflandırılmıştır.
Silinen görüntüler	İçeriğin görünmediği ve bu nedenle analiz edilemediği desen odaklı olmayan yapılara ait görüntüler, aynı içeriğe sahip eşleşen görüntüler, kültürel miras alanlarını içermeyen ilgisiz tüm görseller, dijital ortamda üretilmiş görseller bu kategoride sınıflandırılmıştır.

Veri filtreleme aşamasında, görüntü tamamlama işleminde eksik kısımları tamamlanacak unsurların görüntü içeriklerine göre farklılık göstermesi dikkate alınmıştır. Bu doğrultuda, filtreleme sürecinde; alakasız içerikler, bozuk veya çözülemeyen görüntüler ile dijital

ortamda üretilmiş görseller veri kümesinden çıkarılmıştır. Veri kümesi yalnızca kültürel miras alanlarını temsil eden fotoğraflardan oluşacak şekilde düzenlenmiştir. Sınıflandırma şeması Çizelge 3.2’de görülmektedir.

Verinin filtrelenmesinde temel sorun, görsellerin çok sayıda ilgisiz veya kullanılamaz görsel içermesidir. Bu çalışmada, alakasız ya da kullanılamaz görseller öncelikle görselin birincil konusu olmadığı ya da orijinal bağlamı önemli ölçüde değiştirecek şekilde düzenlenmiş görseller olmuştur. Alakasız görseller geometrik desenler yapı ya da sanat eserlerine ait olmayan, görüntü kalitesi düşük görsellerdir. Şekil 3.6’da veri setindeki bazı alakasız görüntüleri göstermektedir. Bunlar desenin algılanamadığı fotoğraflar, bitkisel motifler, alakasız öğelerin görüntünün büyük bir kısmını kapladığı görüntüler, kufi yazıları içeren görüntülerden oluşmaktadır.



Şekil 3.6. Geometrik desen kategorisi ile ilgisiz görüntüler

Veri filtreleme aşamasında, Çizelge 3.2’de belirlenen kriterler doğrultusunda görüntüler çıkarılmıştır. Görüntülerin çoğunluğu filtreleme kriterlerine dayalı olarak yapılan aramalarda silinen içerikler kategorisine girmekte ve çoğunlukla eşleşen görüntülerden oluşmaktadır. Bu nedenle, alakasız içeriklerin yanı sıra farklı aramalarda çıkan veya farklı dosya adlarıyla kayıtlı olan aynı görseller de tespit edilerek veri kümesinden çıkarılmıştır.

Kategori tanımlama aşaması ise, arama sonuçlarının görsel içerik özellikleri ve bağlamsal bilgileri dikkate alınarak değerlendirilmesini kapsamaktadır. İslami geometrik desen fotoğrafları, çekim açısı ve kompozisyon özelliklerindeki farklılıklar dikkate alındığında;

dik açıyla doğrudan çekilmiş fotoğraflar, farklı açılardan çekilmiş (perspektifli) fotoğraflar ve yapı bileşeni içeren fotoğraflar olmak üzere üç alt gruba ayrılmıştır. Bu ayrım, desenlerin görüntü tamamlama algoritmaları üzerindeki etkilerini farklı perspektif koşulları ve bağlamsal unsurlar altında incelenmesini sağlamaktadır.

İnternet arşivleri aracılığı ile toplanan veriler

Veri kümesinin oluşturulması için kullanılan bir diğer yöntem ise İslami geometrik desenleri içeren internet arşivlerinin kullanılmasıdır. Bu veri oluşturma aşamasında aşağıdaki adımlar izlenmiştir.

1. Kaynakların elde edilmesi
2. Verilerin toplanması
3. İlgisiz verilerin ayrıştırılması – veri filtreleme
4. İlgilenilen unsurların ve kategorilerin tanımı

İnternet arşivleri özellikle İslami geometrik desenlere odaklanarak İslam dünyasındaki zengin mimari dekorasyon mirasını sergilemektir. Bu web siteleri, İslami geometrik tasarımın güzelliğini ve önemini paylaşmak için bir platform olarak hizmet vermekte ve sanat tarihçileri, tasarımcılar ve sanat meraklılarına kaynak sağlamaktadır. Bu web sitelerinden (Pattern Islamic Art, Art of Islamic Pattern web siteleri) elde edilen geometrik desenler veriye önemli derecede kaynak sağlamaktadır. Verinin oluşturulması aşamasında bu web sitelerinin koleksiyonları incelenmiştir. İlgili web siteleri fotoğraf arşivleri sunmaktadır. Görüntülerde, geometrik desen içermeyen süsleme sanatlarına ait motifler, desenin algılanamadığı fotoğraflar ayıklanmıştır. İlk aşamada görüntüler herhangi bir filtreleme olmaksızın toplanmıştır. Elde edilen verilerin genel bir kapsamı içermesi gereği, yalnızca alakasız görüntüleri değil aynı zamanda çözilemeyen görüntüleri de içeren fotoğraflar çıkarılmıştır.

Veri toplama sürecinde görüntü işlemede kullanılabilecek boyut ve çözünürlükte, desen görüntüsünün net olarak algılanabildiği görüntüler toplanmış ve birleştirilmiştir. Toplamda 2882 fotoğraf görüntüsünden oluşan bir veri seti oluşturulmuştur.



4. ALAN ÇALIŞMASI

Bu bölümde, İslami geometrik desenler için oluşturulan veri setinin kapsamı, sınıflandırma aşamaları ve yapılan uygulamaların bulguları yer almaktadır. Aşamalı olarak yöntem kısmında detaylandırılan süreçlerin uygulamaları gerçekleştirilmiştir. Alan çalışmalarında ilk olarak yeniden yapılandırma uygulamaları izlenmiş, daha sonra sınıflandırma ve tamamlama algoritmaları uygulanmıştır. Sınıflandırma aşamasında çeşitli CNN tabanlı derin öğrenme modelleri kullanılmış ve performansları doğruluk ve kayıp değerleri ile karşılaştırılmıştır. Görüntü tamamlama işlemleri, görüntü tamamlama algoritmaları aracılığıyla yürütülmüş; modellerin başarısı hem görsel hem de nicel analizlerle değerlendirilmiştir. Elde edilen bulguların, önerilen yöntemin desen üretimi ve restorasyonunda kullanılabilirliği gözlemlenmiştir.

4.1. İGD' de Veriye Dayalı Yeniden Yapılandırma

Çalışmanın bu bölümünde, desen üretiminde veri temelli bir yaklaşımın olanaklarını araştırmak amacıyla, derin öğrenme tabanlı bir üretici model olan Derin Evrişimli Üretici Çekişmeli Ağ (DCGAN) uygulanmıştır. DCGAN, bir görsel veri kümesinin dağılımını öğrenerek bu dağılıma benzer yeni görüntüler üretebilen bir mimaridir. Üretilen görsellerin, doğrudan veri kümesinden alınmamış olmasına rağmen, orijinal desenlerin stilistik ve yapısal özelliklerini taşıması beklenmektedir. Bu sayede, daha önce veri kümesinde yer almamış ancak onun istatistiksel yapısına uygun yeni desen örnekleri üretilebilmektedir. Bu bölümde, hem İGD veri setinin içerdiği varyasyonlara uygun üretici bir modelin nasıl tasarlandığı hem de bu modelin görsel üretim başarımı değerlendirilmektedir. Böylece yalnızca eksik parçaların tamamlanması değil, aynı zamanda yeni desen önerilerinin otomatik şekilde üretilip üretilmeyeceği sorusuna da yanıt aranmaktadır.

Kullanılan modelde yüksek performansın sağlanması büyük miktarda eğitim verisinin bulunmasına bağlıdır. Ancak çalışmada, büyük veri toplamanın zorluğu göz önüne alındığında, elde edilen kısıtlı veri kümeleri süreçte yapılan denemelerde, veri görselleştirme konusunda çeşitli zorluklar ortaya çıkmıştır. Bu sebeple elde edilen verilerden dijital ortamda üretilmiş (sentetik) ve fotoğraf görüntüleri üzerinden tekrar düzenlemeler yapılmıştır. Sentetik görüntüler olarak işlenen birincil veri setleri, daha temiz ve net görüntü varsayıldığından, geometrik desenlerin farklı tekrarlayan birimlerini içermektedir. Bu

görüntüler geometrik desenin tekrar eden en küçük parçalarından elde edilmiştir. Fiziksel olarak elde edilen görüntülerden oluşan bu veriler, farklı gruplara ve karmaşıklıklara dahil çizimler 272 adet görüntüden oluşturmaktadır. Desenlerde herhangi bir çoğaltma işlemi uygulanmamıştır. İkincil olarak fotoğraf görüntülerinden elde edilen veri setinde ise, herhangi bir sınıfa ayrılmaksızın fotoğrafların olabildiğince desene dik bir bakış açısıyla çekilmiş olanlardan seçilmiştir. Farklı gruplara ve karmaşıklıklara dahil fotoğraflar 1244 adet görselden oluşturmaktadır. Verilere ait örnekler Şekil 4.1’de gösterilmektedir.



Şekil 4.1. Dijital ortamda üretilmiş görüntüler (solda), fotoğraf görüntüleri (sağda)

DCGAN aracılığıyla veri setlerinin eğitimi

Çalışmada kullanılan DCGAN mimarisi, bir üretici ve bir ayırt edici olmak üzere iki sinir ağından oluşmaktadır. Üretici ağda aktivasyon fonksiyonu olarak, ReLU kullanılmış ve her bir evrişim adımının ardından eğitim sürecini kararlı hale getirmek için toplu normalizasyon uygulanmıştır. Çıkış katmanında ise üretilen görüntülerin normalize edilebilmesi için Tanh aktivasyon fonksiyonu tercih edilmiştir. Ayırıcı ağda ise, Her evrişim katmanında Leaky ReLU aktivasyon fonksiyonu kullanılarak olası “ölü nöron” problemlerinin önüne geçilmesi amaçlanmıştır. Son katmanda Sigmoid aktivasyon fonksiyonu ile çıktı, 0–1 aralığında bir olasılık değeri olarak üretilmiştir. Bu değer, girdinin “gerçek görüntü” olma olasılığını ifade etmektedir. Ayırıcı ağda da, tıpkı üretici ağda olduğu gibi, ara katmanlardan sonra toplu normalizasyon uygulanmıştır.





Eğitim sürecinde, iki kategoriye ayrılmış veri seti kullanılmıştır. Epok sayısı 1500, batch size 64 olarak belirlenmiş ve tüm görüntüler 64×64 piksel boyutuna ölçeklendirilmiştir. Çalışmanın bu bölümü, görüntü üretme teknolojisinin bir aşaması olarak değerlendirilmiş; kullanılan veri seti, model yapısı ve üretilen çıktılar ayrıntılı olarak incelenmiştir. Dijital ortamda üretilmiş sentetik görüntülerine ait farklı epok değerlerindeki üretim çıktıları ve


kayıp grafikleri Çizelge 4.1 ve Şekil 4.2’de, fotoğraf görüntülerinden oluşan veri grubuna ait farklı epok değerlerindeki üretim çıktıları ve kayıp grafikleri, Çizelge 4.2 ve Şekil 4.3’te gösterilmektedir.

Değerlendirmeler

Elde edilen bulgular genel olarak değerlendirildiğinde, DCGAN tabanlı modelin veri dağılımını öğrenme ve yeni örnekler üretme konusunda sergilediği performans göz önünde bulundurulmuştur. Bununla birlikte, model çıktılarında gözlemlenen sınırlılıklar da dikkate değerdir. Sentetik görüntülerde kısmen benzerlik elde edilebilirken, fotoğraf verileriyle elde edilen yapay görüntülerde görülen bulanıklık ve detay eksikliği, model kapasitesinin veya eğitim süresinin yetersiz kaldığı durumlarda ortaya çıkabilmektedir. Bu problemler, çekişmeli üretici ağlar literatüründe de sıkça vurgulanan, eğitim zorlukları ve veri yetersizliğine bağlı sınırlılıklardır.

Çizelge 4.1. Farklı Epok değerlerinde dijital ortamda üretilmiş görüntülerin eğitim sonuçları


1 Epok	100 Epok
	
1000 Epok	1500 Epok
	



Şekil 4.2. Dijital ortamda üretilmiş görüntülerin 1500 epok eğitim sonucu üretici ve ayırıcı kayıp değerleri

Çizelge 4.2. Farklı epok değerlerinde fotoğraf görüntülerinin eğitim sonuçları

1 Epok	100 Epok
1000 Epok	1500 Epok



Şekil 4.3. Fotoğraf görüntülerinin 1500 epok eğitim sonucu üretici ve ayırıcı kayıp değerleri

Sonuç olarak, DCGAN modeliyle yapılan eğitim süreci sonunda, üretici ağ öğrenilen veri dağılımından yeni örnekler türetebilmiştir. Ancak elde edilen örnek görüntüler incelendiğinde, modelin eğitim veri setindeki temel desen ve şekil özelliklerini düşük oranda yakalayabildiği görülmüştür. Özellikle fotoğraf görüntüleri değerlendirildiğinde, üretilen görüntüler orijinal veri kümesindeki nesnelerin genel biçim ve düzenine benzer yapılar sergileyememektedir. Bu durum, üretici ağın girdi olarak aldığı rastgele vektörleri, eğitim verisine benzer özniteliklere sahip görüntülere dönüştürmekte başarısının düşük olduğunu göstermektedir. Sentetik görüntülerden üretilen görseller genel hatlarıyla orijinal veri setindeki örnekleri andırmakla birlikte, eksikler dikkat çekmektedir. Benzer şekilde, model ayrıntıları üretmede zorlanmıştır; özellikle eğitim verisinde nadir görülen ince detaylar, yapay görsellerde tam olarak yeniden oluşturulamamıştır. Çizelgelerde de görüldüğü üzere model, veri kümesinin genel dağılımından örnekler üretse de, orijinal görüntülerle karşılaştırıldığında çözünürlük ve netlik bakımından farklılıklar mevcuttur. Bununla birlikte, modelin ürettiği görseller incelendiğinde, tekrarlayan birimden oluşan verilerin eğitim verisindeki temel yapıyı ve kompozisyonu diğer verilerden daha iyi yansıttığını söylemek mümkündür. Özetlemek gerekirse, DCGAN ile elde edilen bulgular, veri tabanlı görsel içerik üretiminin düşük kalitede olduğunu göstermektedir. Model temel düzeyde sonuçlar üretmiştir. Bu yönüyle, çalışma hem mevcut yöntemlerin yetkinliklerini ortaya koymakta hem de araştırmanın süreci için bir zemin hazırlamaktadır.

4.2. İGD’ de Veriye Dayalı Sınıflandırma

Literatür kısmında bahsedildiği gibi İslami geometrik desenler, karmaşık yapılar içermektedir. Verinin elde edilme sürecinde ise desene ve anlaşılabilirliğine odaklanılsa da verinin heterojen yapısından dolayı görsellerde bazı ayırt edici özellikler ortaya çıkmaktadır. Görsellerin bir kısmı fotoğraf ve perspektif açıları içerirken bir kısmı da kemer, sütun, minare, kubbe gibi yapı bileşenlerini kapsamaktadır. Görüntü tamamlama görevinde bu farklılıkların etkisi düşünüldüğünde, ilk olarak sınıflandırma modeli ile YZ araçlarının ayırt edebilme performansı değerlendirilmiştir. Böylelikle bu farklılıkların, sınıflandırma modeli kullanılarak analiz edilmesi ve verinin ne kadar tutarlı ya da ayırık olduğunun test edilmesi çalışmanın ilerleyen adımlarına katkı sağlayabilecek bir ara aşama oluşturmaktadır.


Modelde, İGD görselleri analiz edilmekte ve fotoğraf görüntülerden oluşan veriler üç farklı kategoride etiketlenmektedir. Bunun için veri setinin hazırlanması bölümünde bahsedilen fotoğraf verileri kullanılmıştır. İlk aşamada belirlenen kategorilere ait olmayan ya da görüntü boyutu sebebiyle algılama zorluğuna sebep olan desenler filtrelenmiş ve sınıflara ayrılmıştır. Toplamda 2882 adet her görüntü kategorisi için etiketli görüntülerden oluşan bir veri seti elde edilmiştir. Dik bir bakış açısıyla elde edilen doğrudan desen görüntüleri 1947 adet, açılı desen görüntüleri 375 adet, yapı bileşeni içeren görüntüler 560 adet etiketli veri içermektedir. Verilerden kategorilerinden örnekler Şekil 4.4’ te görülmektedir.



Şekil 4.4. 3 sınıfa ayrılmış veri seti

Elde edilen veriler sınıflandırma görevlerine göre eğitim veri kümesi ve doğrulama veri kümesi olarak bölünmüştür. Eğitim veri seti, toplam etiketli verinin %85 'ini içermektedir. Doğrulama veri seti toplam etiketli verinin yaklaşık %15'ini kapsamaktadır. Doğrulama veri seti, verilerin geri kalanını etiketlenmemiş bir biçimde içermektedir. Bu adımda görüntünün boyutlarını 256, 256 olacak şekilde tanımlanmıştır.

Çalışmada, veri boyutu ve desen görüntülerindeki benzerlikler göz önüne alındığında, sınıflandırmadan verimli bir sonuç elde edebilmek için kullanılacak algoritmaları belirlemek önemlidir. Bu sebeple hassas tespitler elde edilebilmesi amacıyla oluşturulan veri seti ile CNN mimarileri çeşitli sınıflandırma algoritmaları ile birlikte test edilmiştir. Kullanılan algoritmalar arasında VGG-19 (Simonyan ve Zisserman, 2015), AlexNet (Krizhevsky ve diğerleri, 2012), EfficientNet (Tan ve Le, 2019) ve ResNet (He, Zhang, Ren ve Sun, 2016) derin öğrenme modelleri bulunmaktadır. VGG-19 modeli, katman sayısının fazla olması nedeniyle evrimsel ağ derinliğini artırarak öğrenme kapasitesini artırmaktadır. Ayrıca, VGG-19' un transfer öğrenme yetenekleri, büyük filtreleme görevlerine ihtiyaç duymadan daha küçük veri kümelerinde kullanılabilirliğini artırmaktadır (Simonyan ve Zisserman, 2015). EfficientNet modeli, ölçekleme yöntemi sayesinde daha az parametre ve hesaplama kaynağı kullanarak çeşitli boyutlardaki ağları optimize etmekte ve yüksek performans sağlamaktadır. Ayrıca transfer öğrenme yeteneği sayesinde daha az veri kullanarak iyi sonuçlar vermektedir (Tan ve Le, 2019). Görüntü sınıflandırma görevleri için kullanılan modellerden biri de Alexnet mimarisidir. Alexnet mimarisi 2012 yılında geliştirilmiş bir derin öğrenme modelidir ve dönemin modellerine göre daha derin ve geniş yeteneklere sahiptir (Krizhevsky ve diğerleri, 2012). ResNet mimarisi ise derin sinir ağlarının geleneksel ağ mimarisi kullanılarak inşa edildiğinde ortaya çıkan optimum derinlik sonrası azalan doğrulukta özellik yeniden kullanımı sorununu ele almaktadır (He ve diğerleri, 2016; Shafiq ve Gu, 2022). Şekil 4.5, sınıflandırma sürecinin genel iş akışını (veri ön işleme, eğitim, sınıflandırma ve değerlendirme) göstermektedir. Süreçte, tüm modeller PyTorch derin öğrenme çerçevesiyle kodlanmış, Google Colab Pro ortamında NVIDIA A100 GPU kullanılarak eğitilmiştir. Eğitim ve doğrulama kayıpları farklı epok sayılarında izlenmiştir. Erken durdurma göz önünde bulundurulmuş fakat tutarlılık açısından tüm modeller 100 epok eğitilmiştir.



Şekil 4.5. Çalışma şeması


İlk uygulamada 19 konvolüsyonel katmandan oluşan VGG19 transfer öğrenme modeli kullanılmaktadır. Bu katmanlar 3x3 konvolüsyon katmanı, maksimum havuzlama katmanı ve ardından da üç tam bağlı katmandan oluşmaktadır. Böylelikle derinlik kademeli olarak artırılmaktadır (Simonyan ve Zisserman, 2015). Modelde eğitim aşamasında sinir ağları için önemli bir adım olan epok ve batch değerleri tanımlanmıştır. Derin öğrenme modelleri için verimliliğini ve süreci etkileyen bu değerler, veriye ve modele bağlı olarak farklı sayılarda ifade edilebilmektedir. Bu uygulamada eğitim için 30, 50 ve 100 epok ve 64 batch değerleri kullanılmıştır. Model oluşturulduktan ve eğitildikten sonra; zaman, loss (kayıp), accuracy (doğruluk), validation loss (doğrulama kaybı) ve validation accuracy (doğrulama doğruluğu) değerleri uygulanan modelin farklı epok değerlerine göre gösterilmiştir (Çizelge 4.3).

Çizelge 4.3. VGG19 modeli farklı epok sayıları için doğruluk ve kayıp değerleri


	Loss	Accuracy	Val_Loss	Val_Accuracy	Zaman
Epok 10	0.3007	0.8958	0.2992	0.8975	~6.5 dk
Epok 20	0.2303	0.9182	0.2550	0.9175	~13 dk
Epok 30	0.1597	0.9393	0.2168	0.9320	~19.5 dk
Epok 50	0.1309	0.9489	0.1733	0.9515	~40.7 dk
Epok 80	0.1117	0.9556	0.1567	0.9570	~52.3 dk
Epok 100	0.0983	0.9635	0.1339	0.9660	~1 s 7 dk

VGG19 için toplam eğitim süresi, 100 epok için yaklaşık 1 saat sürmüştür. Epok 10'da VGG19'un yaklaşık %89,7 doğrulama doğruluğuna ulaştığı, epok 30'da %93,2'ye ve epok 50'de yaklaşık %95,2'ye yükseldiği ve %96,6'da sonlandığı gözlemlenmektedir. Bu ilerleme, 50-80 epoktan sonra azalan artışa işaret etmektedir, ancak model 100 epoka doğru biraz daha

fazla doğruluk elde etmiştir. Aşırı uyumdan kaçınmak için eğitim 100 epokta sonlandırılmıştır. Ayrıca, eğitim seti üzerinde eğitilen modelin doğruluğunun doğrulama setine karşı bir değerlendirme oluşturması için grafik görselleri elde edilmiştir. Grafiklerde veri kümesinin 30, 50 ve 100 epok değerlerinde eğitim sonucunun doğruluk ve kaybı gösterilmektedir (Şekil 4.6) 30 epok grafiği diğer grafiklere göre daha düşük doğruluk oranları ile başlamaktadır. 50 epok eğitim doğruluğu neredeyse %95 seviyesine kadar ulaşmış durumdadır. Doğrulama doğruluğu da paralel bir şekilde yükselme eğilimindedir ancak dalgalanmalar görülmektedir. Bu sebeple değer artırılarak devam etmiştir. 100 Epok'da eğitim doğruluğu %95-98 seviyelerine ulaşmıştır. Doğrulama doğruluğu da yüksek seviyelere ulaşmış ve daha kararlı bir hale gelmiştir. Eğitim kaybı ise zamanla düzenli bir şekilde azalırken, doğrulama kaybı genel olarak düşüş eğiliminde olsa da küçük dalgalanmalarla daha kararlı bir hale gelmiştir. Bu sonuçlar, VGG19 tarafından öğrenilen derin özelliklerin örüntü sınıflandırma görevinin iyi bir şekilde genelleştirildiğini göstermektedir.




Şekil 4.6. VGG19 her bir epoktaki doğruluk ve kayıp değerlerinin grafikleri




Şekil 4.6. (devam) VGG19 her bir epoktaki doğruluk ve kayıp değerlerinin grafikleri

İkinci uygulamada evrişimli katmana sahip EfficientNet (Tan ve Le, 2019) öğrenme modeli kullanılmıştır. Model, B3 boyutunda önceden eğitilmiş ağırlıklarla kullanılmaktadır. Modelin katmanları konvolüsyonel, batch, normalizasyon, aktivasyon ve havuzlama derin öğrenme bileşenlerinden oluşmaktadır. Ağda 3x3 Konvolüsyon filtresi kullanılmaktadır. Ayrıca başlangıç bloğunda Swish Aktivasyon fonksiyonu kullanılmıştır. Çalışma etiketlerle kategorik sınıflandırma içerdiğinden, kullanılan son aktivasyon Softmax'tır. Uygulama sonucunda; EfficientNet, eğitim doğruluğu biraz daha yüksek olmasına rağmen (~%97,1), VGG19'dan biraz daha düşük olan yaklaşık %91,9'luk bir nihai doğrulama doğruluğuna ulaşmıştır (Şekil 4.7).



Şekil 4.7. EfficientNet her bir epoktaki doğrulama doğruluğu ve kayıp değerlerinin grafikleri



Şekil 4.7. (devam) EfficientNet her bir epoktaki doğrulama doğruluğu ve kayıp değerlerinin grafikleri

Ara dönem sonuçlarına bakıldığında, EfficientNet'in doğrulama doğruluğu %92 civarında zirve yaptıktan sonra hafifçe dalgalanırken, eğitim doğruluğu 80-100 dönemine kadar yaklaşık %99'a yükselmeye devam etmiştir. Sonunda EfficientNet için doğrulama kaybı (0,473) VGG19'dan daha yüksektir, bu da modelin doğrulama seti görüntülerinde bazı hatalar yaptığını göstermiştir. Bununla birlikte, %91,9 güçlü bir sonuçtur ve eğitimde epok 10-20 civarında modeller arasında en düşük doğrulama kaybını elde etmiştir.

Çizelge 4.4 modelin farklı epok sayılarındaki doğruluk ve kayıp değerlerini göstermektedir. Eğitim süresi ve periyodları arttıkça doğruluk oranının arttığı görülmektedir. 100 epok sonucunda ağ doğruluk oranının arttığını ve kayıp değerinin düştüğü görülmektedir. Değerlendirme verisinin sonuçlarında ise doğrulama kaybı (val_loss) ve doğrulama doğruluğu (val_accuracy) değerleri karşılaştırılmaktadır. Değerlendirme verilerinde eğitim verilerine göre sapmalar görülsede doğruluk ve kayıp değerlerinin sınıflandırmayı sağladığı görülmektedir.

Çizelge 4.4. Farklı epok sayıları için modelin EfficientNet değerleri

	Loss	Accuracy	Val_loss	Val_accuracy	Zaman
Epok 10	0.2350	0.9171	0.2693	0.9057	~16dk
Epok 20	0.1036	0.9590	0.3481	0.8852	~18dk
Epok 30	0.0943	0.9581	0.3776	0.8995	~20dk
Epok 50	0.0498	0.9773	0.3530	0.9091	~22dk
Epok 80	0.0507	0.9855	0.4755	0.9187	~26dk
Epok 100	0.0506	0.9712	0.4727	0.9187	~29dk

Uygulamada ayrıca görüntü sınıflandırma görevleri için tasarlanmış bir başka model olan AlexNet kullanılmıştır. Model beş konvolüsyonel katman, üç tam bağlı katman ve bir softmax sınıflandırma katmanından oluşmaktadır. Tüm eğitim 100 epok ve yaklaşık 3 saat 20 dakika sürmüştür. Uygulanan modelin farklı epok sayılarına göre modelin zaman, kayıp, doğruluk, val_loss, val_accuracy ve val_loss değerleri çizelgede gösterilmektedir (Çizelge 4.5).


Çizelge 4.5. Farklı epok sayıları için modelin AlexNet değerleri

	Loss	Accuracy	Val_Loss	Val_Accuracy	Zaman
Epok 10	0.7368	0.7188	0.6294	0.6407	~24dk
Epok 20	0.4394	0.8281	0.4730	0.8947	~45dk
Epok 30	0.1011	0.9688	0.4156	0.8947	~1s 7dk
Epok 50	0.1077	0.9531	0.994	0.7895	~1s 42dk
Epok 80	0.0168	0.9822	0.2135	0.9474	~2s 39dk
Epok 100	0.0361	0.9834	0.0315	0.9711	~3s 20dk


Daha eski bir mimari olmasına rağmen, AlexNet'in doğrulama setindeki performansı VGG19'a yakın bir performans göstermiştir. Ancak AlexNet'in bu noktaya gelene kadar izlediği yol, eğitim sırasında istikrarsızlık belirtileri göstermektedir. Epok 10'a kadar, eğitim doğruluğu yaklaşık %71,9'a yükselmiştir, ancak bu noktada doğrulama doğruluğu yalnızca yaklaşık %64,1' de kalmaktadır. Doğrulama doğruluğu eğitim devam ettikçe artmış ve 20-30. epoklarda %89 civarına ulaşmıştır. Eğitim doğruluğu %95,3 olmasına rağmen, doğrulama doğruluğunda epok 50 civarında %78,9'a bir düşüş gözlemlenmektedir. Daha yüksek epoklara geçtikçe, doğrulama performansı iyileşmiştir. Epok 80'de doğrulama doğruluğu %94,7'ye yükselmiş ve epok 100'de %97,1'e ulaşmıştır. Eş zamanlı olarak, eğitim

doğruluğu yaklaşık %98,3 ve eğitim kaybı 0,036 değeriyle düşük hale gelmiştir. Epok 100'de, AlexNet için doğrulama kaybı 0,032 ile önemli derecede düşmüştür. Bu da AlexNet'in doğrulama seti görüntüleri üzerinde güvenli tahminler yaptığını göstermektedir.

AlexNet'in grafiklerine bakıldığında (Şekil 4.8) eğitim ilerledikçe sınıflara makul ölçüde uyum sağlamayı başardığı söylenebilmektedir. Eğitim sürecinde, eğitim doğruluğu yüksek bir öğrenim oranı sağlarken doğrulama doğruluğunun eğitim verilerine kıyasla daha düşük performans sağladığı söylenebilir. Kayıp grafiğinde ise eğitim kaybı minimuma indirirken doğrulama kaybı azalma sürekliliği olmaksızın dalgalanma yapan bir eksenle ilerlemiştir. Doğrulama ve kayıp grafikleri diğer algoritmalarla göre dalgalı bir şekilde seyretmesine rağmen Epok 100'e gelindiğinde, eğitim ve doğrulama setinde anlamlı bir öğrenme sağlamıştır. Bu sonuçta da AlexNet'in maksimum doğruluğa ulaşması için 100 epokun tamamının kullanılmasını gerektiğini yorumlamak mümkündür. Öğrenme dinamikleri dalgalı yapısıyla modelin doğrulama kaybını tutarlı bir şekilde indirmekte daha fazla sorun yaşadığını göstermektedir. Ancak, AlexNet'in performansı, daha az katmana sahip olmasına rağmen, nispeten küçük veri kümeleri için iyi sonuçlar alabileceğini söylemek mümkündür.



Şekil 4.8. AlexNet mimarisi 100 epok doğrulama doğruluğu ve kayıp değerlerinin grafikleri



Şekil 4.8. (devam) AlexNet mimarisi 100 epok doğrulama doğruluğu ve kayıp değerlerinin grafikleri


Sınıflandırmada kullanılan bir diğer algoritma ResNet mimarisidir. Bu model konvolüsyonel sinir ağlarına kısa yol bağlantıları ekleyerek derin ağların eğitimini kolaylaştırmayı hedeflemektedir (He ve diğerleri, 2016). ResNet mimarisi, ReLU aktivasyon fonksiyonu ve bir toplu normalleştirme katmanı bulunduran iki adet 3×3 konvolüsyonel katmandan oluşmaktadır. Uygulanan modelin farklı epok sayılarına göre modelin zaman, kayıp, doğruluk, val_loss, val_accuracy ve val_loss değerleri çizelgede gösterilmektedir (Çizelge 4.6).

Çizelge 4.6. Farklı epok sayıları için modelin ResNet değerleri


	Loss	Accuracy	Val_Loss	Val_Accuracy	Zaman
Epok 10	2.2847	0.4516	0.9437	0.4951	~6 dk
Epok 20	0.9492	0.5560	0.8720	0.5971	~11 dk
Epok 30	0.9275	0.5730	0.8566	0.6942	~17 dk
Epok 50	0.7700	0.6786	0.5558	0.7885	~28 dk
Epok 80	0.7617	0.6635	0.6558	0.7767	~45 dk
Epok 100	0.6983	0.6985	0.6167	0.7524	~61dk

ResNet-50, 100 eğitim epoku boyunca hem eğitim hem de doğrulama doğruluğunda istikrarlı bir gelişme göstermiştir. Nihai eğitim doğruluğu %69,8'e ulaşırken, doğrulama doğruluğu %75,2'ye ulaşmıştır. Modelin doğrulama kaybı 0,6167'ye düşerek istikrarlı bir düşüş eğilimi göstermiş ve tahminlerde orta düzey yansıtmıştır. Eğitim düzeni göz önüne alındığında, bu sonuçlar ResNet-50'nin örüntü kategorileri için modeli diğer algoritmalar kadar etkili bir sonuca ulaştırmadığını göstermektedir. Bu da ResNet-50 mimarisinin veri

miktarı için çok katmanlı yapıya sahip olmasından kaynaklı olarak, aşırı uyuma yatkın olması olarak yorumlanabilir. ResNet'in başlangıçtaki ilerlemesinin yavaş olması ile beraber epok 10'da çok daha yüksek başlayan diğer modellerin aksine, doğrulama doğruluğunda %49 ve eğitim doğruluğunda ~%45'e ulaşmıştır (Şekil 4.9). 80. epokta eğitim doğruluğu ~%66,3 ve doğrulama doğruluğu ~%77,7 iken 100. epokta eğitim %69,9'e yükselirken doğrulama %75,2'ye düşmüştür. ResNet için doğrulama kaybı yaklaşık 0,616 gibi bir oranla nispeten yüksek kalmıştır ve tutarlı bir düşüş eğilimi göstermemiştir, bunun yerine inişler ve çıkışlar görülmektedir.



Şekil 4.9. ResNet mimarisi 100 epok doğrulama doğruluğu ve kayıp değerlerinin grafikleri



Şekil 4.9. (devam) ResNet mimarisi 100 epok doğrulama doğruluğu ve kayıp değerlerinin grafikleri

ResNet sonucu, Shafiq ve Gu (2022) tarafından belirtilen, veri özellikleri orijinal eğitim alanından farklıysa veya veri miktarı yetersizse, daha derin ağların her zaman daha iyi performansı garanti etmediği fikriyle uyumludur.

Son olarak, derin öğrenme modelleri epok sayısına bağlı olarak modellerdeki farklı değerler karşılaştırılmıştır. Çizelge 4.7, performans ölçümlerini özetlemektedir. Doğruluk açısından, AlexNet (%97,1) ve VGG19 (%96,6) en iyi performansı göstermiş, EfficientNet (%91,9) ve ardından ResNet-50 (%75,2) gerilerde kalmıştır. Doğrulama kaybıyla ilgili olarak, AlexNet ve VGG19'un kaybının düşük olması güvenli tahminlere işaret etmektedir. İyi doğruluğa rağmen, EfficientNet'in daha yüksek doğrulama kaybı (0,4727), hatalarının daha az olduğunu, ancak bazen daha az emin olduğunu veya belirli görüntülerde daha büyük hatalar yaptığını göstermektedir. Benzer bir veri kümesi üzerindeki bir üretim senaryosu için, hesaplama kaynakları çok sınırlı olmadığı sürece, tutarlı genelleme için daha güvenli bir seçim olarak VGG19'un daha fazla kararlılıkla olduğu söylenebilir.

Çizelge 4.7. Modellerin değerlendirilmesi

Model	Accuracy	Val_Accuracy	Loss	Val_Loss
VGG19	96.35	96.60	0.0983	0.1339
EfficientNet	97.12	91.87	0.0506	0.4727
AlexNet	98.34	97.11	0.0361	0.0315
ResNet-50	0.6985	0.7524	0.6983	0.6167

Çalışma doğrultusunda, sınıflandırma görevinin yüksek doğrulukla gerçekleştirilebildiği üzerine düşünmek aydınlatıcı olacaktır. Üç görüntü kategorisi rastgele bölünmelerden ziyade CNN'lerin öğrenebileceği doğal görsel farklılıklara sahiptirler. Doğrudan desen görüntüsü tipik olarak desene net bir şekilde odaklanır, genellikle ortalanır ve perspektif bozulması olmaz. Ağlar bu görüntülerin bozulmamış simetrisini ve düzenli ızgara veya radyal özelliklerini tanımayı öğrenebilirler. Açılı görüntülerde ağ, desenlerin perspektifini, eğrisel yüzeyleri veya kısaltılmış motifleri algılayabilir. Diğer sınıf görüntüleri genellikle mimari unsurların parçalarını içerir, böylece CNN bu bağlamsal ipuçlarını tespit etmeyi öğrenebilir. Sonuçlar CNN'lerin ayırt edici özellikler bulduğunu doğrulamaktadır. Bu da veri setinin çeşitli olmasına rağmen bu sınıflar arasında yeterince tutarlı farklılıklar olduğunu ortaya koymaktadır. Bu da sınıflandırmanın veri seti tutarlılığını analiz etmek için bir araç olarak hizmet edebileceği yönündeki ilk öngörüyü doğrulamaktadır.


4.3. İGD'de Veriye Dayalı Tamamlama

Bu bölümde, İslami geometrik desenlerin eksik kısımlarının tamamlanması amacıyla geliştirilen veriye dayalı görüntü içi boyama (inpainting) yöntemleri ele alınmaktadır. Daha önceki bölümlerde sınıflandırılan ve analiz edilen desen verileri, bu aşamada otomatik tamamlama algoritmalarıyla işlenmiştir. Yapılan çalışmalar, geleneksel desenlerin dijital ortamlarda eksik kısımlarının tamamlanması sürecinde yapay zekâ destekli modellerin performansını değerlendirmeye odaklanmaktadır. Bu kapsamda kullanılan üç model kenar sürekliliği, motif detayları ve ölçekler arası bütünlük gibi farklı açılardan İGD desenlerine katkı sağlamaktadır. Her üç modelin birlikte değerlendirilmesi, desenlerin yapısal özelliklerinin daha tutarlı bir şekilde yeniden inşa edilmesine olanak tanımakta ve metodolojinin çok yönlü uygulanabilirliğini artırmaktadır. Bölüm kapsamında, uygulama süreci, kullanılan mimari yapılar ve elde edilen sonuçlar sunulmaktadır.

Veri setleri


Uygulamalarda kullanılan veri seti, verinin oluşturulma aşamasında bahsedilen fotoğraf görüntülerinden oluşmaktadır. Fotoğraflar görüntü içeriğine göre dik açı ile çekilmiş deseni ifade eden doğrudan görüntüler, farklı açılardan çekilmiş deseni ifade eden açılı görüntüler ve fotoğrafın içinde desen harici yapı elemanı içeren görüntüler olmak üzere üç kategoride

test edilmiştir. Veri setine ait görüntülerden bazıları şekilde görülmektedir. Test için her kategoriden 26 görüntü olmak üzere 78 görüntü kullanılmıştır.



Şekil 4.10. Veri setine ait görsellerden örnekler

Görüntüler uygulamalar sırasında sırasıyla 512×512 ya da 256×256 olacak şekilde yeniden boyutlandırılmıştır. Tamamlama görevinde bilinmeyen bölge aralığının etkisini analiz etmek için düzensiz görüntü maskeleri kullanılmaktadır. Maske görüntüleri giriş görüntüleri ile eşit miktarda olacak şekilde düzenlenmiştir. Bu maskeler (10–20%) (20–30%) (30–40%) (40–50%) (50–60%) olmak üzere altı sınıfa ayrılmıştır. Maske görüntülerinde tüm sınıflar kendi içerisinde eşit sayıda olacak şekilde dağıtılmıştır. Şekil 4.11’de maske veri setinden örnekler görülmektedir.




Şekil 4.11. Maske verilerine ait görseller

4.3.1. Kenar bağlantı algoritması ile görüntü restorasyonu

Görüntü restorasyonu çalışmalarında ilk olarak, kenar bağlantı algoritması ile görüntü tamamlama yaklaşımı kullanılmıştır. Mevcut görüntü tamamlama yaklaşımlarının büyük çoğunluğu, tek bir giriş üzerinden hedef görüntüyü doğrudan üretmeyi amaçlamaktadır. Kenar bağlantı algoritması ile görüntü tamamlama sürecinde ise, süreç iki ayrı evreye ayrılarak önce eksik bölgelere ait kenar yapılarını üretmekte, ardından bu kenar verisini kullanarak içerik ve doku bakımından tutarlı bir bütünlük sağlanmaktadır (Nazeri ve diğerleri, 2019). Çalışmada, İslami geometrik desenlerin belirgin kontur yapısı ve yüksek simetrik düzenleri göz önünde bulundurularak, bu algoritmanın desen restorasyonuna yapısal süreklilik ve geometrik doğruluk açısından anlamlı katkılar sunabileceği düşünülmektedir. Bu nedenle, çalışmada kenar bilgisini ayrı bir aşama olarak değerlendiren ve iki aşamalı bir tamamlama süreci öngören EdgeConnect algoritması (Nazeri ve diğerleri, 2019) tercih edilmiştir.

Ağ mimarisi

Çalışmada iki aşamadan oluşan bir görüntü tamamlama ağı kullanılmaktadır (Şekil 4.12). İlk aşamada üretici ağ, eksik bölgeler için kenar üretimini sağlarken, ikinci aşamada ise üretilen kenar haritası, eksik görüntü girişiyle birlikte görüntü tamamlama ağına aktarılmakta ve tamamlama işlemi gerçekleştirilmektedir (Nazeri ve diğerleri, 2019). Şekil 4.12’ de modelin genel akış şeması sunulmaktadır. Her iki aşama da üretici ve ayırt edici bileşenlerden oluşan çekişmeli ağ (Goodfellow ve diğerleri, 2014) üzerine kuruludur. Modelin giriş aşaması, eksik veya bozulmuş bölgeler içeren orijinal görüntü ile bu bölgeleri tanımlayan ikili bir maske görüntüsünden oluşmaktadır. Kenar oluşturma modülünde üretici ağ, maskelenen alanlardaki eksik kenar yapılarını tahmin ederken; ayırt edici ağ, bu kenar haritalarının gerçekçiliğini değerlendirmektedir. Görüntü oluşturma aşamasında ise tahmin edilen kenar haritası, giriş görüntüsüyle birlikte ikinci üretici ağa aktarılmakta ve eksik alanlara içerik ve doku açısından uygun pikseller üretilmektedir. Bu aşamada kullanılan ayırt edici ağ, tamamlanan görüntünün gerçek mi yoksa yapay mı olduğunu ayırt etmektedir. Son aşamada ise tamamlanmış görüntüler, orijinal görüntüyle karşılaştırılarak çeşitli görüntü kalite metrikleri üzerinden değerlendirilmektedir.



Şekil 4.12. Ağ akış şeması (Nazeri ve diğerleri, 2019)' dan uyarlanmıştır.


Görüntüden kenar uygulama aşaması, görüntüdeki en belirgin yapısal özellikler olarak kenarlara odaklanmaktadır. Kenar haritaları, kontur veya çizgileri oluşturarak görüntüdeki semantik ilişkilendirmeleri oluşturmaktadır; ayrıca doku, pürüzsüzlük, renk bölgeleri gibi özelliklerin ölçümlerini sağlamaktadır (Liu ve diğerleri, 2018). Çalışmanın ileri aşamalarında, görüntü işleme görevinde kullanılan çeşitli kenar algılama yöntemlerinden (Canny, 1986; Kittler, 1983; Marr ve Hildreth, 1980; Suzuki, 1985), Canny kenar tespiti kullanılarak kenar haritalarının çıkarıldığı bir eğitim düzeni oluşturulmaktadır (Canny, 1986).

Bilgisayar görme ve dijital görüntü işlemede en yaygın kullanılan kenar dedektörü olarak tanımlanan Canny kenar tespiti, 1986 yılında John F. Canny tarafından kenar bağlantısının hesaplama yaklaşımı olarak önerilmiştir (Canny, 1986). Bu yaklaşım kenar bağlantısını oluşturmak için iki farklı yönde komşularıyla eşleştirilen çok aşamalı bir algorithmadan oluşmaktadır. Algorithma görüntü yatay (G_x) ve dikey yönde (G_y) formüldeki gibi filtrelenmektedir (Open Source Computer Vision, 2024).

$$\text{Edge_Gradient}(G) = \sqrt{G_x^2 + G_y^2} \quad (4.1)$$


$$\text{Angle}(\theta) = \tan^{-1} \left(\frac{G_y}{G_x} \right) \quad (4.2)$$

Kenar tespiti uygulamasında, algoritma ilk olarak giriş görüntüsünü gri tonlamaya dönüştürmekte; ardından belirlenen düşük ve yüksek eşik değerlerine göre kenar olup olmadığına karar vermektedir. Yüksek eşik değerinin üzerinde kalan yoğunluklar kenar olarak kabul edilirken, düşük eşik değerinin altındaki pikseller atılmaktadır (Canny, 1986). Orta aralıkta kalan değerler ise bağlantı sürekliliğine göre sınıflandırılmaktadır. Canny kenar dedektörünün hassasiyeti, seçilen eşik değerlerine doğrudan bağlıdır. Eşik değerlerinin farklı kombinasyonları kullanıldığında, kenar çıkarımının yoğunluğu ve sürekliliği değişmektedir. Şekil 4.13’ te desende farklı eşik değerleri ile elde edilen sonuçlar görülmektedir.



Şekil 4.13. Eşik değerlerinin kenar tespitine etkisi

Karmaşık geometrik desenler için bu aşama, modelin simetrik ve açısal kuralları açısından kenar tahminleri sağlayarak yapısal bir öncelik oluşturmaktadır. Bu çalışma öncelikle, önceden eğitilmiş ağırlıkları kullanılarak Google Colaboratory ortamında ince ayar da öğrenme oranı: 0,00002, batch boyutu: 2 maksimum iterasyon: 60000 olmak üzere eğitilmiştir. Model çıktıları Şekil 4.14’te görülmektedir.



Şekil 4.14. (a) Orijinal görüntü, (b) %20-%30 maskelenmiş görüntü ve tamamlanan görüntü, (c) %30-%40 maskelenmiş görüntü ve tamamlanan görüntü, (d) %40-%50 maskelenmiş görüntü ve tamamlanan görüntü, (e) %50-%60 maskelenmiş görüntü ve tamamlanan görüntü

Eğitim sonucunda üç farklı kategoride veri seti üzerinde test işlemleri gerçekleştirilmiştir. Uygulama sonuçları düşük maske boyutlarında başarılı performans gösterse de veri seti dağılımı ve farklılıkları yüksek maske boyutlarında görüntülerde karışmalara neden olmaktadır. Sonuçlar değerlendirildiğinde model performansında belirgin bir iyileşme görülmemektedir (EK-25). İkinci uygulama olarak, öğrenme oranı: 0.0001, batch boyutu: 8 kullanılarak önceden eğitilmiş ağırlıklarla üç farklı kategoride ve altı farklı düzensiz maske boyutu ile veriler tekrar test edilmiştir. Nicel ve nitel değerlendirmeler bu uygulama üzerinden devam etmiştir.

Nicel değerlendirme

Modelin farklı geometrik yapılara ve çeşitli bozulma türlerine karşı benzerlik kapasitesinin kapsamlı bir şekilde analiz edilmesini sağlamak amacıyla performansı; PSNR, SSIM, LPIPS ve L1 Loss metrikleri kullanılarak nicel olarak değerlendirilmiştir (Çizelge 4.8). Kenar bağlantı algoritması ile gerçekleştirilen restorasyon süreci, özellikle düşük oranlı maskeleme durumlarında (%0–10) yüksek başarı sergilemiştir. Doğrudan çekilmiş görüntülerde PSNR değeri 31,58'e, SSIM değeri ise 0,9632'ye ulaşmıştır. Bu değerler, modelin hem piksel bazlı doğruluğu (yüksek PSNR ve düşük L1 değeriyle 2,81) hem de yapısal bütünlüğü güçlü şekilde koruduğunu göstermektedir. Aynı oranda LPIPS değeri 0,0359 gibi oldukça düşük bir seviyededir; bu da modelin tamamladığı görüntünün insan algısına göre orijinale son derece yakın olduğunu ortaya koymaktadır. Görüntü tamamlama çıktılarında LPIPS değerinin düşük olması, özellikle dokusal ve kenar yapılarının doğal görünümünü koruyabildiğini gösterir.

Açılı çekilmiş görüntülerde de benzer bir eğilim izlenmiştir. %0–10 oranında 30,79 PSNR ve 0,9651 SSIM gibi yüksek başarı değerleri elde edilmiş, LPIPS değeri 0,0371 ile düşük kalmıştır. Ancak maskeleme oranı %50–60 aralığına ulaştığında, PSNR değeri 17,44'e ve SSIM değeri 0,5461'e düşmüştür. Bu değerler, perspektif etkisiyle birlikte kenar sürekliliğinin bozulmasının modelin tahmin gücünü ciddi biçimde etkilediğini ortaya koymaktadır. Özellikle LPIPS değerinin 0,3304'e yükselmiş olması, algısal olarak tamamlanan görüntülerin orijinalden uzaklaştığını; L1 kaybının 20,39'a çıkması ise sayısal farkların da arttığını göstermektedir. Bu durum, açılı görüntülerde yapısal sürekliliğin korunmasının model için daha zorlu olduğunu göstermektedir.

Yapı bileşeni içeren görüntülerde ise model, %0–10 oranında PSNR 30,2831, SSIM 0,9612, LPIPS 0,0395 ve L1 2,9748 gibi tatmin edici başlangıç değerleri üretmiştir. Ancak maskeleme oranı arttıkça bu metriklerde düşüş gözlemlenmiştir. %50–60 oranında PSNR değeri 17,1304’e, SSIM değeri 0,547’ye kadar inmiş; LPIPS 0,3268, L1 değeri ise 21,3922 gibi yüksek seviyelere çıkmıştır. Bu da modelin karmaşık yapısal bileşen içeren alanlarda daha fazla bilgi kaybına uğradığını ve restorasyon kalitesinde düşüş yaşadığını göstermektedir.

Çizelge 4.8. Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı)




Veri Setleri	Maske tipi ve oranı	Algoritma	PSNR ↑	SSIM ↑	LPIPS ↓	L1 ↓
			Değerler	Değerler	Değerler	Değerler
Doğrudan görüntüler	Düzensiz (%0–10)	Kenar bağlantı algoritması ile görüntü restorasyonu EdgeConnect	31,5838	0,9632	0,0359	2,8126
	Düzensiz (%10–20)		26,0654	0,9137	0,0808	4,8645
	Düzensiz (%20–30)		22,9756	0,8443	0,1373	7,7302
	Düzensiz (%30–40)		20,8501	0,7698	0,2006	10,8162
	Düzensiz (%40–50)		19,0592	0,6704	0,2695	15,0771
	Düzensiz (%50–60)		17,3788	0,5568	0,3456	20,5819
Açılı görüntüler	Düzensiz (%0–10)	Kenar bağlantı algoritması ile görüntü restorasyonu EdgeConnect	30,7927	0,9651	0,0371	2,8867
	Düzensiz (%10–20)		25,649	0,9107	0,0842	5,148
	Düzensiz (%20–30)		22,6735	0,8373	0,1406	8,0372
	Düzensiz (%30–40)		20,8347	0,7636	0,1939	11,1351
	Düzensiz (%40–50)		18,9225	0,6579	0,2676	15,605
	Düzensiz (%50–60)		17,4481	0,5461	0,3304	20,3997
Yapı bileşeni içeren görüntüler	Düzensiz (%0–10)	Kenar bağlantı algoritması ile görüntü restorasyonu EdgeConnect	30,2831	0,9612	0,0395	2,9748
	Düzensiz (%10–20)		24,7951	0,9068	0,0848	5,4275
	Düzensiz (%20–30)		21,7856	0,8406	0,1327	8,1711
	Düzensiz (%30–40)		20,0057	0,7535	0,1977	12,3015
	Düzensiz (%40–50)		18,343	0,6549	0,2603	16,5229
	Düzensiz (%50–60)		17,1304	0,547	0,3268	21,3922

Bu genel eğilimler, kenar tabanlı yaklaşımın özellikle düşük ve orta düzey bozulmalarda başarılı olduğunu; ancak yüksek oranlı eksikliklerde yapısal sürekliliği sürdürme kapasitesinin sınırlı kaldığını ortaya koymaktadır. Buna karşın, model farklı geometri türlerine karşı belirli bir düzeyde genelleme yeteneği sergileyerek, çalışmanın temel hedeflerinden biri olan desen bütünlüğünü korumaya yönelik çıktılar sunmuştur.

Nitel değerlendirme

Model tarafından elde edilen görüntülerin bir kısmı Çizelge 4.9, Çizelge 4.10, Çizelge 4.11, Çizelge 4.12, Çizelge 4.13, Çizelge 4.14’de gösterilmektedir. Model, düşük maske oranlarında (%10–%20) görüntü yapılarının büyük bir kısmı bozulmuş girdilerde gerçekçi sonuçlar üretebilmektedir. Önemli olarak, bazı görüntülerde minimal bulanıklık görülmektedir. Maske oranı yüksek seviyelere çıktığında, tamamlanan bölgelerde geometrik yapının belirgin şekilde zayıfladığı, eksik kenarların hatalı tahmin edildiği ve motif tekrarlarının yer yer bozulduğu görülmektedir.

Çizelge 4.9. %10 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Kenar tespiti	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					


Çizelge 4.10. %10-%20 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Kenar tespiti	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					

Çizelge 4.11. %20-%30 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Kenar tespiti	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					


Çizelge 4.12. %30-%40 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Kenar tespiti	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					

Çizelge 4.13. %40-%50 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Kenar tespiti	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					

Çizelge 4.14. %50-%60 maske boyutlarına göre kenar bağlantı algoritmasında karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Kenar tespiti	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					


4.3.2. Derin Füzyon ağı ile görüntü restorasyonu

Bu çalışmada ikinci olarak derin görüntü restorasyon modellerinden; mevcut verinin kullanımı, sentezi ve adaptasyonu göz önünde bulundurularak, Derin Füzyon Ağı (DFNet) (Hong, Xiong, Ji ve Fan, 2019) algoritması tercih edilmiştir. Verinin, geleneksel yöntemlerle restore edilmesi zor olan, karmaşık geometrik desenlerden oluştuğu düşünüldüğünde; bu tür verilerde, kenar keskinliği ve desen sürekliliği korunarak eksik bölgelerin tamamlanması büyük önem taşımaktadır. Derin görüntü tamamlama yöntemleri, özellikle sınır bölgelerinde, geri yüklenen alanı mevcut içerikle bütünleştirmekte yetersiz kalabilmektedir. DFNet ise bu probleme yeni bir çözüm önererek sınır bölgelerinde daha yumuşak geçişler sağlamaya odaklanmaktadır. Model, orijinal ve tamamlanmış bölgeler arasında yapısal sürekliliği güçlendirerek özellikle sınır geçişlerinde başarılı sonuçlar elde edebilmektedir (Hong, Xiong, Ji ve Fan, 2019).

Ağ mimarisi

Ağ mimarisi temel olarak üç ana bileşenden oluşmaktadır. İlk bileşen, U-Net (Ronneberger ve diğerleri, 2015) yapısını temel alan kodlayıcı ve kod çözücü katmanlarıdır. Süreç ilk olarak, eksik bölgeler içeren bir görüntü ve eksik alanları belirten bir maske girdisi ile başlamaktadır. Model ilk aşamada, kodlayıcı-kod çözücü mimarisini kullanarak eksik alanların çevresindeki özellikleri analiz etmektedir. Kodlayıcı, görüntünün bilinen alanlarından düşük ve yüksek seviyeli özellikleri çıkararak düşük boyutlu bir temsil üretmekte; kod çözücü ise bu temsili kullanarak eksik bölgelerin içeriklerini tahmin etmektedir. Geleneksel U-Net modellerinden farklı olarak, bu mimaride kod çözücünün belirli katmanlarına füzyon blokları eklenmiştir. Füzyon blokları, tamamlanan alan ile bilinen bölgeleri birleştirerek bütünleşme sağlamaktadır. Bu süreçte, tamamlanmış görüntü ve bilinen alanlardan türetilen özellik haritaları işlenerek, model tarafından üretilen alfa kompozisyon haritası yardımıyla eksik bölge ve bilinen alanlar arasındaki geçişleri daha dengeli hale getiren bir bileşim gerçekleştirilmektedir. Bu aşama, model sınır bölgelerindeki sert geçişleri engelleyerek eksik alanları daha doğal bir şekilde doldurmayı hedeflemektedir (Hong ve diğerleri, 2019).

Son aşamada ise çok ölçekli öğrenme yaklaşımı kullanılmaktadır. Model, düşük çözünürlükte genel yapıyı öğrenirken yüksek çözünürlükte doku detaylarını iyileştirmekte; böylece hem yapısal hem de dokusal bütünlük korunmaktadır (Hong ve diğerleri, 2019). Bu yaklaşım, geleneksel görüntü tamamlama yöntemlerine kıyasla daha başarılı sonuçlar üretmekte, özellikle sınır bölgelerinde sert geçişlerin önüne geçerek eksik bölgelerin tamamlanan alanlarla bütünleşmesini sağlamaktadır. Böylece, hem yapısal hem de dokusal uyumu sağlayarak daha estetik ve gerçekçi sonuçlar üretilebilmektedir.



Şekil 4.15. Algoritma akış şeması (Hong ve diğerleri, 2019)’ dan uyarlanmıştır.

Algoritma hazırlanmış olan veri kümesi üzerinde değerlendirilmiştir. Model Google Colaboratory ortamında uygulanmıştır. Öğrenme oranı: 0,0002, batch boyutu: 6 ve optimizasyon algoritması olarak Adam kullanılarak önceden eğitilmiş ağırlıklarla üç farklı kategoride ve altı farklı düzensiz maske boyutu ile test edilmiştir. Tamamlanan görüntülerin performansı benzerlik metrikleri ile değerlendirilmiştir.

Nicel değerlendirme

Modelin performansı PSNR, SSIM, LPIPS ve L1 Loss metrikleri kullanılarak ölçülmektedir. Elde edilen sonuçlar, algoritmanın özellikle düşük oranlı maskeleme durumlarında yüksek başarı sağladığını ortaya koymaktadır. Doğrudan desenlerde %0–10 maske oranında elde edilen PSNR (33,216) ve SSIM (0,9722) değerleri, modelin eksik bölgeleri neredeyse kayıpsız biçimde tamamladığını göstermektedir. Bu oranda L1 kaybı yalnızca 1,1878 ve LPIPS değeri 0,0252 ile sınırlı kalmış; bu da hem piksel düzeyinde oldukça düşük hata olduğunu hem de modelin görsel olarak son derece tutarlı çıktılar ürettiğini doğrulamaktadır. LPIPS’in düşük olması, modelin tamamladığı desenlerin insan algısına göre orijinal görüntüyle çok yüksek benzerlik taşıdığını göstermektedir. Maskeleme oranı arttıkça tüm metriklerde kademeli bir bozulma gözlenmiştir (Çizelge 4.15). Örneğin doğrudan görüntülerde %50–60 oranında PSNR 17,0431’e ve SSIM 0,5566’ya gerilemiştir. Bu düşüş, yapısal benzerliğin kaybedildiğini ve tamamlamanın daha az isabetli olduğunu ortaya koymaktadır. Buna karşın LPIPS değeri 0,3402’ye, L1 değeri ise 20,582’ye yükselmiştir.

LPIPS'teki artış modelin görsel bütünlükte başarısızlaştığını, L1'deki artış ise tahminlerin piksel düzeyinde hataya düştüğünü göstermektedir.

Açılı görüntülerde de benzer bir eğilim izlenmiştir. Düşük maskeleme oranlarında (%0–10), model 31,7909 PSNR ve 0,9721 SSIM gibi güçlü değerler üretmiştir. Bu oranda LPIPS 0,0263 ve L1 1,32 gibi düşük seviyelerde kalmıştır. Ancak maskeleme %50–60'a ulaştığında, PSNR 17,0424, SSIM 0,5437, LPIPS 0,3162 ve L1 20,5451 değerlerine ulaşarak önemli ölçüde düşüş yaşanmıştır. Bu durum, açılı görüntülerdeki perspektif bozulmalarının, modelin tamamladığı kenar sürekliliğini korumasını zorlaştırdığını göstermektedir.

Yapı bileşeni içeren görüntülerde de model %0–10 oranında oldukça başarılı sonuçlar üretmiş, PSNR 30,7088, SSIM 0,9668, LPIPS 0,0279 ve L1 1,5253 gibi değerlerle nitelikli tamamlama yapmıştır. Ancak maskeleme oranı yükseldikçe, özellikle %50–60 oranında SSIM 0,5433'e düşmüş, L1 21,3627, LPIPS ise 0,3087 seviyesine çıkmıştır. Bu tablo, karmaşık yapısal bileşenlerin bulunduğu desenlerde eksik alçan arttıkça modelin hem algısal hem de sayısal başarıda zorlandığını ortaya koymaktadır.

Sonuç olarak, DFNet modeli düşük ve orta seviye bozulmalarda yapısal süreklilik, görsel tutarlılık ve piksel doğruluğu açısından oldukça güçlü sonuçlar üretmiştir. PSNR ve SSIM değerleri modelin genel tamamlama başarısını gösterirken, LPIPS ve L1 değerleri sayesinde bu başarının görsel sadakat ve sayısal hata düzeyleri de açıkça izlenebilmiştir. Ancak yüksek oranlı eksikliklerde, özellikle açılı ve yapı bileşenli desenlerde performansta anlamlı düşüşler yaşanmış; bu da modelin tamamlamayı sürdürebilirlik açısından sınırlı kalabildiğini göstermiştir. Bununla birlikte, modelin tüm görüntü türlerinde dengeli ve tutarlı bir genel performans profili sunduğu da vurgulanmalıdır.






Çizelge 4.15. Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı)

Veri Setleri	Maske tipi ve oranı	Algoritma	PSNR ↑	SSIM ↑	LPIPS ↓	L1 ↓
			Değerler	Değerler	Değerler	Değerler
Doğrudan görüntüler	Düzensiz (%0–10)	Derin Füzyon ağı ile görüntü restorasyonu DfNet	33,2160	0,9722	0,0252	1,1878
	Düzensiz (%10–20)		26,6030	0,9213	0,0701	3,3575
	Düzensiz (%20–30)		23,1727	0,8507	0,1284	6,4944
	Düzensiz (%30–40)		20,8961	0,7744	0,1908	9,7832
	Düzensiz (%40–50)		18,9123	0,6702	0,2676	14,6942
	Düzensiz (%50–60)		17,0431	0,5566	0,3402	20,582
Açılı görüntüler	Düzensiz (0–10%)	Derin Füzyon ağı ile görüntü restorasyonu DfNet	31,7909	0,9721	0,0263	1,3200
	Düzensiz (10–20%)		25,7873	0,917	0,0721	3,7840
	Düzensiz (20–30%)		22,7448	0,8418	0,1272	6,9407
	Düzensiz (30–40%)		20,8539	0,7692	0,1797	10,1886
	Düzensiz (40–50%)		18,6601	0,6589	0,2558	15,3847
	Düzensiz (50–60%)		17,0424	0,5437	0,3162	20,5451
Yapı bileşeni içeren görüntüler	Düzensiz (0–10%)	Derin Füzyon ağı ile görüntü restorasyonu DfNet	30,7088	0,9668	0,0279	1,5253
	Düzensiz (10–20%)		25,5942	0,9194	0,063	3,6126
	Düzensiz (20–30%)		22,0465	0,835	0,1222	7,4124
	Düzensiz (30–40%)		20,0882	0,7565	0,1733	10,9956
	Düzensiz (40–50%)		18,2231	0,6539	0,2416	16,0267
	Düzensiz (50–60%)		16,7184	0,5433	0,3087	21,3627





Nitel değerlendirme

Model tarafından elde edilen görüntülerin bir kısmı Çizelge 4.16, Çizelge 4.17, Çizelge 4.18, Çizelge 4.19, Çizelge 4.20, Çizelge 4.21’de gösterilmektedir. Model, görüntü yapılarının büyük bir kısmı bozulmamış olarak gerçekçi sonuç üretebilmektedir. Eksik alanın boyutu arttıkça bazı görüntülerde bozulmalar seyretmektedir. Model, özellikle sınırlı oranda hasar içeren ve belirgin konturlara sahip desenlerde kabul edilebilir düzeyde bütünlük sağlayabilmektedir.






Çizelge 4.16. %10 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar

Görüntü sınıfı	Giriş görüntüsü	Raw tamamlama	Alpha Birleşimi	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					





Çizelge 4.17. %10-%20 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar

Görüntü sınıfı	Giriş görüntüsü	Raw tamamlama	Alpha Birleşimi	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					

Çizelge 4.18. %20-%30 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar

Görüntü sınıfı	Giriş görüntüsü	Raw tamamlama	Alpha Birleşimi	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					

Çizelge 4.19. %30-%40 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar

Görüntü sınıfı	Giriş görüntüsü	Raw tamamlama	Alpha Birleşimi	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					

Çizelge 4.20. %40-%50 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar

Görüntü sınıfı	Giriş görüntüsü	Raw tamamlama	Alpha Birleşimi	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					

Çizelge 4.21. %50-%60 maske boyutlarına göre füzyon bloğunda karşılık gelen sonuçlar

Görüntü sınıfı	Giriş görüntüsü	Raw tamamlama	Alpha Birleşimi	Tahmin edilen görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü					
Açılı görüntü					
Yapı bileşeni içeren görüntü					


4.3.3. Filtreleme tabanlı görüntü restorasyonu

Görüntü seviyesindeki tahmine dayalı filtreleme yöntemleri, farklı sahnelere göre adapte olarak uygun özellikler üretebilen ve görüntü restorasyonunda yaygın şekilde kullanılan yaklaşımlar arasında yer almaktadır. Bu yöntemler, her bir piksel için çevresel bilginin daha odaklı ve etkili bir şekilde öğrenilmesine olanak tanıyarak, yerel yapıları koruma ve yapaylıkları önleme konusunda önemli avantajlar sunmaktadır (Li, X. ve diğerleri, 2022). Çalışmanın bu kısmında bu avantajdan yararlanılarak, görüntü tamamlama problemine filtreleme yaklaşımıyla çözüm arama olasılığı değerlendirilmiştir. Bu doğrultuda, eksik bölgelerin tamamlanmasında hem yerel yapıların korunmasını hem de özellik düzeyinde tutarlılığın sağlanmasını hedefleyen, Çok Düzeyli İnteraktif Siyam Filtreleme (*Multi-level Interactive Siamese Filtering - MISF*) yöntemi tercih edilmiştir (Li, X. ve diğerleri, 2022). Görüntü tamamlama problemi yalnızca bir üretim süreci değil, aynı zamanda filtreleme ve bilgi yayma problemi olarak ele alan bu yaklaşım, eksik bölgelerin doldurulmasında düşük seviyeli detaylarla yüksek seviyeli semantik bilgilerin etkin biçimde bütünleşmesini hedeflemektedir. Bu kapsamda model, tahmine dayalı filtreleme yaklaşımını yalnızca görüntü seviyesinde değil, aynı zamanda derin özellik düzeyine taşımakta ve çok seviyeli bilgi akışı sağlamaktadır. Bu sayede, filtreleme temelli yaklaşımlar derin öğrenme mimarileri ile birleştirilerek, eksik bölgelerin tamamlanmasında daha gerçekçi ve yapısal olarak tutarlı sonuçlar üretilmesine olanak tanımaktadır (Li, X. ve diğerleri, 2022).

Ağ mimarisi


Algoritma, görüntü seviyesi ve derin özellik seviyesi filtrelemenin her iki avantajından da yararlanmak için, ayrıntıların yanı sıra anlamsal bilgileri de tamamlayan çok seviyeli anlamsal ve görüntü filtrelemeyi önermektedir (Li, X. ve diğerleri, 2022). Bu kapsamda önerilen ağ mimarisi, kodlayıcı-kod çözücü yapısına dayalı olarak tasarlanmış ve her katmanda üretilen çok seviyeli özellik haritalarına dayanan dinamik filtreleme işlemleri gerçekleştirilmiştir. Şekil 4.21'de görüldüğü gibi, algoritmanın akış şeması iki ana etkileşimli bileşenden oluşmakta ve dinamik evrişim çekirdekleri aracılığıyla yönlendirilmiş filtreleme gerçekleştirilmektedir. Giriş görüntüsü işleme alanında evrişim parametreleri, her bir görüntünün bilgisi ve semantik anlamlara göre, tahmine dayalı olarak ayarlanmaktadır. Tahmin mekanizmasının ürettiği dinamik çekirdekler, çok seviyeli özellik haritalarına uygulanarak eksik bölgelerde yönlendirilmiş filtreleme sağlamaktadır. Sonuç olarak, ağ

mimarisi; anlam bütünlüğünü koruyan, lokal yapı detaylarını bozmayan ve farklı görüntü türlerine adapte bir şekilde yanıt verebilen güçlü bir yapı sergilemektedir (Li, X. ve diğerleri, 2022).



Şekil 4.16. Algoritma akış şeması (Li, X. ve diğerleri, 2022)’den uyarlanmıştır.

Algoritma ile üretilen desenlerde dinamik işlemin yüksek kaliteli boyama sonuçları için belirleyici olduğu görülmektedir. Maskelenmiş alanların tamamlanmasında yalnızca çevresel doku bilgisinden değil, aynı zamanda çok seviyeli anlamsal bilgiden yararlanılmaktadır. Anlamsal filtreleme sayesinde, farklı desen yapılarında modelin uyum yeteneği ön plana çıkmakta; pikseller yapısal süreklilik gösteren formlarla doldurulabilmektedir. Ayrıca, hem anlamsal hem de görüntü tabanlı filtrelemeyi bütüncül şekilde değerlendiren bu yaklaşım, yalnızca genel şekil bütünlüğünü değil, aynı zamanda ince detayları da kurtararak doğal görünümlü tamamlama sonuçları üretebilmektedir. İlk olarak algoritma hazırlanan veri seti üzerinden önceden eğitilmiş ağırlıklar kullanılarak ince ayar; öğrenme oranı: 0,00001, batch boyutu: 2, iterasyon: 50000 olmak üzere eğitilmiştir. Model Google Colaboratory ortamında uygulanmıştır. Şekil 4.17’ de farklı maske boyutlarında model çıktıları görülmektedir.



Şekil 4.17. (a) Orijinal görüntü, (b) %20-%30 maskelenmiş görüntü ve tamamlanan görüntü, (c) %30-%40 maskelenmiş görüntü ve tamamlanan görüntü, (d) %40-%50 maskelenmiş görüntü ve tamamlanan görüntü, (e) %50-%60 maskelenmiş görüntü ve tamamlanan görüntü.

Çalışmada test çıktıları nicel ve nitel olarak karşılaştırıldığında modelin performansı belirgin bir artışa yol açmamıştır (EK-25). Bunun sonucunda algoritma hazırlanan veri kümesi üzerinde tekrar değerlendirilmiştir. Önceden eğitilmiş ağırlıklar kullanılarak; öğrenme oranı: 0,0001, batch boyutu: 2 olmak üzere görüntüler 6 farklı maske boyutunda ve 3 farklı sınıfta test edilmiştir. Tamamlanan görüntülerin performansı nitel ve nicel olarak değerlendirilmiştir.

Nicel değerlendirme

Modelin farklı geometrik yapılara ve çeşitli bozulma türlerine karşı benzerlik kapasitesinin analiz edilmesini sağlamak amacıyla performansı; PSNR, SSIM, LPIPS ve L1 Loss metrikleri kullanılarak nicel olarak değerlendirilmiştir. Çizelge 4.22 tamamlanan geometrik desenlerin farklı maske boyutlarına göre performansını göstermektedir.

Filtreleme tabanlı görüntü restorasyonu gerçekleştiren MISF algoritması, düşük oranlı maskeleme seviyelerinde oldukça güçlü sonuçlar üretmiştir. Doğrudan görüntülerde, %0–10 maske oranı altında 32,4229 PSNR ve 0,97 SSIM gibi oldukça yüksek değerler elde edilmiştir. Bu durum, modelin düşük bozulma oranlarında yapısal tutarlılığı koruma becerisinin güçlü olduğunu ortaya koymaktadır. Aynı örnekte LPIPS değeri 0,0296 ve L1 kaybı 3,3803 gibi düşük seviyelerde kalarak modelin hem algısal hem de sayısal düzeyde başarılı çıktılar ürettiğini göstermektedir. Ancak maskeleme oranı %30–40 seviyelerine

ulaştığında PSNR değeri 21,3719'a, SSIM ise 0,7917'ye kadar gerilemiştir. Bu, modelin özellikle doğrudan desenlerde eksik alan arttıkça bütünsel tamamlamada zorlandığını göstermektedir. Performans, %50–60 aralığında daha da düşerek PSNR açısından 17,6646'ya, SSIM açısından ise 0,5764 seviyesine kadar gerilemiştir.

Açılı görüntülerde, MISF algoritması %0–10 oranında 31,5011 PSNR ve 0,9707 SSIM ile güçlü bir başlangıç performansı göstermiştir. Ayrıca bu görüntü türünde LPIPS değeri 0,0329 ile doğrudan görüntülere göre bir miktar daha yüksektir; bu da modelin perspektif bozulmalara karşı daha az algısal farklılık ürettiğini göstermektedir. Maskeleme oranı arttıkça tüm metriklerde kademeli bir düşüş gözlemlenmiş; %50–60 oranında SSIM değeri 0,5621'e, PSNR değeri ise 17,7106'ya kadar gerilemiştir. Bu durum, modelin açılı görüntülerde yapısal sürekliliği korumakta daha fazla zorluk yaşadığını göstermektedir.

Yapı bileşeni içeren görüntülerde ise MISF algoritması, %0–10 maskeleme oranında 30,863 PSNR ve 0,9665 SSIM gibi yüksek başlangıç değerleri üretmiştir. Ancak maskeleme oranı arttıkça, bu metriklerde önemli düşüşler görülmüştür. %50–60 oranında PSNR değeri 17,302'ye, SSIM değeri ise 0,562'ye kadar inmiştir. Aynı oran için LPIPS 0,3196'ya ve L1 değeri 21,2369'a çıkarak, modelin bu tür geometrilere yüksek bozulma oranlarında algısal ve sayısal uyum konusunda zorlandığını göstermektedir.

Genel olarak MISF algoritması, düşük ve orta seviyeli bozulmalarda etkili ve dengeli sonuçlar sunmuş; özellikle doğrudan ve yapı bileşeni içeren görüntü türlerinde yapısal benzerliği koruma konusunda tatmin edici sonuçlar üretmiştir. Ancak maskeleme oranı arttıkça, özellikle açılı ve karmaşık bileşen içeren görüntülerde hem yapısal bütünlük hem de algısal tutarlılık açısından performansında belirgin azalmalar gözlenmiştir.

Çizelge 4.22. Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı)

Veri Setleri	Maske tipi ve oranı	Algoritma	PSNR ↑	SSIM ↑	LPIPS ↓	L1 ↓
			Değerler	Değerler	Değerler	Değerler
Doğrudan görüntüler	Düzensiz (%0–10)	Filtreleme tabanlı görüntü restorasyonu MISF	32,4229	0,9700	0,0296	3,3803
	Düzensiz (%10–20)		27,1183	0,9264	0,0684	5,1031
	Düzensiz (%20–30)		23,7242	0,8636	0,1214	7,6911
	Düzensiz (%30–40)		21,3719	0,7917	0,1814	10,549
	Düzensiz (%40–50)		19,4687	0,6944	0,2547	14,6209
	Düzensiz (%50–60)		17,6646	0,5764	0,3402	20,3305
Açılı görüntüler	Düzensiz (%0–10)	Filtreleme tabanlı görüntü restorasyonu MISF	31,5011	0,9707	0,0329	3,3417
	Düzensiz (%10–20)		26,4051	0,9237	0,072	5,3289
	Düzensiz (%20–30)		23,3562	0,8567	0,1261	7,9088
	Düzensiz (%30–40)		21,3239	0,7854	0,1759	10,8708
	Düzensiz (%40–50)		19,2645	0,6816	0,2519	15,2177
	Düzensiz (%50–60)		17,7106	0,5621	0,3264	20,1096
Yapı bileşeni içeren görüntüler	Düzensiz (%0–10)	Filtreleme tabanlı görüntü restorasyonu MISF	30,8632	0,9665	0,0341	3,3986
	Düzensiz (%10–20)		25,4664	0,919	0,0731	5,5144
	Düzensiz (%20–30)		22,3808	0,8481	0,1232	8,4691
	Düzensiz (%30–40)		20,4808	0,773	0,1767	11,6601
	Düzensiz (%40–50)		18,6359	0,6764	0,2401	16,028
	Düzensiz (%50–60)		17,3027	0,562	0,3196	21,2369

Nitel değerlendirme

Model tarafından elde edilen görüntülerin bir kısmı Çizelge 4.23'te gösterilmektedir. Model, görüntü yapılarının büyük bir kısmı bozulmamış olarak foto-gerçekçi sonuçlar üretebilir. Eksik görüntü alanı arttıkça bazı görüntülerde minimal bulanıklık görülmektedir.

Çizelge 4.23. %10 maske boyutlarına göre karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Tamamlanmış görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü				
Açılı görüntü				
Yapı bileşeni içeren görüntü				

Çizelge 4.24. %10-%20 maske boyutlarına göre karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Tamamlanmış görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü				
Açılı görüntü				
Yapı bileşeni içeren görüntü				

Çizelge 4.25. %20-%30 maske boyutlarına göre karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Tamamlanmış görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü				
Açılı görüntü				
Yapı bileşeni içeren görüntü				

Çizelge 4.26. %30-%40 maske boyutlarına göre karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Tamamlanmış görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü				
Açılı görüntü				
Yapı bileşeni içeren görüntü				

Çizelge 4.27. %40-%50 maske boyutlarına göre karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Tamamlanmış görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü				
Açılı görüntü				
Yapı bileşeni içeren görüntü				

Çizelge 4.28. %50-%60 maske boyutlarına göre karşılık gelen sonuçlar

Görüntü sınıfı	Maske girdisi	Maskelenmiş görüntü	Tamamlanmış görüntü	Orijinal görüntü
Doğrudan (dik açı) Görüntü				
Açılı görüntü				
Yapı bileşeni içeren görüntü				


4.4. Uygulama Sonuçlarının Ölçüm ve Analizi

İslami geometrik desenlerin görsel tamamlama süreçlerinde biçimsel, yapısal ve algısal yeterliliğini değerlendirmek amacıyla, bu çalışmada dört kriter referans alınmıştır. Bunlar; simetri, tekrarlılık/modülerlik, topolojik süreklilik/desen–kenar geçiş bütünlüğü ve algısal/içerik benzerliğidir. Simetri özelliği, desenin eksenel veya radyal düzenini koruma kapasitesini ifade etmektedir. Tekrarlılık/modülerlik, geometrik motiflerin uzamsal olarak periyodik yinelenmesi ile temel modüllerin kendi iç bütünlüğü ve komşularla kurduğu düzenli bağların sürekliliğini kapsamaktadır. Topolojik süreklilik, tamamlanan bölgelerin orijinal kenarlarla bütünleşmesini; kontur devamlılığı, birleşim hızası ve bütünsel yapısal taşıyıcılığın korunmasını belirtir. Algısal/İçerik Benzerliği ise sonuçların orijinal görüntüye görsel/içerik yakınlığını (PSNR, SSIM, LPIPS, L1) ifade etmektedir. Benzerlik sonuçları, biçimsel kriterlerin yanında, orijinal görüntüye görsel yakınlığı nicel olarak ortaya koymak için kullanılmıştır. Bu dört başlık, desenin estetik bütünlüğü ile geometrik–topolojik organizasyonunu bütüncül biçimde değerlendirmektedir. Bu çalışmada kullanılan dört değerlendirme ölçütü ve kısa tanımları Çizelge 4.29’ da özetlenmiştir.

Çizelge 4.29. İGD’ de değerlendirme kriterleri

Ölçüt	Açıklama
Simetri	Desenin eksenel ve/veya radyal simetri düzenini koruma kapasitesidir. Fourier spektrumunda merkezlenmiş ve düzenli yönelime sahip yapılar yüksek simetri göstergesidir.
Tekrarlılık/Modülerlik	Geometrik motiflerin uzamsal olarak periyodik yinelenmesi ile temel modüllerin kendi iç bütünlüğü ve komşularla kurduğu düzenli bağların sürekliliğidir. Tepe noktalarının alan başına yoğunluğunun düzenli olması, kümelenme biçimlerinin kararlı görünmesi ile ilişkilidir.
Topolojik Süreklilik /Desen-Kenar Geçiş Bütünlüğü	Tamamlanan desen ile orijinal kenarların birleşim noktalarında görülen süreklilik, kontur devamlılığı ve yapay kesikliklerin varlığına dair ölçüttür. Bağlantılı bileşen sayılarının tutarlı kalması ile kontur hizalanma hatalarının küçük olması yüksek topolojik süreklilik göstergesidir.
Algısal / İçerik Benzerliği	Sonucun orijinal görüntüye içerik ve algısal yakınlığını tanımlar. PSNR ve SSIM değerlerinin yüksek, LPIPS ve L1 değerlerinin düşük olması beklenir; farklı maske yüzdelğinde özetlenir ve algoritmalar arası karşılaştırmalarla raporlanır.

Tanımlanan ölçütler farklı yöntemlerle değerlendirilmektedir. Tamamlama çıktılarında, topolojik süreklilik, yapılan topolojik analizle (uç nokta, bağlantılı bileşen ve çevrim tutarlılığı; kontur hizalanması) sayısallaştırılmıştır. Tekrarlılık/modülerlik, tepe noktaları ve yoğunluk haritalarından elde edilen yoğunluluk ve düzenlilik göstergeleriyle değerlendirilmiştir. Simetri, Fourier spektrumu ve açısal güç yoğunluğu yardımıyla, beklenen simetri derecesine göre frekans yönelim yoğunlukları çıkarılarak karşılaştırılmıştır. LPIPS gibi algısal yada SSIM gibi yapısal bozulma ölçütleri ve pikselle sınırlı metrikler Algısal ve içerik benzerliği olarak değerlendirilmiş farklı maske oranlarında yöntemler arası kıyaslama desteklemiştir. Değerlendirme süreci ve ilişkileri Şekil 4.18’de gösterilmektedir.



Şekil 4.18. Değerlendirme bağlantı şeması

4.4.1. Görüntü kalite metriklerinin karşılaştırılması

Bu çalışmada kullanılan üç farklı görüntü tamamlama algoritması, genel performans açısından değerlendirilmiş ve elde edilen sayısal veriler grafiksel olarak sunulmuştur. Yöntemlerin karşılaştırılmasında, algoritmaların görsel çıktılarının yapısal bütünlüğü ve benzerliği üzerine odaklanılmamış; doğrudan SSIM, PSNR, L1 Loss ve LPIPS gibi standart performans metrikleri esas alınmıştır. Her algoritmanın kendi içerisinde nasıl bir başarı sağladığı ve birbirlerine göre ne ölçüde üstünlük gösterdiği, grafiksel karşılaştırmalar

yoluyla analiz edilmiştir. Bu karşılaştırma, modellerin İGD verisi üzerindeki genel yeterlilik düzeylerini ortaya koymayı amaçlamaktadır.

Yapılan deneysel uygulamaların nicel sonuçları, dört temel metrik üzerinden Çizelge 4.30'da analiz edilmiştir. SSIM değeri, tamamlanan desenin orijinal desenle yapısal benzerliğini ölçerken; PSNR değeri, tamamlanan görselin gürültü oranını ve genel kalite seviyesini göstermektedir. L1 Loss değeri, tamamlanan görüntü ile orijinal görüntü arasındaki piksel bazlı farkı yansıtarak hatanın mutlak seviyesini ortaya koymaktadır. LPIPS ise insan algısına dayalı görsel benzerliği ölçerek, tamamlamanın algısal kalitesine ilişkin daha derinlikli bilgi sunmaktadır. Çizelgede sunulan değerler, bu dört metrik dikkate alınarak sıralanmıştır. Grafikler, her algoritmanın farklı maskelenme oranlarında nasıl performans gösterdiğini görsel olarak ortaya koymaktadır. Değerlendirme, doğrudan, açılı ve yapısal bileşen içeren görüntü grupları için ayrı ayrı yapılmıştır. Bu sonuçlar, algoritmaların metrik bazlı performanslarını ortaya koymakta ve desen tipine göre model seçiminin veriye bağlı olarak optimize edilebileceğini göstermektedir.

Çizelge 4.30. Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı)

Veri Setleri	Maske tipi ve oranı	Algoritma	PSNR ↑	SSIM ↑	LPIPS ↓	L1 ↓
			Değerler	Değerler	Değerler	Değerler
Doğrudan görüntüler	Düzensiz (0–10%)		31,5838	0,9632	0,0359	2,8126
	Düzensiz (10–20%)	Kenar bağlantı algoritması ile görüntü restorasyonu	26,0654	0,9137	0,0808	4,8645
	Düzensiz (20–30%)		22,9756	0,8443	0,1373	7,7302
	Düzensiz (30–40%)	EdgeConnect	20,8501	0,7698	0,2006	10,8162
	Düzensiz (40–50%)		19,0592	0,6704	0,2695	15,0771
	Düzensiz (50–60%)		17,3788	0,5568	0,3456	20,5819
Açılı görüntüler	Düzensiz (0–10%)		30,7927	0,9651	0,0371	2,8867
	Düzensiz (10–20%)	Kenar bağlantı algoritması ile görüntü restorasyonu	25,649	0,9107	0,0842	5,148
	Düzensiz (20–30%)		22,6735	0,8373	0,1406	8,0372
	Düzensiz (30–40%)	EdgeConnect	20,8347	0,7636	0,1939	11,1351
	Düzensiz (40–50%)		18,9225	0,6579	0,2676	15,605
	Düzensiz (50–60%)		17,4481	0,5461	0,3304	20,3997
Yapı bileşeni içeren görüntüler	Düzensiz (0–10%)		30,2831	0,9612	0,0395	2,9748
	Düzensiz (10–20%)	Kenar bağlantı algoritması ile görüntü restorasyonu	24,7951	0,9068	0,0848	5,4275
	Düzensiz (20–30%)		21,7856	0,8406	0,1327	8,1711
	Düzensiz (30–40%)	EdgeConnect	20,0057	0,7535	0,1977	12,3015
	Düzensiz (40–50%)		18,343	0,6549	0,2603	16,5229
	Düzensiz (50–60%)		17,1304	0,547	0,3268	21,3922


Çizelge 4.30. (devam) Nicel sonuçların karşılaştırılması (↓ Alçak değer daha başarılı, ↑ yüksek değer daha başarılı)

Veri Setleri	Maske tipi ve oranı	Algoritma	PSNR ↑	SSIM ↑	LPIPS ↓	L1 ↓
			Değerler	Değerler	Değerler	Değerler
Doğrudan görüntüler	Düzensiz (0–10%)	Derin Füzyon ağı ile görüntü restorasyonu DfNet	33,2160	0,9722	0,0252	1,1878
	Düzensiz (10–20%)		26,6030	0,9213	0,0701	3,3575
	Düzensiz (20–30%)		23,1727	0,8507	0,1284	6,4944
	Düzensiz (30–40%)		20,8961	0,7744	0,1908	9,7832
	Düzensiz (40–50%)		18,9123	0,6702	0,2676	14,6942
	Düzensiz (50–60%)		17,0431	0,5566	0,3402	20,582
Açılı görüntüler	Düzensiz (0–10%)	Derin Füzyon ağı ile görüntü restorasyonu DfNet	31,7909	0,9721	0,0263	1,3200
	Düzensiz (10–20%)		25,7873	0,917	0,0721	3,7840
	Düzensiz (20–30%)		22,7448	0,8418	0,1272	6,9407
	Düzensiz (30–40%)		20,8539	0,7692	0,1797	10,1886
	Düzensiz (40–50%)		18,6601	0,6589	0,2558	15,3847
	Düzensiz (50–60%)		17,0424	0,5437	0,3162	20,5451
Yapı bileşeni içeren görüntüler	Düzensiz (0–10%)	Derin Füzyon ağı ile görüntü restorasyonu DfNet	30,7088	0,9668	0,0279	1,5253
	Düzensiz (10–20%)		25,5942	0,9194	0,063	3,6126
	Düzensiz (20–30%)		22,0465	0,835	0,1222	7,4124
	Düzensiz (30–40%)		20,0882	0,7565	0,1733	10,9956
	Düzensiz (40–50%)		18,2231	0,6539	0,2416	16,0267
	Düzensiz (50–60%)		16,7184	0,5433	0,3087	21,3627
Doğrudan görüntüler	Düzensiz (0–10%)	Filtreleme tabanlı görüntü restorasyonu MISF	32,4229	0,9700	0,0296	3,3803
	Düzensiz (10–20%)		27,1183	0,9264	0,0684	5,1031
	Düzensiz (20–30%)		23,7242	0,8636	0,1214	7,6911
	Düzensiz (30–40%)		21,3719	0,7917	0,1814	10,549
	Düzensiz (40–50%)		19,4687	0,6944	0,2547	14,6209
	Düzensiz (50–60%)		17,6646	0,5764	0,3402	20,3305
Açılı görüntüler	Düzensiz (0–10%)	Filtreleme tabanlı görüntü restorasyonu MISF	31,5011	0,9707	0,0329	3,3417
	Düzensiz (10–20%)		26,4051	0,9237	0,072	5,3289
	Düzensiz (20–30%)		23,3562	0,8567	0,1261	7,9088
	Düzensiz (30–40%)		21,3239	0,7854	0,1759	10,8708
	Düzensiz (40–50%)		19,2645	0,6816	0,2519	15,2177
	Düzensiz (50–60%)		17,7106	0,5621	0,3264	20,1096
Yapı bileşeni içeren görüntüler	Düzensiz (0–10%)	Filtreleme tabanlı görüntü restorasyonu MISF	30,8632	0,9665	0,0341	3,3986
	Düzensiz (10–20%)		25,4664	0,919	0,0731	5,5144
	Düzensiz (20–30%)		22,3808	0,8481	0,1232	8,4691
	Düzensiz (30–40%)		20,4808	0,773	0,1767	11,6601
	Düzensiz (40–50%)		18,6359	0,6764	0,2401	16,028
	Düzensiz (50–60%)		17,3027	0,562	0,3196	21,2369

Sonuçlar, niceliksel açıdan değerlendirildiğinde elde edilen veriler anlamlı performans göstermektedir. %0–10 oranında düzensiz maskeleme uygulanarak yapılan


değerlendirmelerde elde edilen bulgulara göre, PSNR ve SSIM metriklerinde DFNet modeli görüntü türlerinde (doğrudan, açılı ve yapısal bileşenli) çoğunlukla yüksek değer sağlamış ve bu metriklerde diğer algoritmalarından ayrılmıştır. Bu durum, DFNet'in düşük oranlı bozulmalarda yapıyı koruyan ve yüksek kaliteli sonuçlar üreten bir model olduğunu göstermektedir (Şekil 4.19).

LPIPS metriğine göre değerlendirildiğinde ise DFNet'in algısal benzerlik açısından da en düşük hata oranlarını sunduğu görülmektedir. Bu durum, modelin sadece sayısal olarak değil, görsel algı açısından da başarılı sonuçlar verdiğini göstermektedir. L1 analizinde de benzer bir tablo ortaya çıkmaktadır. Grafiklerin genel eğilimi, %0–10 maske oranında özellikle DFNet'in istikrarlı ve yüksek performans sergilediğini, EdgeConnect'in ise bazı metriklerde orta düzeyde kaldığını; MISF'in ise özellikle L1 gibi metriklerde daha yüksek hata oranlarına sahip olduğunu göstermektedir. Modelleri genel olarak değerlendirdiğimizde piksel yoğunluğu, görsel yapı tutarlığı, algısal kalite olarak başarılı sonuçlar elde ettiğini söylemek mümkündür.




Şekil 4.19. %0-10 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması

%10–20 oranında maskeleme uygulandığında elde edilen bulgular, önceki oranla benzer bir genel eğilimi sürdürmektedir. PSNR ve SSIM değerleri incelendiğinde, MISF, basit yüzeylerde yüksek değerlerle öne çıkmaktadır. DFNet ise, yapısal karmaşık görüntülerde semantik olarak görsel bütünlüğü koruyan model olarak öne çıkmaktadır. Yapı koruma açısından ise MISF genel olarak daha iyi performans göstermektedir. EdgeConnect, %20 maske oranıyla hem yapısal bütünlük hem de algısal kalite açısından diğer algoritmaların gerisinde kalmaktadır. Genel olarak %10–20 aralığındaki maske oranı altında, DFNet’in yapısal bütünlüğü ve görsel kaliteyi koruma konusundaki başarısını sürdürdüğü; EdgeConnect ve MISF’in ise belirli görüntü türlerinde performans farklılıkları gösterdiği anlaşılmaktadır (Şekil 4.20).




Şekil 4.20. %10-20 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması

Desenlerde maskeleme miktarı arttıkça tüm modellerin performansında genel bir düşüş eğilimi gözlemlenmiştir. %20–30 maske aralığına bakıldığında; MISF, bazı metriklerde göreceli bir üstünlük sunmaktadır. Bu maske oranında EdgeConnect’in görüntülerde yapısal tutarlılığı daha az koruduğu görülmektedir. DFNet ise genel olarak her üç metrikte de orta düzey bir başarı sergilemiştir (Şekil 4.21).




Şekil 4.21. %20-30 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması

%30–40 maske oranına ait değerlendirmeler, algoritmaların performansındaki bozulmaların daha da belirginleştiğini göstermektedir. PSNR metriği açısından çok ölçekli filtreleme yöntemi, doğrudan görüntülerde en yüksek değeri üretmiş ve diğer modellere göre bu oranda daha tutarlı bir performans sergilemiştir. Bu anlamda algoritma sayısal doğruluğu ve yapısal bütünlüğü genel olarak daha iyi korumuştur. Derin füzyon ağı ise yapı grubunda semantik olarak daha tutarlı çıktı üretimi sağlamıştır. Ayrıca piksel bazlı sapmasının minimumda olması kararlılık açısından güçlü olduğunu göstermektedir. Sonuç olarak %40 maske oranı altında yapılan analiz, düşük oranlı senaryolarda gösterilen başarı düzeylerinin sürdürülemediğini ortaya koymaktadır. MISF modeli, basit yüzeylerde ve açılı görüntülerde başarılı sonuçlar üretse de, yapısal yoğunluk barındıran desenlerde zayıflık göstermektedir (Şekil 4.22)




Şekil 4.22. %30-40 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması

%40-50 oranındaki maskeleme seviyelerinde desen tamamlama başarıları daha farklılık gösteren bir yapıya ulaşmıştır. Bu oran, görsel bütünlüğün bozulma altında olduğu bir senaryo olduğundan, algoritmaların dayanıklılığı, semantik süreklilik, yapısal koruma kapasitesi ve piksel düzeyli hata toleransı daha kritik hale gelmektedir. %40-50 aralığında yapılan karşılaştırmalarda, görsel kaliteyi ölçen değerlerde MISF yöntemi özellikle doğrudan ve açılı görüntülerde daha yüksek sonuçlar üretmiş, bu yönüyle dikkat çekmiştir. Yapısal bütünlük açısından ise MISF derin semantik özellikleri etkili biçimde modelleyerek maskelenmiş bölgelerde bütünlüğü daha başarılı şekilde yeniden inşa ettiğini göstermektedir. Derin füzyon ağı ise özellikle piksel düzeyli hata açısından MISF'e yakın sonuçlar üretmiş, ancak yapısal ve algısal metriklerde geri planda kalmıştır. EdgeConnect ise bu aralıkta üç metrik ailesinde de zayıf performans sergileyerek, algısal yakınlık ve kontur sürekliliğinde daha fazla kayıp üretmektedir. Sonuç olarak, %40-50 bandında MISF, yüksek maskeleme altında istikrarlı ve genel performansta daha iyi sonuçlar vermiştir. DFNet ise kısmi piksel-hata avantajlarına rağmen algısal ve yapısal göstergelerde ikinci sırada kalmaktadır (Şekil 4.23).



Şekil 4.23. %40-50 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması

%50–60 oranındaki en yüksek maskeleme durumunda, maske oranı altındaki test senaryosu, modellerin sınır durumlardaki kararlılığını değerlendirmek açısından anlamlı bir eşiği temsil etmektedir. Bu bağlamda MISF modeli, PSNR ve SSIM metriklerinde en yüksek değerlere ulaşarak sayısal ve yapısal bütünlük bakımından öne çıkmıştır; özellikle karmaşık desenler ve açılı görüntülerde dahi 17 üzeri PSNR ve ~ 0.56 – 0.57 aralığında SSIM'i koruması, semantik açıdan tutarlı yapı üretme kapasitesine işaret etmektedir. Derin füzyon ağı için LPIPS özelinde, açılı ve yapı bileşenli görüntü gruplarında daha düşük değerlere ulaşıldığı gözlenmiştir; doğrudan görüntülerde ise DFNet ve MISF algoritmalarında yakın bir performans söz konusudur. Bu sonuç, DFNet'in belirli sahne türlerinde algısal yakınlığı daha iyi yakalayabildiğini göstermektedir. EdgeConnect ise bu maske aralığında dört metrikte de görece zayıf kalmış; özellikle yapı bileşeni içeren örneklerde LPIPS (~ 0.3268) ve SSIM (~ 0.547) değerleri, algısal ve yapısal başarı eşiğinin altında seyretilmiştir (Şekil 4.24).



Şekil 4.24. %50-60 maske boyutlarına göre yapılan çalışmaların görüntü kalite metriklerinin karşılaştırılması


Desenlerin tamamlanmasında görsel süreklilik, geometrik yapılar, estetik uyum açısından genel bir değerlendirme yapıldığında, genel görsel tutarlılık düşük maske boyutları için yeterli bir başarı düzeyine işaret etmektedir. Görüntü boşluğu arttıkça biçimlendirme özelliklerini sağlamakta zorlanmaktadır. Çizelge 4.31’de sonuçlar İGD’de değerlendirme kriterlerine göre açıklamaktadır.

Çizelge 4.31. Görüntü kalitesi sonuçlarının değerlendirilmesi

Maske Oranı	İGD Biçimlenme	Açıklama (Algısal fark, içerik benzerliği)
%0-%10	Uygun	Aralıkta görüntü sınıfları yakın performans göstermektedir
%10-%20	Uygun	Değerler düşmüş doğrudan görüntülerde görüntü kalitesi diğer sınıflara göre daha iyi korunmuştur.
%20-%30	Sınırlı Kullanım	Görüntü benzerliği ve algısal fark düşmüştür. Doğrudan görüntüler en iyi yapısal benzerliği sağlamakta en düşük performans yapı bileşeni içeren görüntüler göstermektedir.
%30-%40	Sınırlı Kullanım	Benzerlik değerlerinde düşme devam etmektedir.
%40-%50	Zayıflama	Benzerlikte zayıflama, yapı bileşeni içeren görüntüler performans olarak geride kalmıştır
%50-%60	Zayıflama	Görüntü kalitesi değerlerinin en düşük olduğu aralıktır.


4.4.2. Topolojik yapısal analiz

Topolojik veri analizi, verinin geometrik yapısını küçük gürültü ve şekil deformasyonlarına karşı kararlı bir çerçevede ortaya koymaktadır. Görüntü temelli uygulamalarda bu yaklaşım, yapısal süreklilik ve boşluk örgüsü gibi morfolojik özelliklerin nicel olarak karşılaştırılmasına imkân tanımaktadır. Bu bölümde, tamamlanan görüntülerin topolojik veri analizi için DAAR Topology yazılımı (Ali ve Asaad, 2020) kullanılmıştır. Uygulamada ilk olarak orijinal ve tamamlanmış görüntüler giriş verisi olarak değerlendirilmiştir. Şekil 4.25'te derin füzyon modeli ile oluşturulan örnek giriş görüntüleri gösterilmektedir.




Şekil 4.25. Orijinal görüntü ve DFNet modeli ile tamamlanmış görüntü

Topolojik analiz yaklaşımında, her bir görüntü için yedi farklı geometri özelliği sekiz ayrı rotasyon altında işlenerek kalıcı barkodlar elde edilmektedir. Örneğin, orijinal görüntünün G6 geometrisi ve R1 rotasyonu temelinde üretilen grafikler (Şekil 4.26) bağlantılı bileşenlerin dağılımını göstererek ilgili görüntünün topolojik bir tanımını sunmaktadır.



Şekil 4.26. Orijinal görüntünün G6 geometrisinin R1 dönüşünün diyagramları

Görüntülerde Barkod 0 değerleri bağlantılı bileşenlerin doğum–ölüm aralıklarını kodlayarak motif parçalarının sayısı ve sürekliliği hakkında nicel bilgi üretir; uzun ömürlü Barkod 0 segmentleri kararlı yapısal bölümlere, kısa ömürlüler ise küçük parçalanmalara karşılık gelir. Barkod 1 ise boşlukları veya döngüleri ifade etmektedir. Uzun ömürlü Barkod 1 segmentleri iç boşluk örgüsünün korunduğunu, ömürlerin kısalması veya seyrekleşmesi ise bu örgünün zayıfladığını gösterir. Kalıcı diyagramda ise bu değerler birlikte görselleştirilmektedir. Böylece G6–R1 için barkodların ömür dağılımı, ilgili motiftteki parça bütünlüğü (Barkod 0) ile boşluk organizasyonunun (Barkod 1) birlikte ve kompakt biçimde tanımlanmasını sağlar.



Şekil 4.27. Tamamlanmış görüntünün G6 geometrisinin R1 dönüşünün diyagramları

Görüntü boyama kalitesinin ve boyama tekniğinin etkinliğinin değerlendirilmesi için TVA yaklaşımı Bölüm 2.5.2'de detaylı olarak açıklanmıştır. Tamamlama görevinde görüntü kalitesini değerlendirmek için, bu yaklaşım görüntülerde orijinal ve tamamlanmış görüntülere odaklanmaktadır. Bu kapsamda üç kategoriden görüntüler seçilmiştir. Seçilen görüntüler Şekil 4.28'de gösterilmektedir.




Şekil 4.28. Topolojik yapısal analiz için seçilen desenler

Sonuç görüntülerinin karşılaştırılmasında; altı farklı maske boyutunda ve üç farklı veri sınıfında seçilen görüntüler, tek bir rotasyonda (R1) ve yedi farklı geometride, tek eşik değerinde ($T=10$), bağlı bileşen sayılarının ortalamaları alınmış ve sonuçları karşılaştırılmıştır. Bu geometri değerleri kenar, köşe bilgileri, bitiş çizgileri, düz alanlar gibi kısımlar hakkında bilgiler vermektedir. G1, G7 sınıfları doğal görüntüler bağlamında semantik adlandırma almamaktadır; bu nedenle bu çalışmada sınıfları sayısal kod olarak raporlanmış ve karşılaştırmalar orijinal ve çıktı farkı üzerinden yapılmıştır. Bu bilgiler doğrultusunda görüntüler İGD değerlendirme kriterleri kapsamında, kenar geçiş bütünlüğü, topolojik süreklilik özellikleri değerlendirilmiştir. İlk olarak dik bakış açısıyla çekilen doğrudan görüntülerin sonuçları karşılaştırılmıştır (Şekil 4.29).



Şekil 4.29. Farklı maske oranına göre doğrudan görüntülerin kullanılan algoritmalarda orijinal ve tamamlanmış görüntü topolojik analiz sonuçları



Şekil 4.29. (devam) Farklı maske oranına göre doğrudan görüntülerin kullanılan algoritmalarda orijinal ve tamamlanmış görüntü topolojik analiz sonuçları

Grafiklerde düşük maske oranlarında (%10-%30) G1 değerinde bağlı bileşen sayılarının ortalaması gerçeğe oldukça yakın seyretmektedir. Kenar ve kontur sınıflarında ise düşük maske boyutlarında kenar bağlantı algoritması daha iyi performans göstermektedir. Diğer sınıflarda maske boyutu arttıkça bu algortmada genel olarak bağlı bileşen farkı açılmaktadır. Çizgi sonlarını algılamada algoritmalar genel olarak zorlanmamıştır. Köşe temsillerinde ise sapmalar görülmektedir. Algoritmalar genel olarak yakın performanslar gösterse de orijinal görüntüyle aralarında sapmalar mevcuttur. Maske oranına göre İGD değerlendirme kriterlerine uygunluğu Çizelge 4.32’de görülmektedir.


Çizelge 4.32. Doğrudan görüntülerin İGD kriterlerine göre değerlendirmesi

Maske Oranı	İGD Biçimlenme	Açıklama (Topolojik Süreklilik /Desen-Kenar Geçiş Bütünlüğü)
%0-%10	Uygun	Köşe temsillerinde ve çizgi uçlarında algoritmalar yakın performans göstermektedir.
%10-%20	Uygun	Köşe ve geçişlerde kırılmalar bulunmaktadır
%20-%30	Sınırlı Kullanım	Çizgi sonları ve köşe detaylarda DFNet ve MISF yakın performans göstermektedir.
%30-%40	Sınırlı Kullanım	Kenar sürekliliği ve köşe detaylarında dalgalanmalar mevcut, DFNet ve MISF köşe yapılarında benzer yakınlık göstermektedir.
%40-%50	Zayıflama	Kenar sürekliliği ve detaylarda bozulma devam etmektedir.
%50-%60	Zayıflama	Detaylarda bozulma, EdgeConnect algoritması kenar bütünlüğünde ve çizgi sonlarında geride kalmaktadır.


Açılı görüntülerin topolojik analizinde %10 maske oranında genel gruplarda orijinal görüntüye oldukça yakın sonuçlar sunmaktadır. %20-%30 maske boyutunda DFNet ve

MISF kenar ve köşe detaylarında gerçeğe yakın sonuçlar vermektedir. %30-%40 aralığında ise Edge Connect algoritması biraz geride kalmıştır. %40-%60 yüksek maske oranlarında ise genel olarak DFNet ve MISF orijinal görüntüye daha yakın kalmaya devam ederken Edge Connect detaylarda zayıflamaktadır.

Bitiş çizgilerinde (G6), DFNet ve MISF tüm maske oranlarında başarılı sonuçlar üretmektedir. G2 geometrisinde ise üç algoritma da farklı maske oranlarında başarılıdır. G4 geometrisinde EdgeConnect, maske oranı arttıkça orijinal görüntüden uzaklaşmaktadır. G3 ve G5 geometrilerinde DFNet ve MISF daha iyi performans sergilerken, EdgeConnect %30 maske oranından itibaren daha düşük sonuçlar vermektedir. Özellikle %40-%60 maske aralığında köşe yapılarının (G3 ve G5) tamamlanmasında MISF'in daha başarılı olduğu görülmektedir.



Şekil 4.30. Farklı maske oranına göre açılı görüntülerin kullanılan algoritmalarda orijinal ve tamamlanmış görüntü topolojik analiz sonuçları



Şekil 4.30. (devam) Farklı maske oranına göre açılı görüntülerin kullanılan algoritmalarda orijinal ve tamamlanmış görüntü topolojik analiz sonuçları


Genel olarak değerlendirildiğinde, EdgeConnect düşük maske oranlarında (özellikle G2 bölgelerinde) güçlü performans sergilerken, yüksek maske oranlarında DFNet ve MISF öne çıkmaktadır. DFNet ve MISF, %10–%30 maske oranlarında tutarlı ve başarılı sonuçlar sunmuş, %40–%60 oranlarında da orijinal görüntüye daha yakın kalmayı sürdürmüştür. Maske oranına göre İGD değerlendirme kriterlerine uygunluğu Çizelge 4.33’de görülmektedir.

Çizelge 4.33. Açılı görüntülerin İGD kriterlerine göre değerlendirmesi

Maske Oranı	İGD Biçimlenme	Açıklama (Topolojik Süreklilik /Desen-Kenar Geçiş Bütünlüğü)
%0-%10	Uygun	Köşe temsillerinde ve çizgi uçlarında algoritmalar yakın performans göstermektedir.
%10-%20	Sınırlı Kullanım	Köşe geçişlerinde bozulma başlangıcı görülmektedir.
%20-%30	Sınırlı Kullanım	Çizgi sonları ve köşe detaylarda DFNet ve MISF yakın performans göstermektedir.
%30-%40	Sınırlı Kullanım	Görsel bütünlük kısmen var ancak topolojik kayıplar mevcuttur.
%40-%50	Zayıflama	Doku ve köşe detaylarında bozulmalar devam etmektedir.
%50-%60	Zayıflama	Detaylarda bozulma, EdgeConnect algoritması kenar bütünlüğünde ve çizgi sonlarında geride kalmaktadır.

Yapı bileşeni içeren görüntülerde bozulmalar daha erken başlamaktadır. Bütün maske oranlarında kenar ve birleşim bölgelerinde fazla bileşen sayımı gözlemlenmektedir. Bu da görüntülerde sapmalara işaret etmektedir. G3 ve G5 gruplarında ise belirgin bir şekilde pozitif sapmalar oluşmuştur. G2 ve G4 kenarlarda ise düşük maske oranlarında (%10-%30), Edge Connect orijinal görüntüye en yakın sonuçları sağlamıştır. Yüksek oranlarda (%40-

%60), G2, G3 grubu MISF ve DFNet, Edge Connect'in ilerisine geçmiştir. Çizgi sonlarının belirlenmesinde orijinal görüntüye uzaklaşmalar görülmektedir.



Şekil 4.31. Farklı maske oranına göre yapı bileşeni içeren görüntülerin kullanılan algoritmalarda orijinal ve tamamlanmış görüntü topolojik analiz sonuçları

Yapı bileşeni içeren görüntülerde tamamlama diğer veri sınıflarına göre daha dalgalı bir yapılanma seyretmektedir. Maske oranına göre İGD değerlendirme kriterlerine uygunluğu Çizelge 4.34'te görülmektedir.

Çizelge 4.34. Yapı bileşeni içeren görüntülerin İGD kriterlerine göre değerlendirmesi


Maske Oranı	İGD Biçimlenme	Açıklama (Topolojik Süreklilik /Desen-Kenar Geçiş Bütünlüğü)
%0-%10	Sınırlı kullanım	Tüm algoritmalarda tekil uçlarda, kenar sürekliliğinde zayıflama başlangıcı görülür.
%10-%20	Sınırlı Kullanım	Genel olarak yapısal yüzey alanlarında sapmalar mevcuttur.
%20-%30	Sınırlı Kullanım	Kontur ve bağlantı sapmaları devam eder.
%30-%40	Sınırlı Kullanım	G2 ve G3 köşe grubu daha iyi korunurken, diğer gruplarda topolojik çözülme hızlanır.
%40-%50	Zayıflama	G2 ve G3 grubunda MISF ve DFNet daha az sapma sağlarken diğer gruplarda pozitif ve negatif sapmalar mevcuttur.
%50-%60	Zayıflama	Tüm gruplarda sapma farkları görülür.

4.4.3. Yoğunluk haritası analizi ve frekans alanlı simetri

Çalışmanın bu bölümünde ilk olarak, İslami geometrik desenlerin orijinal ve tamamlanma sonrası görüntülerin İGD özelliklerinin karşılaştırılması açısından Gaussian yoğunluk haritası ve tepe noktası tespiti analizleri uygulanmıştır. Bu yöntemler, desen içerisindeki motif yoğunluğu, eleman sayısı ve konumlarındaki tutarlılık gibi kriterleri ölçmektedir. Özellikle İGD'ye özgü biçimlenme ilkeleri olan tekrarlılık, modülerlik, simetri eksenlerine göre denge, ve boşluk-doluluk oranı gibi yapısal özellikler bu analizlerle dolaylı olarak değerlendirilebilmektedir. Gaussian yoğunluk haritası, desenin genelinde ögelerin hangi bölgelerde yoğunlaştığını göstererek modülerlik ve tekrarlılık ilkelerinin uygulanıp uygulanmadığını görselleştirmek için kullanılmıştır. Tepe noktalarının bu yoğunluk haritası üzerinde tespiti, desenin modüler merkezlerini ortaya çıkarmaktadır. Bu merkezler arası mesafeler ve dağılım biçimi, geometrik düzenlilik ve hiyerarşik örüntüleme gibi İGD'nin temel organizasyon ilkeleriyle doğrudan ilişki kurmaktadır.

Bu aşamada kullanılan görsel analiz süreci, gri tonlamaya dönüştürme ve normalize etme, Gaussian yoğunluk haritası oluşturma ve tepe noktası tespiti olmak üzere üç temel aşamadan oluşmaktadır. İlk adımda RGB formatında verilen görsel, gri tonlamaya dönüştürülmektedir

(Şekil 4.32 a). Renk kanallarını ortadan kaldıran bu işlem ve eşik değeri ayarı yapısal yoğunluk bilgisini öne çıkarmaktadır. Ardından, görsel boyutu tüm örneklerde tutarlılığı sağlamak amacıyla 512×512 piksel olarak yeniden boyutlandırılır ve piksel değerleri $[0, 1]$ aralığında normalize edilir. Görsel üzerinde uygulanan iki boyutlu Gaussian filtre, her pikseli çevresindeki piksellerle ağırlıklı olarak birleştirerek bir bulanıklaştırma işlemi gerçekleştirir. Bu işlem sonucunda, görseldeki yüksek frekanslı detaylar (kenar gürültüsü, rastlantısal noktalar) bastırılırken, yapısal motiflerin yoğunlaştığı bölgeler daha görünür hale gelmektedir (Şekil 4.32 b). Ayrıca, Gaussian yoğunluk haritası üzerinden yerel maksimum tespiti işlemi gerçekleştirilmektedir. Elde edilen tepe noktaları yoğunluk değeri, birim alan başına düşen tepe sayısını ifade etmektedir (Şekil 4.32 c). Bu metrik, farklı desenler arasında yapısal yoğunluk karşılaştırmaları yapmak için kullanılmıştır. Örnek bir desenin gri tonlamalı görüntüsü, Gaussian yoğunluk haritası ve tepe noktaları tespiti şekil Şekil 4.32’de görülmektedir.




Şekil 4.32. Desenin gri tonlamalı görüntüsü (a), Gaussian yoğunluk haritası (b) ve tepe noktaları tespiti (c)

Orijinal desenle karşılaştırıldığında görüntü tamamlama sonrası yoğunluk haritasında yeni bir tepe görünüyorsa, bu noktada algoritmanın biçimsel uyumu koruyamayıp özgün eleman yerine öngörülemez bir yapıyı sentezlemiş olma ihtimalini artırmaktadır. Bu durum, özellikle yapısal ritmin ve ağ örgüsünün bozulduğuna işaret eder. Ayrıca, bazı beklenen tepe noktalarının tamamlanmış desende kaybolması da, algoritmanın boşluk-doluluk dengesi veya simetri merkezlerinin sürekliliği gibi kriterleri koruyamadığını göstermektedir.


Çalışmanın değerlendirme bölümünde ayrıca, İslami geometrik desenlerin orijinal ve tamamlanma sonrası görsellerinin karşılaştırmalı analizinde Fourier dönüşümü ve açısal

enerji profili çıkarımı yöntemleri birleştirilmiştir. Bu süreç, desenin uzamsal düzenliliğini frekans uzayında inceleyerek, dönme simetrisi ve yönelimli tekrarlılık gibi biçimlenme ilkelerinin sayısal olarak analiz edilmesini sağlamaktadır. Algoritma akışında ilk olarak giriş görseli gri tonlamaya çevrildikten sonra, yapısal detayların belirginleştirilmesi için Gaussian bulanıklaştırma ve ardından Canny edge detection uygulanmıştır. Bu adım, Fourier analizinin desenin kenar çizgilerine odaklanmasını sağlamaktadır. Sonrasında, elde edilen kenar görüntüsü üzerinden 2D Fourier dönüşümü hesaplanmıştır. Son olarak ise filtrelenmiş Fourier spektrumu üzerinde, merkezden tüm enerji dağılımı analiz edilmektedir. Elde edilen veriler, her yön (0–360°) için ortalama enerji değerini temsil etmekte ve grafiksel olarak frekans yönelim dağılımını vermekte ve frekansın tepe noktaları, desenin yönsel tekrarlarını ve dönme simetrisini yansıtmaktadır. Bu yöntem zinciri sayesinde, yalnızca görsel veri kullanılarak dönme simetrisi, tekrar yapısı ve frekans tabanlı düzenlilik gibi biçimlenme ilkeleri nicel olarak analiz edilebilmektedir. Şekil 4.33'te bir desenin simetri tespiti aşamaları yer almaktadır.



Şekil 4.33. Fouier dönüşümü ile simetri tespiti aşamaları

Bu değerlendirme sürecinde, görüntü tamamlama aşamasında elde edilen farklı maske boyutlarındaki (%10-20, %20-30, %30-40, %50-60) tamamlanmış üç farklı veriden oluşan (doğrudan,açılı,yapı bileşeni) görüntülerle, orijinal görüntülerin karşılaştırılması yapılmıştır. Böylelikle tamamlanmış görüntülerin orijinal görüntülere kıyasla; simetri, tekrarlılık, modülerlik özelliklerini ne derecede karşıladığı tartışılmıştır. Bir kaç bölümü ve algoritmayı kapsayan, çok adımlı bir tespit sürecinden oluşturulan bu adımlar, İGD biçimlenme kriterlerine uygunluklarının değerlendirilmesi için önem taşımaktadır. Şekil 4.34'te geometrik bir desenin fotoğraflanmış orijinal hali ile %30-40 boşluğunda tamamlanmış görüntünün bir karşılaştırılması yapılmıştır. Karşılaştırmada üç tamamlama algoritmasıyla üretilen görüntüler, orijinal görüntü ile yoğunluk değeri, tepe noktaları ve simetri tahminleri ölçütleriyle değerlendirilmiştir (Karşılaştırmaların devamı için Ekler' e bakınız).



Şekil 4.34. Geometrik bir desenin orijinal hali ile %30-40 boşluğunda tamamlanmış görüntünün bir karşılaştırılması

%30-40 boşluğunda değerlendirildiğinde, derin füzyon ağı merkezden hafif kayma olsa da yüksek kontrastlı ve belirgin yönelim tekrarını sağlamaktadır. Kenar bağlantı algoritması ise tepe noktası kaybı ve simetri tespitinde bazı yanılgılar yaşamaktadır. Bu analiz sürecinde,

özellikle simetri eksenlerinin sürekliliği, modüler merkezlerin varlığı, yönelimsellik düzeyi, kontur yapısı ve Fourier spektrumundaki dağılım düzeni temel alınmıştır. Aşağıdaki tablo, %10 ile %60 arasında artan maske oranlarına göre üç algoritmanın (DFNet, MISF, EdgeConnect) ürettiği desenlerin biçimsel tutarlılığını özetlemektedir. Her bir maske aralığı için yapısal bütünlük, tepe noktası dağılımı, açısallık frekans enerjisi ve estetik süreklilik düzeyi göz önünde bulundurularak, “İGD Biçimlenme Uygunluğu” başlığı altında sınıflandırma yapılmıştır.

Çizelge 4.35. Tamamlanan görüntülerin İGD kriterlerine göre değerlendirmesi

Maske Oranı	İGD Biçimlenme	Açıklama (simetri,tekrarlılık,modülerlik)
%10–%20	Uygun	Algoritmalar bu aralıkta tekrar ve modüler dizilimi koruyabilmektedir. Tepe noktası sayıları referansa yakındır. Fourier spektrumu merkezli ve açısallık frekans grafikleri simetrik tekrarlara işaret etmektedir.
%20–%30	Sınırlı Kullanım	Bu aralıkta yapı bozulmaları başlasa da algoritmalar tepe noktası ve yoğunluk değerleri gerçek değerlerden çok uzaklaşmamıştır. Simetri eksenlerinde yönelimsellik korunmaktadır.
%30–%40	Sınırlı Kullanım	Tekrar ve modüler hizalanmalar giderek zayıflamaktadır. Ancak merkez motifler genel hatlarıyla seçilebilmektedir.
%50–%60	Zayıflama	Tepe noktalarının sayısı azalmış; yapısal merkezlilik bazı kısımlarda kaybolmuştur. Fourier spektrumu yoğunluk göstermesine rağmen bazı simetri tahminleri karıştırmaktadır.

4.5. Tartışma

Çalışmada, algoritmalarının farklı maske oranları altındaki görüntü performansı İslami geometrik desenlerin temel biçimlenme ölçütleri doğrultusunda, görüntü kalite metrikleri, topolojik analiz ve yoğunluk haritası, frekans yönelimi yöntemleri ile değerlendirilmiştir. Bu çalışmalarda, kriterler göz önünde bulundurulduğunda %10–20 aralığında tüm ölçütler yüksek düzeyde korunmuş; özellikle simetri, tekrarlılık ve modüler yapı net biçimde sürdürülmüştür. Bu oran, algoritmaların yapısal bütünlüğü bozmadan başarılı şekilde tamamlamalar yapabildiği güvenli bölgeyi temsil etmektedir. %20–30 aralığında ise yönelimsellikte ve kontur sürekliliğinde ilk sapmalar görülmeye başlanmış, özellikle modüler ilişkilerde sapmalar dikkat çekmiştir. %30–40 aralığı, strüktürel çözülmenin belirginleştiği kritik eşiği oluşturur; burada hem simetri aksları hem de oransal bütünlük zayıflamaktadır. %40 ve üzeri maskelenmelerde tüm ölçütlerde düşüşler gözlenmiştir. Özellikle %50–60 aralığında hem tepe noktası yoğunluğu azalmış hem de desen-topoloji

ilişkisi gerilemiştir. Simetri, tekrarlılık ve modüler ilişki nitelikleri en düşük düzeye inmiştir. Bu analiz, düşük maske oranlarında algoritmaların biçimsel bütünlüğü koruyabildiğini, ancak maskeleme arttıkça estetik ve yapısal sürekliliğin hızla zayıfladığını ortaya koymaktadır.

Her üç test görsel kategorisi (doğrudan, açılı ve yapısal bileşen içeren desenler) değerlendirildiğinde, algoritmaların biçimsel performansları değişkenlik göstermiştir. Genel olarak, doğrudan desenler, algoritmalar tarafından en başarılı şekilde tamamlanan kategori olmuştur. Bu tür desenlerde simetri eksenleri net, kontur geçişleri belirgin ve modüler yapı açık olduğundan, %10–40 arası maskeleme oranlarında hem yapısal süreklilik hem de tekrarlılık korunabilmiştir. Özellikle DFNet ve MISF, bu kategoride %30'a kadar olan oranlarda modüler ilişkileri yüksek doğrulukla yeniden kurabilmiş, kenar sürekliliği ve oran dengesini büyük ölçüde muhafaza edebilmiştir.

Açılı desenler orta zorluk düzeyine sahiptir. Bu desenlerde yönelimsellik baskındır ancak simetri eksenleri çoğunlukla çapraz veya eğik konumlandığı için algoritmaların çizgisel süreklilik sağlama yetisi sınanmaktadır. %20–30 maske oranı aralığında dahi açılal frekans analizinde eksen sapmaları gözlenmiş, desen-kenar geçiş bütünlüğü kullanılan algoritmalarda kırılğan hale gelmiştir.

Yapısal bileşen içeren desenler algoritmalar için en zorlayıcı test kümesini oluşturmuştur. Bu desenlerde motiflerin arka planla olan ilişkisi daha karmaşık, modüler dağılım daha düzensizdir. %20'den itibaren strüktürel süreklilik hızla zayıflamış, modüler bağlantılar kopmuş ve Fourier spektrumunda enerji dağılımı merkezsizleşmiştir. %50–60 maskeleme oranında, bu kategoride üretilen tamamlamalarda simetri tamamen bozulmuş, görsel yoğunluk haritalarında tepe noktası sayısı dramatik şekilde düşmüş, bu da topolojik çözülmenin hızlandığını göstermiştir.

Sonuç olarak, test görsel türleri arasında algoritmaların en yüksek başarıyı doğrudan desenlerde, orta başarıyı açılı desenlerde, en düşük başarıyı ise yapısal bileşen içeren desenlerde gösterdiği açıkça gözlemlenmiştir. Bu farklar, İGD biçimlenme ölçütlerinin maskeleme koşullarında nasıl korunduğuna dair nitel farklara işaret etmektedir. Özellikle yüksek maske oranlarında yapısal karmaşıklık yüksek desenler, modellerin sınırlarını daha belirgin şekilde ortaya koymuştur.



5. SONUÇ VE ÖNERİLER

İslami geometrik desenler, tarih boyunca İslam sanat ve mimarisinin estetik ve kültürel zenginliğini yansıtan önemli bir unsuru olmuştur. Bu desenler, yüksek düzeyde simetrik düzenleri, matematiksel temelleri ve geometrik bütünlükleri ile dikkat çekmektedir (Broug, 2008; Critchlow, 1976). Ancak, zamanla bu desenlerin bazıları çeşitli nedenlerle tahrip olmuş, eksik kısımlar ortaya çıkmıştır. Bu tez, geleneksel mimari süslemelerin dijital teknoloji aracılığıyla korunması ve yeniden üretilmesi konularına katkı sunmaktadır. Tarihi yapıların parçası olan İslami geometrik desenlerin zamanla aşınma, kayıp veya tahribat sonucu bütünlüğünü yitirmesi, kültürel mirasın sürekliliği açısından kritik bir sorundur. Çalışma, derin öğrenme tabanlı görüntü tamamlama algoritmalarını kullanarak bu kayıp desen parçalarını otomatik tamamlamayı önererek dijital koruma alanında bir adım atmaktadır.

Literatürde, İslami geometrik desenlerin analizine ilişkin pek çok yöntem geliştirilmiştir. Müller (1944) tarafından başlatılan grup teorisi yaklaşımı, simetri gruplarının desenlerin yapısal analizi için temel bir çerçeve sunduğu çalışmalardan biridir (Müller, 1944). Daha sonraki araştırmalarda, Broug (2008) ve Kaplan (2005) gibi araştırmacılar, İslami geometrik desenlerin matematiksel ve geometrik yapılarına odaklanmıştır (Broug, 2008; Kaplan, 2005). Genellikle analiz ve sınıflandırmalara dayanan bu çalışmalarda kullanılan dijital yöntemler vektörel çizim tabanlı araçlara dayanmakta ve bu nedenle desenlerin üretim süreçlerini sınırlı ölçüde modelleyebilmektedir. Bu tür araçlar, desenin geometrisini tanımlarken üretim kurallarını, dönüşümlerini ele alırken, eksik kısımların algoritmik tamamlamasını içeren daha dinamik ve yapay zekâ destekli yaklaşımların üretici bir araç olarak kullanımı önemli bir gelişme olarak ortaya çıkmaktadır. Bu tez söz konusu yaklaşımları İslami geometrik desenler özelinde uygulayarak, kültürel miras unsurlarının sayısal ortamda yeniden canlandırılmasına yönelik yöntemleri ele almaktadır. Sonuçlar ise, gelişmiş görüntü tamamlama tekniklerinin mimari detayların dijital onarımında kullanılabileceğini göstererek, hesaplamalı mimarlık ve sayısal restorasyon literatürüne katkı sağlamayı amaçlamaktadır.

Tezin mimarlık disiplinine katkısı yalnızca teknik iyileştirmeler sunmakla sınırlı kalmayıp; aynı zamanda geleneksel desen tasarım bilgisinin çağdaş dijital araçlarla etkileşimine dair

bir çerçeve önermektedir. Asırlardır ustadan ustaya aktarılan desen kuralları ve geometrik prensipler, bu tez kapsamında derin öğrenme modellerinin eğitimi aracılığıyla dijital ortama taşınmıştır. Mimari desenler görsel bir dil gibi düşünüldüğünde, bu dilin simetri, tekrar, modülerlik gibi kuralları model tarafından öğrenilmiş ve üretilen çıktılarda yansımıştır. Dolayısıyla çalışma, geleneksel desen bilgisinin dijital ortama aktarılması konusunda bir köprü işlevi görmektedir. Bu durum, mimarlık alanında yapay zekâ ve dijital araçların kültürel mirası koruma ve belgelemeye yönelik kullanımının artan önemine işaret etmektedir.

Bu çalışmanın ilk aşamasında, İslami geometrik desenlerin restorasyonuna yönelik bir yöntem geliştirmek amacıyla veri toplama işlemi gerçekleştirilmiştir. Modellerin başarısı büyük ölçüde eğitim verisinin kapsamına dayanmaktadır. Bu sebeple toplama işlemi farklı kaynaklardan kısıtlılıklar belirlenerek gerçekleştirilmiştir. Kültürel miras kapsamına girmeyen, desen odaklı olmayan, detayların anlaşılamadığı düşük çözünürlüklü görseller kapsam dışı bırakılmıştır. Coğrafya, dönem ve malzeme gibi detay ayırımına gidilmemiştir. Veriler doğru bir açıyla çekilen desen odaklı görüntülerden elde edilmeye çalışılsa da veri setlerinin kısıtlanmaması adına desen algısının kaybolmadığı farklı açılarla çekilmiş ve desenle beraber kemer, sütun gibi yapı bileşenlerinin de fotoğrafa dahil olduğu görüntüler veri sınıfına dahil edilmiştir. Elde edilen veriler, geleneksel İslami geometrik desenlerin anlaşılabilir görsellerini içermekte ve çeşitli kaynaklardan elde edilen yüksek çözünürlüklü görüntülerden oluşmaktadır. Çalışmada ilk olarak Derin Evrişimli Üretici Çekişmeli Ağ kullanılarak yeniden yapılandırmaya dayalı bir ön çalışma yapılmıştır. Bu uygulamada tekrarlayan birimlerden oluşan sentetik görüntüler ve dik açıyla çekilmiş fotoğraf görüntüleri kullanılmıştır. Sonuçlar sentetik görüntülerde daha anlamlı sonuçlar verse de fotoğraf görüntülerinde istenilen sonucu vermemektedir. Veri kısıtlılıkları sebebi ile tekrar veri ayırımına gidilmiş ve incelenen desenler, fotoğraflanma açısı ve uygulandıkları yüzey bakımından; (1) Doğrudan düz bakışlı desenler (düzlemine tam karşıdan bakılan, perspektif bozulması olmayan), (2) Açılı görüntülenmiş desenler (desenin farklı açılardan görüldüğü, eğrisel yüzeylerde yer alan desenleri içeren fotoğraflar), (3) Yapı bileşeni içeren desenler (desenin kubbe, kemer gibi üç boyutlu bir form üzerinde yer aldığı veya başka mimari öğelerle kesintiye uğradığı) olmak üzere üç tipoloji altında değerlendirilmiştir. Bu sınıfların doğru bir şekilde oluşturulup oluşturulmadığını ölçmek ve algoritmaların bu görselleri ne kadar tanıyabildiğini değerlendirmek amacıyla bir sınıflandırma analizi gerçekleştirilmiştir. Teorik çerçevenin modern CNN tabanlı mimarilerle birleştirildiği bu aşamada, ResNet50,

VGG19, AlexNet, EfficientNet modelleri kullanılarak modellerin performansı bu farklı senaryolarda ayrı ayrı incelenmiş ve sonuçlar ilişkilendirilerek yorumlanmıştır. Desen görüntülerinin düz bakış, açılı/perspektif ve mimari bileşen içeren olarak genel olarak %90'ın üzerinde doğrulukla ayrılabilirdiği gösterilmiştir. Bu bulgu, desenlerin özelliklerine göre ayrıştırılabileceğini kanıtlayarak restorasyon sürecine girdi olabilecek otomatik bir ön analiz aracı sunmaktadır. Ayrıca bu aşama, farklı sınıfların özelliklerini daha iyi anlamayı ve bunların yapısal analizine dair önemli veriler elde etmeyi sağlamıştır. Bu ayrımın temel amacı, desenlerin geometrik yapılarına bağlı olarak sınıflandırma ve analiz sürecine katkı sağlamaktır. Özellikle, eğrisel yüzeylerden veya perspektif açıdan çekilmiş desenlerin algoritmalar tarafından işlenmesindeki zorlukları anlamak ve bu zorlukları aşmak kritik bir öneme sahiptir.

Yeniden yapılandırma uygulamaları, ince detayların korunmasında ve desenin geometrik bütünlüğünün sağlanmasında sınırlamalar göstermiştir. Bu durum, alternatif görüntü üretme yöntemlerine yönelme gerekliliğini ortaya koymuştur. Çalışmanın devamında eksik desenlerin tamamlanmasında derin görüntü boyama algoritmaları incelenmiştir. Çalışma kapsamında, literatürde başarıyla kullanılan üç görüntü boyama algoritması seçilmiş ve performansları detaylı bir şekilde karşılaştırılmıştır. Görüntü tamamlama sürecinde başarılı sonuçlar veren, ayrıntıları daha iyi koruyabilen bir algoritma olarak DFNet, kenar tespiti tabanlı bir görüntü boyama algoritması olarak, EdgeConnect ve filtreleme özelliği ile MISF algoritmalarıdır.

Eksik desen parçalarının tamamlanması için seçilen derin görüntü boyama algoritmaları sayesinde, desenler yeniden elde edilmiştir. Özellikle EdgeConnect (kenar tespiti destekli GAN tabanlı tamamlayıcı model), DFNet (çok ölçekli derin füzyon ağı) ve MISF (çok düzeyli etkileşimli filtreleme ağı) algoritmaları, gerçek tarihi desen fotoğraflarında oluşan düzensiz ve geniş boşlukları doldurmak üzere uygulanmış ve karşılaştırmalı analizleri yapılmıştır. Sonuçlar, bu yöntemlerin eksik bölgeleri yapısal kenar sürekliliği, simetri, modüler ilişki, tekrarlılık ve görsel kalite açısından değerlendirilmiştir. Özellikle filtreleme tabanlı yaklaşımın ince detayları korumadaki başarısı, EdgeConnect modelinin desenlerin geometrik iskeletini yeniden kurmadaki etkisi, DFNet ise mevcut içerikle üretilen içeriği uyumlu biçimde birleştirerek doku geçişlerinde süreklilik sağlaması vurgulanmıştır. Bu bulgular, derin öğrenme tabanlı tamamlama tekniklerinin kültürel miras desenlerinde,

geleneksel yöntemlere kıyasla daha tutarlı ve hızlı restorasyon imkânı sunduğunu ortaya koymaktadır.

Önerilen yöntemlerin çıktıları, üç farklı başlık altında değerlendirilmiş ve İslami geometrik desenlerin mevcut tamamlama kriterleri üzerinden karşılaştırma yapılmıştır. İlk olarak uygulama sonuçları PSNR ve SSIM gibi yaygın görüntü kalite metrikleri ile değerlendirilmiştir. Tamamlanan desen görüntülerinin, orijinal desenlere yakın sinyal-gürültü oranı ve yapısal benzerlik değerleri sergilediği ölçülmüştür. Bu metrikler strüktürel süreklilik ve kenar geçiş bütünlüğü özelliklerinde ele alınmıştır. Bunun yanı sıra, sonuçların geometrik ve topolojik uyumunu nicel olarak ölçmek amacıyla topolojik veri analizi uygulanmıştır. TVA sonuçları, tamamlanan desenlerin düşük maske boyutlarında geçiş bütünlüğünü ve yapısını koruduğunu ortaya koymuştur. Son olarak yoğunluk haritası ve frekans yönelimi analizleri ile desenlerde simetri, tekrarlılık ve modüler ilişki özellikleri değerlendirilmiştir. Nitel değerlendirmelerde de tamamlanmış desenlerin düşük kayıplarda görsel bütünlüğünün tatmin edici bulunduğu, üretilen motiflerin çevreleyen orijinal desenle uyum içerisinde olduğu gözlemlenmiştir. Bununla birlikte, çalışmanın bazı sınırlılıkları da mevcuttur. Algoritmaların performansı yüksek hasar oranlarında düşmekte, perspektif bozulması içeren desenlerde sınırlı kalmaktadır. Modellerin performansı, eksik alanların boyutu ve desenin karmaşıklığı arttıkça düşüş gösterebilmektedir. Özellikle perspektif bozulmalı veya mimari bileşen içeren karmaşık desenlerde ve %50–60 gibi yüksek oranlarda hasar söz konusu olduğunda, tamamlanan desenin kalitesinde belirgin düşüşler gözlenmiştir. Bu çalışmada oluşturulan veri seti, literatürdeki birçok deseni içerse de, verinin kapasitesi kısıtlıdır. Bu da, modelin eğitildiği veri dışında kalan desen tiplerinde genelleme performansının sınırlı olabileceği anlamına gelir. Ayrıca derin model eğitimi ve test süreçleri hesaplama gücü gerektirmesinden dolayı, bu tür bir yöntemlerin kolaylıkla uygulanabilmesi için hesaplama altyapısı da göz önünde bulundurulması gereken bir faktördür.

Bu tez çalışmasının alana sunduğu bulgular ve katkılarda, teorik olarak geleneksel desen tasarımının matematiksel ilkeleri, modern yapay zekâ modellerinin öğrenme kapasitesiyle örtüştürülerek hesaplamalı mimarlık kuramına yeni bir bakış açısı kazandırmaktadır. Tez kapsamında önerilen yöntem, mimari restorasyon alanında yeni bir metodoloji ortaya koymuştur. Geleneksel dijital desen çizim tekniklerinden farklı olarak, derin görüntü tamamlama algoritmaları kültürel miras desenlerinin onarımına uygulanmıştır. Bu yaklaşım, İslami geometrik motiflerin eksik kısımlarını otomatik tamamlamak üzere yapay zekâ

kullanımını sistematik biçimde incelemektedir. Özellikle birden fazla derin öğrenme modelinin entegre şekilde kullanıldığı bir çerçeve sunulmuştur. Bu metodolojik entegrasyon, mimarlık ve dijital koruma alanında disiplinlerarası bir yenilik olarak değerlendirilebilir. Uygulama sonuçlarını değerlendirmek için kullanılan topolojik veri analizi tabanlı ölçümleme, restorasyon kalitesini sadece piksel bazlı değil, desenin topolojik ve geometrik sürekliliği açısından da inceleyen bu yaklaşımla derin öğrenme ile üretilen desenlerde yapısal bütünlüğün korunup korunmadığı nesnel bir şekilde anlaşılabilir. Bu da gelecekte benzer çalışmalar için metodolojik bir referans niteliğindedir. Tasarımcıların zihninde veya pratiklerinde mevcut olan simetri, tekrar gibi kurallar, bu çalışma ile yapay zekâ modellerinin örtük bilgisine dönüştürülmüştür. Bir başka deyişle, mimari desenlerin görsel dili, derin öğrenme modeli tarafından öğrenilmiş ve modelin ürettiği çıktılarda yansıtılmıştır. Bu durum, kültürel mirasın soyut bilgi birikiminin korunması ve geleceğe aktarılması açısından önemli bir özgünlüktür. Yapay zekânın geleneksel sanatsal mirası yorumlayıp yeniden üretebilmesi, mimarlık tarihi ile hesaplamalı tasarım arasında yeni bir etkileşim alanı oluşturmuştur. Son olarak, elde edilen sonuçlar mimari koruma ve restorasyon pratiğine doğrudan katkı sunabilecek niteliktedir. Geliştirilen derin öğrenme tabanlı sistem, geleneksel yöntemlere kıyasla ciddi zaman tasarrufu sağlayarak eksik desenlerin tamamlanmasını mümkün kılmıştır. Uzman müdahalesini tamamen ortadan kaldırmasa da, tekrarlayan ve zahmetli desen tamamlama işlerini otomatikleştirerek uzmanların yaratıcı ve kritik kararlarına daha fazla odaklanabilmesine imkân tanımaktadır. Bu açıdan bakıldığında çalışma, sadece bir teknoloji gösterisi olmayıp yöntemsel bir katkı olarak değerlendirilmelidir. Böylece yapay zekâ, insan yaratıcılığını destekleyen ve tekrarlayan işleri üstlenen araçsal bir yardımcı rolü görmektedir.

Bu çalışmanın sonuçları, gelecekteki araştırmalar için bir temel oluşturabileceği ve aşağıdaki önerilerin, bu alandaki çalışmaları daha ileriye taşıyabileceği düşünülmektedir:

- Modellerin genelleme kabiliyetini artırmak için farklı coğrafya, dönem ve malzemeleri kapsayan daha büyük veri setleri oluşturulabilir. Ayrıca, desenlerin farklı malzeme üzerindeki görünümünü (çini üzerindeki aynı motif ile ahşap üzerindeki versiyonu gibi) içeren alt veri setleri modelin stil adaptasyonunu güçlendirebilir.
- İlerleyen çalışmalarda, 3 boyutlu yüzeylerdeki desenlerin tamamlanmasına odaklanmak özel bir genişleme alanı sağlayabilir.

- Yapay zekâ tabanlı tamamlamanın pratikte tam anlamıyla kullanılabilmesi için, çıktıların vektörel formata dönüştürülebilmesi önemli bir hedeftir. Gelecekte, doğrudan vektör üreten derin öğrenme modelleri veya mevcut modellerin çıktılarını otomatik olarak vektörize eden algoritmalar geliştirilebilir. Böylece ortaya matematiksel olarak tanımlanabilir, vektörel nitelikte bir çıktı sağlanır. Bu tür gelişmeler, dijital restorasyon ile fiziksel uygulama arasındaki boşluğu kapatarak, yapay zekâ sonuçlarının doğrudan üretime dönebilmesini sağlar.
- İnsan etkileşimli tamamlama sistemleri olarak gelecekte, yapay zekâ modellerini uzman kullanıcının görüşleriyle harmanlayan interaktif araçlar geliştirmek önem taşımaktadır.
- Derin öğrenme algoritmalarının hızını ve verimliliğini artırmak için daha optimize edilmiş modellerin tasarlanması bu alanın hızlı ilerlemesine katkıda bulunacaktır.

Bu çalışmanın sonuçları, kültürel mirasın korunması, mimarlık, sanat ve dijital restorasyon gibi alanlarda geniş bir uygulama potansiyeline sahiptir. Özellikle dijital tasarım araçlarının geliştirilmesi ve eğitim materyallerinin oluşturulması, bu metodolojinin somut faydalarından bazılarıdır.

Sonuç olarak, bu tez çalışması, derin öğrenme tabanlı görüntü tamamlama tekniklerinin İslami geometrik desenlerin dijital restorasyonunda uygulanabilirliğini ortaya koymuştur. Elde edilen sonuçlar, dijital koruma ve hesaplamalı tasarımın kesişim kümesinde geleneksel mimari motiflerin yapay zekâ vasıtasıyla yeniden üretimi ve yorumlanması olarak yeni bir bilgi alanı oluşturduğunu göstermektedir. Çalışma sayesinde, geçmişin estetik ve geometrik mirası ile günümüzün ileri hesaplama yöntemleri arasında anlamlı bir diyalog kurulmuştur. Bu diyalog sonucunda, hem teknik düzeyde (görsel kalite, yapısal tutarlılık gibi) hem de kavramsal düzeyde bulgular elde edilmiştir. Eleştirel bir perspektifle bakıldığında, yöntemin dikkatli kullanılmazsa hatalı sonuçlar üretebileceği açıktır. Ancak tez, bu risklerin farkında olarak, yapay zekânın araçsal kullanımının getirilerini vurgulamaktadır. Doğru verilerle eğitilip uzman kontrolünde kullanılan derin öğrenme modelleri, mimari restorasyon ve tasarım alanında geleneksel yöntemlere kıyasla ciddi zaman kazandırabilir, yeni seçenekler sunabilir ve insan yaratıcılığını destekleyen bir rol oynayabilir. Bu da, tekniğin yalnızca bir teknoloji gösterisi değil, aynı zamanda metodolojik bir katkı olduğunu ortaya koymaktadır. Ayrıca, İslami geometrik desenlerin eksik kısımlarını yapay zekâ ile tamamlama yolculuğunda elde edilen kazanımlar, gelecekte hem kültürel miras koruma projelerinde hem de modern tasarım uygulamalarında kullanılabilecek bir bilgi birikimi yaratmıştır. Geçmişin

ustaları tarafından yaratılmış incelikli desenlerin, dijital zekâ yardımıyla yeniden hayat bulması, kültürel süreklilik açısından umut vericidir. Çalışmanın bulguları, derin öğrenme algoritmalarının kültürel miras alanındaki potansiyelini göstermekte ve gelecekteki çalışmalar için önemli bir yol haritası sunmaktadır. Bundan sonraki çalışmalar, bu alandaki kavramsal ve pratik çerçeveyi genişleterek, mimarlık mirasının dijital çağda yaşatılmasına katkı sunmaya devam edecektir.





KAYNAKLAR

- Abas, S. J. (2001). Islamic geometrical patterns for the teaching of mathematics of symmetry. *Symmetry: Culture and Science*, 12 (1-2), 53-65.
- Abas, S. J., Salman, A. S. (1994). *Symmetries of Islamic geometrical patterns*. London, UK: World Scientific, 74-133.
- Abdullahi, Y., Embi, M. R. B. (2013). Evolution of Islamic geometric patterns. *Frontiers of Architectural Research*, 2 (2), 243-251.
- Abed jooy Divshali, A. (2022). *Generative models for multi-modality image inpainting and resolution enhancement*. Doktora Tezi, University of Ontario Institute of Technology, Oshawa, Ontario.
- Adanova, V., Tari, S. (2019). Analysis of planar ornament patterns via motif asymmetry assumption and local connections. *Journal of Mathematical Imaging and Vision*, 61 (3), 269-291.
- Afaq, S., Rao, S. (2020). Significance of epochs on training a neural network. *International Journal of Scientific and Technological Research*, 9 (06), 485-488.
- Aggarwal, C. C. (2018). *Neural networks and deep learning: A textbook*. New York, USA: Springer International Publishing, 18-47.
- Ahadian, M., Bastanfard, A. (2011a). *Classification of Islamic Geometric Pattern Images Using Zernike Moments*. 2011 Eighth International Conference Computer Graphics, Imaging and Visualization, Singapore, 19-24.
- Ahadian, M., Bastanfard, A. (2011b). *Islamic Star Pattern Images Recognition by Central Moment Invariants*. Proceedings of the International Conference on Image Processing, Computer Vision, and Pattern Recognition (IPCV), Las Vegas, USA.
- Al-Jaberi, A. (2019). *An Evaluation of Partial Differential Equations Based Digital Inpainting Algorithms*. Doktora Tezi, Mathematics and Computation, The University of Buckingham, Buckingham.
- Al Ajlouni, R. A. (2005). *Development and evaluation of a digital tool for virtual reconstruction of historic Islamic geometric patterns*. Doktora Tezi, Architecture, Texas A&M University, Texas.
- Albert, F., Gómis, J. M., Blasco, J., Valiente, J. M., Aleixos, N. (2015). A new method to analyse mosaics based on Symmetry Group theory applied to Islamic Geometric Patterns. *Computer Vision and Image Understanding*, 130, 54-70.
- Allen, D. M. (1971). Mean square error of prediction as a criterion for selecting variables. *Technometrics*, 13 (3), 469-475.
- Alpaydin, E. (2009). *Introduction to machine learning*. Cambridge: MIT press, 1-16.

- Aoulalay, A., El Makhfi, N., Abounaima, M. C., Massar, M. (2020). *Classification of Moroccan decorative patterns based on machine learning algorithms*. IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS), Kenitra, Morocco.
- Aoulalay, A., El Mhouthi, A., Massar, M. (2022). *Classification of Islamic geometric patterns based on machine learning techniques*. 2nd International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET), 1-6.
- Asaad, A. T. (2020). *Persistent homology tools for image analysis*. Doktora Tezi, Mathematics to the School of Computing, University of Buckingham.
- Asha, V., Nagabhushan, P., Bhajantri, N. U. (2012). Automatic extraction of texture-periodicity using superposition of distance matching functions and their forward differences. *Pattern Recognition Letters*, 33 (5), 629-640.
- Badrinarayanan, V., Kendall, A., Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39 (12), 2481-2495.
- Bakhsh, R. A. (2021). *Unsettling notions of “Islamic art” and the “other”: Representations of Islamic cultures in contemporary art in North America and the Middle East*. Doktora Tezi, Queen’s University, Ontario, Canada.
- Ballester, C., Bertalmio, M., Caselles, V., Sapiro, G., Verdera, J. (2001). Filling-in by joint interpolation of vector fields and gray levels. *IEEE Transactions on Image Processing*, 10 (8), 1200-1211.
- Barlow, H. B. (1989). Unsupervised learning. *Neural Computation*, 1 (3), 295-311.
- Barnes, C., Shechtman, E., Finkelstein, A., Goldman, D. B. (2009). PatchMatch: A randomized correspondence algorithm for structural image editing. *ACM Transactions on Graphics (TOG)*, 28 (3), 24.
- Belém, C., dos Santos, L. F., & Leitão, A. . (2019, June 26–28). *On the impact of machine learning: Architecture without architects?* 18th International Conference CAAD Futures 2019 : Computer-Aided Architectural Design. "Hello, Culture", June 26–28, Daejeon, Korea, 274-293.
- Berggren, J. L. (2017). *Episodes in the mathematics of medieval Islam*. New York: Springer-Verlag, 1-27.
- Bertalmio, M., Sapiro, G., Caselles, V., Ballester, C. (2000). *Image inpainting*. Proceedings of the 27th Annual Conference on Computer graphics and Interactive Techniques, New Orleans, LA, USA, 417-424.
- Bier, C. (2015). Geometry in Islamic Art. *Encyclopaedia of the History of Science, Technology, and Medicine in Non-Western Cultures*, 1-21.

- Bjorck, N., Gomes, C. P., Selman, B., Weinberger, K. Q. (2018). Understanding batch normalization. *Advances in Neural Information Processing Systems*, 31.
- Bodner, B. L. (2012). From Sultaniyeh to Tashkent scrolls: Euclidean constructions of two nine- and twelve-pointed interlocking star polygon designs. *Nexus Network Journal*, 14 (2), 307-332.
- Bodner, B. L. (2011). *A nine-and twelve-pointed star polygon design of the tashkent scrolls*. Proceedings of Bridges 2011: Mathematics, Music, Art, Architecture, Culture, Coimbra, Portugal, 147-154.
- Bonner, J. (2003). *Three traditions of self-similarity in fourteenth and fifteenth century Islamic geometric ornament*. ISAMA-Bridges Conference Proceedings, Alhambra, 1-12.
- Bonner, J. (2016). The historical significance of the geometric designs in the northeast dome chamber of the Friday Mosque at Isfahan. *Nexus Network Journal*, 18 (1), 55-103.
- Bonner, J. (2017). *Islamic geometric patterns: Their historical development and traditional methods of construction*. New York: Springer New York, 7-254.
- Bonner, J. (2018). Doing the Jitterbug with Islamic geometric patterns. *Journal of Mathematics and the Arts*, 12 (2-3), 128-143.
- Bourgoin, J. (1879). *Les éléments de l'art arabe: le trait des entrelacs*. Paris: Firmin-Didot et cie.
- Bracewell, R. N. (1989). The fourier transform. *Scientific American*, 260 (6), 86-95.
- Broug, E. (2008). *Islamic geometric patterns*. London: Thames & Hudson London, 12-107.
- Broug, E. (2013). *Islamic geometric design*. London: Thames & Hudson, 12-200.
- Burckhardt, T. (2009). *Art of Islam: language and meaning*. Bloomington, Indiana: World Wisdom, 59-66.
- Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence* (6), 679-698.
- Cao, J., Li, Y., Zhang, Q., Cui, H. (2019). Restoration of an ancient temple mural by a local search algorithm of an adaptive sample block. *Heritage Science*, 7 (1), 1-14.
- Cao, J., Zhang, Z., Zhao, A., Cui, H., Zhang, Q. (2020). Ancient mural restoration based on a modified generative adversarial network. *Heritage Science*, 8 (1), 1-14.
- Carlsson, G. (2009). Topology and data. *Bulletin of the American Mathematical Society*, 46 (2), 255-308.

- Chai, T., Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7 (3), 1247-1250.
- Chan, C. H., Kittler, J., Messer, K. (2007). *Multi-scale local binary pattern histograms for face recognition*. In International Conference on Biometrics, Heidelberg, Berlin, 809-818.
- Chan, T. F., Shen, J. (2002). Mathematical models for local nontexture inpaintings. *SIAM Journal on Applied Mathematics*, 62 (3), 1019-1043.
- Chapelle, O., Scholkopf, B., Zien, A. (2009). Semi-supervised learning *IEEE Transactions on Neural Networks*, 20 (3), 542-542.
- Chorbachi, W. a. K. (1989). In the Tower of Babel: Beyond symmetry in islamic design. *Computers & Mathematics with Applications*, 17 (4-6), 751-789.
- Creswell, A., White, T., Dumoulin, V., Arulkumaran, K., Sengupta, B., Bharath, A. A. (2018). Generative adversarial networks: An overview. *IEEE Signal Processing Magazine*, 35 (1), 53-65.
- Criminisi, A., Perez, P., Toyama, K. (2003). *Object removal by exemplar-based inpainting*. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Madison, WI, 2.
- Criminisi, A., Pérez, P., Toyama, K. (2004). Region filling and object removal by exemplar-based image inpainting. *IEEE Transactions on Image Processing*, 13 (9), 1200-1212.
- Critchlow, K. (1976). *Islamic patterns: An analytical and cosmological approach*. London: Thames and Hudson London, 70-78.
- Cromwell, P. R. (2016). Modularity and hierarchy in Persian geometric ornament. *Nexus Network Journal*, 18 (1), 7-54.
- Crump, M. J., McDonnell, J. V., Gureckis, T. M. (2013). Evaluating Amazon's Mechanical Turk as a tool for experimental behavioral research. *PloS one*, 8 (3), e57410.
- Demiriz, Y. (2017). *İslam sanatında geometrik süsleme: bir envanter denemesi*. İstanbul: Hayalperest Yayınevi (İlk baskı 2000).
- Deng, L., Yu, D. (2014). Deep learning: methods and applications. *Foundations and Trends in Signal Processing*, 7 (3-4), 197-387.
- Djibril, M. O., Hadi, Y., Thami, R. O. H. (2006). *Fundamental region based indexing and classification of islamic star pattern images*. International Conference Image Analysis and Recognition (ICIAR), Póvoa de Varzim, Portugal, 865-876.
- Djibril, M. O., Thami, R. O. H. (2008). Islamic geometrical patterns indexing and classification using discrete symmetry groups. *Journal on Computing and Cultural Heritage (JOCCH)*, 1 (2), 1-14.

- Dong, Q., Cao, C., Fu, Y. (2022). *Incremental transformer structure enhanced image inpainting with masking positional encoding*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 11358-11368.
- Drori, I., Cohen-Or, D., Yeshurun, H. (2003). Fragment-based image completion. *ACM SIGGRAPH 2003 Papers*, 303-312.
- Dumoulin, V., Visin, F. (2016). A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*.
- Edelsbrunner, H. , Morozov, D. (2012). *Persistent homology: theory and practice*. Proceedings of the European Congress of Mathematics, Zurich, 31–50.
- Efros, A. A., Leung, T. K. (1999). *Texture synthesis by non-parametric sampling*. Proceedings of the Seventh IEEE International Conference on Computer Vision, Kerkyra, Greece, 1033-1038.
- El-Said, I., El-Bouri, T., Critchlow, K. (1993). *Islamic Art and Architecture: The Systems of Geometric Design*. UK: Garnet Publishing Ltd.
- El Ouazizi, A., Nasri, A., Benslimane, R. (2015). A rotation symmetry group detection technique for the characterization of Islamic Rosette Patterns. *Pattern Recognition Letters*, 68, 111-117.
- Eskicioglu, A. M., Fisher, P. S. (1995). Image quality measures and their performance. *IEEE Transactions on Communications*, 43 (12), 2959-2965.
- Etikan, S. (2008). The use of the Kufic script, an element of Islamic ornament in Turkish Rug Art. *The Social Sciences*, 3 (2), 104-112.
- Fedorov, E. (1891). Simmetrija na ploskosti. *Zapiski Imperatorskogo Sant-Petersburgskogo Mineralogicheskogo Obshchestva*, 28, 245-291.
- Fraser, M., Kwiatkowski, W. (2006). *Ink and gold: Islamic calligraphy*. London: Paul Holberton Publishing.
- Gaganov, G. (1958). Geometricheskiy ornament Sredney Azii. *Arhitekturnoe Nasledstvo*, 11, 181-208.
- Ghiro, G. (2022). *Test-time training for image inpainting*. Yüksek Lisans Tezi, Computer Science, University of Waterloo, Kanada.
- Ghosh, M., Obaidullah, S. M., Gherardini, F., Zdimalova, M. (2021). Classification of geometric forms in mosaics using deep neural network. *J Imaging*, 7 (8), 149.
- Ghrist, R. (2008). Barcodes: the persistent topology of data. *Bulletin of the American Mathematical Society*, 45 (1), 61-75.
- Gonzalez, R. C., Woods, R. E. (2008). *Digital image processing* (Vol. 3rd edition). USA: Pearson Prentice Hall, 354-355.

- Gonzalez, V. (2001). *Beauty and Islam: Aesthetics in Islamic Art and Architecture*. London: I.B. Tauris Publishers, 85.
- Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep learning*. Cambridge, MA, USA: MIT press, 228-372.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*, 27.
- Grünbaum, B., Grünbaum, Z., Shephard, G. (1986). Symmetry in Moorish and other ornaments. *Symmetry*. New York: Elsevier, 641-653.
- Grünbaum, B., Shephard, G. C. (1987). *Tilings and patterns*. New York: W. H. Freeman and Company.
- Gupta, M. K., Chandra, P. (2020). A comprehensive survey of data mining. *International Journal of Information Technology*, 12 (4), 1243-1257.
- Haenlein, M., Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61 (4), 5-14.
- Hajebi, B., Hajebi, P. (2024). Improving recognition of deteriorated historical Persian geometric patterns by fusion decision methods. *Neural Computing and Applications*, 36 (20), 11809-11831.
- Han, J. (2022). *Deep learning for scientific data representation and generation*. Doktora Tezi, Computer Science and Engineering, University of Notre Dame.
- Hasan, K. (2023). *From Fully-Supervised Single-Task to Semi-Supervised Multi-Task Deep Learning Architectures for Segmentation in Medical Imaging Applications*. Doktora Tezi, Imaging Science, Rochester Institute of Technology
- Hastie, T., Tibshirani, R., Friedman, J., Franklin, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (Vol. 27). New York: Springer Series in Statistics.
- He, K., Zhang, X., Ren, S., Sun, J. (2016). *Deep residual learning for image recognition*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 770-778.
- Ho, J., Jain, A., Abbeel, P. (2020). Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*, 33, 6840-6851.
- Hoffman, J., Tzeng, E., Park, T., Zhu, J.-Y., Isola, P., Saenko, K., Efros, A., Darrell, T. (2018). *Cycada: Cycle-consistent adversarial domain adaptation*. International Conference on Machine Learning (ICML), Stockholm, Sweden, 1989-1998.

- Hong, X., Xiong, P., Ji, R., Fan, H. (2019). *Deep Fusion Network for Image Completion*. Proceedings of the 27th ACM International Conference on Multimedia, Nice, France, 2033-2042.
- Huang, J.-B., Kang, S. B., Ahuja, N., Kopf, J. (2014). Image completion using planar structure guidance. *ACM Transactions on Graphics*, 33 (4), 1-10.
- Iglesias, G., Talavera, E., Díaz-Álvarez, A. (2023). A survey on GANs for computer vision: Recent research, analysis and taxonomy. *Computer Science Review*, 48, 100553.
- Iizuka, S., Simo-Serra, E., Ishikawa, H. (2017). Globally and locally consistent image completion. *ACM Transactions on Graphics (TOG)*, 36 (4), 1-14.
- Ioffe, S. (2015). *Batch normalization: Accelerating deep network training by reducing internal covariate shift*. Proceedings of the 32nd International Conference on Machine Learning, France, 448–456.
- İnternet: Ali, D., Asaad, A. (2020). DAAR Topology: A software to build topological features from images (Version 1.2) [Computer software]. DAAR Topology. URL: <https://github.com/daartopology/DAAR-Topology>, Son Erişim Tarihi: 05.05.2024.
- İnternet: Belcic, I., Stryker, C. (2024). What is learning rate in machine learning? URL: https://www.ibm.com/think/topics/learning-rate?utm_source=chatgpt.com, Son Erişim Tarihi: 03.02.2025.
- İnternet: Open Source Computer Vision (2024). Canny Edge Detection. URL: https://docs.opencv.org/3.4/da/d22/tutorial_py_canny.html, Son Erişim Tarihi: 10.08.2024.
- İnternet: Song, P. (2025). What is an Epoch in Machine Learning? URL: https://mljourney.com/what-is-an-epoch-in-machine-learning/?utm_source=chatgpt.com, Son Erişim Tarihi: 22.02.2025.
- Jam, J. (2021). *Context-aware Facial Inpainting with GANs*. Doktora Tezi, Department of Computing and Mathematics, Manchester Metropolitan University.
- Jones, O. (2016). *The grammar of ornament: A visual reference of form and colour in architecture and the decorative arts*. Princeton, New Jersey: Princeton University Press (İlk baskı 1856).
- Kaplan, C. (2005). *Islamic star patterns from polygons in contact*. Proceedings of the Graphics Interface, Victoria, Canada, 177-185.
- Kaplan, C. S., Salesin, D. H. (2004). Islamic star patterns in absolute geometry. *ACM Transactions on Graphics*, 23 (2), 97–119.
- Kaplan, C. S. (2002). *Computer graphics and geometric ornamental design*. Doktora Tezi, Computer Science & Engineering, University of Washington, Washington.

- Kappraff, J. (2001). *Connections: The geometric bridge between art and science* (Vol. 25). Singapore World Scientific.
- Kasraei, M. H., Nourian, Y., Mahdavejad, M. (2016). Girih for domes: Analysis of three Iranian domes. *Nexus Network Journal*, 18 (1), 311-321.
- Ke-Chen, S., Yun-Hui, Y., Wen-Hui, C., Zhang, X. (2013). Research and perspective on local binary pattern. *Acta Automatica Sinica*, 39 (6), 730-744.
- Keller, Y., Shkolnisky, Y. (2006). A signal processing approach to symmetry detection. *IEEE Transactions on Image Processing*, 15 (8), 2198-2207.
- Keskar, N. S., Mudigere, D., Nocedal, J., Smelyanskiy, M., Tang, P. T. P. (2017). *On large-batch training for deep learning: Generalization gap and sharp minima*. Proceedings of International Conference on Learning Representations, Toulon.
- Kittler, J. (1983). On the accuracy of the Sobel edge detector. *Image and Vision Computing*, 1 (1), 37-42.
- Knight, T. W. (1998). Infinite patterns and their symmetries. *Leonardo*, 31 (4), 305-312.
- Koliji, H. (2016). Gazing Geometries: Modes of Design Thinking in Pre-Modern Central Asia and Persian Architecture. *Nexus Network Journal*, 18 (1), 105-132.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60 (6), 84-90.
- Kwatra, V., Essa, I., Bobick, A., Kwatra, N. (2005). *Texture optimization for example-based synthesis*. SIGGRAPH05: Special Interest Group on Computer Graphics and Interactive Techniques Conference, Los Angeles, California, 795-802.
- LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature*, 521 (7553), 436-444.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1 (4), 541-551.
- Lee, A. J. (1987). Islamic star patterns. *Muqarnas Online*, 4 (1), 182-197.
- Li, J., Wang, N., Zhang, L., Du, B., Tao, D. (2020). *Recurrent feature reasoning for image inpainting*. Proceedings of Conference on Computer Vision and Pattern Recognition (CVPR), 7760-7768.
- Li, L., Zou, Q., Zhang, F., Yu, H., Chen, L., Song, C., Huang, X., Wang, X. (2022). Line Drawing Guided Progressive Inpainting for Mural Damages. *ACM Journal on Computing and Cultural Heritage*, accepted 17 May 2025.

- Li, W., Lin, Z., Zhou, K., Qi, L., Wang, Y., Jia, J. (2022). *Mat: Mask-aware transformer for large hole image inpainting*. Proceedings of Conference on Computer Vision and Pattern Recognition (CVPR), 10758-10768.
- Li, X., Guo, Q., Lin, D., Li, P., Feng, W., Wang, S. (2022). *Misf: Multi-level interactive siamese filtering for high-fidelity image inpainting*. Proceedings of Conference on Computer Vision and Pattern Recognition (CVPR), 1869-1878.
- Lin, H.-C., Wang, L.-L., Yang, S.-N. (1997). Extracting periodicity of a regular texture based on autocorrelation functions. *Pattern Recognition Letters*, 18 (5), 433-443.
- Linnainmaa, S. (1970). *The representation of the cumulative rounding error of an algorithm as a Taylor expansion of the local rounding errors*. Yüksek Lisans Tezi, University of Helsinki, Helsinki.
- Liu, G., Reda, F. A., Shih, K. J., Wang, T. C., Tao, A., Catanzaro, B. (2018). *Image inpainting for irregular holes using partial convolutions*. Proceedings of the European Conference on Computer Vision (ECCV), Munich, Germany, 85-100.
- Liu, H., Jiang, B., Song, Y., Huang, W., Yang, C. (2020). *Rethinking image inpainting via a mutual encoder-decoder with feature equalizations*. ECCV: European Conference on Computer Vision, Glasgow, UK, 725-741.
- Liu, J. (2020). *Generative Adversarial Networks in Resource Constrained Environment*. Doktora Tezi, Computer Science and Engineering, University of Notre Dame.
- Liu, K., Li, J., Hussain Bukhari, S. S., Ullah, F. (2022). Overview of Image Inpainting and Forensic Technology. *Security and Communication Networks*, 2022, 1-27.
- Liu, Y., Collins, R. T., Tsin, Y. (2004). A computational model for periodic pattern perception based on frieze and wallpaper groups. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26 (3), 354-371.
- Liu, Y. (2019). *Computing Long-Term Daylighting Simulations from High Dynamic Range Imagery Using Deep Neural Networks*. Doktora Tezi, University of Washington, Ann Arbor.
- Lomov, N., Seredin, O., Kushnir, O., Liakhov, D. (2023). *Search for rotational symmetry of binary images via Radon transform and Fourier analysis*. International Joint Conference on Computer Vision, Imaging and Computer Graphics (VISIGRAPP), 280-289.
- Lugmayr, A., Danelljan, M., Romero, A., Yu, F., Timofte, R., Van Gool, L. (2022). *Repaint: Inpainting using denoising diffusion probabilistic models*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, 11461-11471.
- Maas, A. L., Hannun, A. Y., Ng, A. Y. (2013). *Rectifier Nonlinearities Improve Neural Network Acoustic Models*. In Proceedings of the 30th International Conference on Machine Learning, Atlanta, GA, USA, 3.

- Maiti, S., Kumar, A., Jain, S., Bhatnagar, G. (2021). A novel image inpainting framework using regression. *ACM Transactions on Internet Technology*, 21 (3), 62.
- Makovicky, E. (2017). On the Kond style of Islamic tiling: a study in practical Islamic geometry. *Rendiconti Lincei-Scienze Fisiche E Naturali*, 28 (1), 35-51.
- Marr, D., Hildreth, E. (1980). Theory of edge detection. *Proceedings of the Royal Society B: Biological Sciences*, 207 (1167), 187-217.
- McCulloch, W. S., Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5, 115-133.
- Michie, D., Spiegelhalter, D. J., Taylor, C. C., Campbell, J. (1994). *Machine learning, neural and statistical classification*. England: Ellis Horwood, 87-130.
- Moor, J. (2006). The Dartmouth College artificial intelligence conference: The next fifty years. *AI Magazine*, 27 (4), 87-87.
- Mostafa, M. (1979). *The Museum of Islamic Art*. Egyptian: General Egyptian Book Organization.
- Müller, E. (1944). *Gruppentheoretische und Strukturanalytische Untersuchungen der Maurischen Ornamente aus der Alhambra in Granada*. Doktora Tezi, University of Zürich.
- Nagarajan, A. (2021). *Comparative Study on Generative Adversarial Networks: DCGAN and Cycle GAN*. Yüksek Lisans Tezi, The Florida State University, Ann Arbor.
- Nair, V., Hinton, G. E. (2010). *Rectified Linear Units Improve Restricted Boltzmann Machines*. Proceedings of the 27th International Conference on Machine Learning Vancouver 807-814.
- Naeini, K. N. (2019). *Structure Guided Image Restoration a Deep Learning Approach*. Yüksek Lisans Tezi, Modelling and Computational Science, University of Ontario Institute of Technology, Oshawa, Ontario, Canada.
- Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of Big Data*, 2, 1-21.
- Naqa, İ., Li, R., Murphy, M. J. (2015). *Machine learning in radiation oncology: Theory and applications*. New York: Springer International Publishing, 5-9.
- Nasri, A., Benslimane, R. (2014). *Symmetrical motif extraction for periodic ornamental patterns*. 2014 International Conference on Multimedia Computing and Systems (ICMCS), 99-104.
- Nasri, A., Benslimane, R. (2017). Parametric shape grammar formalism for Moorish geometric design analysis and generation. *Journal on Computing and Cultural Heritage (JOCCH)*, 10 (4), 1-20.

- Nazeri, K., Ng, E., Joseph, T., Qureshi, F. Z., Ebrahimi, M. (2019). Edgeconnect: Generative image inpainting with adversarial edge learning. *arXiv preprint arXiv:1901.00212*.
- Necipoğlu, G. (1996). *The Topkapi scroll: geometry and ornament in Islamic architecture*. Los Angeles: Getty Publications, 13-150.
- Necipoğlu, G. (2017). *The Arts of Ornamental Geometry: A Persian Compendium on Similar and complementary Interlocking Figures. A Volume Commemorating Alpay Özduval*. Leiden, Netherlands: Brill Academic Publishing.
- Necipoğlu, G., Al-Asad, M. (1995). The Topkapı Scroll: Geometry and Ornament in Islamic Architecture: Topkapı Palace Museum Library MSNo Title. *Julia Bloomfield, Thomas F. Reese, Salvatore Settis, Santa Monica: Getty Center for the History of Art and the Humanities*.
- Ojala, T., Pietikäinen, M., Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29 (1), 51-59.
- Ojala, T., Pietikäinen, M., Maenpää, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24 (7), 971-987.
- Osher, S., Burger, M., Goldfarb, D., Xu, J., Yin, W. (2005). An iterative regularization method for total variation-based image restoration. *Multiscale Modeling & Simulation*, 4 (2), 460-489.
- Ostromoukhov, V. (1998). *Mathematical tools for computer-generated ornamental patterns*. International Conference on Raster Imaging and Digital Typography, St. Malo, France, 193-223.
- Özdemir, M., Selçuk, S. A., Çüngen, H. F. (2022). The geometric patterns of İzzettin Keykavus Tomb. *Nexus Network Journal*, 24 (4), 869-895.
- Özdural, A. (1996). On interlocking similar or corresponding figures and ornamental patterns of cubic equations. *Muqarnas*, 13, 191-211.
- Özdural, A. (2000). Mathematics and arts: Connections between theory and practice in the medieval Islamic world. *Historia Mathematica*, 27 (2), 171-201.
- Özgan, S. Y. (2018). *Computational Design In The Medieval Seljuk Art: Learning From The Hands-On Creative Traditions Of Geometric Patterns* Doktora Tezi, Istanbul Technical University, İstanbul.
- Özgenel, Ç. (2018). *Crack detection with deep learning: An exemplary study of data design in architecture*. Doktora Tezi, Middle East Technical University, Ankara.
- Pathak, D., Krahenbuhl, P., Donahue, J., Darrell, T., Efros, A. A. (2016). *Context Encoders: Feature Learning by Inpainting*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2536-2544.

- Pérez-Gómez, R. (1987). The four regular mosaics missing in the Alhambra. *Computers & Mathematics with Applications*, 14 (2), 133-137.
- Perez, D. (2021). *Feature extraction and design in deep learning models*. Doktora Tezi, Old Dominion University, Virginia.
- Polya, G. (1924). *Über die Analogie der Kristallsymmetrie in der Ebene*. Munich: Akademische Verlagsgesellschaft.
- Poole, D. L., Mackworth, A. K. (2010). *Artificial Intelligence: foundations of computational agents*. Cambridge: Cambridge University Press, 3-10.
- Qin, C., Schlemper, J., Caballero, J., Price, A. N., Hajnal, J. V., Rueckert, D. (2019). Convolutional Recurrent Neural Networks for Dynamic MR Image Reconstruction. *IEEE Trans Med Imaging*, 38 (1), 280-290
- Qi, X., Shen, L., Zhao, G., Li, Q., Pietikäinen, M. (2015). Globally rotation invariant multi-scale co-occurrence local binary pattern. *Image and Vision Computing*, 43, 16-26.
- Qin, Z., Zeng, Q., Zong, Y., Xu, F. (2021). Image inpainting based on deep learning: A review. *Displays*, 69, 102028.
- Qu, H., Zhou, Y., Chau, K., Mok, P. (2020,). *Repeated Pattern Extraction with Knowledge-Based Attention and Semantic Embeddings*. 14th IADIS International Conference on Computer Graphics, Visualization, Computer Vision and Image Processing, , 99-106.
- Radford, A., Metz, L., Chintala, S. (2016). *Unsupervised representation learning with deep convolutional generative adversarial networks*. Proceedings of 4th International Conference on Learning Representations, Puerto Rico.
- Rajabi, F., Khosravi, M. (2019). Formation of geometric patterns in the architectural decoration: An investigation on the Ilkhanids' period. *Tarih Kultur Ve Sanat Arastirmalari Dergisi-Journal of History Culture and Art Research*, 8 (3), 330-352.
- Ramachandran, P., Zoph, B., Le, Q. V. (2017). Searching for activation functions. *arXiv preprint arXiv:1710.05941*.
- Rasouli, P., Bastanfard, A., Rezvanian, A., Jalilian, O. (2008). *Fast Algorithms for Computer Generated Islamic Patterns of 8-ZOHREH and 8-SILI*. In Advances in Multimedia Information Processing-PCM 2008: 9th Pacific Rim Conference on Multimedia, Tainan, Taiwan, 825-829.
- Rempel, L. (1961). *Architectural ornament of Uzbekistan. History of development and construction theory*. Tashkent: State Fiction Literature Publishing House of the UzSSR.
- Ren, Y., Yu, X., Zhang, R., Li, T. H., Liu, S., Li, G. (2019). *Structureflow: Image inpainting via structure-aware appearance flow*. Proceedings of the IEEE/CVF International Conference on Computer Vision, Seoul, Korea (South), 181-190.

- Rombach, R., Blattmann, A., Lorenz, D., Esser, P., Ommer, B. (2022). *High-resolution image synthesis with latent diffusion models*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, LA, 10684-10695.
- Ronneberger, O., Fischer, P., Brox, T. (2015). *U-net: Convolutional networks for biomedical image segmentation*. Medical Image Computing and Computer Assisted Intervention (MICCAI) 18th International Conference, Munich, Germany, 234-241.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3 (3), 210-229.
- Sara, U., Akter, M., Uddin, M. S. (2019). Image quality assessment through FSIM, SSIM, MSE and PSNR—a comparative study. *Journal of Computer and Communications*, 7 (3), 8-18.
- Sarhangi, R. (2012). Interlocking Star Polygons in Persian Architecture: The Special Case of the Decagram in Mosaic Designs. *Nexus Network Journal*, 14 (2), 345-372.
- Schattschneider, D. (1978). The plane symmetry groups: their recognition and notation. *The American Mathematical Monthly*, 85 (6), 439-450.
- Setiadi, D. R. I. M. (2021). PSNR vs SSIM: imperceptibility quality assessment for image steganography. *Multimedia Tools and Applications*, 80 (6), 8423-8444.
- Shafiq, M., Gu, N. (2022). Deep residual learning for image recognition: A survey. *Applied Sciences*, 12 (18).
- Shakya, A. K., Pillai, G., Chakrabarty, S. (2023). Reinforcement learning algorithms: A brief survey. *Expert Systems with Applications*, 231, 120495.
- Sharma, S., Sharma, S., Athaiya, A. (2017). Activation functions in neural networks. *Towards Data Science*, 6 (12), 310-316.
- Shen, B., Hu, W., Zhang, Y., Zhang, Y. J. (2009). *Image inpainting via sparse representation*. IEEE International Conference on Acoustics, Speech and Signal Processing, Taipei, Taiwan, 697-700.
- Shen, Y. (2021). *The Argus FPGA-based CNN Accelerator Generator*. Doktora Tezi, Department of Computer Science, Stony Brook University, New York.
- Sibi, P., Jones, S. A., Siddarth, P. (2013). Analysis of different activation functions using back propagation neural networks. *Journal of Theoretical and Applied Information Technology*, 47 (3), 1264-1268.

- Sidorov, O., Yngve Hardeberg, J. (2019). *Deep hyperspectral prior: Single-image denoising, inpainting, super-resolution*. Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops, Seoul, Korea (South), 3844–3851.
- Simonyan, K., Zisserman, A. (2015). *Very deep convolutional networks for large-scale image recognition*. International Conference on Learning Representations, San Diego.
- Singh, S., Kumar, R., Payra, S., Singh, S. K. (2023). Artificial intelligence and machine learning in pharmacological research: bridging the gap between data and drug discovery. *Cureus*, 15 (8).
- Skains, R. L. (2018). Creative practice as research: discourse on methodology. *Media Practice and Education*, 19 (1), 82-97.
- Smith, S. L., Kindermans, P.-J., Ying, C., Le, Q. V. (2018). *Don't decay the learning rate, increase the batch size*. International Conference on Learning Representations, Vancouver, (arXiv:1711.00489).
- Song, Y., Yang, C., Shen, Y., Wang, P., Huang, Q., Kuo, C.-C. J. (2018). Spg-net: Segmentation prediction and guidance network for image inpainting. *arXiv*, arXiv:1409.1556.
- Sönmez, S. E. (2020). *Anadolu Selçuklu sanatının geometrik dili: Anadolu Selçuklu ve beylikler donemi : geometrik desen analizleri*. İstanbul: Ketebe Yayınları.
- Stierlin, H., Stierlin, A., & Klinkhamels, S. (1996). *Islam. Taschen's World Architecture*. Köln, New York: Taschen.
- Suvorov, R., Logacheva, E., Mashikhin, A., Remizova, A., Ashukha, A., Silvestrov, A., Kong, N., Goka, H., Park, K., Lempitsky, V. (2022). *Resolution-robust large mask inpainting with fourier convolutions*. Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, Waikoloa, HI, USA, 2149-2159.
- Suzuki, S. (1985). Topological structural analysis of digitized binary images by border following. *Computer Vision, Graphics and Image Processing*, 30 (1), 32-46.
- Tan, M., Le, Q. (2019). *Efficientnet: Rethinking model scaling for convolutional neural networks*. International Conference on Machine Learning (ICML), CA, USA, 6105-6114.
- Telea, A. (2004). An image inpainting technique based on the fast marching method. *Journal of Graphics Tools*, 9 (1), 23-34.
- Torfi, A. (2020). *Privacy-preserving synthetic medical data generation with deep learning*. Doktora Tezi, Computer Science and Application, Virginia Polytechnic Institute and State University, Virginia.
- Tseng, H.-Y. (2021). *Generative adversarial networks for content creation*. Doktora Tezi, Electrical Engineering and Computer Science, University of California, California.

- Wang, T. H. (2012). *Customizing Pattern-Based Tessellation for NURBS Surface Reconstruction with Irregular Boundary Conditions*. Doktora Tezi, School of Architecture College of Fine Arts, Carnegie Mellon University, Pittsburgh.
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, 49 (236), 433-460.
- Wade, D. (1976). *Pattern in Islamic art*. Woodstock, N. Y.: The Overlook Press.
- Wan, Z., Zhang, J., Chen, D., Liao, J. (2021). *High-fidelity pluralistic image completion with transformers*. Proceedings of the IEEE/CVF International Conference on Computer Vision, Montreal, BC, Canada, 4692-4701.
- Wang, Z., Bovik, A. C. (2006). Modern image quality assessment. *Synthesis Lectures on Image, Video and Multimedia Processing*, 2 (1), 1-156.
- Wang, Z., Bovik, A. C., Lu, L. (2002). *Why is image quality assessment so difficult?* IEEE International Conference on Acoustics, Speech, and Signal Processing, IV-3313-IV-3316.
- Wang, Z., Bovik, A. C., Sheikh, H. R., Simoncelli, E. P. (2004). *Image quality assessment: from error visibility to structural similarity*. IEEE Transactions on Image Processing, 600-612.
- Weyl, H. (1952). *Symmetry* (Vol. 104). Princeton, NJ, USA: Princeton University Press, 3-119.
- Wu, Q., Chen, Y., Meng, J. (2020). DCGAN-Based Data Augmentation for Tomato Leaf Disease Identification. *IEEE Access*, 8.
- Xie, C., Liu, S., Li, C., Cheng, M.-M., Zuo, W., Liu, X., Wen, S., Ding, E. (2019). *Image inpainting with learnable bidirectional attention maps*. Proceedings of the IEEE/CVF International Conference on Computer Vision, Seoul, Korea, 8858-8867.
- Xiong, W., Yu, J., Lin, Z., Yang, J., Lu, X., Barnes, C., Luo, J. (2019). *Foreground-aware image inpainting*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, CA, USA, 5840-5848.
- Xu, Z., Zhang, X., Chen, W., Yao, M., Liu, J., Xu, T., Wang, Z. (2023). A review of image inpainting methods based on deep learning. *Applied Sciences*, 13 (20), 11189.
- Yang, C., Lu, X., Lin, Z., Shechtman, E., Wang, O., Li, H. (2017). *High-resolution image inpainting using multi-scale neural patch synthesis*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 6721-6729.
- Yeh, R. A., Chen, C., Yian Lim, T., Schwing, A. G., Hasegawa-Johnson, M., Do, M. N. (2017). *Semantic image inpainting with deep generative models*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 5485-5493.

- Yu, J., Lin, Z., Yang, J., Shen, X., Lu, X., Huang, T. S. (2018). *Generative image inpainting with contextual attention*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), UT, USA, 5505-5514.
- Yu, J., Lin, Z., Yang, J., Shen, X., Lu, X., Huang, T. S. (2019). *Free-form image inpainting with gated convolution*. Proceedings of the IEEE/CVF International Conference on Computer Vision, Seoul, Korea 4471-4480.
- Yu, Y., Zhan, F., Wu, R., Pan, J., Cui, K., Lu, S., Ma, F., Xie, X., Miao, C. (2021). *Diverse image inpainting with bidirectional and autoregressive transformer*. Proceedings of the 29th ACM International Conference on Multimedia, China, 69-78.
- Zamir, S. W., Arora, A., Khan, S., Hayat, M., Khan, F. S., Yang, M.-H., Shao, L. (2021). *Multi-stage progressive image restoration*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, 14821-14831.
- Zeng, Y., Fu, J., Chao, H., Guo, B. (2019). *Learning pyramid-context encoder network for high-quality image inpainting*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, 1486-1494.
- Zeng, Y., Fu, J., Chao, H., Guo, B. (2022). *Aggregated contextual transformations for high-resolution image inpainting*. IEEE Transactions on Visualization and Computer Graphics.
- Zeng, Y., Lin, Z., Yang, J., Zhang, J., Shechtman, E., Lu, H. (2020). *High-resolution image inpainting with iterative confidence feedback and guided upsampling*. Computer Vision—ECCV 2020: 16th European Conference, Glasgow, UK, 1-17.
- Zhang, R., Isola, P., Efros, A. A., Shechtman, E., Wang, O. (2018, June 18-23). *The unreasonable effectiveness of deep features as a perceptual metric*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 18-23, Salt Lake City, Utah, 586-595.
- Zhang, X., Wang, X., Shi, C., Yan, Z., Li, X., Kong, B., Lyu, S., Zhu, B., Lv, J., Yin, Y. (2022). *De-gan: Domain embedded gan for high quality face image inpainting*. *Pattern Recognition*, 124, 108415.
- Zhao, L., Mo, Q., Lin, S., Wang, Z., Zuo, Z., Chen, H., Xing, W., Lu, D. (2020). *UCTGAN: Diverse Image Inpainting Based on Unsupervised Cross-Space Translation*. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 5740-5749.
- Zhao, S., Cui, J., Sheng, Y., Dong, Y., Liang, X., Chang, E. I., Xu, Y. (2021). *Large scale image completion via co-modulated generative adversarial networks*. International Conference on Learning Representations, Vienna.
- Zhao, Z. (2020). *Augmenting and Sampling for GAN Training and Generating Natural Adversaries*. Doktora Tezi, Computer Science, University of California, Irvine.

- Zheng, C., Cham, T.-J., Cai, J. (2019). *Pluralistic image completion*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, USA, 1438-1447.
- Zhou, Z., Liu, X., Shang, J., Huang, J., Li, Z., Jia, H. (2022). Inpainting digital Dunhuang murals with structure-guided deep network. *ACM Journal on Computing and Cultural Heritage*, 15 (4), Article 77.
- Zhou, T. (2017). *A study of generative adversarial networks and possible extensions of GANs*. Yüksek Lisans Tezi, The University of Texas at Austin.
- Zomorodian, A., Carlsson, G. (2004). *Computing Persistent Homology*. Proceedings of the Twentieth Annual Symposium on Computational Geometry, Brooklyn, New York, USA, 347-356.







EKLER

EK-1. AlexNet ađ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
conv2d (Conv2D)	(None, 35, 35, 96)	34,944
max_pooling2d (MaxPooling2D)	(None, 17, 17, 96)	0
zero_padding2d (ZeroPadding2D)	(None, 21, 21, 96)	0
conv2d_1 (Conv2D)	(None, 17, 17, 256)	614,656
max_pooling2d_1 (MaxPooling2D)	(None, 8, 8, 256)	0
conv2d_2 (Conv2D)	(None, 8, 8, 384)	885,120
conv2d_3 (Conv2D)	(None, 8, 8, 384)	1,327,488
conv2d_4 (Conv2D)	(None, 8, 8, 256)	884,992
flatten (Flatten)	(None, 16384)	0
dense (Dense)	(None, 4096)	67,112,960
dropout (Dropout)	(None, 4096)	0
dense_1 (Dense)	(None, 4096)	16,781,312
dropout_1 (Dropout)	(None, 4096)	0
dense_2 (Dense)	(None, 7)	28,679

EK-2. VGG19 ağ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
input_layer_3 (InputLayer)	(None, 224, 224, 3)	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1,792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36,928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73,856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147,584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295,168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590,080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590,080
block3_conv4 (Conv2D)	(None, 56, 56, 256)	590,080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1,180,160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2,359,808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2,359,808
block4_conv4 (Conv2D)	(None, 28, 28, 512)	2,359,808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
flatten_3 (Flatten)	(None, 25088)	0
dense_6 (Dense)	(None, 256)	6,422,784
dropout_3 (Dropout)	(None, 256)	0

EK-3. EfficientNetB3 ağ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
input_layer_6 (InputLayer)	(None,256,256,3)	0
rescaling_6 (Rescaling)	(None,256,256,3)	0
normalization_3	(None,256,256,3)	7
rescaling_7 (Rescaling)	(None,256,256,3)	0
stem_conv_pad (ZeroPadding2D)	(None,257,257,3)	0
stem_conv (Conv2D)	(None,128,128,40)	1,08
stem_bn (BatchNormalization)	(None,128,128,40)	160
stem_activation (Activation)	(None,128,128,40)	0
block1a_dwconv (DepthwiseConv2D)	(None,128,128,40)	360
block1a_bn (BatchNormalization)	(None,128,128,40)	160
block1a_activation (Activation)	(None,128,128,40)	0
block1a_se_squeeze (GlobalAveragePooling2D)	(None,40)	0
block1a_se_reshape	(None,1,1,40)	0
block1a_se_reduce (Conv2D)	(None,1,1,10)	410
block1a_se_expand (Conv2D)	(None,1,1,40)	440
block1a_se_excite (Multiply)	(None,128,128,40)	0
block1a_project_conv (Conv2D)	(None,128,128,24)	960
block1a_project_bn (BatchNormalization)	(None,128,128,24)	96
block1b_dwconv (DepthwiseConv2D)	(None,128,128,24)	216
block1b_bn (BatchNormalization)	(None,128,128,24)	96
block1b_activation (Activation)	(None,128,128,24)	0
block1b_se_squeeze (GlobalAveragePooling2D)	(None,24)	0
block1b_se_reshape (Reshape)	(None,1,1,24)	0
block1b_se_reduce (Conv2D)	(None,1,1,6)	150
block1b_se_expand (Conv2D)	(None,1,1,24)	168
block1b_se_excite (Multiply)	(None,128,128,24)	0
block1b_project_conv (Conv2D)	(None,128,128,24)	576
block1b_project_bn (BatchNormalization)	(None,128,128,24)	96
block1b_drop(Dropout)	(None,128,128,24)	0
block1b_add(Add)	(None,128,128,24)	0
block2a_expand_conv (Conv2D)	(None,128,128,144)	3,456
block2a_expand_bn (BatchNormalization)	(None,128,128,144)	576
block2a_expand_activation (Activation)	(None,128,128,144)	0
block2a_dwconv_pad (ZeroPadding2D)	(None,129,129,144)	0
block2a_dwconv (DepthwiseConv2D)	(None,64,64,144)	1,296
block2a_bn (BatchNormalization)	(None,64,64,144)	576
block2a_activation (Activation)	(None,64,64,144)	0
block2a_se_squeeze (GlobalAveragePooling2D)	(None,144)	0
block2a_se_reshape (Reshape)	(None,1,1,144)	0
block2a_se_reduce (Conv2D)	(None,1,1,6)	870
block2a_se_expand (Conv2D)	(None,1,1,144)	1,008
block2a_se_excite (Multiply)	(None,64,64,144)	0
block2a_project_conv (Conv2D)	(None,64,64,32)	4,608
block2a_project_bn (BatchNormalization)	(None,64,64,32)	128
block2b_expand_conv (Conv2D)	(None,64,64,192)	6,144

EK-3.(devam) EfficientNetB3 ağı mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
block2b_expand_bn (BatchNormalization)	(None,64,64,192)	768
block2b_expand_activation (Activation)	(None,64,64,192)	0
block2b_dwconv (DepthwiseConv2D)	(None,64,64,192)	1,728
block2b_bn (BatchNormalization)	(None,64,64,192)	768
block2b_activation (Activation)	(None,64,64,192)	0
block2b_se_squeeze (GlobalAveragePooling2D)	(None,192)	0
block2b_se_reshape (Reshape)	(None,1,1,192)	0
block2b_se_reduce (Conv2D)	(None,1,1,8)	1,544
block2b_se_expand (Conv2D)	(None,1,1,192)	1,728
block2b_se_excite (Multiply)	(None,64,64,192)	0
block2b_project_conv (Conv2D)	(None,64,64,32)	6,144
block2b_project_bn (BatchNormalization)	(None,64,64,32)	128
block2b_drop(Dropout)	(None,64,64,32)	0
block2b_add(Add)	(None,64,64,32)	0
block2c_expand_conv (Conv2D)	(None,64,64,192)	6,144
block2c_expand_bn (BatchNormalization)	(None,64,64,192)	768
block2c_expand_activation (Activation)	(None,64,64,192)	0
block2c_dwconv (DepthwiseConv2D)	(None,64,64,192)	1,728
block2c_bn (BatchNormalization)	(None,64,64,192)	768
block2c_activation (Activation)	(None,64,64,192)	0
block2c_se_squeeze (GlobalAveragePooling2D)	(None,192)	0
block2c_se_reshape (Reshape)	(None,1,1,192)	0
block2c_se_reduce (Conv2D)	(None,1,1,8)	1,544
block2c_se_expand (Conv2D)	(None,1,1,192)	1,728
block2c_se_excite (Multiply)	(None,64,64,192)	0
block2c_project_conv (Conv2D)	(None,64,64,32)	6,144
block2c_project_bn (BatchNormalization)	(None,64,64,32)	128
block2c_drop(Dropout)	(None,64,64,32)	0
block2c_add(Add)	(None,64,64,32)	0
block3a_expand_conv (Conv2D)	(None,64,64,192)	6,144
block3a_expand_bn (BatchNormalization)	(None,64,64,192)	768
block3a_expand_activation (Activation)	(None,64,64,192)	0
block3a_dwconv_pad (ZeroPadding2D)	(None,67,67,192)	0
block3a_dwconv (DepthwiseConv2D)	(None,32,32,192)	4,8
block3a_bn (BatchNormalization)	(None,32,32,192)	768
block3a_activation (Activation)	(None,32,32,192)	0
block3a_se_squeeze (GlobalAveragePooling2D)	(None,192)	0
block3a_se_reshape (Reshape)	(None,1,1,192)	0
block3a_se_reduce (Conv2D)	(None,1,1,8)	1,544
block3a_se_expand (Conv2D)	(None,1,1,192)	1,728
block3a_se_excite (Multiply)	(None,32,32,192)	0
block3a_project_conv (Conv2D)	(None,32,32,48)	9,216
block3a_project_bn (BatchNormalization)	(None,32,32,48)	192
block3b_expand_conv (Conv2D)	(None,32,32,288)	13,82
block3b_expand_bn (BatchNormalization)	(None,32,32,288)	1,152

EK-3.(devam) EfficientNetB3 ağ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
block3b_expand_activation (Activation)	(None,32,32,288)	0
block3b_dwconv (DepthwiseConv2D)	(None,32,32,288)	7,2
block3b_bn (BatchNormalization)	(None,32,32,288)	1,152
block3b_activation (Activation)	(None,32,32,288)	0
block3b_se_squeeze (GlobalAveragePooling2D)	(None,288)	0
block3b_se_reshape (Reshape)	(None,1,1,288)	0
block3b_se_reduce (Conv2D)	(None,1,1,12)	3,468
block3b_se_expand (Conv2D)	(None,1,1,288)	3,744
block3b_se_excite (Multiply)	(None,32,32,288)	0
block3b_project_conv (Conv2D)	(None,32,32,48)	13,82
block3b_project_bn (BatchNormalization)	(None,32,32,48)	192
block3b_drop(Dropout)	(None,32,32,48)	0
block3b_add(Add)	(None,32,32,48)	0
block3c_expand_conv (Conv2D)	(None,32,32,288)	13,82
block3c_expand_bn (BatchNormalization)	(None,32,32,288)	1,152
block3c_expand_activation (Activation)	(None,32,32,288)	0
block3c_dwconv (DepthwiseConv2D)	(None,32,32,288)	7,2
block3c_bn (BatchNormalization)	(None,32,32,288)	1,152
block3c_activation (Activation)	(None,32,32,288)	0
block3c_se_squeeze (GlobalAveragePooling2D)	(None,288)	0
block3c_se_reshape (Reshape)	(None,1,1,288)	0
block3c_se_reduce (Conv2D)	(None,1,1,12)	3,468
block3c_se_expand (Conv2D)	(None,1,1,288)	3,744
block3c_se_excite (Multiply)	(None,32,32,288)	0
block3c_project_conv (Conv2D)	(None,32,32,48)	13,82
block3c_project_bn (BatchNormalization)	(None,32,32,48)	192
block3c_drop(Dropout)	(None,32,32,48)	0
block3c_add(Add)	(None,32,32,48)	0
block4a_expand_conv (Conv2D)	(None,32,32,288)	13,82
block4a_expand_bn (BatchNormalization)	(None,32,32,288)	1,152
block4a_expand_activation (Activation)	(None,32,32,288)	0
block4a_dwconv_pad (ZeroPadding2D)	(None,33,33,288)	0
block4a_dwconv (DepthwiseConv2D)	(None,16,16,288)	2,592
block4a_bn (BatchNormalization)	(None,16,16,288)	1,152
block4a_activation (Activation)	(None,16,16,288)	0
block4a_se_squeeze (GlobalAveragePooling2D)	(None,288)	0
block4a_se_reshape (Reshape)	(None,1,1,288)	0
block4a_se_reduce (Conv2D)	(None,1,1,12)	3,468
block4a_se_expand (Conv2D)	(None,1,1,288)	3,744
block4a_se_excite (Multiply)	(None,16,16,288)	0
block4a_project_conv (Conv2D)	(None,16,16,96)	27,65
block4a_project_bn (BatchNormalization)	(None,16,16,96)	384
block4b_expand_conv (Conv2D)	(None,16,16,576)	55,3
block4b_expand_bn (BatchNormalization)	(None,16,16,576)	2,304
block4b_expand_activation (Activation)	(None,16,16,576)	0

EK-3.(devam) EfficientNetB3 ağı mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
block4b_dwconv (DepthwiseConv2D)	(None,16,16,576)	5,184
block4b_bn (BatchNormalization)	(None,16,16,576)	2,304
block4b_activation (Activation)	(None,16,16,576)	0
block4b_se_squeeze (GlobalAveragePooling2D)	(None,576)	0
block4b_se_reshape (Reshape)	(None,1,1,576)	0
block4b_se_reduce (Conv2D)	(None,1,1,24)	13,85
block4b_se_expand (Conv2D)	(None,1,1,576)	14,4
block4b_se_excite (Multiply)	(None,16,16,576)	0
block4b_project_conv (Conv2D)	(None,16,16,96)	55,3
block4b_project_bn (BatchNormalization)	(None,16,16,96)	384
block4b_drop(Dropout)	(None,16,16,96)	0
block4b_add(Add)	(None,16,16,96)	0
block4c_expand_conv (Conv2D)	(None,16,16,576)	55,3
block4c_expand_bn (BatchNormalization)	(None,16,16,576)	2,304
block4c_expand_activation (Activation)	(None,16,16,576)	0
block4c_dwconv (DepthwiseConv2D)	(None,16,16,576)	5,184
block4c_bn (BatchNormalization)	(None,16,16,576)	2,304
block4c_activation (Activation)	(None,16,16,576)	0
block4c_se_squeeze (GlobalAveragePooling2D)	(None,576)	0
block4c_se_reshape (Reshape)	(None,1,1,576)	0
block4c_se_reduce (Conv2D)	(None,1,1,24)	13,85
block4c_se_expand (Conv2D)	(None,1,1,576)	14,4
block4c_se_excite (Multiply)	(None,16,16,576)	0
block4c_project_conv (Conv2D)	(None,16,16,96)	55,3
block4c_project_bn (BatchNormalization)	(None,16,16,96)	384
block4c_drop(Dropout)	(None,16,16,96)	0
block4c_add(Add)	(None,16,16,96)	0
block4d_expand_conv (Conv2D)	(None,16,16,576)	55,3
block4d_expand_bn (BatchNormalization)	(None,16,16,576)	2,304
block4d_expand_activation (Activation)	(None,16,16,576)	0
block4d_dwconv (DepthwiseConv2D)	(None,16,16,576)	5,184
block4d_bn (BatchNormalization)	(None,16,16,576)	2,304
block4d_activation (Activation)	(None,16,16,576)	0
block4d_se_squeeze (GlobalAveragePooling2D)	(None,576)	0
block4d_se_reshape (Reshape)	(None,1,1,576)	0
block4d_se_reduce (Conv2D)	(None,1,1,24)	13,85
block4d_se_expand (Conv2D)	(None,1,1,576)	14,4
block4d_se_excite (Multiply)	(None,16,16,576)	0
block4d_project_conv (Conv2D)	(None,16,16,96)	55,3
block4d_project_bn (BatchNormalization)	(None,16,16,96)	384
block4d_drop(Dropout)	(None,16,16,96)	0
block4d_add(Add)	(None,16,16,96)	0
block4e_expand_conv (Conv2D)	(None,16,16,576)	55,3
block4e_expand_bn (BatchNormalization)	(None,16,16,576)	2,304
block4e_expand_activation (Activation)	(None,16,16,576)	0

EK-3.(devam) EfficientNetB3 ağ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
block4e_dwconv (DepthwiseConv2D)	(None,16,16,576)	5,184
block4e_bn (BatchNormalization)	(None,16,16,576)	2,304
block4e_activation (Activation)	(None,16,16,576)	0
block4e_se_squeeze (GlobalAveragePooling2D)	(None,576)	0
block4e_se_reshape (Reshape)	(None,1,1,576)	0
block4e_se_reduce (Conv2D)	(None,1,1,24)	13,85
block4e_se_expand (Conv2D)	(None,1,1,576)	14,4
block4e_se_excite (Multiply)	(None,16,16,576)	0
block4e_project_conv (Conv2D)	(None,16,16,96)	55,3
block4e_project_bn (BatchNormalization)	(None,16,16,96)	384
block4e_drop (Dropout)	(None,16,16,96)	0
block4e_add (Add)	(None,16,16,96)	0
block5a_expand_conv (Conv2D)	(None,16,16,576)	55,3
block5a_expand_bn (BatchNormalization)	(None,16,16,576)	2,304
block5a_expand_activation (Activation)	(None,16,16,576)	0
block5a_dwconv (DepthwiseConv2D)	(None,16,16,576)	14,4
block5a_bn (BatchNormalization)	(None,16,16,576)	2,304
block5a_activation (Activation)	(None,16,16,576)	0
block5a_se_squeeze (GlobalAveragePooling2D)	(None,576)	0
block5a_se_reshape (Reshape)	(None,1,1,576)	0
block5a_se_reduce (Conv2D)	(None,1,1,24)	13,85
block5a_se_expand (Conv2D)	(None,1,1,576)	14,4
block5a_se_excite (Multiply)	(None,16,16,576)	0
block5a_project_conv (Conv2D)	(None,16,16,136)	78,34
block5a_project_bn (BatchNormalization)	(None,16,16,136)	544
block5b_expand_conv (Conv2D)	(None,16,16,816)	111
block5b_expand_bn (BatchNormalization)	(None,16,16,816)	3,264
block5b_expand_activation (Activation)	(None,16,16,816)	0
block5b_dwconv (DepthwiseConv2D)	(None,16,16,816)	20,4
block5b_bn (BatchNormalization)	(None,16,16,816)	3,264
block5b_activation (Activation)	(None,16,16,816)	0
block5b_se_squeeze (GlobalAveragePooling2D)	(None,816)	0
block5b_se_reshape (Reshape)	(None,1,1,816)	0
block5b_se_reduce (Conv2D)	(None,1,1,34)	27,78
block5b_se_expand (Conv2D)	(None,1,1,816)	28,56
block5b_se_excite (Multiply)	(None,16,16,816)	0
block5b_project_conv (Conv2D)	(None,16,16,136)	111
block5b_project_bn (BatchNormalization)	(None,16,16,136)	544
block5b_drop (Dropout)	(None,16,16,136)	0
block5b_add (Add)	(None,16,16,136)	0
block5c_expand_conv (Conv2D)	(None,16,16,816)	111
block5c_expand_bn (BatchNormalization)	(None,16,16,816)	3,264
block5c_expand_activation (Activation)	(None,16,16,816)	0
block5c_dwconv (DepthwiseConv2D)	(None,16,16,816)	20,4
block5c_bn (BatchNormalization)	(None,16,16,816)	3,264

EK-3.(devam) EfficientNetB3 ağ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
block5c_activation (Activation)	(None,16,16,816)	0
block5c_se_squeeze (GlobalAveragePooling2D)	(None,816)	0
block5c_se_reshape (Reshape)	(None,1,1,816)	0
block5c_se_reduce (Conv2D)	(None,1,1,34)	27,78
block5c_se_expand (Conv2D)	(None,1,1,816)	28,56
block5c_se_excite (Multiply)	(None,16,16,816)	0
block5c_project_conv (Conv2D)	(None,16,16,136)	111
block5c_project_bn (BatchNormalization)	(None,16,16,136)	544
block5c_drop(Dropout)	(None,16,16,136)	0
block5c_add(Add)	(None,16,16,136)	0
block5d_expand_conv (Conv2D)	(None,16,16,816)	111
block5d_expand_bn (BatchNormalization)	(None,16,16,816)	3,264
block5d_expand_activation (Activation)	(None,16,16,816)	0
block5d_dwconv (DepthwiseConv2D)	(None,16,16,816)	20,4
block5d_bn (BatchNormalization)	(None,16,16,816)	3,264
block5d_activation (Activation)	(None,16,16,816)	0
block5d_se_squeeze (GlobalAveragePooling2D)	(None,816)	0
block5d_se_reshape (Reshape)	(None,1,1,816)	0
block5d_se_reduce (Conv2D)	(None,1,1,34)	27,78
block5d_se_expand (Conv2D)	(None,1,1,816)	28,56
block5d_se_excite (Multiply)	(None,16,16,816)	0
block5d_project_conv (Conv2D)	(None,16,16,136)	111
block5d_project_bn (BatchNormalization)	(None,16,16,136)	544
block5d_drop(Dropout)	(None,16,16,136)	0
block5d_add(Add)	(None,16,16,136)	0
block5e_expand_conv (Conv2D)	(None,16,16,816)	111
block5e_expand_bn (BatchNormalization)	(None,16,16,816)	3,264
block5e_expand_activation (Activation)	(None,16,16,816)	0
block5e_dwconv (DepthwiseConv2D)	(None,16,16,816)	20,4
block5e_bn (BatchNormalization)	(None,16,16,816)	3,264
block5e_activation (Activation)	(None,16,16,816)	0
block5e_se_squeeze (GlobalAveragePooling2D)	(None,816)	0
block5e_se_reshape (Reshape)	(None,1,1,816)	0
block5e_se_reduce (Conv2D)	(None,1,1,34)	27,78
block5e_se_expand (Conv2D)	(None,1,1,816)	28,56
block5e_se_excite (Multiply)	(None,16,16,816)	0
block5e_project_conv (Conv2D)	(None,16,16,136)	111
block5e_project_bn (BatchNormalization)	(None,16,16,136)	544
block5e_drop(Dropout)	(None,16,16,136)	0
block5e_add(Add)	(None,16,16,136)	0
block6a_expand_conv (Conv2D)	(None,16,16,816)	111
block6a_expand_bn (BatchNormalization)	(None,16,16,816)	3,264
block6a_expand_activation (Activation)	(None,16,16,816)	0
block6a_dwconv_pad (ZeroPadding2D)	(None,19,19,816)	0
block6a_dwconv (DepthwiseConv2D)	(None,8,8,816)	20,4

EK-3.(devam) EfficientNetB3 ağ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
block6a_bn (BatchNormalization)	(None,8,8,816)	3,264
block6a_activation (Activation)	(None,8,8,816)	0
block6a_se_squeeze (GlobalAveragePooling2D)	(None,816)	0
block6a_se_reshape (Reshape)	(None,1,1,816)	0
block6a_se_reduce (Conv2D)	(None,1,1,34)	27,78
block6a_se_expand (Conv2D)	(None,1,1,816)	28,56
block6a_se_excite (Multiply)	(None,8,8,816)	0
block6a_project_conv (Conv2D)	(None,8,8,232)	189,3
block6a_project_bn (BatchNormalization)	(None,8,8,232)	928
block6b_expand_conv (Conv2D)	(None,8,8,1392)	322,9
block6b_expand_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6b_expand_activation (Activation)	(None,8,8,1392)	0
block6b_dwconv (DepthwiseConv2D)	(None,8,8,1392)	34,8
block6b_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6b_activation (Activation)	(None,8,8,1392)	0
block6b_se_squeeze (GlobalAveragePooling2D)	(None,1392)	0
block6b_se_reshape (Reshape)	(None,1,1,1392)	0
block6b_se_reduce (Conv2D)	(None,1,1,58)	80,79
block6b_se_expand (Conv2D)	(None,1,1,1392)	82,13
block6b_se_excite (Multiply)	(None,8,8,1392)	0
block6b_project_conv (Conv2D)	(None,8,8,232)	322,9
block6b_project_bn (BatchNormalization)	(None,8,8,232)	928
block6b_drop(Dropout)	(None,8,8,232)	0
block6b_add(Add)	(None,8,8,232)	0
block6c_expand_conv (Conv2D)	(None,8,8,1392)	322,9
block6c_expand_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6c_expand_activation	(None,8,8,1392)	0
block6c_dwconv (DepthwiseConv2D)	(None,8,8,1392)	34,8
block6c_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6c_activation (Activation)	(None,8,8,1392)	0
block6c_se_squeeze (GlobalAveragePooling2D)	(None,1392)	0
block6c_se_reshape (Reshape)	(None,1,1,1392)	0
block6c_se_reduce (Conv2D)	(None,1,1,58)	80,79
block6c_se_expand (Conv2D)	(None,1,1,1392)	82,13
block6c_se_excite (Multiply)	(None,8,8,1392)	0
block6c_project_conv (Conv2D)	(None,8,8,232)	322,9
block6c_project_bn (BatchNormalization)	(None,8,8,232)	928
block6c_drop(Dropout)	(None,8,8,232)	0
block6c_add(Add)	(None,8,8,232)	0
block6d_expand_conv (Conv2D)	(None,8,8,1392)	322,9
block6d_expand_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6d_expand_activation (Activation)	(None,8,8,1392)	0
block6d_dwconv (DepthwiseConv2D)	(None,8,8,1392)	34,8
block6d_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6d_activation (Activation)	(None,8,8,1392)	0

EK-3.(devam) EfficientNetB3 ağ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
block6d_se_squeeze (GlobalAveragePooling2D)	(None,1392)	0
block6d_se_reshape (Reshape)	(None,1,1,1392)	0
block6d_se_reduce (Conv2D)	(None,1,1,58)	80,79
block6d_se_expand (Conv2D)	(None,1,1,1392)	82,13
block6d_se_excite (Multiply)	(None,8,8,1392)	0
block6d_project_conv (Conv2D)	(None,8,8,232)	322,9
block6d_project_bn (BatchNormalization)	(None,8,8,232)	928
block6d_drop(Dropout)	(None,8,8,232)	0
block6d_add(Add)	(None,8,8,232)	0
block6e_expand_conv (Conv2D)	(None,8,8,1392)	322,9
block6e_expand_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6e_expand_activation (Activation)	(None,8,8,1392)	0
block6e_dwconv (DepthwiseConv2D)	(None,8,8,1392)	34,8
block6e_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6e_activation (Activation)	(None,8,8,1392)	0
block6e_se_squeeze (GlobalAveragePooling2D)	(None,1392)	0
block6e_se_reshape (Reshape)	(None,1,1,1392)	0
block6e_se_reduce (Conv2D)	(None,1,1,58)	80,79
block6e_se_expand (Conv2D)	(None,1,1,1392)	82,13
block6e_se_excite (Multiply)	(None,8,8,1392)	0
block6e_project_conv (Conv2D)	(None,8,8,232)	322,9
block6e_project_bn (BatchNormalization)	(None,8,8,232)	928
block6e_drop(Dropout)	(None,8,8,232)	0
block6e_add(Add)	(None,8,8,232)	0
block6f_expand_conv (Conv2D)	(None,8,8,1392)	322,9
block6f_expand_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6f_expand_activation (Activation)	(None,8,8,1392)	0
block6f_dwconv (DepthwiseConv2D)	(None,8,8,1392)	34,8
block6f_bn (BatchNormalization)	(None,8,8,1392)	5,568
block6f_activation (Activation)	(None,8,8,1392)	0
block6f_se_squeeze (GlobalAveragePooling2D)	(None,1392)	0
block6f_se_reshape (Reshape)	(None,1,1,1392)	0
block6f_se_reduce (Conv2D)	(None,1,1,58)	80,79
block6f_se_expand (Conv2D)	(None,1,1,1392)	82,13
block6f_se_excite (Multiply)	(None,8,8,1392)	0
block6f_project_conv (Conv2D)	(None,8,8,232)	322,9
block6f_project_bn (BatchNormalization)	(None,8,8,232)	928
block6f_drop(Dropout)	(None,8,8,232)	0
block6f_add(Add)	(None,8,8,232)	0
block7a_expand_conv (Conv2D)	(None,8,8,1392)	322,9
block7a_expand_bn (BatchNormalization)	(None,8,8,1392)	5,568
block7a_expand_activation (Activation)	(None,8,8,1392)	0
block7a_dwconv (DepthwiseConv2D)	(None,8,8,1392)	12,53
block7a_bn (BatchNormalization)	(None,8,8,1392)	5,568
block7a_activation (Activation)	(None,8,8,1392)	0

EK-3.(devam) EfficientNetB3 ağ mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
block7a_se_squeeze (GlobalAveragePooling2D)	(None,1392)	0
block7a_se_reshape (Reshape)	(None,1,1,1392)	0
block7a_se_reduce (Conv2D)	(None,1,1,58)	80,79
block7a_se_expand (Conv2D)	(None,1,1,1392)	82,13
block7a_se_excite (Multiply)	(None,8,8,1392)	0
block7a_project_conv (Conv2D)	(None,8,8,384)	534,5
block7a_project_bn (BatchNormalization)	(None,8,8,384)	1,536
block7b_expand_conv (Conv2D)	(None,8,8,2304)	884,7
block7b_expand_bn (BatchNormalization)	(None,8,8,2304)	9,216
block7b_expand_activation (Activation)	(None,8,8,2304)	0
block7b_dwconv (DepthwiseConv2D)	(None,8,8,2304)	20,74
block7b_bn (BatchNormalization)	(None,8,8,2304)	9,216
block7b_activation (Activation)	(None,8,8,2304)	0
block7b_se_squeeze (GlobalAveragePooling2D)	(None,2304)	0
block7b_se_reshape	(None,1,1,2304)	0

EK-4. Resnet50 ağı mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
input_layer	(None, 224, 224, 3)	0
conv1_pad	(None, 230, 230, 3)	0
conv1_conv	(None, 112, 112, 64)	9,472
conv1_bn (BatchNormalization)	(None, 112, 112, 64)	256
conv1_relu	(None, 112, 112, 64)	0
pool1_pad	(None, 114, 114, 64)	0
pool1_pool	(None, 56, 56, 64)	0
conv2_block1_1_conv (Conv2D)	(None, 56, 56, 64)	4,16
conv2_block1_1_bn (BatchNormalization)	(None, 56, 56, 64)	256
conv2_block1_1_relu (Activation)	(None, 56, 56, 64)	0
conv2_block1_2_conv (Conv2D)	(None, 56, 56, 64)	36,928
conv2_block1_2_bn (BatchNormalization)	(None, 56, 56, 64)	256
conv2_block1_2_relu (Activation)	(None, 56, 56, 64)	0
conv2_block1_0_conv (Conv2D)	(None, 56, 56, 256)	16,64
conv2_block1_3_conv (Conv2D)	(None, 56, 56, 256)	16,64
conv2_block1_0_bn (BatchNormalization)	(None, 56, 56, 256)	1,024
conv2_block1_3_bn (BatchNormalization)	(None, 56, 56, 256)	1,024
conv2_block1_add	(None, 56, 56, 256)	0
conv2_block1_out (Activation)	(None, 56, 56, 256)	0
conv2_block2_1_conv (Conv2D)	(None, 56, 56, 64)	16,448
conv2_block2_1_bn (BatchNormalization)	(None, 56, 56, 64)	256
conv2_block2_1_relu (Activation)	(None, 56, 56, 64)	0
conv2_block2_2_conv (Conv2D)	(None, 56, 56, 64)	36,928
conv2_block2_2_bn (BatchNormalization)	(None, 56, 56, 64)	256
conv2_block2_2_relu (Activation)	(None, 56, 56, 64)	0
conv2_block2_3_conv (Conv2D)	(None, 56, 56, 256)	16,64
conv2_block2_3_bn (BatchNormalization)	(None, 56, 56, 256)	1,024
conv2_block2_add	(None, 56, 56, 256)	0
conv2_block2_out (Activation)	(None, 56, 56, 256)	0
conv2_block3_1_conv (Conv2D)	(None, 56, 56, 64)	16,448
conv2_block3_1_bn (BatchNormalization)	(None, 56, 56, 64)	256
conv2_block3_1_relu (Activation)	(None, 56, 56, 64)	0
conv2_block3_2_conv (Conv2D)	(None, 56, 56, 64)	36,928
conv2_block3_2_bn (BatchNormalization)	(None, 56, 56, 64)	256
conv2_block3_2_relu (Activation)	(None, 56, 56, 64)	0
conv2_block3_3_conv (Conv2D)	(None, 56, 56, 256)	16,64
conv2_block3_3_bn (BatchNormalization)	(None, 56, 56, 256)	1,024
conv2_block3_add	(None, 56, 56, 256)	0
conv2_block3_out (Activation)	(None, 56, 56, 256)	0
conv3_block1_1_conv (Conv2D)	(None, 28, 28, 128)	32,896
conv3_block1_1_bn (BatchNormalization)	(None, 28, 28, 128)	512
conv3_block1_1_relu (Activation)	(None, 28, 28, 128)	0
conv3_block1_2_conv (Conv2D)	(None, 28, 28, 128)	147,584
conv3_block1_2_bn (BatchNormalization)	(None, 28, 28, 128)	512

EK-4. (devam) Resnet50 ağı mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
conv3_block1_2_relu (Activation)	(None, 28, 28, 128)	0
conv3_block1_0_conv (Conv2D)	(None, 28, 28, 512)	131,584
conv3_block1_3_conv (Conv2D)	(None, 28, 28, 512)	66,048
conv3_block1_0_bn (BatchNormalization)	(None, 28, 28, 512)	2,048
conv3_block1_3_bn (BatchNormalization)	(None, 28, 28, 512)	2,048
conv3_block1_add	(None, 28, 28, 512)	0
conv3_block1_out (Activation)	(None, 28, 28, 512)	0
conv3_block2_1_conv (Conv2D)	(None, 28, 28, 128)	65,664
conv3_block2_1_bn (BatchNormalization)	(None, 28, 28, 128)	512
conv3_block2_1_relu (Activation)	(None, 28, 28, 128)	0
conv3_block2_2_conv (Conv2D)	(None, 28, 28, 128)	147,584
conv3_block2_2_bn (BatchNormalization)	(None, 28, 28, 128)	512
conv3_block2_2_relu (Activation)	(None, 28, 28, 128)	0
conv3_block2_3_conv (Conv2D)	(None, 28, 28, 512)	66,048
conv3_block2_3_bn (BatchNormalization)	(None, 28, 28, 512)	2,048
conv3_block2_add	(None, 28, 28, 512)	0
conv3_block2_out (Activation)	(None, 28, 28, 512)	0
conv3_block3_1_conv (Conv2D)	(None, 28, 28, 128)	65,664
conv3_block3_1_bn (BatchNormalization)	(None, 28, 28, 128)	512
conv3_block3_1_relu (Activation)	(None, 28, 28, 128)	0
conv3_block3_2_conv (Conv2D)	(None, 28, 28, 128)	147,584
conv3_block3_2_bn (BatchNormalization)	(None, 28, 28, 128)	512
conv3_block3_2_relu (Activation)	(None, 28, 28, 128)	0
conv3_block3_3_conv (Conv2D)	(None, 28, 28, 512)	66,048
conv3_block3_3_bn (BatchNormalization)	(None, 28, 28, 512)	2,048
conv3_block3_add	(None, 28, 28, 512)	0
conv3_block3_out (Activation)	(None, 28, 28, 512)	0
conv3_block4_1_conv (Conv2D)	(None, 28, 28, 128)	65,664
conv3_block4_1_bn (BatchNormalization)	(None, 28, 28, 128)	512
conv3_block4_1_relu (Activation)	(None, 28, 28, 128)	0
conv3_block4_2_conv (Conv2D)	(None, 28, 28, 128)	147,584
conv3_block4_2_bn (BatchNormalization)	(None, 28, 28, 128)	512
conv3_block4_2_relu (Activation)	(None, 28, 28, 128)	0
conv3_block4_3_conv (Conv2D)	(None, 28, 28, 512)	66,048
conv3_block4_3_bn (BatchNormalization)	(None, 28, 28, 512)	2,048
conv3_block4_add	(None, 28, 28, 512)	0
conv3_block4_out (Activation)	(None, 28, 28, 512)	0
conv4_block1_1_conv (Conv2D)	(None, 14, 14, 256)	131,328
conv4_block1_1_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block1_1_relu (Activation)	(None, 14, 14, 256)	0
conv4_block1_2_conv (Conv2D)	(None, 14, 14, 256)	590,08
conv4_block1_2_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block1_2_relu (Activation)	(None, 14, 14, 256)	0
conv4_block1_0_conv (Conv2D)	(None, 14, 14, 1024)	525,312

EK-4. (devam) Resnet50 ağı mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
conv4_block1_3_conv (Conv2D)	(None, 14, 14, 1024)	263,168
conv4_block1_0_bn (BatchNormalization)	(None, 14, 14, 1024)	4,096
conv4_block1_3_bn (BatchNormalization)	(None, 14, 14, 1024)	4,096
conv4_block1_add	(None, 14, 14, 1024)	0
conv4_block1_out (Activation)	(None, 14, 14, 1024)	0
conv4_block2_1_conv (Conv2D)	(None, 14, 14, 256)	262,4
conv4_block2_1_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block2_1_relu (Activation)	(None, 14, 14, 256)	0
conv4_block2_2_conv (Conv2D)	(None, 14, 14, 256)	590,08
conv4_block2_2_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block2_2_relu (Activation)	(None, 14, 14, 256)	0
conv4_block2_3_conv (Conv2D)	(None, 14, 14, 1024)	263,168
conv4_block2_3_bn (BatchNormalization)	(None, 14, 14, 1024)	4,096
conv4_block2_add	(None, 14, 14, 1024)	0
conv4_block2_out (Activation)	(None, 14, 14, 1024)	0
conv4_block3_1_conv (Conv2D)	(None, 14, 14, 256)	262,4
conv4_block3_1_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block3_1_relu (Activation)	(None, 14, 14, 256)	0
conv4_block3_2_conv (Conv2D)	(None, 14, 14, 256)	590,08
conv4_block3_2_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block3_2_relu (Activation)	(None, 14, 14, 256)	0
conv4_block3_3_conv (Conv2D)	(None, 14, 14, 1024)	263,168
conv4_block3_3_bn (BatchNormalization)	(None, 14, 14, 1024)	4,096
conv4_block3_add	(None, 14, 14, 1024)	0
conv4_block3_out (Activation)	(None, 14, 14, 1024)	0
conv4_block4_1_conv (Conv2D)	(None, 14, 14, 256)	262,4
conv4_block4_1_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block4_1_relu (Activation)	(None, 14, 14, 256)	0
conv4_block4_2_conv (Conv2D)	(None, 14, 14, 256)	590,08
conv4_block4_2_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block4_2_relu (Activation)	(None, 14, 14, 256)	0
conv4_block4_3_conv (Conv2D)	(None, 14, 14, 1024)	263,168
conv4_block4_3_bn (BatchNormalization)	(None, 14, 14, 1024)	4,096
conv4_block4_add	(None, 14, 14, 1024)	0
conv4_block4_out (Activation)	(None, 14, 14, 1024)	0
conv4_block5_1_conv (Conv2D)	(None, 14, 14, 256)	262,4
conv4_block5_1_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block5_1_relu (Activation)	(None, 14, 14, 256)	0
conv4_block5_2_conv (Conv2D)	(None, 14, 14, 256)	590,08
conv4_block5_2_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block5_2_relu (Activation)	(None, 14, 14, 256)	0
conv4_block5_3_conv (Conv2D)	(None, 14, 14, 1024)	263,168
conv4_block5_3_bn (BatchNormalization)	(None, 14, 14, 1024)	4,096
conv4_block5_add	(None, 14, 14, 1024)	0

EK-4. (devam) Resnet50 ağı mimarisi

Katman Türü	Çıkış Boyutu	Parametre Sayısı
conv4_block5_out (Activation)	(None, 14, 14, 1024)	0
conv4_block6_1_conv (Conv2D)	(None, 14, 14, 256)	262,4
conv4_block6_1_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block6_1_relu (Activation)	(None, 14, 14, 256)	0
conv4_block6_2_conv (Conv2D)	(None, 14, 14, 256)	590,08
conv4_block6_2_bn (BatchNormalization)	(None, 14, 14, 256)	1,024
conv4_block6_2_relu (Activation)	(None, 14, 14, 256)	0
conv4_block6_3_conv (Conv2D)	(None, 14, 14, 1024)	263,168
conv4_block6_3_bn (BatchNormalization)	(None, 14, 14, 1024)	4,096
conv4_block6_add	(None, 14, 14, 1024)	0
conv4_block6_out (Activation)	(None, 14, 14, 1024)	0
conv5_block1_1_conv (Conv2D)	(None, 7, 7, 512)	524,8
conv5_block1_1_bn (BatchNormalization)	(None, 7, 7, 512)	2,048
conv5_block1_1_relu (Activation)	(None, 7, 7, 512)	0
conv5_block1_2_conv (Conv2D)	(None, 7, 7, 512)	2,359,808
conv5_block1_2_bn (BatchNormalization)	(None, 7, 7, 512)	2,048
conv5_block1_2_relu (Activation)	(None, 7, 7, 512)	0
conv5_block1_0_conv (Conv2D)	(None, 7, 7, 2048)	2,099,200
conv5_block1_3_conv (Conv2D)	(None, 7, 7, 2048)	1,050,624
conv5_block1_0_bn (BatchNormalization)	(None, 7, 7, 2048)	8,192
conv5_block1_3_bn (BatchNormalization)	(None, 7, 7, 2048)	8,192
conv5_block1_add	(None, 7, 7, 2048)	0
conv5_block1_out (Activation)	(None, 7, 7, 2048)	0
conv5_block2_1_conv (Conv2D)	(None, 7, 7, 512)	1,049,088
conv5_block2_1_bn (BatchNormalization)	(None, 7, 7, 512)	2,048
conv5_block2_1_relu (Activation)	(None, 7, 7, 512)	0
conv5_block2_2_conv (Conv2D)	(None, 7, 7, 512)	2,359,808
conv5_block2_2_bn (BatchNormalization)	(None, 7, 7, 512)	2,048
conv5_block2_2_relu (Activation)	(None, 7, 7, 512)	0
conv5_block2_3_conv (Conv2D)	(None, 7, 7, 2048)	1,050,624
conv5_block2_3_bn (BatchNormalization)	(None, 7, 7, 2048)	8,192
conv5_block2_add	(None, 7, 7, 2048)	0
conv5_block2_out (Activation)	(None, 7, 7, 2048)	0
conv5_block3_1_conv (Conv2D)	(None, 7, 7, 512)	1,049,088
conv5_block3_1_bn (BatchNormalization)	(None, 7, 7, 512)	2,048
conv5_block3_1_relu (Activation)	(None, 7, 7, 512)	0
conv5_block3_2_conv (Conv2D)	(None, 7, 7, 512)	2,359,808
conv5_block3_2_bn (BatchNormalization)	(None, 7, 7, 512)	2,048
conv5_block3_2_relu (Activation)	(None, 7, 7, 512)	0
conv5_block3_3_conv (Conv2D)	(None, 7, 7, 2048)	1,050,624
conv5_block3_3_bn (BatchNormalization)	(None, 7, 7, 2048)	8,192
conv5_block3_add	(None, 7, 7, 2048)	0
conv5_block3_out (Activation)	(None, 7, 7, 2048)	0
avg_pool (GlobalAveragePooling2D)	(None, 2048)	0
predictions (Dense)	(None, 10)	20,49

EK-5. DCGAN ağ mimarisi

Generator Model Özeti

Katman Türü	Giriş Boyutu	Çıkış Boyutu	Parametre Sayısı	Aktivasyon
Dense	(100,)	(4×4×256)	409600	ReLU
Reshape	(4096,)	(4, 4, 256)	0	-
UpSampling2D	(4, 4, 256)	(8, 8, 256)	0	-
Conv2D	(8, 8, 256)	(8, 8, 256)	590080	-
BatchNormalization	(8, 8, 256)	(8, 8, 256)	1024	-
ReLU	-	-	0	ReLU
UpSampling2D	(8, 8, 256)	(16, 16, 256)	0	-
Conv2D	(16, 16, 256)	(16, 16, 256)	590080	-
BatchNormalization	(16, 16, 256)	(16, 16, 256)	1024	-
ReLU	-	-	0	ReLU
UpSampling2D	(16, 16, 256)	(32, 32, 256)	0	-
Conv2D	(32, 32, 256)	(32, 32, 128)	295040	-
BatchNormalization	(32, 32, 128)	(32, 32, 128)	512	-
ReLU	-	-	0	ReLU
UpSampling2D	(32, 32, 128)	(96, 96, 128)	0	-
Conv2D	(96, 96, 128)	(96, 96, 128)	147584	-
BatchNormalization	(96, 96, 128)	(96, 96, 128)	512	-
ReLU	-	-	0	ReLU
Conv2D	(96, 96, 128)	(96, 96, 3)	3459	tanh

Discriminator Model Özeti

Katman Türü	Giriş Boyutu	Çıkış Boyutu	Parametre Sayısı	Aktivasyon
Conv2D	(96, 96, 3)	(48, 48, 32)	896	LeakyReLU(0.2)
Dropout	(48, 48, 32)	(48, 48, 32)	0	-
Conv2D	(48, 48, 32)	(24, 24, 64)	18496	LeakyReLU(0.2)
ZeroPadding2D	(24, 24, 64)	(25, 25, 64)	0	-
BatchNormalization	(25, 25, 64)	(25, 25, 64)	256	-
Dropout	(25, 25, 64)	(25, 25, 64)	0	-
Conv2D	(25, 25, 64)	(13, 13, 128)	73856	LeakyReLU(0.2)
BatchNormalization	(13, 13, 128)	(13, 13, 128)	512	-
Dropout	(13, 13, 128)	(13, 13, 128)	0	-
Conv2D	(13, 13, 128)	(13, 13, 256)	295168	LeakyReLU(0.2)
BatchNormalization	(13, 13, 256)	(13, 13, 256)	1024	-
Dropout	(13, 13, 256)	(13, 13, 256)	0	-
Conv2D	(13, 13, 256)	(13, 13, 512)	1180160	LeakyReLU(0.2)
BatchNormalization	(13, 13, 512)	(13, 13, 512)	2048	-
Dropout	(13, 13, 512)	(13, 13, 512)	0	-
Flatten	(13, 13, 512)	(86528,)	0	-
Dense	(86528,)	(1,)	86529	sigmoid

EK-6. Kenar bağlantı algoritması ağ mimarisi

InpaintGenerator		
Katman Türü	Çıkış Boyutu	Parametre Sayısı
ReflectionPad2d	(None, 4, 258, 258)	0
Conv2d	(None, 64, 252, 252)	12608
InstanceNorm2d	(None, 64, 252, 252)	128
ReLU	(None, 64, 252, 252)	0
Conv2d	(None, 128, 126, 126)	131200
InstanceNorm2d	(None, 128, 126, 126)	256
ReLU	(None, 128, 126, 126)	0
Conv2d	(None, 256, 63, 63)	524544
InstanceNorm2d	(None, 256, 63, 63)	512
ReLU	(None, 256, 63, 63)	0
ResnetBlock	(None, 256, 63, 63)	0
ConvTranspose2d	(None, 128, 126, 126)	524416
InstanceNorm2d	(None, 128, 126, 126)	256
ReLU	(None, 128, 126, 126)	0
ConvTranspose2d	(None, 64, 252, 252)	131136
InstanceNorm2d	(None, 64, 252, 252)	128
ReLU	(None, 64, 252, 252)	0
ReflectionPad2d	(None, 64, 258, 258)	0
Conv2d	(None, 3, 252, 252)	9411

EdgeGenerator		
Katman Türü	Çıkış Boyutu	Parametre Sayısı
ReflectionPad2d	(None, 3, 258, 258)	0
Conv2d	(None, 64, 252, 252)	9472
InstanceNorm2d	(None, 64, 252, 252)	128
ReLU	(None, 64, 252, 252)	0
Conv2d	(None, 128, 126, 126)	131200
InstanceNorm2d	(None, 128, 126, 126)	256
ReLU	(None, 128, 126, 126)	0
Conv2d	(None, 256, 63, 63)	524544
InstanceNorm2d	(None, 256, 63, 63)	512
ReLU	(None, 256, 63, 63)	0
ResnetBlock	(None, 256, 63, 63)	0
ConvTranspose2d	(None, 128, 126, 126)	524416
InstanceNorm2d	(None, 128, 126, 126)	256
ReLU	(None, 128, 126, 126)	0
ConvTranspose2d	(None, 64, 252, 252)	131136
InstanceNorm2d	(None, 64, 252, 252)	128
ReLU	(None, 64, 252, 252)	0
ReflectionPad2d	(None, 64, 258, 258)	0
Conv2d	(None, 1, 252, 252)	3137

EK-6. (devam) Kenar bağlantı algoritması ağ mimarisi

Discriminator		
Katman Türü	Çıkış Boyutu	Parametre Sayısı
Conv2d	(None, 64, 127, 127)	3136
LeakyReLU	(None, 64, 127, 127)	0
Conv2d	(None, 128, 63, 63)	131200
LeakyReLU	(None, 128, 63, 63)	0
Conv2d	(None, 256, 31, 31)	524544
LeakyReLU	(None, 256, 31, 31)	0
Conv2d	(None, 512, 30, 30)	2097664
LeakyReLU	(None, 512, 30, 30)	0
Conv2d	(None, 1, 29, 29)	8193
ResnetBlock		
Katman Türü	Çıkış Boyutu	Parametre Sayısı
ReflectionPad2d	(None, 256, 65, 65)	0
Conv2d	(None, 256, 63, 63)	590080
InstanceNorm2d	(None, 256, 63, 63)	512
ReLU	(None, 256, 63, 63)	0
ReflectionPad2d	(None, 256, 65, 65)	0
Conv2d	(None, 256, 63, 63)	590080
InstanceNorm2d	(None, 256, 63, 63)	512

EK-7. Derin Füzyon ağı ile görüntü restorasyonu DfNet ağ mimarisi

Katman Adı	Katman Türü	Giriş Boyutu	Çıkış Boyutu	Parametre Sayısı	Kullanılan Normalizasyon	Kullanılan Aktivasyon
EncodeBlock_0	Conv2d	(3+1)x256x256	64x128x128	11,52	None	None
EncodeBlock_1	Conv2d BatchNorm2d	+ 64x128x128	128x64x64	131,328	BatchNorm2d	ReLU
EncodeBlock_2	Conv2d BatchNorm2d	+ 128x64x64	256x32x32	524,544	BatchNorm2d	ReLU
EncodeBlock_3	Conv2d BatchNorm2d	+ 256x32x32	512x16x16	2,097,664	BatchNorm2d	ReLU
EncodeBlock_4	Conv2d BatchNorm2d	+ 512x16x16	512x8x8	2,097,664	BatchNorm2d	ReLU
EncodeBlock_5	Conv2d BatchNorm2d	+ 512x8x8	512x4x4	2,097,664	BatchNorm2d	ReLU
EncodeBlock_6	Conv2d BatchNorm2d	+ 512x4x4	512x2x2	2,097,664	BatchNorm2d	ReLU
EncodeBlock_7	Conv2d BatchNorm2d	+ 512x2x2	512x1x1	2,097,664	BatchNorm2d	ReLU
DecodeBlock_0	ConvTranspose2d	512x1x1 512x2x2	512x2x2	2,097,664	None	None
FusionBlock_0	Conv2d BatchNorm2d Sigmoid	+ 3x256x256	3x256x256	195,747	BatchNorm2d	Sigmoid
DecodeBlock_1	Conv2d BatchNorm2d	+ 512x2x2 256x4x4	256x4x4	1,572,355	BatchNorm2d	LeakyReLU (0.2 slope)
FusionBlock_1	Conv2d BatchNorm2d Sigmoid	+ 3x256x256	3x256x256	195,747	BatchNorm2d	Sigmoid
DecodeBlock_2	Conv2d BatchNorm2d	+ 256x4x4 128x8x8	128x8x8	394,243	BatchNorm2d	LeakyReLU (0.2 slope)
FusionBlock_2	Conv2d BatchNorm2d Sigmoid	+ 3x256x256	3x256x256	195,747	BatchNorm2d	Sigmoid
DecodeBlock_3	Conv2d BatchNorm2d	+ 128x8x8 64x16x16	64x16x16	98,819	BatchNorm2d	LeakyReLU (0.2 slope)
FusionBlock_3	Conv2d BatchNorm2d Sigmoid	+ 3x256x256	3x256x256	195,747	BatchNorm2d	Sigmoid
DecodeBlock_4	Conv2d BatchNorm2d	+ 64x16x16 64x32x32	64x32x32	197,507	BatchNorm2d	LeakyReLU (0.2 slope)
FusionBlock_4	Conv2d BatchNorm2d Sigmoid	+ 3x256x256	3x256x256	195,747	BatchNorm2d	Sigmoid
DecodeBlock_5	Conv2d BatchNorm2d	+ 64x32x32 64x64x64	64x64x64	197,507	BatchNorm2d	LeakyReLU (0.2 slope)

EK-8. Filtreleme tabanlı görüntü restorasyonu MISF ağ mimarisi

InpaintGenerator						
Katman Adı	Katman Türü	Giriş Boyutu	Çıkış Boyutu	Parametre Sayısı	Kullanılan Normalizasyon	Kullanılan Aktivasyon
encoder0	Conv2d + ReflectionPad2d	4x256x256	64x250x250	12,16	InstanceNorm2d (track_running_stats=False)	ReLU(True)
encoder1	Conv2d	64x250x250	128x128x128	131,2	InstanceNorm2d (track_running_stats=False)	ReLU(True)
encoder2	Conv2d	128x128x128	256x64x64	524,544	InstanceNorm2d (track_running_stats=False)	ReLU(True)
ResnetBlock (8 adet)	ResnetBlock	256x64x64	256x64x64	-	InstanceNorm2d (track_running_stats=False)	ReLU(True)
decoder	ConvTranspose2d + ReflectionPad2d + Conv2d	256x64x64	3x256x256	1,179,651	InstanceNorm2d (track_running_stats=False)	ReLU(True)
kernel_pred	KernelConv	256x64x64	256x64x64	-	-	-
Discriminator						
Katman Adı	Katman Türü	Giriş Boyutu	Çıkış Boyutu	Parametre Sayısı	Kullanılan Normalizasyon	Kullanılan Aktivasyon
conv1	Conv2d + LeakyReLU(0.2)	3x256x256	64x128x128	3,2	SpectralNorm	LeakyReLU(0.2, inplace=True)
conv2	Conv2d + LeakyReLU(0.2)	64x128x128	128x64x64	131,2	SpectralNorm	LeakyReLU(0.2, inplace=True)
conv3	Conv2d + LeakyReLU(0.2)	128x64x64	256x32x32	524,544	SpectralNorm	LeakyReLU(0.2, inplace=True)
conv4	Conv2d + LeakyReLU(0.2)	256x32x32	512x32x32	2,097,664	SpectralNorm	LeakyReLU(0.2, inplace=True)
conv5	Conv2d (+ Sigmoid)	512x32x32	1x32x32	8,193	SpectralNorm	Sigmoid (if use_sigmoid=True)

EK-9. Simetri tespiti, tepe noktalarının belirlenmesi

```

simetri hesaplama.ipynb ☆ ☁
Dosya Düzenle Göster Ekle Çalışma zamanı Araçlar Yardım

utlar | + Kod + Metin | ▶ Tümünü çalıştır ▼

▶ import os
import cv2
import numpy as np
import matplotlib.pyplot as plt
from scipy.fft import fft2, fftshift
from scipy.signal import find_peaks
from scipy.ndimage import gaussian_filter, gaussian_filter1d
from skimage.feature import peak_local_max

# --- Yardımcı Fonksiyonlar ---

def bandpass_filter(f_shifted, low_cutoff=0.05, high_cutoff=0.7):
    """Frekans bandı filtresi"""
    center = np.array(f_shifted.shape) // 2
    Y, X = np.indices(f_shifted.shape)
    R = np.sqrt((X - center[1])**2 + (Y - center[0])**2)
    R_norm = R / np.max(R)

    mask = (R_norm >= low_cutoff) & (R_norm <= high_cutoff)
    return f_shifted * mask

def robust_angular_profile(data, bins=360, percentile=75):
    """Gelişmiş açısal profil - orijinal koddan"""
    center = np.array(data.shape) // 2
    Y, X = np.indices(data.shape)

    # Merkez bölgeyi maskeleye (DC bileşenini çıkar)
    R = np.sqrt((X - center[1])**2 + (Y - center[0])**2)
    mask = R > 10 # Merkezdeki 10 piksel yarıçapını maskeleye

    angle = np.degrees(np.arctan2(-(Y - center[0]), X - center[1])) % 360

    angular_values = []
    angles = np.linspace(0, 360, bins, endpoint=False)

    for i, ang in enumerate(angles):
        # Her açı için dar bir sektör tanımla
        angle_mask = (angle >= ang - 0.5) & (angle < ang + 0.5) & mask
        if np.sum(angle_mask) > 0:
            # Outlier'ları azaltmak için percentile kullan
            values = data[angle_mask]
            angular_values.append(np.percentile(values, percentile))
        else:
            angular_values.append(0)

    return angles, np.array(angular_values)

def find_rotation_symmetry(angular_profile, min_peaks=3):
    """Rotasyon simetrisi tespiti - iyileştirilmiş"""
    # Sinyali normalize et
    if np.std(angular_profile) == 0:
        return []

    profile = (angular_profile - np.mean(angular_profile)) / np.std(angular_profile)

    # Daha hassas tepe tespiti - 6-katlı simetriyi yakalamak için
    peaks, properties = find_peaks(profile, height=0.2, distance=8, prominence=0.1)

    if len(peaks) < min_peaks:
        return []
    |
    # Debug: Tepe pozisyonlarını yazdır
    peak_angles = [360 * p / len(profile) for p in peaks]
    print(f"Tespit edilen tepe açıları: {[f'{angle:.1f}°' for angle in peak_angles]}")

```

EK-9.(devam) Simetri tespiti, tepe noktalarının belirlenmesi

```

# Muhtemel simetri sayılarını test et
possible_orders = []
for order in range(2, 13): # 2-12 katlı simetri test et
    expected_spacing = 360 / order
    matches = 0
    total_possible = 0

    for peak in peaks:
        peak_angle = 360 * peak / len(profile)
        # Bu order için beklenen diğer pozisyonları kontrol et
        for k in range(1, order):
            expected_angle = (peak_angle + k * expected_spacing) % 360
            total_possible += 1

            # En yakın tepe pozisyonunu bul
            min_diff = float('inf')
            for other_peak in peaks:
                other_angle = 360 * other_peak / len(profile)
                diff = min(abs(other_angle - expected_angle),
                           360 - abs(other_angle - expected_angle))
                min_diff = min(min_diff, diff)

            # Eğer yeterince yakınsa eşleşme sayısını artır
            if min_diff < 15: # 15 derece tolerans
                matches += 1

    # Simetri skorunu hesapla
    if total_possible > 0:
        score = matches / total_possible
        expected_peaks = order
        actual_peaks = len(peaks)

        # En az yarısı kadar tepe varsa ve skor yeterince yüksekse
        if actual_peaks >= expected_peaks / 2 and score >= 0.4:
            # 6-katlı simetri için özel kontrol
            if order == 6:
                print(f"6-katlı test: {actual_peaks} tepe, skor: {score:.2f}")
                possible_orders.append((order, score))

    # Skora göre sırala
    possible_orders.sort(key=lambda x: x[1], reverse=True)
    return [order for order, score in possible_orders]

# --- Ana Analiz Fonksiyonu ---

def analyze_symmetry(img_path, threshold=0.15, show_plots=True):
    """Simetri analizi ana fonksiyonu"""

    # --- Görseli Oku ---
    img = cv2.imread(img_path)
    if img is None:
        print(f"Görsel yüklenemedi: {img_path}")
        return None

    # Griye çevir
    if len(img.shape) == 3:
        gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
    else:
        gray = img.copy()

    # Normalize ve yeniden boyutlandır
    gray = cv2.resize(gray, (512, 512)).astype('float32') / 255.0

```


EK-9.(devam) Simetri tespiti, tepe noktalarının belirlenmesi

```

# --- Analiz Adımları ---
|
# 1. Threshold uygulanmış gri görsel
thresh_img = np.where(gray >= threshold, gray, 0)

# 2. Gaussian yoğunluk haritası
density_map = gaussian_filter(gray, sigma=5)

# 3. Tepe noktaları tespiti
coordinates = peak_local_max(density_map, min_distance=10, threshold_rel=0.3)
count_peaks = len(coordinates)
area = gray.shape[0] * gray.shape[1]
peak_density = count_peaks / area

# 4. Edge Detection ve İşleme (Orijinal koddan)
# Gürültü azaltma
gray_blur = cv2.GaussianBlur(gray, (3, 3), 0.8)

# Kenar tespiti ile geometrik yapıları vurgulama
edges = cv2.Canny((gray_blur * 255).astype(np.uint8), 30, 100)
processed = edges.astype('float32') / 255.0

# Eğer kenar tespiti çok az bilgi verirse, threshold kullan
if np.sum(processed) < 1000:
    processed = thresh_img
    print("Kemar tespiti yetersiz, threshold görüntüsü kullanılıyor")
else:
    print("Kemar tespiti başarılı, edge-detected görüntü kullanılıyor")

# 5. Fourier dönüşümü (PROCESSED image ile!)
f_transform = fft2(processed)
f_shifted = fftshift(f_transform)

# Frekans filtresi uygula (orijinal koddan)
f_filtered = bandpass_filter(f_shifted, 0.05, 0.7)
magnitude = np.abs(f_filtered)
magnitude_spectrum = np.log(magnitude + 1)

# 6. Gelişmiş Angular profile hesaplama (orijinal koddan)
angles_deg, directionality = robust_angular_profile(magnitude)

# --- Simetri Tespiti ---
symmetry_orders = find_rotation_symmetry(directionality)

# --- Sonuçları Göster ---
if show_plots:
    # 5 panel tek satırda - daha yakın ve angular profile geniş
    fig, axes = plt.subplots(1, 5, figsize=(28, 6), gridspec_kw={'width_ratios': [1, 1, 1, 1, 1.5]})

    # 1. Threshold
    axes[0].imshow(thresh_img, cmap='gray')
    axes[0].set_title(f'Threshold (T = {threshold:.2f})', fontsize=30)
    axes[0].axis('off')

    # 2. Edge Detection Sonucu (Processed Image)
    axes[1].imshow(processed, cmap='gray')
    axes[1].set_title('Kemar Tespiti', fontsize=30)
    axes[1].axis('off')

    # 3. Tepe noktaları
    axes[2].imshow(density_map, cmap='RdYlBu')
    for y, x in coordinates:
        axes[2].add_patch(plt.Circle((x, y), radius=5, edgecolor='#0033cc',
                                     facecolor='none', linewidth=1.8))
    axes[2].set_title(f'Tepe Noktaları\nSayı:{count_peaks}, Yoğunluk:{peak_density:.6f}', fontsize=30)
    axes[2].axis('off')

```

EK-9.(devam) Simetri tespiti, tepe noktalarının belirlenmesi

```

else:
    print("Belirgin rotasyon simetrisi tespit edilemedi")
    print("\n*50")

return {
    'symmetry_orders': symmetry_orders,
    'angular_profile': (angles_deg, directionality),
    'threshold_image': thresh_img,
    'processed_image': processed, # Edge-detected görüntü
    'density_map': density_map,
    'peaks': coordinates,
    'peak_density': peak_density,
    'magnitude_spectrum': magnitude_spectrum
}

# --- Kullanım Örneği ---
if __name__ == "__main__":
    # Görsel yolunu güncelle
    img_path = '/content/drive/MyDrive/ColabNotebooks/simetri_hesapla/ornekler/misf/40result (25).png'

    # Analizi çalıştır (threshold ayarlanabilir)
    results = analyze_symmetry(img_path, threshold=0.15)

    if results:
        print("\nDetaylı Sonuçlar:")
        print(f"- Tepe noktası sayısı: {len(results['peaks'])}")
        print(f"- Tepe yoğunluğu: {results['peak_density']:.6f}")
        if results['symmetry_orders']:
            print(f"- Simetri katları: {results['symmetry_orders']}")
        else:
            print("- Simetri tespit edilemedi")
    else:
        print("- Simetri tespit edilemedi")


```

Kenar tespiti başarılı, edge-detected görüntü kullanılıyor
Tespit edilen tepe açıları: ['10.0°', '19.0°', '69.0°', '81.0°', '92.0°', '104.0°', '164.0°', '175.0°', '190.0°', '199.0°', '249.0°', '261.0°', '272.0°', '284.0°',
6-katlı test: 16 tepe, skor: 0.68

Threshold (T = 0.15)




Kenar Tespiti




Tepe Noktaları


Sayı:189, Yoğunluk:0.000721



Fourier Spektrumu



Açı Frekans Analizi



Ortalama Enerji

Açı (°)

Tespit Edilen:

- 2-katlı
- 4-katlı
- 10-katlı


```

=====
SYMMETRY ANALYSIS RESULTS
=====
Tespit edilen simetri katları: [2, 4, 10]
En olası simetri: 2-katlı
=====


Detaylı Sonuçlar:
- Tepe noktası sayısı: 189
- Tepe yoğunluğu: 0.000721
- Simetri katları: [2, 4, 10, 5, 11, 8, 6, 12, 9, 7, 3]

```



EK-10. %10 ve %10-%20 kayıp görüntüde tamamlanmış doğrudan görüntülerin karşılaştırması




EK-11. %20-%30 ve %30-%40 kayıp görüntüde tamamlanmış doğrudan görüntülerin karşılaştırması




EK-12. %40-%50 ve %50-%60 kayıp görüntüde tamamlanmış doğrudan görüntülerin karşılaştırması




EK-13. %10 ve %10-%20 kayıp görüntüde tamamlanmış açılı görüntülerin karşılaştırması




EK-14. %20-%30 ve %30-%40 kayıp görüntüde tamamlanmış açılı görüntülerin karşılaştırması




EK-15. %40-%50 ve %50-%60 kayıp görüntüde tamamlanmış açılı görüntülerin karşılaştırması




EK-16. %10 ve %10-%20 kayıp görüntüde tamamlanmış yapı bileşeni içeren görüntülerin karşılaştırması




EK-17. %20-%30 ve %30-%40 kayıp görüntüde tamamlanmış yapı bileşeni içeren görüntülerin karşılaştırması




EK-18. %40-%50 ve %50-%60 kayıp görüntüde tamamlanmış yapı bileşeni içeren görüntülerin karşılaştırması




EK-19. %10-20, %20-30 kayıp görüntüde tamamlanmış doğrudan görüntülerin analizi




EK-20. %30-40, %50-60 kayıp görüntüde tamamlanmış doğrudan görüntülerin analizi




EK-21. %10-20, %20-30 kayıp görüntüde tamamlanmış yapı bileşeni görüntülerin analizi



EK-22. %30-40, %50-60 kayıp görüntüde tamamlanmış yapı bileşeni görüntülerin analizi




EK-23. %10-20, %20-30 kayıp görüntüde tamamlanmış açılı görüntülerin analizi



% 10- %20 maske boyutu

%20- %30 maske boyutu

EK-24. %30-40, %50-60 kayıp görüntüde tamamlanmış açılı görüntülerin analizi



EK-25. Uygulama nicel değerlendirmeleri

Veri Setleri	Maske tipi ve oranı	PSNR ↑ SSIM ↑ LPIPS ↓ L1 ↓				
		Algoritma	Değerler	Değerler	Değerler	Değerler
Doğrudan görüntüler	Düzensiz (%0–10)	Kenar bağlantı algoritması ile görüntü restorasyonu EdgeConnect Uygulama-1	28,4690	0.9227	0.0986	5.4551
	Düzensiz (%10–20)		24.1811	0.8630	0.1467	7.9588
	Düzensiz (%20–30)		21.4647	0.7848	0.2013	11.2854
	Düzensiz (%30–40)		19.7719	0.7307	0.2561	14.3609
	Düzensiz (%40–50)		18.0606	0.6121	0.3168	18.8551
	Düzensiz (%50–60)		16.4495	0.5268	0.3717	24.1621
Açılı görüntüler	Düzensiz (%0–10)	Kenar bağlantı algoritması ile görüntü restorasyonu EdgeConnect Uygulama-1	27.6326	0.9269	0.1113	5.7813
	Düzensiz (%10–20)		24.1486	0.8651	0.1533	8.1288
	Düzensiz (%20–30)		21.6994	0.7891	0.2015	11.0631
	Düzensiz (%30–40)		19.9770	0.7123	0.2477	14.3016
	Düzensiz (%40–50)		18.4057	0.6128	0.3093	18.3263
	Düzensiz (%50–60)		16.5370	0.5232	0.3543	23.6544
Yapı bileşeni içeren görüntüler	Düzensiz (%0–10)	Kenar bağlantı algoritması ile görüntü restorasyonu EdgeConnect Uygulama-1	27.5275	0.9167	0.1257	5.9154
	Düzensiz (%10–20)		23.5334	0.8557	0.1682	8.5226
	Düzensiz (%20–30)		21.0462	0.7764	0.2118	11.7388
	Düzensiz (%30–40)		19.6188	0.6998	0.2571	14.7814
	Düzensiz (%40–50)		17.8079	0.6068	0.3159	19.2165
	Düzensiz (%50–60)		16.5811	0.5196	0.3640	23.9472
Doğrudan görüntüler	Düzensiz (%0–10)	Filtreleme tabanlı görüntü restorasyonu MISF Uygulama-1	31,3096	0,9525	0,0528	4,1723
	Düzensiz (%10–20)		25,9763	0,8969	0,0971	6,2875
	Düzensiz (%20–30)		23,1318	0,8279	0,1510	8,9701
	Düzensiz (%30–40)		21,2327	0,7552	0,2069	11,8072
	Düzensiz (%40–50)		19,6602	0,6599	0,2704	15,6135
	Düzensiz (%50–60)		18,3365	0,5777	0,3325	19,5593
Açılı görüntüler	Düzensiz (%0–10)	Filtreleme tabanlı görüntü restorasyonu MISF Uygulama-1	29,8126	0,9517	0,0650	4,5167
	Düzensiz (%10–20)		26,8563	0,9149	0,0924	5,9584
	Düzensiz (%20–30)		22,8618	0,8184	0,1599	9,4625
	Düzensiz (%30–40)		21,0611	0,7461	0,2081	12,3844
	Düzensiz (%40–50)		19,3898	0,6433	0,2727	16,3114
	Düzensiz (%50–60)		18,2971	0,5609	0,3254	19,5208
Yapı bileşeni içeren görüntüler	Düzensiz (%0–10)	Filtreleme tabanlı görüntü restorasyonu MISF Uygulama-1	29,1080	0,9362	0,0827	5,2250
	Düzensiz (%10–20)		24,8664	0,8800	0,1218	7,4433
	Düzensiz (%20–30)		22,5381	0,8098	0,1124	9,9754
	Düzensiz (%30–40)		20,9609	0,7358	0,1646	12,7706
	Düzensiz (%40–50)		19,3023	0,6438	0,2651	16,5374
	Düzensiz (%50–60)		18,0861	0,5591	0,3241	20,6150



Gazili olmak ayrıcalıktır