

**HASARLI RÖLYEF VE MOZAIK RESİMLERİNİN ÇEKİŞMELİ
ÜRETİCİ AĞ KULLANILARAK TAMAMLANMASI**

Mehmet Kıvılcım KELEŞ

191450204

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Doktora Programı

Danışman: Dr. Öğr. Üyesi Erdal GÜVENOĞLU

İstanbul

T.C. Maltepe Üniversitesi

Lisansüstü Eğitim Enstitüsü

Mayıs, 2023

HASARLI RÖLYEF VE MOZAIK RESİMLERİNİN ÇEKİŞMELİ ÜRETİCİ AĞ KULLANILARAK TAMAMLANMASI

Mehmet Kıvılcım KELEŞ
191450204
ORCID: 0000-0001-5358-8301

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Doktora Programı
Danışman: Dr. Öğr. Üyesi Erdal GÜVENOĞLU

İstanbul
T.C. Maltepe Üniversitesi
Lisansüstü Eğitim Enstitüsü
Mayıs, 2023



JÜRİ VE ENSTİTÜ ONAYI

Bu belge, Yükseköğretim Kurulu tarafından 19.01.2021 tarihli “Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge” ile bildirilen 6698 Sayılı Kişisel Verilerin Korunması Kanunu kapsamında gizlenmiştir.



ETİK İLKE VE KURALLARA UYUM BEYANI

Bu belge, Yükseköğretim Kurulu tarafından 19.01.2021 tarihli “Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge” ile bildirilen 6698 Sayılı Kişisel Verilerin Korunması Kanunu kapsamında gizlenmiştir.



TEŐEKKÜR

Doktora tez alıőmam hem akademik hem de kltrel kaynaklarımı geliőtiren ve farkındalıđımı arttıran bir sre oldu. Bu srete, akademik olarak beni destekleyen, ynlendiren ve yol gsteren deđerli danıőmanım Dr. đr. yesi Erdal Gvenođlu'na, tez izleme jrimde yer alarak yaptıkları yorumlar ve verdikleri bilimsel katkı sayesinde araőtırmamızın geliőtmesine yardımcı olan Prof. Dr. Emin Murat Esin'e ok teőekkr ederim.

Hayatım boyunca her zaman beni destekleyen ve sevgisini esirgemeyen kıymetli aileme teőekkr ediyorum. alıőma sırasında gl yzleri ile bana ilham veren ođullarım ınar ve Tuna KELEŐ'e bu alıőmayı atfediyorum.

Mehmet Kıvılcım KELEŐ

Mayıs, 2023

ÖZET

HASARLI RÖLYEF VE MOZAİK RESİMLERİNİN ÇEKİŞMELİ ÜRETİCİ AĞ KULLANILARAK TAMAMLANMASI

Mehmet Kıvılcım Keleş

Doktora Tezi

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Doktora Programı

Danışman: Dr. Öğr. Üyesi Erdal Güvenoğlu

Maltepe Üniversitesi Lisansüstü Eğitim Enstitüsü, 2023

Mozaik ve rölyef eserleri ülkemiz coğrafyasında yapılan arkeolojik kazılarda gün yüzüne çıkarılan sanat eserlerindedir. Bu eserler tarih boyunca buldukları dönemden etkilenmiş, çok farklı uygarlıklar tarafından geliştirilmiş ve kullanılmışlardır. Maddeler yapıları gereği eskimesi ve yıpranması mümkündür. Mozaik ve rölyef eserleri de doğa koşulları veya insanın olumsuz etkileri ile günümüze yıpranmış veya tahribata uğramış şekilde gelebilmekteler. Tarihi eserlerdeki tahribatın onarılması ve orijinal görüntüsüne ulaşılması gerekliliği arkeoloji deki temel ihtiyaçlardandır.

Görüntü tamamlama ve görüntünün orijinal halini oluşturma problemi literatür de farklı teknikler ile çözülmeye çalışılan üzerinde çalışılan güncel bir problemdir. Bu tez çalışmasında görüntü tamamlama problemini derin öğrenme tabanlı yöntemlerden çekişmeli üretici ağ yöntemleri uygulanarak çıkan sonuçlar incelenmiştir. Çalışmada uygulanan yöntemlerin yapısal benzerlik indisi, tepe sinyal gürültü oranı ve ortalama hata karesi metriklerine bakılarak karşılaştırmalı sonuçlar verilmiştir. Yapılan çalışmada mozaik ve rölyef veri seti üzerinde bağlamsal dikkat yöntemi ile hasarlı giderilmiş görüntü ile orijinal görüntü arasında yapısal benzerlik indisinin az hasarlı görüntülerde 0.92 – 0.97, çok hasarlı görüntülerde ise 0.82 – 0.93 ile en iyi başarıyı sağladığı tespit edilmiştir.

Bu tez kapsamında yapay zekâ algoritmaları ile tarihi eserlerdeki tahribatın onarılması mümkün mü ve orijinal görüntüsü nasıldı sorularına cevap aranmıştır. Bu cevaplara ulaşabilmek için ilk olarak Türkiye de bulunan mozaik ve rölyef eserlerine ait görsel bir

veri seti oluşturulup literatüre de kazandırılmıştır. Bu çalışma arkeolojik eserlerin orijinal görüntüsünün hızlı bir şekilde görselleştirilmesi ile kazı ve müze alanlarında verimli bir araç olarak kullanılma potansiyeli bulunmaktadır.

Anahtar Sözcükler: Rölyef, Mozaik, Çekişmeli Üretici Ağ, Derin Öğrenme, Görüntü Tamamlama.



ABSTRACT

DAMAGED RELIEF AND MOSAIC IMAGE INPAINTING USING GENERATIVE ADVERSARIAL NETWORK

Mehmet Kıvılcım Keleş

PhD Thesis

Department of Computer Engineering

Computer Engineering Programme

Thesis Advisor: Assist. Prof. Dr. Erdal Güvenoğlu

Maltepe University Graduate School, 2023

Mosaic and relief works are among the works of art unearthed in archaeological excavations in our country. These artifacts have been influenced by the period in which they were found throughout history, and have been developed and used by many different civilizations. It is possible for materials to wear out and wear out due to their structure. Mosaic and relief works can also come to our day in a worn or damaged form due to natural conditions or the negative effects of human beings. The necessity of repairing the damage in historical artifacts and reaching their original appearance is one of the basic needs in archeology.

The problem of image inpainting and creating the original version of the image is a current problem that is tried to be solved with different techniques in the literature. In this thesis, the results of the image inpainting problem by applying the generative adversarial network methods, one of the deep learning-based methods, were examined. Comparative results are given by looking at the structural similarity index, peak signal-to-noise ratio and mean square error metrics of the methods applied in the study. In the study, it was determined that the structural similarity index between the damaged image and the original image on the mosaic and relief data set, with the contextual attention method, provided the best performance with 0.92 - 0.97 in the slightly damaged images and 0.82 - 0.93 in the heavily damaged images.

Within the scope of this thesis, answers have been sought to the questions of whether it is possible to repair the damage in historical artifacts with artificial intelligence algorithms and how was the original appearance. In order to reach these answers, firstly,

a visual data set of mosaic and relief works in Turkey was created and brought to the literature. This study has the potential to be used as an efficient tool in excavation and museum areas with the rapid visualization of the original image of archaeological artifacts.

Keywords: Relief, Mosaic, Generative Adversarial Network, Deep Learning, Image Inpainting



İÇİNDEKİLER

JÜRİ VE ENSTİTÜ ONAYI	ii
ETİK İLKE VE KURALLARA UYUM BEYANI	iii
TEŞEKKÜR.....	iv
ÖZET	v
ABSTRACT.....	vii
İÇİNDEKİLER	ix
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ	xiii
KISALTMALAR.....	xvi
SEMBOLLER.....	xvii
1. GİRİŞ.....	1
1.1 Problem	2
1.2 Amaç	3
1.3 Önem.....	3
1.4 Varsayımlar	4
1.5 Sınırlıklar.....	4
1.6 Tanımlar	4
2. LİTERATÜR ARAŞTIRMASI.....	5
2.1 Geleneksel Yöntemler ile Görüntü Tamamlama.....	6
2.2 Otomatik Kodlayıcılar (Auto Encoders)	6
2.3 Bağlam Kodlayıcılar ile Görüntü Tamamlama (Context Encoders Feature Learning by Inpainting)	8
2.4 Çok Ölçekli Nöral Yama Sentezi Kullanarak Görüntü Tamamlama (High Resolution Image Inpainting using Multi-Scale Neural Patch Synthesis).....	10
3. MATERYAL VE YÖNTEM.....	13

3.1	Yapay Zeka	13
3.2	Makine Öğrenmesi	14
3.3	Derin Öğrenme	16
3.3.1	Biyolojik sinir ağları	16
3.3.2	Yapay sinir ağları	17
3.4	Veriler ve Toplanması	20
3.4.1	Mozaik veri seti	21
3.4.2	Rölyef veri seti	21
3.5	Verilerin Değerlendirilmesi ve Yorumlanması	22
3.5.1	Yapısal benzerlik indisi (Structural similarity index)	22
3.5.2	Ortalama hata karesi (Mean square error)	23
3.5.3	Ortalama hata karesi kökü (Root mean square error)	23
3.5.4	Tepe sinyal gürültü oranı (Peak signal-to-noise ratio)	24
3.5.5	Ölçek değişmez özellik dönüşümü (Scale invariant feature transform) ...	24
3.6	Çekişmeli Üretici Ağ (Generative Adversarial Networks)	25
3.6.1	Bölge bazında görüntü tamamlama (Region-wise generative adversarial image inpainting for large missing areas)	30
3.6.2	Çoğul görüntü tamamlama (Pluralistic image completion)	32
3.6.3	Büyük kayıplı görüntü tamamlama için maske uyumlu dönüştürücü (Mask aware transformer for large hole image inpainting)	34
3.6.4	Bağlamsal dikkat ile görüntü tamamlama (Generative image inpainting with contextual attention)	35
3.7	Gerçekleştirilen Çalışma	38

4. BULGULAR VE TARTIŞMA.....	40
4.1 Az Hasarlı Görüntülerde Görüntü Tamamlama.....	40
4.2 Çok Hasarlı Görüntülerde Görüntü Tamamlama.....	58
5. SONUÇ ve ÖNERİLER	75
KAYNAKLAR	76
ÖZGEÇMİŞ	82



TABLULAR LİSTESİ

Tablo 1. Aktivasyon Fonksiyonları.....	29
Tablo 2. Az Hasarlı Mozaik 1 Görüntü Tamamlama Başarı Kıyaslama	43
Tablo 3. Az Hasarlı Mozaik 2 Görüntü Tamamlama Başarı Kıyaslama	46
Tablo 4. Az Hasarlı Mozaik 3 Görüntü Tamamlama Başarı Kıyaslama	49
Tablo 5. Az Hasarlı Rölyef 1 Görüntü Tamamlama Başarı Kıyaslama.....	52
Tablo 6. Az Hasarlı Rölyef 2 Görüntü Tamamlama Başarı Kıyaslama.....	55
Tablo 7. Az Hasarlı Rölyef 3 Görüntü Tamamlama Başarı Kıyaslama.....	58
Tablo 8. Çok Hasarlı Mozaik 1 Görüntü Tamamlama Başarı Kıyaslama	61
Tablo 9. Çok Hasarlı Mozaik 2 Görüntü Tamamlama Başarı Kıyaslama	64
Tablo 10. Çok Hasarlı Rölyef 1 Görüntü Tamamlama Başarı Kıyaslama.....	67
Tablo 11. Çok Hasarlı Rölyef 2 Görüntü Tamamlama Başarı Kıyaslama.....	70

ŞEKİLLER LİSTESİ

Şekil 1. Otomatik Kodlayıcı Yapısı.....	7
Şekil 2. Mimariye Genel Bakış.....	9
Şekil 3. Mimariye Genel Bakış.....	11
Şekil 4. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Arasındaki İlişki	13
Şekil 5. Yapay Zeka Uygulamaları.....	14
Şekil 6. Gözetimli Öğrenme Akışı	15
Şekil 7. Nöron Yapısı	16
Şekil 8. Yapay Nöron Yapısı.....	17
Şekil 9. Yapay Nöronda Ağırlıklar.....	17
Şekil 10. Aktivasyon Fonksiyon Grafikleri.....	18
Şekil 11. Yapay Sinir Hücresi Yapısı.....	19
Şekil 12. Tek Katmanlı Sinir Ağı Yapısı.....	19
Şekil 13. Çok Katmanlı Sinir Ağı Yapısı	20
Şekil 14. Çekişmeli Üretici Ağ Mimarisi	26
Şekil 15. Evrişimli Sinir Ağ Modeli.....	27
Şekil 16. Matris Düzleştirme İşlemi	28
Şekil 17. Genel Mimari	30
Şekil 18. İki Paralel Ardışık Mimariye Genel Bakış	33
Şekil 19. Genel Mimari	34
Şekil 20. Yönteme Genel Bakış.....	36
Şekil 21. Bağlamsal Dikkat Katmanı Çizimi.....	37
Şekil 22. Akış Diagramı	39
Şekil 23. Mozaik 1 Orijinal – Az Hasarlı Görsel	41
Şekil 24. Mozaik 1 Üzerinde Gerçekleştirilen Bölge Bazlı Evrişimler Yöntemi.....	41

Şekil 25. Mozaik 1 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi.....	42
Şekil 26. Mozaik 1 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi.....	42
Şekil 27. Mozaik 2 Orijinal – Az Hasarlı Görsel	44
Şekil 28. Mozaik 2 Üzerinde Gerçekleştirilen Bölge Bazlı Evrişimler Yöntemi.....	44
Şekil 29. Mozaik 2 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi.....	45
Şekil 30. Mozaik 2 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi.....	45
Şekil 31. Mozaik 3 Orijinal – Az Hasarlı Görsel	47
Şekil 32. Mozaik 3 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi	47
Şekil 33. Mozaik 3 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi.....	48
Şekil 34. Mozaik 3 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi.....	48
Şekil 35. Rölyef 1 Orijinal – Az Hasarlı Görsel.....	50
Şekil 36. Rölyef 1 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi	50
Şekil 37. Rölyef 1 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi	51
Şekil 38. Rölyef 1 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi	51
Şekil 39. Rölyef 2 Orijinal – Az Hasarlı Görsel.....	53
Şekil 40. Rölyef 2 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi	53
Şekil 41. Rölyef 2 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi	54
Şekil 42. Rölyef 2 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi	54
Şekil 43. Rölyef 3 Orijinal – Az Hasarlı Görsel.....	56
Şekil 44. Rölyef 3 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi	56
Şekil 45. Rölyef 3 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi	57
Şekil 46. Rölyef 3 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi	57
Şekil 47. Mozaik 1 Orijinal – Çok Hasarlı Görsel	59
Şekil 48. Mozaik 1 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi	59
Şekil 49. Mozaik 1 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi.....	60

Şekil 50. Mozaik 1 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi.....	60
Şekil 51. Mozaik 2 Orijinal – Çok Hasarlı Görsel	62
Şekil 52. Mozaik 2 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi	62
Şekil 53. Mozaik 2 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi.....	63
Şekil 54. Mozaik 2 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi.....	63
Şekil 55. Rölyef 1 Orijinal – Çok Hasarlı Görsel.....	65
Şekil 56. Rölyef 1 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi	65
Şekil 57. Rölyef 1 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi	66
Şekil 58. Rölyef 1 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi	66
Şekil 59. Rölyef 2 Orijinal – Çok Hasarlı Görsel.....	68
Şekil 60. Rölyef 2 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi	68
Şekil 61. Rölyef 2 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi	69
Şekil 62. Rölyef 2 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi	69
Şekil 63. Deneysel Çalışma 1	71
Şekil 64. Deneysel Çalışma 2	71
Şekil 65. Deneysel Çalışma 3	72
Şekil 66. Deneysel Çalışma 4	72
Şekil 67. Deneysel Çalışma 5	73
Şekil 68. Deneysel Çalışma 6	73
Şekil 69. Deneysel Çalışma 7	74
Şekil 70. Deneysel Çalışma 8	74

KISALTMALAR

SSMI	: Yapısal Benzerlik İndisi
MSE	: Ortalama Hata Karesi
RMSE	: Ortalama Hata Karesi Kökü
PSNR	: Tepe Sinyal Gürültü Oranı
MSE	: Ortalama Hata Karesi
MSE	: Ortalama Hata Karesi
GAN	: Çekişmeli Üretici Ağ
CNN	: Evrişimli Sinir Ağ
WGAN	: Wasserstein GAN
WGAN-GP	: Gradyan cezalı Wasserstein Çekişmeli Üretici Ağ
DCGAN	: Derin Evrişimli Çekişmeli Üretici Ağ
SGD	: Stokastik Gradyan İnişi
NN	: En Yakın Komşu
ELU	: Üstel Doğrusal Birim Fonksiyon
ReLU	: Doğrultulmuş Doğrusal Birim Fonksiyon
Leaky ReLU	: Sızıntı Doğrultulmuş Doğrusal Birim Fonksiyon
VGG	: Görsel Geometri Grubu
SIFT	: Ölçek Değişmez Özellik Dönüşümü

SEMBOLLER

\mathcal{L}_{rec}	: Normalleştirilmiş Maskelenmiş Yeniden Yapılandırma Kaybı Mesafesi
\mathcal{L}_{adv}	: Bağlam Kodlayıcılar İçin Çekişmeli Kayıp
\mathcal{L}	: Genel Kayıp
\mathbf{X}_1	: Girdi
μ_x	: Yaklaşık Parlaklık
$ \mathbf{R}^\phi $: R^ϕ Bölgesinde Örneklenen Yama Sayısı
\mathbf{P}_i	: i Konumunda Ortalanmış Yerel Sinirsel Yama
$\mathcal{Y}(x)$: Pürüzsüzlük Kaybı Hesabı
$\mathbf{nn}(i)$: En Yakın Komşuluk
σ_x	: Kontrast Standart Sapması
\mathbf{C}_1	: Pozitif Sabit
$\mathbf{x}(i)$: Gerçek Görüntü Örneği
$\mathbf{z}(i)$: Gürültü Vektörünü Temsili
\mathbf{I}_g	: Orijinal Görüntümüz, maskelenmiş Görüntü
\mathbf{I}_c	: Gizli Piksellerini İçeren Tamamlayıcı Görüntü
\mathbf{I}_m	: Gizli Pikselleri İçeren Tamamlayıcı Görüntü
\mathbf{I}_c	: Üstel Doğrusal Birim Fonksiyon
\mathbf{f}	: İçerik Ağı
\mathbf{t}	: Doku Ağı

I_{max} : En Büyük Gri Ton Deęeri

u : Girdilerin Aęırlık Deęerleri

S_c : Grnt Koşullu stil

ϵ : Kk Sabit



1. GİRİŞ

Ülkemiz sınırları içerisinde ve günümüze ulaşan tarihi eserlerden en sık karşılaşılan yapı örnekleri rölyef ve mozaiklerdir. Anadolu da yaşamış birçok farklı dönem ve uygarlıkta bu eserler kullanılmışlardır. Geçmişten günümüze ulaşan mimari eserlerde, çeşitli madenlerden yapılmış eşyalarda ve ahşap işlerinde rölyef sanatı sıklıkla görülmektedir. Rölyef sanatındaki figürler yapıldığı dönemden etkilenmiş ve bulunduğu dönem göre stil farklılıkları oluşmuştur.

Rölyef eserlerinde, yiyecek ve içecek sahneleri, avlanma sahneleri ve yok edilemez bir beden betimlenmesi şeklindeki tasvirler sıklıkla kullanılmıştır (Panofsky, 2012). Anadolu'da bulunan rölyeflerde daha çok savaş ve av sahnelerini, hayvan tasvirleri, kılıçlı, mızraklı ve okçu asker tasvirleri yapılmıştır.

Anadolu da gün yüzüne sıklıkla çıkarılan tarihi eserlerden bir diğeri de mozaiklerdir. Mozaik sanatı, ilk yapılmaya başladığı günden itibaren zaman içinde bulunduğu dönem ve olaylardan etkilenmiş sanatsal gelişim ve değişim geçirmiştir.

Gordion mozaikleri, Türkiye sınırları içerisinde tespit edilmiş en eski mozaiklerden biridir. Gordion mozaiklerinde genel olarak taban döşemelerinde kullanılmış ve çoğunlukla geometrik desenler hâkimdir (Üstüner, 2002). Roma ve Bizans dönemlerinde ise farklı yerlerde kullanım alanları, desenlerde ise insan ve hayvan gibi nesnelerin kullanımı da karşımıza çıkmaktadır.

Alan Turing'in "Computing Machinery & Intelligence" adlı metninde "Makineler Düşünebilir Mi?" sorusu ile ortaya çıkan makine öğrenmesi kavramı ilk olarak 1950'li yılların başında ortaya çıkmıştır. Uzun yıllardır üzerinde çalışılan makine öğrenmesi, teknoloji ve bilgisayarların gelişimi hayatımızın önemli bir parçası haline gelmiştir.

Makine Öğrenmesi geçmişteki veriden beslenir ve yeni bir veri üretimi için en uygun modeli bulmaya çalışır. Makine öğrenmesinin çözüm aradığı problemleri temel anlamda sınıflandırma, kümeleme, regresyon veya boyut indirgeme olarak ele almaktadır. Geleneksel makine öğrenmesi yöntemlerinin ham veriyi işlemede yetersiz olmaları ve bir

uzman tarafından tanımlanmış özniteliklere gereksinim duymaları gibi problemleri söz konusudur (LeCun, Bengio, ve Hinton, 2015). Bu problemlerden dolayı yapılandırılmamış ve etiketlenmemiş ham verilere dayalı olarak öğrenme ve kararlar almasını sağlayan yöntemler popülerlik kazanmış bu alanda yapılan çalışmalar ile derin öğrenme yöntemi ortaya çıkmıştır. Derin öğrenme yapay sinir ağlarını kullanan bir makine öğrenmesi türüdür. Günümüzde donanım gücünün de artması ile derin öğrenme algoritmaları görüntü işleme problemlerin çözümünde güçlü bir araç olarak kullanılmaktadır. Derin öğrenme algoritmaları literatürde popüler olarak; sınıflandırma, segmentasyon, nesne tanıma, görsel stil transferi, çözünürlük artırma ve görsel üretimi problemlerinde kullanılabilir (Brownlee, 2019).

Görüntü tamamlama, hasarlı ya da bir parçası eksik resimlerin tamamlanması, makine öğrenmesi problemleri arasında güncel bir problem olarak bulunmakta ve üzerine çalışmalar yapılmaktadır.

1.1 Problem

Eşyanın doğası gereği ihtiyarlanması, onun görünüşü ve yapısı üzerindeki kaçınılmaz değişimleri “bozulmayı” gündeme getirir. Şüphesiz bu değişimler, çeşitli maddelerin öz direncinin gücü, bozulma faktörlerinin cinsi, şiddeti ve süresiyle orantılıdır (Eskici, 1997).

Arkeolojik eserler yapıldıkları yüzyıllar öncesi orijinal görünüşleri ile günümüzde kazılarda gün yüzüne çıkarıldıkları görünüşleri arasında farklar bulunabilmektedir. Günümüze ulaşan çoğu arkeolojik eserlerde kısmen veya büyük oranda tahribata uğradığı görülmektedir. Buna sebep ise, buldukları yapının yıkılmasıyla zarara uğraması, yangınlardan dolayı yanık izlerine sahip olması, yağmur, bitki kökleri ve yeraltı suları yüzünden zamanla tahribata uğramasıdır (Bassier, 1974). Bu tahribatların nedenlerini zaman içinde gerçekleşen doğa koşullarından, insanların olumsuz etkilerinden veya mozaik yapısının özelliklerinden kaynaklanan bozulmalar olarak sıralanabilmektedir.

Teknolojideki gelişmeler ile birlikte bugün makine öğrenimi algoritmaları, birbirinden farklı pek çok alandaki görevler için başarılı bir şekilde eğitilebilmekte yüksek başarılı sonuçlar vermektedir. Tezin başlığı da olan arkeolojik eserlerdeki tahribatların giderilip

orijinal halinin görüntüsünün üretilip üretemeyeceğinin tartışmasının açılması amacı ile araştırma yapılmaktadır. “Arkeolojik eserin orijinal görüntüsü nasıldı?” sorusunun yanıtı çekişmeli üretici ağ algoritması ile aranacaktır.

1.2 Amaç

Bu tez çalışmasında, üretici çekişmeli ağlar ile tarihi eserler görüntülerinin tamamlama problemi irdelenmiştir. Genel ve özel olmak üzere iki temel amaç belirlenmiştir.

Genel amaç yapay zekâ tarafındaki güncel teknolojik gelişmelerin arkeologların ve bu işlerle ilgilenen kişilerin kullanılabilmesini ve disiplinler arası güç birliğinin farkındalık yaratmasını hedefler.

Özel amaç ise hasarlı rölyef ve mozaik resimlerinin çekişmeli üretici ağ (GAN) kullanılarak hasarlı görüntülerinin tamamlanması ve çalışma süresince farklı yaklaşımların üretim çıktıları değerlendirilecektir.

Diğer bir özel amaç ise yapılacak bu çalışma ile Türkiye’deki arkeoloji müzelerinden toplanacak örnek tarihi eser görüntüleri ile Türkiye’nin ilk rölyef ve mozaik veri seti hazırlanacaktır. Bu veri seti literatüre kazandırılacak ve bu alandaki yeni çalışmalar yapılmasının önünü açacaktır. Ayrıca bu çalışma ile ;

- Hasarlı veya bir parçası eksik olan mozaik ve rölyef görüntülerinin eksik kısımlarının nasıl olması gerektiği sorusunun yanıtlanması,
- Üretilen çıktıların görsel bağlamında yeterliliği ve üretilen çıktının başarısının değerlendirilmesi,
- Bir kısmı hasarlı olan tarihi eserlerin yeniden üretiminde veri setinin seçimi ve veri seti düzeninin nasıl olması gerektiği,
- Oluşturulacak modelin bir uygulama olarak kullanımının değerlendirilmesi hedeflenmektedir.

1.3 Önem

Bu araştırma, Türkiye’nin ilk mozaik ve rölyef resimlerinden oluşan bir veri setinin oluşmasını sağlamıştır. Son yıllarda büyük gelişme gösteren makine öğrenmesinin alt

dallarından olan derin öğrenme yönteminin arkeoloji alanında kullanılması ile literatürdeki bir eksiklik de tamamlanmış olacaktır. Bu çalışma farklı disiplinlerdeki uygulama alanlarının birbirine sağlayacağı faydaların gösterilmesinde de yol gösterici niteliktedir. Öte yandan, benzer amaçlar taşıyacak yeni araştırmalarının yapılması ve yeni algoritmaların ortaya çıkması da kolaylaşmıştır.

1.4 Varsayımlar

Tez çalışması kapsamında çok çeşitli tarihi eserler bulunduğundan hasarlı rölyef görüntülerinde görüntü tamamlama ile başlanmış, farklı tarihi eserlerde de bu problemin çözülebileceği varsayımı kabul edilmiş ve hasarlı mozaik görüntüleri ile çalışma genişletilmiştir. Diğer bir varsayım ise hasarsız görüntüler ile model eğitimi ve yapay hasarlı görüntüler ile test çalışmaları yapılmış ve orijinal hasara sahip görüntülerinde görüntülerin tamamlanabileceği varsayımı ile hareket edilmiştir.

1.5 Sınırlıklar

Çalışmamızda son zamanlarda oldukça popüler olan transformer (dönüştürücü) mimarisi uygulanması ve bunun sonuçları üzerinde bulguların paylaşılması düşünülmüştür. Ancak dönüştürücü mimarisinin eğitim aşamasındaki yüksek donanım gereksinimi nedeni ile çalışmalar ilerletilememiştir.

1.6 Tanımlar

Mozaik; çeşitli renklerdeki küçük parçacıklardan oluşan nesnelerin birleştirilmesi yöntemiyle oluşturulan eserlere denir. Rölyef; bir yüzey üzerine yapılan yükseltme veya çökertme sonucu oluşan kabartma eserlere denir. Yapay zekâ, insan zekâsına benzer şekilde öğrenebilen, çeşitli görevleri yerine getiren, kendini geliştiren sistemlere denir. Çekişmeli üretici ağ; iki adet yapay sinir ağının birbirleri ile çekişmeli çalışmasına dayanan, gözetimsiz makine öğrenmesi kullanan bir sını ağı türüdür.

2. LİTERATÜR ARAŞTIRMASI

Günümüz yapay zekâ algoritmalarından derin öğrenme yönteminin temelini oluşturan sinir sisteminin çalışma prensipleri, ilk olarak “A Logical Calculus of the Ideas Immanent in the Nervous Activity” (McCulloch ve Pitts, 1943) adlı çalışma oluşturmaktadır. Bu çalışmada yapay sinir ağı modelini mantık kapıları ile açıklamış ve nöronun ateşleme sisteminin modelini oluşturmuşlardır. İlk yapay sinir ağı ve perceptron tahminine dayalı sınıflandırma Frank Rosenblatt tarafından çalışılmıştır (Rosenblatt, 1958, 1960). Minsky ve Papert doğrusal olmayan problemleri perceptronun çözemeyeceği açıklamıştır (Minsky ve Papert, 1969). Bundan sonraki dönemde uzman sistemler gelişmeye başlamıştır (Domingos, 2015). Derin öğrenme sisteminin “öğrenme” kısmı için kullanılan geri besleme yöntemi “Learning representations by back-propagating errors” isimli çalışmada ilk olarak önerilmiştir (Rumelhart, Hinton, ve Williams, 1986). Çok katmanlı sinir ağları ilk olarak “A fast learning algorithm for deep belief nets” adlı çalışmada derin sinir ağları kullanılarak hiyerarşik verinin özelliklerini öğrenebilen algoritmalarını sunmuşlardır (Hinton, Osindero, ve Teh, 2006). Derin evrişimli sinir ağları ile yapılan görsel veri sınıflandırma problemi “ImageNet Classification with Deep Convolutional Neural Networks” adlı çalışmada başarı ile çözülmüştür (Krizhevsky, Sutskever, ve Hinton, 2017). Derin öğrenme algoritmaları kullanılarak çekişmeli üretici ağ önerisi ilk olarak “Generative Adversarial Nets” adlı çalışmada sunulmuştur (Goodfellow, Pouget-Abadie, Mirza, Xu, Warde-Farley, Ozair, Courville ve Bengio, 2014).

Geleneksel görüntü tamamlama yöntemlerini difüzyon tabanlı (Ballester, Bertalmio, Caselles, Sapiro, ve Verdera, 2001; Bertalmio, Sapiro, Caselles, ve Ballester, 2000; Levin, Zomet, ve Weiss, 2003) ve yama tabanlı (Bertalmio, Vese, Sapiro, ve Osher, 2003; Criminisi, Perez, ve Toyama, 2003) çözümler olarak ayırılır.

Geleneksel görüntü tamamlama yöntemleri; tamamlanacak bölgeler ile görüntünün geri kalan içeriğinin, benzer içeriği paylaştığını varsayar ve bu bölgeleri tamamlamak için yamayı benzer parçalar ile eşleştirmeye (Barnes, Shechtman, Finkelstein, ve Goldman, 2009) veya doku sentezini (Efros ve Freeman, 2001; Efros ve Leung, 1999) yaparak eş

parçaları yeniden hizalamaktadır. Bu yöntemler görüntü üzerindeki eksik bölgeleri tamamlarken, oluşturulan yeni görüntülerin kalitesini düşürür. Bu yaklaşımlar, özellikle tekdüze boyama da başarılı sonuçlar vermektedir. Bu yöntemler, karmaşık tekrar etmeyen yapılarda örneğin yüzler, nesnelere içerdiği zorlu durumlarda yeni görüntü içeriklerini anlamlandıramaz ve hatalı görüntü oluştururlar. Görüntü tamamlama yöntemleri öğrenmeye dayalı bir yaklaşımla çözmeye çalışan yöntemler ve geleneksel yöntemler olmak üzere iki ana gruba ayrılabilir.

Öğrenme tabanlı yaklaşımlar, derin öğrenme tabanlı yöntemlerin de gelişmesi ile çekişmeli üretici ağlar ile görüntü tamamlamada daha iyi sonuçları üretmek için kullanılmaya başlanmıştır.

2.1 Geleneksel Yöntemler ile Görüntü Tamamlama

Görüntü tamamlama problemi üzerine birçok çalışma yapılmış ve uzun zamandır üzerinde çalışılmakta olan bir konudur. Geleneksel yöntemler difüzyon tabanlı ve yama tabanlı olmak üzere ikiye ayrılır.

Difüzyon tabanlı yöntemlerde, diferansiyel operatörler kullanılır. Diferansiyel operatör ile modellenen ayrıntılar bir süreci izleyerek arka plan verileri ile eksik bölgeleri tamamlarlar (Ballester vd., 2001; Esedoglu ve Shen, 2002).

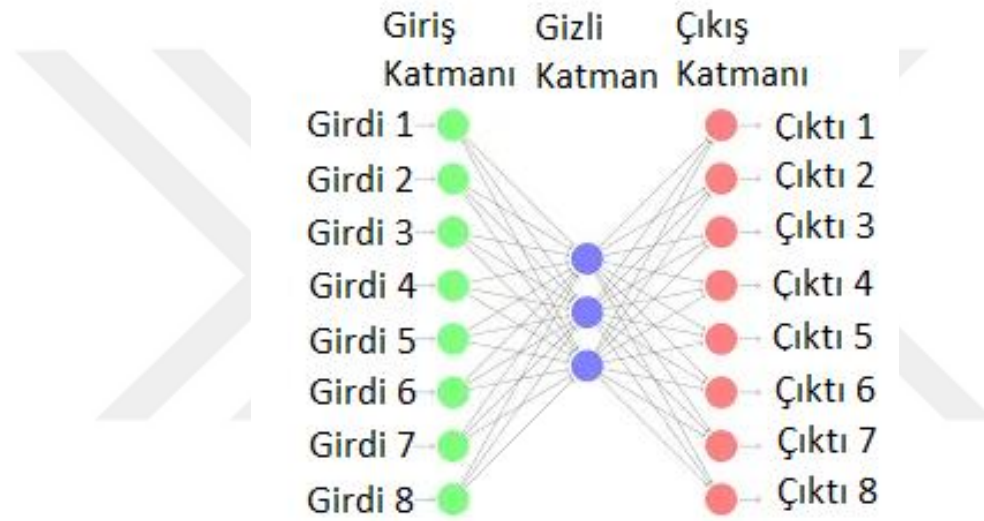
Yama tabanlı yöntemler, yama benzerliğini en üst düzeye çıkaran bir kaynak görüntü kümesinden yamalar ile eksik bölgeleri tamamlarlar (Barnes vd., 2009; Kwatra, Essa, Bobick, ve Kwatra, 2005). Geleneksel yöntemlerde genellikle yama eşleştirme (Barnes vd., 2009; Bertalmio vd., 2003) veya doku sentezi (Efros ve Freeman, 2001; Efros ve Leung, 1999) yöntemleri kullanılmaktadır. Tekrarlanan yapılandırılmış görüntülerin tamamlanmasında bu yöntem başarılıdır. Yama tabanlı yöntemler de görüntü tamamlama süreleri uzundur. Ayrıca, yöntemin doğası gereği karmaşık görüntüler ve sürekli tekrarlanmayan görüntülerde başarıları düşüktür.

2.2 Otomatik Kodlayıcılar (Auto Encoders)

Yapay sinir ağı modellerinin geliştirilmesi ile ortaya çıkmış olan oto kodlayıcılar, denetimsiz bir makine öğrenmesi yöntemidir. Klasik bir yapay sinir ağı modeli daha

önceki kısımlarda bahsedildiği gibi üç katmandan meydana gelmektedir. Yapay sinir ağlarının giriş katmanındaki nöron sayısı veri setindeki özellik sayısı belirtirken, çıkış katmanındaki nöron sayısını ise elde edilecek sınıf sayısı belirlemektedir.

Oto kodlayıcı mimarisinde giriş katmanındaki nöron sayısı genellikle gizli katmandaki nöron sayısından daha fazladır. Ayrıca oto kodlayıcılarda giriş veri setiyle çıkış veri setinin aynı olması dolayısıyla çıktı katmanındaki nöron sayısının girdi katmanındaki nöron sayısına eşittir (Ng, 2011). Şekil 1’de örnek bir otomatik kodlayıcı yapısı verilmektedir.



Şekil 1. Otomatik Kodlayıcı Yapısı

Oto kodlayıcıların girdi sayısı ile çıktı sayısının eşit olmasının amacı veriyi yeniden inşa etmektir. Giriş katman ile gizli katman arasında şifreleyici denir. Şifreleyici çok boyutlu veriyi az boyutlu hale getirir. Gizli katman ile çıkış katmanı arasında şifre çözücü denir. Şifre çözücü sıkıştırılmış gizli katmandaki verinin boyutunu arttırarak girdiyi çıktıya dönüştürür. Bu mimaride önemli girdi özellikleri gizli katmanda çıkarılır.

Oto kodlayıcılarının çok farklı kullanım alanları vardır. Kullanım alanlarına ses ve görüntü verileri içinde olup da veriyi bozan öğelerin veriden temizlenmesi örneği verilebilmektedir.

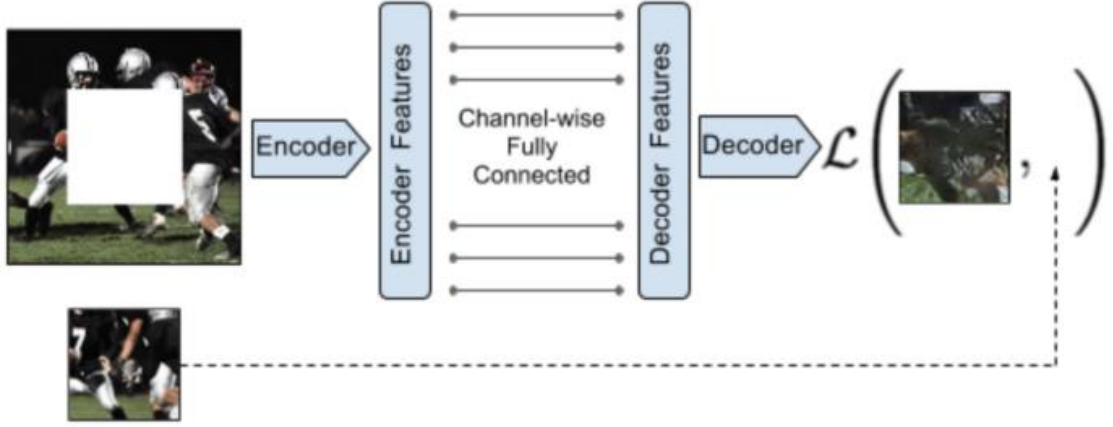
2.3 Baęlam Kodlayıcılar ile Görüntü Tamamlama (Context Encoders Feature Learning by Inpainting)

Baęlam kodlayıcılar, otomatik kodlayıcılara benzer yapıdadır ve bu yapı çekişmeli üretici aęların(GAN) temellerini oluştururlar. Baęlam kodlayıcılar denetimsiz bir görüntü tamamlama algoritmasıdır. Baęlam tabanlı piksel tahmini yaparlar. Otomatik kodlayıcılara benzer olarak, çevresi üzerinde koşullandırılmış rastgele bir görüntü bölgesinin içerięini oluşturmak için eęitilmiş bir evrişimsel sinir aęı altyapısı kullanırlar.

Baęlam kodlayıcılarda, katmanlar arasında tüm özellik konumlarının, geçerli katmandaki her bir özellik konumuna bir önceki katmanın katkıda bulunması prensibindedir. Bu sayede, aę tüm özellik konumları arasındaki ilişkiyi öğrenebilir ve tüm görüntünün daha derin bir anlamsal anlayışını öğrenebilir durumdadır. Baęlam kodlayıcılar, benzer bir kodlayıcı ve kod çözücü mimarisini paylaştığı için otomatik kodlayıcılarla yakından ilişkilidir (Bengio, 2009; Hinton ve Salakhutdinov, 2006).

Otomatik kodlayıcılar, temel olarak bir girdi görüntüsü alır ve görüntünün kompakt bir özellik deęerini elde etmek amacıyla düşük boyutlu bir darboęaz katmanından geçirir. Devamında kod çözücüde sonra görüntüyü yeniden oluşturmaya çalışırlar.

Baęlam kodlayıcılarda ise kodlayıcı, eksik bölgeleri olan tamamlanması gereken bir görüntüyü girdi olarak alır. Alınan görüntünün gizli bir özellik temsili üretir. Kod çözücü ise bu özellik temsilini alır ve eksik olan görüntünün deęerini üretir. Kodlayıcı, kod çözücü ve kod çözücüdeki her birimin tüm görüntü içerięi hakkında akıl yürütmesine izin veren, kanal bazında tam baęlantılı bir katman aracılıęıyla birbirlerine baęlanır. Şekil 2’de baęlam kodlayıcı mimarisine genel bakış verilmektedir.



Şekil 2. Mimariye Genel Bakış (Pathak, Krahenbuhl, Donahue, Darrell, ve Efros, 2016)

Otomatik Kodlayıcılarla ile bağlam kodlayıcılar arasındaki ana fark kanal bazında tam bağlantılı katmandır. Bu katmanlar öznetelik haritalarında uzak konumlardaki özneteliklerden yararlanmayı mümkün kılmaktadır.

Tam bağlantılı katmanlar, mevcut katmandaki her nöronun değeri, önceki katmandaki nöronların tüm değerlerine bağlı olacak şekilde çalışmaktadır. Bu ise, tam bağlantılı katmanlarda çok sayıda parametreye sebep olmaktadır. Bunun sonucunda eğitim zorlaşmaktadır. Bundan dolayı bağlam kodlayıcılarında kanal bazında tam bağlantılı katman kullanılmaktadır.

Kanal bazında tam bağlantılı katmanda, tüm kanallar yerine her kanalı bağımsız olarak bağlanır. Örneğin, $n \times n$ boyutunda m özellik haritamız olduğunu varsayalım. Standart tam bağlı katman kullanılırsa $m^2 n^4$ parametre, Kanal bazında tam bağlantılı katman için mn^4 parametre olur. Kanal bazında tam bağlantılı katmanda, çok fazla ekstra parametre eklemekten uzak konumlardan öznetelikler yakalana bilinir. Sistem iki kayıp fonksiyonundan oluşmaktadır Yeniden yapılandırma kaybı, eksik bölgenin genel yapısını ve bağlamıyla ilgili tutarlılığı yakalamaktan sorumludur. Piksel bazında yeniden yapılandırma doğruluğuna odaklanır ve her zaman bulanık görüntülerle sonuçlanır. Yeniden yapılandırma kaybı fonksiyonu L_{rec} olarak normalleştirilmiş maskelenmiş bir yeniden yapılandırma kaybı mesafesi;

$$L_{rec}(x) = || \hat{M} \odot (x - F((1 - \hat{M}) \odot x)) ||_2^2 \quad (2.1)$$

ile hesaplanmaktadır. Diğer bir kayıp, çekişmeli üretici ağlarda kullanılan çekişmeli bir kayıptır. Gerçek görüntüler ve doldurulmuş görüntüler arasında daha yakın veri dağılımlarını teşvik eder. Bağlam kodlayıcılar için çekişmeli kayıp \mathcal{L}_{adv} ,

$$\mathcal{L}_{adv} = \max_D \mathbb{E}_{x \in X} [\log(D(x)) + \log(1 - D(F((1 - \hat{M}) \odot x)))] \quad (2.2)$$

şeklinde tanımlanır. Genel kayıp fonksiyonunu şu şekilde tanımlanır:

$$\mathcal{L} = \lambda_{rec} \mathcal{L}_{rec} + \lambda_{adv} \mathcal{L}_{adv} \quad (2.3)$$

Bağlam kodlayıcılarda kodlayıcı ve kod çözücü, stokastik gradyan inişi (SGD) ve “Adam” optimizasyonu kullanılarak eğitilir. Bu yöntem, geleneksel yöntemlerden olan en yakın komşu (NN) görüntü tamamlama algoritması ile karşılaştırıldığında daha iyi performans göstermektedir.

Bu yöntemin literatüre ana katkısı kanal bazında tam bağlantılı katmandır. Bu yapı önceki katmandaki tüm özellik konumlarının, geçerli katmandaki her bir özellik konumuna katkıda bulunur. Bu ise görüntünün tamamı hakkında çok daha derin anlamsal anlayışa sahip olmamızı sağlar.

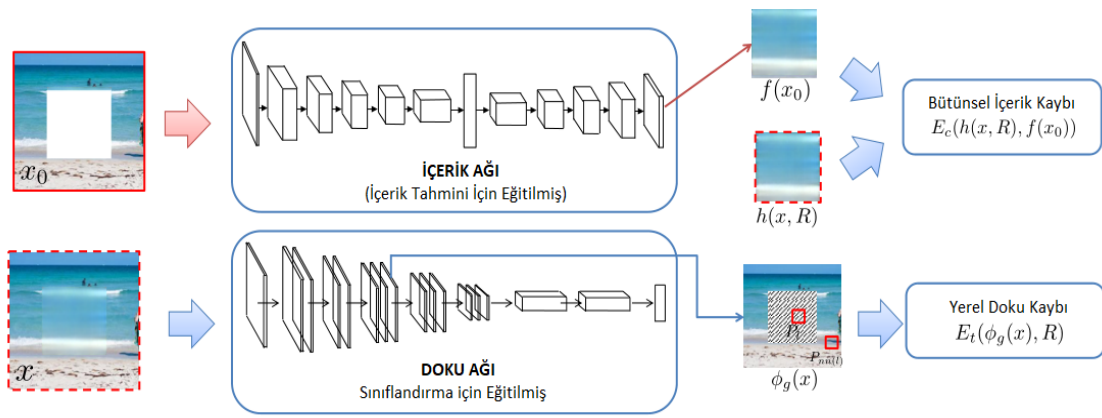
2.4 Çok Ölçekli Nöral Yama Sentezi Kullanarak Görüntü Tamamlama (High Resolution Image Inpainting using Multi-Scale Neural Patch Synthesis)

Bağlam kodlayıcılar ile görüntü tamamlama yönteminde bellek ve eğitim zorluğu nedeni ile düşük çözünürlüklü görüntüleri işler. Bağlam kodlayıcılar ile görüntü tamamlamada, eksik parçalar belirli bir derecede tahmin edebilmektedir. Tahmin edilen piksellerin dokularında ve ayrıntılarında iyileştirmesi gereken yerler olduğundan geliştirilmiş bağlam kodlayıcılar ile görüntü tamamlama yöntemi geliştirilmiştir.

Geliştirilmiş bağlam kodlayıcılar ile görüntü tamamlama yönteminde, eksik parçaları tahmin etmek ve tahmin edilen pikselleri elde etmek için bağlam kodlayıcılar kullanılırken, oluşturulan piksellerin doku ayrıntılarını geliştirmek için stil aktarım algoritmasını kullanır.

Bu yöntemin temeli, tahmin edilen piksellere ve geçerli piksellere, doku ayrıntılarını geliştirmek için en benzer geçerli piksellerin stilini, tahmin edilen piksellere aktarılmasıdır.

Bu yaklaşımda bir görüntünün stilini ve başka bir görüntünün içeriğini birleştiren görüntüler oluşturmak için kullanılabilceği, bu sayede doğal görüntülerin ince dokularını ve yüksek frekanslı ayrıntılarını oluşturmada sinirsel özelliklerin de kullanılabilceği gösterilmiştir. Şekil 3’de nöral yama sentezine dayalı mimariye genel bakış bulunmaktadır.



Şekil 3. Mimariye Genel Bakış (Yang vd., 2017)

Bu yöntemde kullanılan içerik ağı temelde özelleştirilmiş bir bağlam kodlayıcıdır. Orijinal bağlam kodlayıcıdan farkı ortadaki kanal bazında tam bağlantılı katman, standart tam bağlantılı katmanla değiştirilmesidir. Diğer bir fark ise doğrultulmuş doğrusal birim fonksiyon (ReLU) veya sızıntı doğrultulmuş doğrusal birim fonksiyon (Leaky ReLU) aktivasyon fonksiyon katmanları, üstel doğrusal birim fonksiyon (ELU) katmanları ile değiştirilmesidir.

Diğer bir katman olan doku ağının amacı, görüntü tamamlama için oluşturulan piksellerin ince ayrıntılarının, geçerli piksellerin ayrıntılarına benzer olmasını sağlamaktır. Diğer bir deyişle farklı katmanlardaki özellik haritaları, bir dereceye kadar görüntü stillerini temsil eder buradan yola çıkarak iki görüntü benzer özellik haritalarına sahipse, iki görüntünün benzer görüntü stillerine sahip olduğu anlamına gelmektedir.

Geliştirilmiş bağlam kodlayıcılar ile görüntü tamamlamada, toplam kayıp fonksiyonu, içerik kaybı, doku kaybı ve toplam varyasyon kaybı olmak üzere üç kayıp fonksiyonu bulunmaktadır

Girdi görüntüsü x_0 ve görüntüde tamamlanacak çıktı görüntüsü x_i olsun. İçerik ağı f , Doku ağı t olsun.

$$\tilde{x}_{i+1} = \underset{x}{\operatorname{argmin}} E_c(h(x, R), h(x_i, R)) + \alpha E_t(\phi_t(x), R^\Phi) + \beta Y(x) \quad (2.4)$$

Son terim, bir görüntünün düzgünlüğünü sağlamak için görüntü işlemede yaygın olarak kullanılan toplam varyasyon kaybı fonksiyonudur. Alfa ve beta, kayıp fonksiyonu dengelemek için kullanılan ağırlıklardır.

$$E_c(h(x, R), h(x_i, R)) = \|h(x, R) - h(x_i, R)\|_2^2 \quad (2.5)$$

R^Φ bölgesinde örneklenen yama sayısı $|R^\Phi|$, P_i , i konumunda ortalanan yerel sinirsel yamadır.

$$E_t(\phi_t(x), R) = \frac{1}{|R^\Phi|} \sum_{i \in R^\Phi} \|h(\phi_t(x), P_i) - h(\phi_t(x), P_{nn(i)})\|_2^2 \quad (2.6)$$

Her bir görüntü tamamlama yamasının P_i en yakın komşusunu $nn(i)$ aramak için aşağıdaki fonksiyon kullanılır.

$$nn(i) = \underset{i \in N(i) \wedge j \notin R^\Phi}{\operatorname{argmin}} \|h(\phi_t(x), P_i) - h(\phi_t(x), P_j)\|_2^2 \quad (2.7)$$

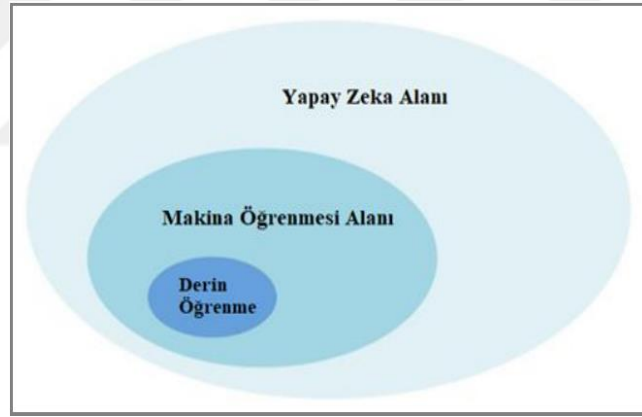
Pürüzsüzlüğü desteklemek ve kaybı hesaplama için aşağıdaki fonksiyon kullanılır.

$$Y(x) = \sum_{i,j} ((x_{i,j+1} - x_{i,j})^2 + (x_{i+1,j} - x_{i,j})^2) \quad (2.8)$$

3. MATERYAL VE YÖNTEM

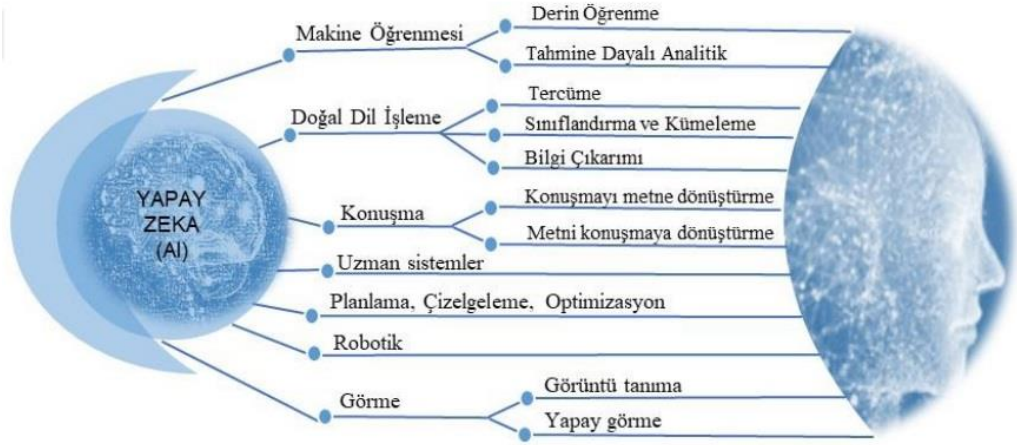
3.1 Yapay Zeka

Zaman içinde yapay zekâyı birçok kişi farklı tanımlamıştır. Nabiyev göre, bir bilgisayarın ya da bilgisayar destekli bir makinenin, genellikle insana özgü nitelikleri, çözüm yolu bulma, anlama, bir mana çıkartma, genelleme ve geçmişteki deneyimlerinden öğrenme gibi yüksek mantık süreçlerini yerine getirebilme yeteneği olarak tanımlarken (Nabiyev, 2012), Andrew ise; sezgisel programlama temelinde olan bir yaklaşım olarak tanımlamıştır (Andrew, 1991). Popov'a yapay zekâyı insanların yaptıklarını bilgisayarlara yaptırabilme çalışması olarak tanımlarken (Popov, 1990), Axe ise akıllı programları hedefleyen bir bilim olarak tanımlamıştır (Copeland, 1993). Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Arasındaki İlişki Şekil 4'te verilmiştir.



Şekil 4. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Arasındaki İlişki (Patterson ve Gibson, 2017)

Yapay zekâ olarak tanımlanan kavram makine öğrenmesi yöntemlerini, makine öğrenmesi kavramı ise derin öğrenme yöntemlerini kapsamaktadır. Yapay zekânın birçok kullanım alanı vardır. Bunlar; robotik, makine öğrenmesi, doğal dil işleme, bilgisayarlı görme, planlama ve optimizasyon gibi birçok uygulama alanı vardır. Bazı uygulama alanları Şekil 5'de gösterilmiştir (Atlam, Walters, ve Wills, 2018).



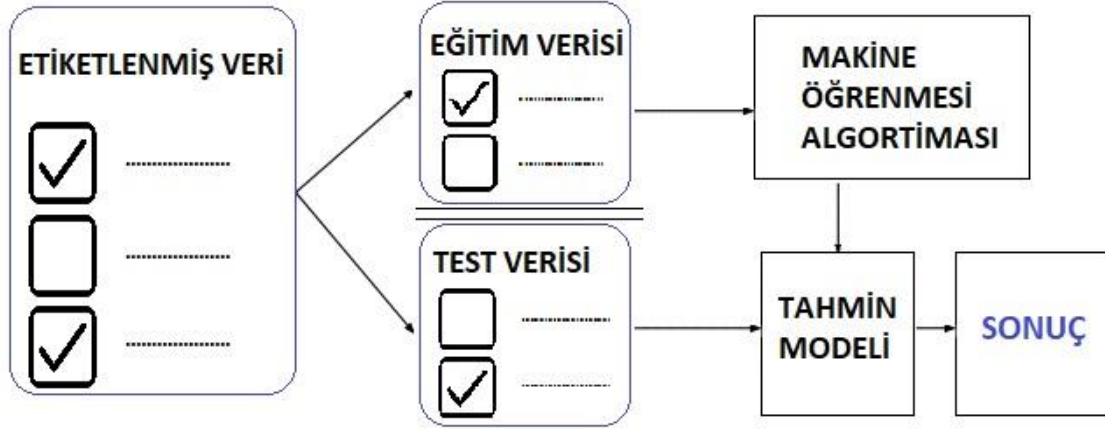
Şekil 5. Yapay Zeka Uygulamaları (Atlam vd., 2018)

3.2 Makine Öğrenmesi

Yapay zekânın bir alt kümesi olan makine öğrenmesi matematik ve istatistik biliminden yararlanarak verilerin üzerinde çıkarımlarda bulunarak tahminler yapan bilgisayarlı sistem modellenmesidir. Makine öğrenmesinin temelinde insan vardır. Makine öğrenmesi modelleri insanda olduğu gibi algılamak, öğrenmek ve karar vermeyi taklit ederler. Modellerdeki temel amaç insandan daha iyi olarak tespit etmek, algılamak ve öğrenmektir. Veri yapılarını analiz etmek yorumlamak ve bu analizlerden sonuçlar çıkarmak için algoritmaları kullanırlar. Makine öğrenmesi algoritmaları her veri ile aynı başarıyı göstermezler. Herhangi bir makine öğrenme algoritması kullanılmadan önce eğitim verilerine göre uygun bir algoritma veya model seçilmesi gereklidir. Makine öğrenmesinde öğrenme türleri üç gruba ayrılır bilinir.

Gözetimli Öğrenme; bu öğrenme şeklinde girdiler ve çıktılar arasında bir ilişki kuran fonksiyon ile oluşturulur. Gözetimli öğrenmede sistem etiketlenmiş veriler ile eğitilir. Bu ise verilerin doğru yanıtla eşleştirildiği anlamına gelmektedir. Temel amaç sonuçları bilinen veri setinden yapılan sınıflandırmadan hareketle sonuçları bilinmeyen veri setine dair etkili tahminler yapabilmektir (Aydın ve Özkul, 2015). Gözetimli öğrenmede algoritma etiketli veriler ile yapılan eğitimden öğrenir, bilinmeyen sonuçlu veriler için algoritma tahminlerde bulunur. Modelin başarısını arttırmak için veri üzerinde teknik uzmanlık gerektirir. En çok kullanılan gözetimli öğrenme algoritmaları karar ağaçları,

lineer regresyon, destek vektör makineleri ve lojistik regresyonu sıralana bilinir. Şekil 6'da gözetimli öğrenme akışı verilmektedir.



Şekil 6. Gözetimli Öğrenme Akışı

Gözetimsiz Öğrenme; bu öğrenmede giriş verisinin sınıfı belirsizdir, çıktılar öğrenmenin içinde bulunmaz ve bilinmeyen bir yapı tahmin edilir. Sistem otomatik olarak keşifler yapar, ilişki ağını ortaya koymaya çalışır (Alpaydın, 2020). Gözetimsiz öğrenmede etiketlenmemiş veri setini anlamlandırmak ve kümelemek için öğrenme algoritmaları kullanılır. Bu algoritmalar insan müdahalesine gerek duymadan verileri sınıflayabilme yeteneğine sahiptir. Gözetimsiz öğrenme modelleri kümeleme, ilişkilendirme ve boyut azaltma için kullanılırlar. Kümeleme verileri benzerliklerine veya farklılıklarına göre sınıflandırmak için kullanılan bir tekniktir. İlişkilendirme, belirli bir veri setinde değişkenler arasında ilişkiyi bulmak için kullanılan bir tekniktir. Boyut azaltma ise bir veri setinde özelliklerin sayısı çok yüksek olduğunda bu özelliklerin belli bir boyuta indirgenmesi yöntemidir.

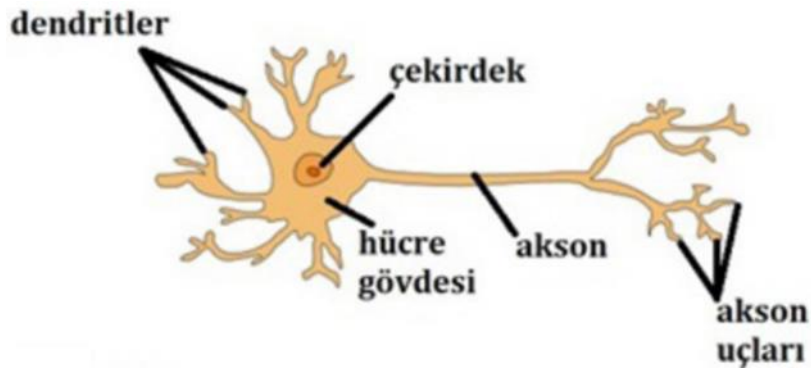
Takviyeli Öğrenmede ise; girdilerin etkileşime girerek ödül veya ceza ile geri bildirimler alması mantığına dayanır. Takviyeli öğrenmede amaç en uygun durumu bulmaktır. Takviyeli öğrenmede problemleri çözüme kavuşturmak için temel mantık eğitim uzayın ortamı iyiye götüreni bulmak, bu faydalı hareketi bulmak için istatistiki yöntemler kullanılmaktadır. Takviyeli öğrenme yönteminde kendisinden ne istediğini bilmemesine rağmen sürekli geri bildirimlerle (ödül veya ceza) görevini öğrenmesini ve onu mükemmel olmasını amaçlar.

3.3 Derin Öğrenme

Derin Öğrenme, beynin yapısından ve yapay sinir ağlarından ilham alınarak geliştirilen bir tür algoritmadır. Makine öğrenmesinin alt dallarından biri olan derin öğrenme, en az bir adet girdisi olan, içerisinde çok sayıda katman bulunan ve bir çıktısı olan bir algoritmadır. Derin öğrenmede her katman, kendisinden önceki katman ile bilgileri birleştirir ve bunlardan anlamlı sonuçlar üretir. Derin öğrenme, makine öğrenmesinin bir alt dalı olduğundan aynı şekilde denetimli ve denetimsiz öğrenme modellerine sahiptir. Derin öğrenme ile görüntü işleme, doğal dil işleme, el yazısı tanıma, çoklu sınıflandırma, regresyon problemleri, ses tanıma gibi birçok alanda çalışmalar yapılmaktadır.

3.3.1 Biyolojik sinir ağları

İnsan beyni çevresindeki olayları algılama, öğrenme ve karar vermesi bilgiye ihtiyaç duyar. Bu bilgi sinir sistemi üzerinden elde edilir. Sinir sistemi milyonlarca sinirden oluşmuş ve vücudu saran bir ağıdır. İnsan vücudundaki sinir sistemi üç aşamadan oluşur: Reseptörler, bir sinir ağı ve efektörler. Reseptörler, dış çevreden uyarıyı alırlar, sonra bilgiyi elektriksel itme biçiminde nöronlara geçirirler. Nöral ağ ise girdileri işler ve çıktılarının kararını verir. Son olarak, efektörler de elektriksel itme sinir ağından dış çevreye verilen yanıtlara dönüştürür. Özetle bu yapıda bilgi alınır, işlenir ve çıktıya dönüştürülür. Bu nöral ağın temel unsurları nöron olarak adlandırılır. Nöronlar gövde, çekirdek, dendrit ve akson dan oluşur. Şekil 7’de insana ait bir nöron yapısı şekli verilmektedir.




Şekil 7. Nöron Yapısı (Yılmaz ve Umut, 2021)

3.3.2 Yapay sinir ağıları


Alan Turing'in Makineler Düşünebilir Mi? sorusu ile ortaya çıkan makine öğrenmesi kavramı, insan beyin yapısının modellenene bilirlği ile de yapay bir sinir ağı sisteminin oluşturmasına imkân tanımıştır.

Sinir sisteminde bulunan biyolojik nöronlarda olduğu gibi, yapay nöronlar giriş sinyallerini alır, bu sinyaller toplanır ve işlenir ve çıkışlara iletilir. Şekil 8'de yapay nöron yapısına ait görsel verilmektedir.



Şekil 8. Yapay Nöron Yapısı (Yılmaz ve Umut, 2021)


Yapay nörona girdi olan her bilginin bir önem derecesi yanı bir ağırlığı vardır. Girdiler nörona geldiğin bu ağırlık değeri ile çarpılırlar. Bu ağırlıklar modelin eğitim süresince güncellenmektedir. Önemli olan girdiler yüksek ağırlığa sahipken, önemsiz girdiler düşük ağırlıklara sahiptirler. X_1 girdisinin W_1 ağırlığı düğümden geçtikten sonra $X_1.W_1$ olarak ifade edilir. Şekil 9'da yapay nöron yapısında ağırlıklara ait görsel verilmektedir.



Şekil 9. Yapay Nöron Ağırlıklar

Girdiye uygulanan ağırlıklara ek ve farklı olarak uygulanan doğrusal birleşene sapma denir. Bu sapma değeri girdinin ağırlık çarpımı sonucuna aralığı değiştirmek için eklenmektedir. X_1 girdisinin W_1 ağırlığı düğümden geçtikten ve sapma değeri eklendikten sonra $X_1 \cdot W_1 + b_1$ olarak ifade edilir.

Aktivasyon fonksiyonu, girdileri çıktılara çevirir. Sigmoid, ReLU, ve Basamak fonksiyonu gibi birçok farklı aktivasyon fonksiyonları bulunmaktadır. Şekil 10'da aktivasyon fonksiyonlarına ait grafikler verilmektedir.

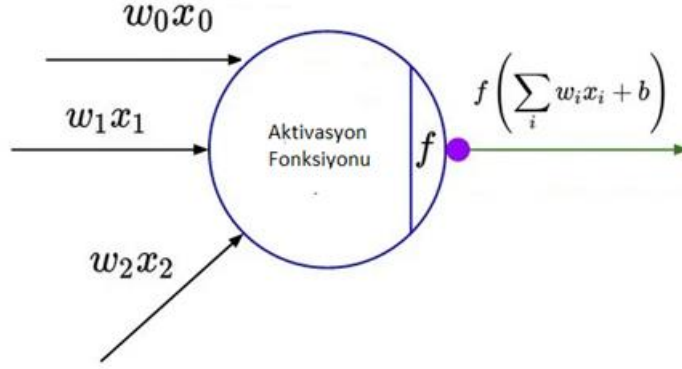


Şekil 10. Aktivasyon Fonksiyon Grafikleri

Girdilerin ağırlık değerlerinin çarpımına sapma değeri eklenmesi sonucu oluşan ifade u olarak kabul ettiğimizde;

$$u = \sum_i (w_i \cdot x_i) + b \quad (3.1)$$

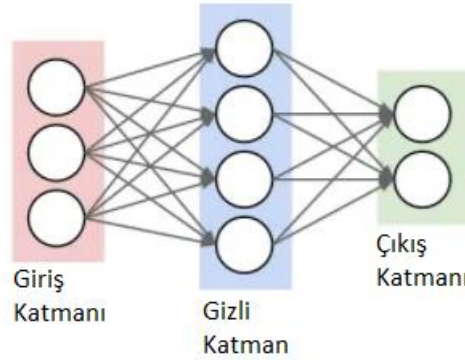
U ifadesine aktivasyon fonksiyonu eklenmesi sonucu $f(u)$ oluşur ve nöronun çıkışı $f(u)$ sonuç değeri olarak ifade edilir. Şekil 11'de yapay sinir hücre yapısı gösterilmektedir.



Şekil 11. Yapay Sinir Hücresi Yapısı


Yapay sinir ağı modelinde yapılan temel işlem; modelin en iyi skoru vereceği ağırlık olan W ve sapma değeri olan b parametrelerinin hesabını yapmaktır. Yapay sinir ağları tek gizli katmanlı olabileceği gibi çok katmanlı karmaşık sinir ağ yapısında olabilmektedir.

Tek katmanlı ağlar sadece giriş katmanı, gizli katman ve çıktı katmanından oluşur. Tek katmanlı sinir ağlarında çıktı fonksiyonu doğrusaldır ve 1 veya -1 değerlerini almaktadır. Eğer çıktı 1 ise birinci sınıfa, -1 ise ikinci sınıfa kabul edilmektedir (Öztemel, 2003). Şekil 12’de tek katmanlı sinir ağı yapısı verilmektedir.



Şekil 12. Tek Katmanlı Sinir Ağı Yapısı

Çok katmanlı sinir ağları doğrusal olmayan aktivasyon fonksiyonu olan birçok nöronun belli bir üstünlük içerisinde bağlandığı yapıya denir. Şekil 13’de çok katmanlı sinir ağı yapısı gösterilmektedir.



Şekil 13. Çok Katmanlı Sinir Ağı Yapısı

3.4 Veriler ve Toplanması

Makine öğrenmesi yöntemlerinde veri çok önemli bir yere sahiptir. Derin öğrenme sistemlerinde genellemeler yapılabilmesi için çok sayıda veriye ihtiyaç duyulmakta ve bu verilerin eğitilmesi gerekmektedir. Eğitim yapılacak konu ile ilgili verilerden oluşturulan kümeye veri seti olarak adlandırılır. Gözetimli öğrenme yönteminde veri setine etiketler atanmaktadır. Gözetimsiz öğrenme yöntemlerinde ise veri etiketlemesine gerek duyulmamaktadır. Çekişmeli üretici algoritmaları çoğunlukla gözetimsiz öğrenme yöntemlerini kullanırlar. Bu sebeple kullanılan veri seti çoğunlukla etiketsiz olarak yonteme verilmektedir. Algoritmanın verimli eğitimi ve yüksek başarılı çıktılar verebilmesi için modelin doğru kurgulanmasının yanı sıra verinin büyüklüğü, çeşitliliği ve temizliği de etkilemektedir.

Yapılan literatür araştırmasında Türkiye’deki arkeolojik eserler ile ilgili görüntülerin olduğu hiçbir veri seti bulunamamıştır. Endonezya da bulunan Borobudur Tapınağına ait kısıtlı bir veri seti bulunmuş bu eserler model geliştirme sürecinde kullanılmıştır.

3.4.1 Mozaik veri seti

Veri seti oluşturulurken dünyanın en büyük iki mozaik müzesi olan Gaziantep Zeugma mozaik müzesi ve Hatay Arkeoloji müzesindeki eserler kullanılmıştır. Veri seti oluşturulurken farklı açıdan görüntüler alınmıştır.

Zeugma mozaik müzesinde Roma Dönemi'ne ait 286 adet eserden 3.000 metrekare mozaığın 2.253 farklı açılarda fotoğrafı çekilmiştir. Hatay Arkeoloji müzesinde ise çoğu Roma dönemine ait 136 adet eserden 1.340 metrekare mozaığın 2.549 adet farklı açıdan fotoğrafı çekilmiştir. Hazırlanan veri setinde Zeugma Mozaik müzesi ve Hatay arkeoloji müzesinden 422 esere ait toplam 4.802 adet farklı açılardan mozaik resmi kullanılmıştır. Çekilen mozaik fotoğraf boyutları farklılık göstermektedir. Mozaik resim kümesinde ön işleme olarak veri arttırma teknikleri kullanılmıştır. Bunun için Albumentations açık kaynak kütüphanesinden yararlanılmıştır (Buslaev vd., 2020). Mozaik veri setindeki verileri arttırma işlemleri; görüntüyü yatay çevirme, görüntüyü büyütme veya küçültme, görüntüyü belirli açılar ile döndürme işlemlerinden oluşmaktadır.

3.4.2 Rölyef veri seti

Veri seti oluşturulurken İstanbul arkeoloji müzesi, Ankara medeniyetler müzesi, Gaziantep arkeoloji müzesi ve Hatay Arkeoloji müzesindeki eserler kullanılmıştır. Veri seti oluşturulurken farklı açıdan görüntüler alınmıştır.

Hazırlanan veri setinde dört arkeoloji müzesinde 568 esere ait toplam 4.297 adet farklı açılardan rölyef resmi kullanılmıştır. Çekilen rölyef fotoğraf boyutları farklılık göstermektedir. Rölyef resim kümesinde ön işleme olarak veri arttırma teknikleri için Albumentations açık kaynak kütüphanesinden yararlanılmıştır (Buslaev vd., 2020). Rölyef veri setindeki verileri arttırma işlemleri; görüntüyü yatay çevirme, görüntüyü büyütme veya küçültme, görüntüyü belirli açılar ile döndürme işlemlerinden oluşmaktadır.

3.5 Verilerin Değerlendirilmesi ve Yorumlanması

Geliştirilen modelin başarısının ölçümlenebilmesi çok önemli bir konudur. Model sonucu oluşan çıktılar da bir görüntü olduğundan bu yeni görüntünün üretilme başarısını ölçümlemek ve sayısal veri haline getirmek doğru yorumlama açısından önemlidir.

Yapay Sinir Ağları ve makine öğrenmesi yöntemlerinin performans değerlendirmelerinde kullanılan temel performans göstergeleri arasında MSE, RMSE ve MAE sayılabilir (Karasu, Altan, Saraç, ve Hacıoğlu, 2018).

Model çıktılarının değerlendirilmesi sürecinde veri seti iki ye bölünmüş, hiçbir hasarı bulunmayan görüntülerden oluşan veri seti kullanılmıştır. Bu veri setinde yapay hasar oluşturulmuş ve bölümde incelenen iki görüntünün karşılaştırılması yöntemleri ile orijinal resim ve üretici modelin ürettiği çıktı görüntüler karşılaştırılarak sonuç değerleri paylaşılmıştır.

3.5.1 Yapısal benzerlik indisi (Structural similarity index)

Yapısal benzerlik indisi (SSIM) 2004 yılında Wang ve arkadaşları tarafından duyurulmuştur (Wang, Bovik, Sheikh, ve Simoncelli, 2004). Yapısal benzerlik indisi parlaklık, kontrast ve yapı olmak üzere üç karşılaştırmaya ayırır.

SSIM, iki resim arasındaki benzerliği korelasyon kaybı, parlaklık bozulması ve kontrast bozulması olmak üzere üç faktörün bir kombinasyonunu modelleyerek ölçmektedir.

x ve y' yi birer görüntü olarak varsayarsak, iki görüntü arasındaki karşılaştırma,

$$SSIM(x, y) = [I(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (3.2)$$

şeklinde gösterilir.

$$I(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (3.3)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (3.4)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x \sigma_y + C_3} \quad (3.5)$$

iki görüntü arasındaki parlaklığı hesaplayan μ_x ve μ_y yaklaşık parlaklığı ölçer. İki görüntünün eşit olması durumunda 1'e eşittir.

iki görüntü arasındaki kontrast yakınlığını hesaplayan σ_x ve σ_y standart sapması kontrastı ölçer, $\sigma_x = \sigma_y$ olduğu durumda maksimum değer olan 1 değerini alır.

SSIM endeksi $[0, 1]$ aralığındadır. İki resim arasında az korelasyon var ise 0, çok korelasyon var ise 1 dir. Pozitif sabitler (C_1, C_2 ve C_3) bölenin sıfır olmasını önlemek için kullanılmıştır (Hore ve Ziou, 2010; Karakis ve Guler, 2018).

3.5.2 Ortalama hata karesi (Mean square error)

Ortalama hata karesi(MSE) bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu söyler. Her zaman pozitif olan bu değer, tahmin edilen değerler gerçek değerlere ne kadar yakınsa ortalama hata karesi o kadar küçük olur ve 0 a yakınsar (Hore ve Ziou, 2010).

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.6)$$

3.5.3 Ortalama hata karesi kökü (Root mean square error)

Ortalama hata karesi kökü (RMSE) hatalarının standart sapmasıdır. Özetle, regresyon hattının veri noktalarından ne kadar uzakta olduğunu bir ölçüsüdür; Ortalama hata karesi kökü 0'dan ∞ aralığında değer alır. Bu değerinin sıfır olması modelin hiç hata yapmadığı anlamına gelmektedir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3.7)$$

3.5.4 Tepe sinyal gürültü oranı (Peak signal-to-noise ratio)

Tepe sinyal gürültü oranı (PSNR), iki görüntü arasındaki desibel cinsinden benzerlik hata oranını hesaplar. I_{max} PSNR değeri hesaplanacak görüntünün en büyük gri ton değeridir. Bu değer en yüksek gri seviye değeri olduğu için genellikle 255 olarak kullanılır.

$$PSNR = 10 \log_{10} \left(\frac{I_{max}^2}{MSE} \right) \quad (3.8)$$

MSE ortalama hata karesi değerini ifade etmektedir. Bu değer sıfıra yaklaştıkça PSNR değeri sonsuza yaklaşır; bu ise daha yüksek bir PSNR değerinin ve daha yüksek bir görüntü kalitesi sağladığını gösterir (Hore ve Ziou, 2010). PSNR değeri küçüldükçe, görüntüler arasında yüksek sayısal farklılıklar anlamına gelir. PSNR değeri ne kadar yüksek olursa, yeniden oluşturulmuş görüntünün kalitesi o kadar iyi olur.

3.5.5 Ölçek değişmez özellik dönüşümü (Scale invariant feature transform)

Ölçek değişmez özellik dönüşümü (SIFT), görüntü tabanlı eşleştirme, benzerlik ve tanıma için kullanılan bir algoritmadır. Bir imgenin farklı görünüşleri arasında anahtar nokta eşleştirme ile görünüm tabanlı nesne tanıma ve eşleştirme mantığı ile çalışır. Algoritma çalışması dört adımdan oluşur. Bunlar ölçek alan tespiti, anahtar nokta yerleştirme, yönlendirme ataması ve anahtar nokta tanımlayıcıdır. Ölçek alan tespitinde görüntünün ölçek alanı oktalara ayrılır. Oktav sayısı ve ölçek orijinal görüntünün boyutuna bağlı olarak değişmekle birlikte her oktavın boyutu bir öncekinin yarısı kadardır. Anahtar nokta yerleştirme adımında tepe noktaları elde edilmesinden sonra her iki yönde gradyan alınarak düz bölge, köşe veya kenar bulunarak anahtar noktalar bulunur. Yönlendirme ataması adımında döndürmeden bağımsız özellik kazandırılarak her bir anahtar nokta için, etrafındaki gradyanların yönleri ve büyüklüğü toplanır. Anahtar nokta tanımlayıcı adımında her bir anahtar nokta birbirinden ayrılarak, her bir pencerede büyüklük ve yön bakımından gradyanlar hesaplanır.

3.6 Çekişmeli Üretici Ağ (Generative Adversarial Networks)

Derin öğrenme algoritmaları temelli olan çekişmeli üretici ağlar üretken modeller içerisinde yer almaktadır. Çekişmeli üretici ağ modellerinin çalışma temeli bir veri seti ile eğitilerek, eğitim sonrasında öğrendiği veriye göre yeni bir değer üretmektedir. Çekişmeli üretici ağlarının başlıca odağında model üretimi bulunmaktadır (Goodfellow, Bengio, ve Courville, 2016).

Çekişmeli üretici ağlar klasik derin ağ mimarilerinden farklı olarak iki farklı derin ağa sahiptir ve bu iki ağın birbiri ile çekişmeli olarak çalışmasıyla öğrenme işlemini gerçekleştirirler. Bu ağlardan biri üretici ağ diğeri ise ayırıcı ağdır.

Üretici model ise; giriş olarak aldığı belirsiz, gürültü şeklindeki bir veriyi daha temiz ve anlaşılabilir bir veriye dönüştürmektedir. Bu işlemi yaparken modelin hedefi her seferinde eğitim kümesindeki gerçek görüntülere benzetmeyi çalışmaktır. Bu işlemi yapmak için ayırıcı modelden gelen maliyet fonksiyonuna bakar. Bu değere göre üretimlerini güncelleyerek en uygun sonuca ulaşana kadar bu işlemi yapmaya devam eder.

Ayırıcı model; evrimsel bir sınıflandırıcıdır, temel olarak yaptığı iş gelen görüntüleri sahte ya da gerçek olarak sınıflandırmaktır. Ayırıcı model, üretici modelin üretimlerini kontrol edebilmesi yani sahte ya da gerçek olarak sınıflandırabilmesi için gerçek veri seti ile eğitilir. Bu modelin iki farklı maliyet fonksiyon çıktı değeri vardır. Bu değerlerden biri eğitim sürecinde kendi eğitimini daha uygun hale getirerek eğitimi iyileştirmek, diğeri ise üretici modelden gelen verinin kontrolü sonucu kayıp fonksiyonu çıktısını üretici modele vermektir.

$x^{(i)}$ gerçek görüntü örneği, $z^{(i)}$ gürültü vektörünü temsil etmek üzere çekişmeli üretici ağ algoritması aşağıdaki gibi verilmiştir (Goodfellow vd., 2014; Hua ve Jégou, 2016).

Adım 1: Başla

Adım 2: **for** iterasyon sayısı **do**

Adım 3: **for** adım sayısı(k) **do**

Adım 4: Sahte görüntü üret $\{G(z^{(1)}), \dots, G(z^{(m)})\}$

Adım 5: $\{(x^{(1)}), \dots, (x^{(m)})\}$ gerçek görüntüleri al ve ayırıcıyı eğit

$$\nabla_{\theta_d} = \frac{1}{m} \sum_{i=1}^m \{\log D(x^{(i)}) + \log(1 - D(G(z^{(i)})))\} \quad (3.9)$$

Adım 6: **end for**

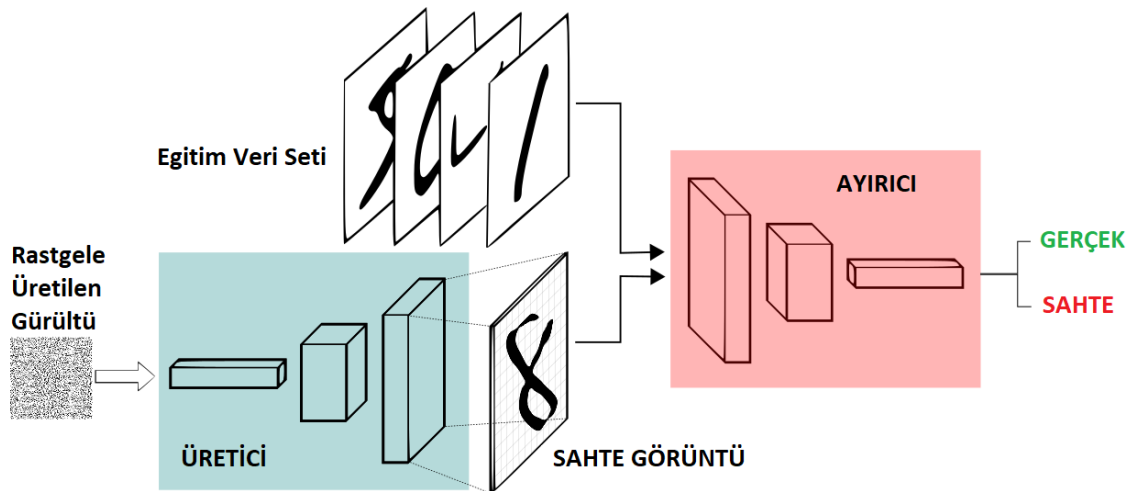
Adım 7: Sahte görüntüler üret $\{G(z^{(1)}), \dots, G(z^{(m)})\}$ Üreticiyi eğit

$$\nabla_{\theta_g} = \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(z^{(i)}))) \quad (3.10)$$

Adım 8: **end for**

Adım 9: $G(z^i)$ sahte görüntü örneği

iterasyon_sayısı değişkeni G ve D ağlarının kaçar defa eğitileceğini belirtmektedir. Sahte ve gerçek görüntüyü ayırt etme işlemini geleneksel evrişimli sinir ağı (CNN) ile yapmaktadır. Şekil 14'te genel olarak çekişmeli üretici ağ mimari verilmektedir.




Şekil 14. Çekişmeli Üretici Ağ Mimarisi (Silva, 2021)

Evrişimli sinir ağları giriş görüntüsündeki çeşitli nesnelere birbirinden ayırabilen derin öğrenme algoritmasıdır. Evrişimsel katmanda girdi görüntüsündeki piksel matrisi üzerinde bir filtre gezdirilerek özellik çıkarımı elde edilmesi amacı ile oluşturulan matris

öznitelik haritası ya da aktivasyon haritası denir. Görüntü üzerinde filtrenin gezmesi ile birlikte, filtre ve görüntüdeki piksel değerleri ile oluşan matris çarpımı işlemi evrişim veya konvolüsyon olarak adlandırılır.

Konvolüsyon katmanındaki çıktıyı etkileyen bir diğer etken adım değeridir. Bu değer konvolüsyon işlemi uygulanırken filtrenin görüntü matrisi üzerinde kaç piksel kayacağı adım değeri ile belirlenmektedir.

Matrise konvolüsyon işlemi uygulandığında kenar piksellerdeki bilgileri kaybetme durumu ortadan kaldırmak için dolgulama işlemi uygulanmaktadır. Literatürde çeşitli dolgulama yöntemleri bulunmaktadır. En yaygın olanları; 0-dolgulama, 1-dolgulama, dairesel dolgulama ve simetrik dolgulama yöntemleri olarak listelenebilir (Paoletti, Haut, Plaza, Plaza, ve Sensing, 2019). Şekil 15’de örnek bir evrişimli sinir ağı modeli verilmektedir.



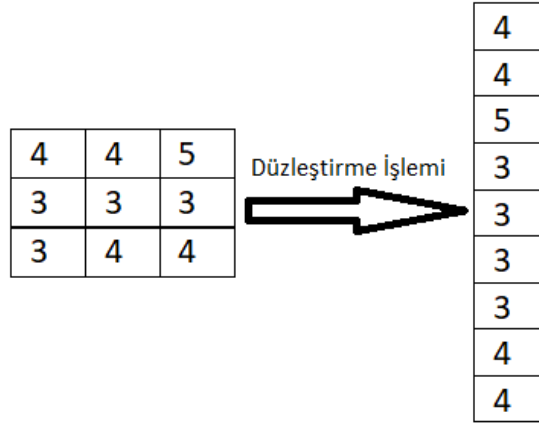
Şekil 15. Evrişimli Sinir Ağı Modeli (Kızrak ve Bolat, 2018)

Havuzlama katmanı matristeki öne çıkan özellikleri daha belirgin hale getirmek, önemsiz özellikleri göz ardı etmek ve matris boyutunun azaltılmasını sağlamaktadır. Bu sayede hesaplama maliyeti azaltılması hedeflenir.

Bu katman ile parametre sayısı azaltılarak, öğrenme yeteneğinin geliştirilmesine katkı sağlanırken ayrıca ağı ezberleme ihtimali azalır. Ortalama havuzlama, en yüksek havuzlama ve toplam havuzlama yöntemleri en yaygın kullanılan yöntemlerdir.

Tam bağlantılı katman; Havuzlama katmanı ve ReLU aktivasyon işlevinden sonra gelir. Bu katmanda matris halinde bulunan girdiye düzleştirme işlemi uygulanır. Düzleştirme işlemi sonrası tam bağlantılı katmanın girdisi hazırlanmış olur. Bazı mimarilerde tam

bağlantılı katmandan sonra bir seyreltme katmanı olabilmektedir. Bu katmanda, nöronların ağırlıkları sifira eşitlenerek ağıdaki ezberlemenin engellenmesi hedeflenir. Şekil 16’da örnek bir matris düzleştirme işlemi verilmiştir.



Şekil 16. Matris Düzleştirme İşlemi

Yapay sinir ağlarında aktivasyon fonksiyonları her bir nöronun çıktısını, hızını ve aktifleşip aktifleşmeyeceğini belirlemektedir. Evrişimli sinir ağlarında ağı öğrenmesine doğrusal olmayan bir yaklaşım sergilemek için genellikle doğrusal olmayan bir aktivasyon fonksiyonu kullanılır. Çeşitli aktivasyon fonksiyonları bulunmaktadır. Sigmoid, tanjant hiperbolik, softmax ve ReLU yaygın kullanılan aktivasyon fonksiyonlarından. Aktivasyon fonksiyonlarından basamak fonksiyonu ikili değer alan bir fonksiyondur, genellikle çıkış katmanlarında tercih edilir. Doğrusal fonksiyonlar basamak fonksiyonlarından farklı olarak ikili değer dışından aktivasyon değeri üretirler. Doğrusal fonksiyonların birleşimi yine bir başka doğrusal fonksiyon olduğundan ara katmanlarda bu soruna sebep olabilmektedir. Sigmoid fonksiyon iyi bir sınıflayıcı fonksiyondur. Bu fonksiyonun avantajı her zaman (0,1) aralığında değer üretir. Sık kullanılmakla beraber gradyanların ölmesi yada kaybolması probleminden dolayı daha verimli alternatifleri de vardır. Hiperbolik Tanjant fonksiyonu, sigmoid fonksiyonuna benzer bir yapıya sahip olup aralığı (-1,+1) olarak tanımlanmaktadır. Sigmoid fonksiyonuna göre avantajı ise bu aralıkta daha çok değer alabilmesidir. Fonksiyon uçlarında gradyanların ölmesi problemi burada da oluşmaktadır. ReLU aktivasyon fonksiyonu negatif değere sahip nöronların ağırlıklarının 0'a eşitlenerek sadece pozitif nöronları aktive eder. Bu sayede hesaplama maliyeti düşerken, ağı daha önce sahip olmadığı doğrusal olmayan özelliğe sahip olması sağlanarak daha iyi sonuçlar vermesi

beklenir. ReLU'nun kullanımı işlemsel gücü bakımından hızlı olmasına rağmen gradyanların ölmesi ya da kaybolması problemi olabilmektedir. Bundan kurtulabilmek için LeakyReLU fonksiyonu kullanılır, bu fonksiyon ise işlem gücü daha yoğun olması nedeniyle eğitim süresini uzatmaktadır. Softmax fonksiyonu, sigmoid fonksiyonuna çok benzer sınıflayıcı olarak kullanıldığında oldukça iyi bir performans sergiler. İki'den fazla sınıflamak gereken durumlarda özellikle modelin çıkış katmanında tercih edilmektedir. Swish fonksiyonu, negatif bölgede ve doğrusal olmayan değerler alır. Tüm aktivasyon fonksiyonları monoton iken Swish fonksiyonun çıktısının girdi arttığında bile düşebilme özelliğine sahiptir. Tablo 1'de aktivasyon fonksiyonlarının bulunduğu aralık ve denklemleri verilmektedir.

Tablo 1. Aktivasyon Fonksiyonları

<i>Fonksiyonlar</i>	<i>Denklem</i>	<i>Aralık</i>
<i>Doğrusal Fonksiyon</i>	$f(x) = x$	$(-\infty, \infty)$
<i>Basamak Fonksiyonu</i>	$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ 1 & \text{için } x \geq 0 \end{cases}$	$\{0,1\}$
<i>Sigmoid Fonksiyon</i>	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0,1)$
<i>Hiperbolik Tanjant Fonksiyonu</i>	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1,1)$
<i>ReLU</i>	$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ x & \text{için } x \geq 0 \end{cases}$	$[0, \infty)$
<i>Sızıntı ReLU</i>	$f(x) = \begin{cases} 0.01 & \text{için } x < 0 \\ x & \text{için } x \geq 0 \end{cases}$	$(-\infty, \infty)$
<i>Swish Fonksiyonu</i>	$f(x) = 2x\sigma(\beta x) = \begin{cases} \beta = 0 & \text{için } f(x) = x \\ \beta \rightarrow \infty & \text{için } f(x) = 2\max(0, x) \end{cases}$	$(-\infty, \infty)$

kullanılarak çekişmeli üretici ağ eğitilir. Bozuk görüntüler gerçek görüntü ile sınırlandırılır ve "en yakın" sağlam olana göre tamamlanır. Görüntü üzerindeki düşük seviyeli bilgilerin üretilmesi ve yüksek frekanslı detaylar üretebilmesi için genellikle optimizasyon tabanlı yaklaşımlar ve örnek tabanlı yaklaşımlar kullanılır.

Optimizasyona Dayalı Yaklaşımda, önceden eğitilmiş görsel geometri grubu (VGG) ağından hesaplanabilen ve çıkarılabilen yüksek frekanslı ayrıntıları üretmek ve yönlendirmek için kullanılır. Örnek Temelli Yaklaşımda, eksik parçanın, mevcut bölgedeki yamaların mekânsal olarak yeniden düzenlenmesi olduğuna mantığı ile çalışmaktadır. Bu yaklaşımda görüntü tamamlama süreci, eksik parçanın dışından içeriye doğru mevcut bölgeleri kullanarak bir arama ve kopyalama işlemi olarak yapılır.

Optimizasyon ve örnek tabanlı yaklaşımlar çoğunlukla bir görüntünün merkez kısmında olduğu varsayılan dikdörtgen şeklindeki boşlukları tamamlamaya odaklanır. Bu ise yaygın olarak kullanılan uygulamaları sınırlar. Bu nedenle, düzensiz alanların doldurmak için çeşitli yöntemler önerilmiştir.

Görüntü tamamlama çözümleri, genellikle mevcut ve eksik bölgeler arasındaki farkı veya korelasyonu görmezden geldiğinden büyük eksik alanları uygun içerik ile dolduramazlar özellikle büyük bitişik eksik bölgelerle karşı karşıya kaldıklarında kötü performans gösterirler. Bölge bazında görüntü tamamlama yönteminde, anlamsal çıkarım ağları ve küresel algılama ağlarından oluşurlar. Semantik çıkarım ağları, bölge bazında evrişim ve yerel olmayan işlemi kullanarak farklı bölgeler arasındaki farklar ve korelasyonlarla ilgilenmeye odaklanır.

Modelin Eğitim Algoritması aşağıdaki gibidir.

Adım 1: **while** tekrarla $t < T_{\text{egit}}$ **do**

Adım 2: I_g örnek toplu resimleri

Adım 3: M devam eden ikili maskeleri

Adım 4: $I_g = I_g \odot M$ giriş görüntüleri

Adım 5: $I_p^{(1)} = D_s(E_s I_g)$ anlamsal çıkarım ağları tarafından tahmini

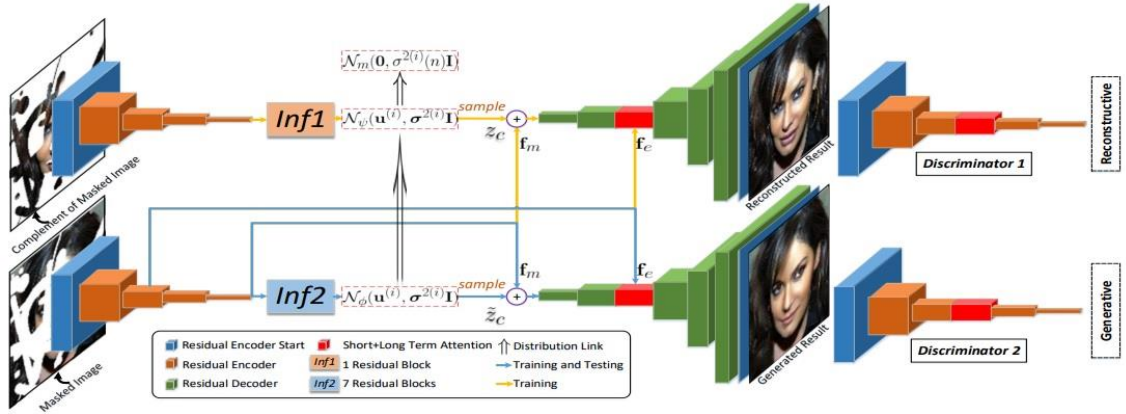
- Adım 6: $I_c^{(1)} = I_g + I_p^{(1)} \odot (1 - M)$ birleştirilmiş görüntüleri
- Adım 7: $I_p^{(2)} = D_g (E_g (I_c^{(1)}))$ küresel algılama ağları tarafından tahmini
- Adım 8: $I_c^{(2)} = I_g + I_p^{(2)} \odot (1 - M)$ çıktı görüntüleri oluşturur
- Adım 9: $I_p^{(1)}$ den \mathcal{L}_c , $I_p^{(2)}$ den \mathcal{L}_s , $I_p^{(1)}$ ve $I_p^{(2)}$ den \mathcal{L}_r hesaplar
- Adım 10: **if** $t < T_{\text{öneğitim}}$ **then**
- Adım 11: E_s , D_s , E_g ve D_g ile \mathcal{L}_c , \mathcal{L}_s ve \mathcal{L}_r günceller
- Adım 12: **else**
- Adım 13: \mathcal{L}_a dan $I_g \odot (1 - M)$, $I_p^{(1)} \odot (1 - M)$ ve $I_p^{(2)} \odot (1 - M)$ hesaplar
- Adım 14: E_s , D_s , E_g ve D_g ile \mathcal{L}_c , \mathcal{L}_s ve \mathcal{L}_a günceller
- Adım 15: D_r ile $-\mathcal{L}_a$ güncelle
- Adım 16: **end if**
- Adım 17: **end while**

3.6.2 Çoğul görüntü tamamlama (Pluralistic image completion)

Doldurulacak içeriğin hayal edilmesi, maskeli ve maskesiz bölgeler arasında yapısal sürekliliğin sağlanması ve eksik bölgeler için görsel olarak gerçekçi içeriğin doldurulması bu sürecin temel adımlarıdır. Görüntü tamamlama ise öznel bir süreçtir (Zheng, Cham, ve Cai, 2019). Hasar görmüş bir portrenin görüntüsünü tamamlanması için bir uzmanlardan yardım alınmak istenseydi gözler, ağız ve burun gibi genel olarak üst düzey tamamlamalar üzerinde genel olarak hemfikir olunsa bile, detay ayrıntıda önemli ölçüde farklı ayrıntılar oluşacak ve farklı portrelerin oluştuğu gözlemlenecekti.

Görüntü tamamlama algoritmalarında pek çok makul olasılık olmasına rağmen, çoğu yöntem her maskelenmiş girdi için yalnızca bir sonuç üretir. Temelde bu yöntem makul diğer olasılıkların da sonucunu çıktı olarak verme prensibine göre çalışır. Bu algorithmada buradan yola çıkarak tamamlanması istenen görüntünün, yalnızca tek bir “tahmin”

üretmeye çalışan yaklaşımların aksine birden fazla ve çeşitli makul sonuçlarını üretmektedir. Şekil 18’de görüldüğü gibi iki paralel ardışık mimariye genel bakışı göstermektedir.



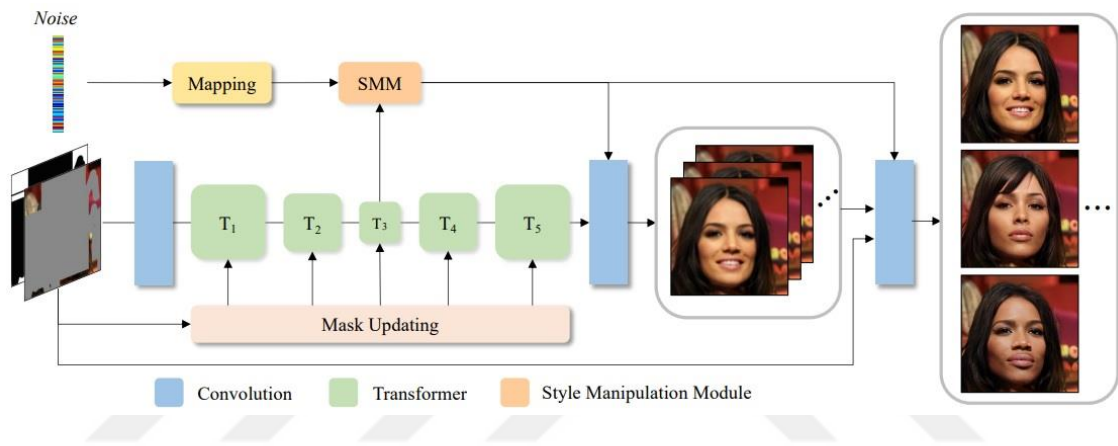
Şekil 18. İki Paralel Ardışık Mimariye Genel Bakış (Zheng vd., 2019)

Orijinal görüntümüz I_g , maskelenmiş kısmi görüntü I_m olduğunu varsayalım. I_c 'yi, gizli piksellerini içeren tamamlayıcı kısmi görüntüsü olarak tanımlıyoruz. Klasik görüntü tamamlama yöntemlerinde, I_m 'den deterministik bir tarzda maskesiz gerçek I_g görüntüsünü yeniden oluşturmaya çalışır. Bu ise yalnızca tek bir çözümle sonuçlanır. Bu yöntemde ise $p(I_c | I_m)$ 'den örnekleme yapmaktadır.

Bu yöntem, şekilde gösterildiği gibi ikili akış olarak çalışmaktadır. Üst rekonstrüktif yol, tüm görüntüden gelen bilgileri kullanır, yani $I_g = \{I_c, I_m\}$, alt üretici yol ise yalnızca I_m görünür bölgelerden gelen bilgileri kullanır. Hem temsil hem de üretim ağları aynı ağırlıkları paylaşır. Üst rekonstrüktif yol için, eğitim sırasında $q_\psi(\cdot | I_c) = N_\psi(\cdot)$ önem fonksiyonunu anlamak için tamamlayıcı kısmi görüntü I_c kullanılır. Örneklenen gizli vektör z_c böylece eksik bölgelerin bilgisini içerirken koşullu öznitelik f_m görünür bölgelerin bilgisini kodlar. Yeterli bilgi olduğu için, bu yoldaki kayıp fonksiyonu, orijinal görüntü I_g 'yi yeniden oluşturmaya çalışır. Aynı zamanda tamamlanacak olan görüntünün gizli dağılımı I_c, I_m 'e dayalı olarak çıkarılır. Bu, üst yoldaki çıkarımdan önemli ölçüde daha az doğru olacaktır. Bu nedenle, yeniden oluşturma kaybı yalnızca görünür bölgeler I_m 'i (f_m aracılığıyla) hedef alır. Her iki yolda da çekişmeli öğrenme ağlarından yararlanır. İdealde bu tam sentezlenmiş verilerin eğitim seti dağılımına uymasını sağlar ve ampirik olarak daha yüksek kaliteli görüntülere yol açar.

3.6.3 Büyük kayıplı görüntü tamamlama için maske uyumlu dönüştürücü (Mask aware transformer for large hole image inpainting)

Bu yöntemde, büyük alanlı görüntü tamamlama için yüksek çözünürlüklü tamamlanmış sonuçlar üretebilen yeni bir görüntü tamamlama dönüştürücüsü geliştirilmiştir. Bu dönüştürücüde, geleneksel katman normalleştirilmesi kaldırılmıştır (Ba, Kiros, ve Hinton, 2016). Öğrenmeyi özellik birleştirme kullanarak ve füzyon öğrenmeyle değiştirilerek optimizasyon kararlılığını artırılmıştır. Performansı iyileştirmek için vanilya dönüştürücü bloğu özelleştirilmiştir.



Şekil 19. Genel Mimari (Li vd., 2022)

Şekil 19'da gösterildiği gibi, bu mimaride bir evrişimli kafa, bir dönüştürücü gövdesi, bir evrişimli kuyruk ve bir stil manipülasyon modülünden oluşur.

Belirteçleri çıkarmak için bir evrişimli kafa kullanılır, ardından değişen çözünürlüklerde (farklı sayıda belirteçle) beş aşamalı dönüştürücü bloğuna sahip ana gövde, önerilen çok başlı bağlamsal dikkat aracılığıyla uzun menzilli etkileşimleri modeller.

Evrişim kafası tamamlanacak görüntü ve verilen maskeyi alır ve belirteçler için kullanılan 1/8 boyutlu özellik haritaları üretir. Bir tanesi giriş boyutunu değiştirmek için ve diğerleri de çözünürlüğü aşağı örneklemek için toplam dört evrişimli katman içerir.

Dönüştürücü gövdesi, uzun menzilli yazışmalar oluşturarak belirteçleri işler. Ek bir maske tarafından yönlendirilen etkili bir dikkat mekanizması ile önerilen dönüştürücü bloklarının beş aşamasını içerir.

Stil işleme modülü ek bir gürültü girişi ile yeniden yapılandırma prosedüründe evrişim katmanlarının ağırlık normalizasyonunu değiştirerek çıktıyı manipüle eder. Gürültü girişlerinin temsil yeteneğini geliştirmek için, hem görüntü özelliği X 'ten hem de koşulsuz gürültü stilinden su öğrenmek için görüntü koşullu stil S_c 'yi uygulanır.

$$S_u = \mathcal{E}(n) \quad (3.11)$$

$$X' = \mathbf{B} \odot X + (\mathbf{1} - \mathbf{B}) \odot \text{Resize}(S_u) \quad (3.12)$$

$$S_c = F(X') \quad (3.13)$$

B , değerlerin p olasılığı ile 1'e ve $1 - p$ ile 0'a ayarlandığı rastgele bir ikili maskedir.

$$s = \mathcal{A}(S_u, S_c) \quad (3.14)$$

$$W'_{ijk} = W_{ijk} \cdot S_i \quad (3.15)$$

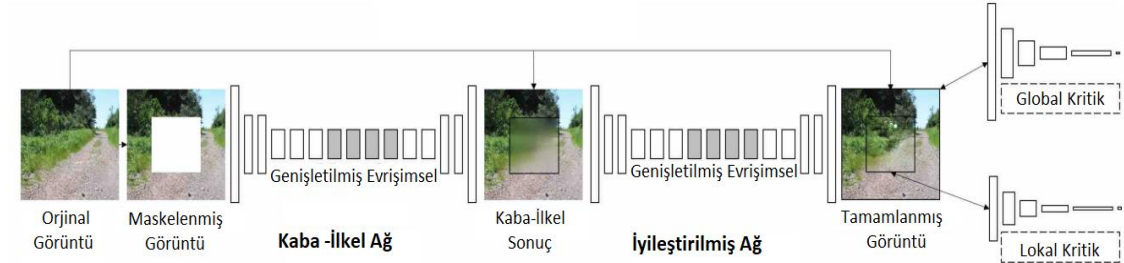
$$W''_{ijk} = W'_{ijk} / \sqrt{\sum_{i,k} W'_{ijk}{}^2 + \epsilon} \quad (3.16)$$

burada i, j, k sırasıyla evrişimin giriş kanallarını, çıkış kanallarını ve uzamsal ayak izini belirtir ve ϵ küçük bir sabittir. Farklı stil temsillerinin modülasyonu çoğulcu çıktılara yol açar.

3.6.4 Bağlamsal dikkat ile görüntü tamamlama (Generative image inpainting with contextual attention)

Görüntü tamamlama problemini çözmeye yönelik birçok farklı çekişmeli üretici ağ mimarisinde görüntü çevresindeki tamamlanacak alanlarda tutarsız, hatalı yapılar ve bulanık görüntüler sıklıkla oluşmaktadır. Görüntü tamamlamanın temel zorluğu, mevcut görüntüdeki veri ile eksik bölgeler için görsel olarak tutarlı ve gerçekçi piksellerin tahmin edilmesidir. Geleneksel çekişmeli üretici ağlarının çoğunda CNN kullanılmaktadır. CNN tabanlı yöntemler mevcut sınırlarından dolayı tamamlanması beklenen alanlarla tutarsız olan çarpık yapılar veya bulanık dokular oluşturmaktadır. Bunun, bağlamsal bilgi mesafesi ve tamamlanacak bölgeler arasındaki uzun vadeli korelasyonları modellemede evrişimli sinir ağlarının etkisizliğinden kaynaklandığını ortaya çıkmıştır (Yu vd., 2018).

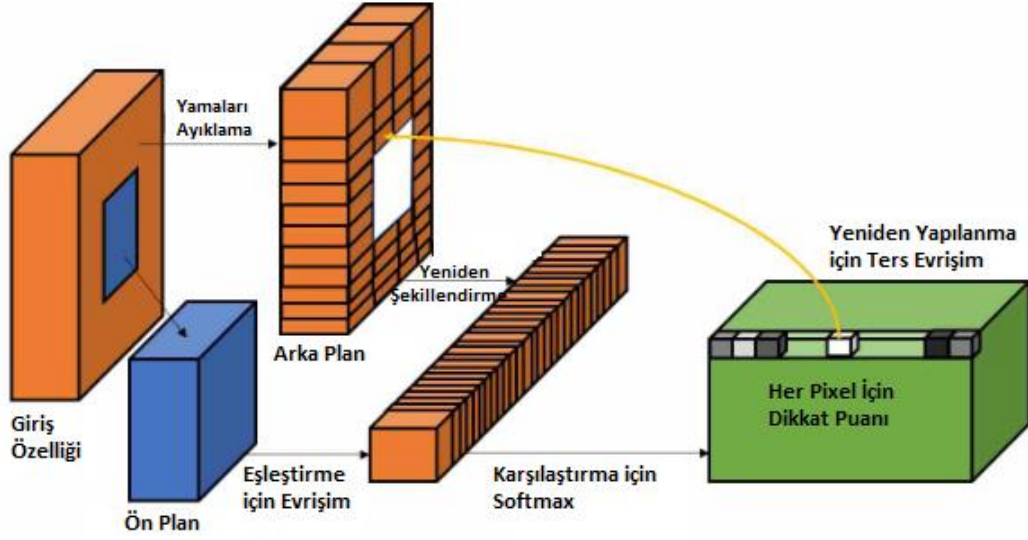
Bu yöntem bir başka görüntü tamamlama çalışması olan (Iizuka, Simo-Serra, ve Ishikawa, 2017) den esinlenerek ve iyileştirme yapılarak geliştirilmiştir. Kabadan inceleme ağ mimarisi Şekil 20’de bağlamsal dikkat modelinin genel yapısı gösterilmektedir.



Şekil 20. Yönteme Genel Bakış (Yu vd., 2018)

Bu ağ iki aşamadan oluşmaktadır. Görüntüde eksik içerikleri düzeltmek için yeniden yapılandırma kaybıyla eğitilmiş bir genişletilmiş evrişimsel ağ ve bağlamsal dikkat aşaması olmak üzere iki ağıdan oluşmaktadır. Temel fikir, üreticinin ürettiği tamamlama yamaları işlemek için bilinen yamaların özelliklerini evrişimli filtreler olarak kullanmaktır. Bu mimaride, küresel ve yerel wasserstein (WGAN) ları çekişmeli denetim için derin evrişimli çekişmeli üretici ağı (DCGAN) dayanır (Radford, Metz, ve Chintala, 2015). Diğer üretken iç boyama ağlarından (Iizuka vd., 2017; Pathak vd., 2016; Yang vd., 2017) farklı olarak, gradyan cezalı wasserstein (WGAN-GP)'nin (Arjovsky, Chintala, ve Bottou, 2017; Gulrajani, Ahmed, Arjovsky, Dumoulin, ve Courville, 2017) değiştirilmiş bir sürümüdür. Sezgisel olarak, görüntü tamamlama yapılacak sınırlardaki eksik pikseller, görüntü tamamlama yapılacak alanın merkezine daha yakın olan piksellerden çok daha az belirsizliğe sahiptir. Bağlamsal dikkat yönteminde bir ağırlık maskesi kullanarak uzaysal olarak indirgenmiş yeniden oluşturma kaybı tanımlanmıştır (Yu vd., 2018). Oluşturulan Maskelerdeki her pikselin ağırlığı, pikselin bilinen en yakın piksele olan mesafesi sabit 0.99 olarak ayarlanmıştır (Yu vd., 2018). Oluşturulan yamaları bilinen bağlamsal yamalar ile eşleştirmek için evrişim, ilgili yamaları tartmak için kanal bazında softmax ve oluşturulan yamaları bağlamsal yamalar ile yeniden yapılandırmak için ters evrişim ile tasarlanmış ve uygulanmıştır (Yu vd., 2018). Ayrıca bağlamsal dikkat modülü uzaysal uyumu sağlamak için uzaysal yayılma katmanına sahiptir. aktivasyon fonksiyonu olarak ReLU yerine ELU kullanılmıştır. Bağlamsal dikkat ağı mimarisinde, geleneksel

ağlara göre model eğitimi hızlıdır. Şekil 22’de bağlamsal dikkat katmanının bir modeli verilmiştir.



Şekil 21. Bağlamsal Dikkat Katmanı Çizimi (Yu vd., 2018)

Şekil 21’de görüleceği gibi, ön plan görüntü tamamlama yamalarının evrişim filtreleri olarak arka plan görüntü tamamlama yamalarıyla eşleşen puanını hesaplamak için evrişim kullanılır. Devamında, her bir görüntü pikseli için karşılaştırma yapmak ve dikkat puanı almak için softmax uygulanır. Son olarak, dikkat puanı üzerinde ters evrişim gerçekleştirilerek ön plan yamaları arka plan yamaları ile yeniden yapılandırılmaktadır.

Bağlamsal dikkat yönteminde 2.9M parametreye sahiptir ve hız olarak çalışmalarında belirtildiği üzere iki ay yerine bir hafta da eğitim tamamlanabilmektedir (Yu vd., 2018). Ayrıca toplu normalleştirme katmanlarını renk tutarlılığını olumsuz etkilediği için bu yöntemde kaldırılmıştır (Ioffe ve Szegedy, 2015). Bağlamsal dikkat ile görüntü tamamlama yönteminde, bağlamsal dikkat katmanına sahip bir ileri beslemeli çekişmeli üretici ağ fikrine dayanmaktadır.

Modelin algoritması aşağıdaki gibidir;

Adım 1: **while** G birleştirilmemiş **do**

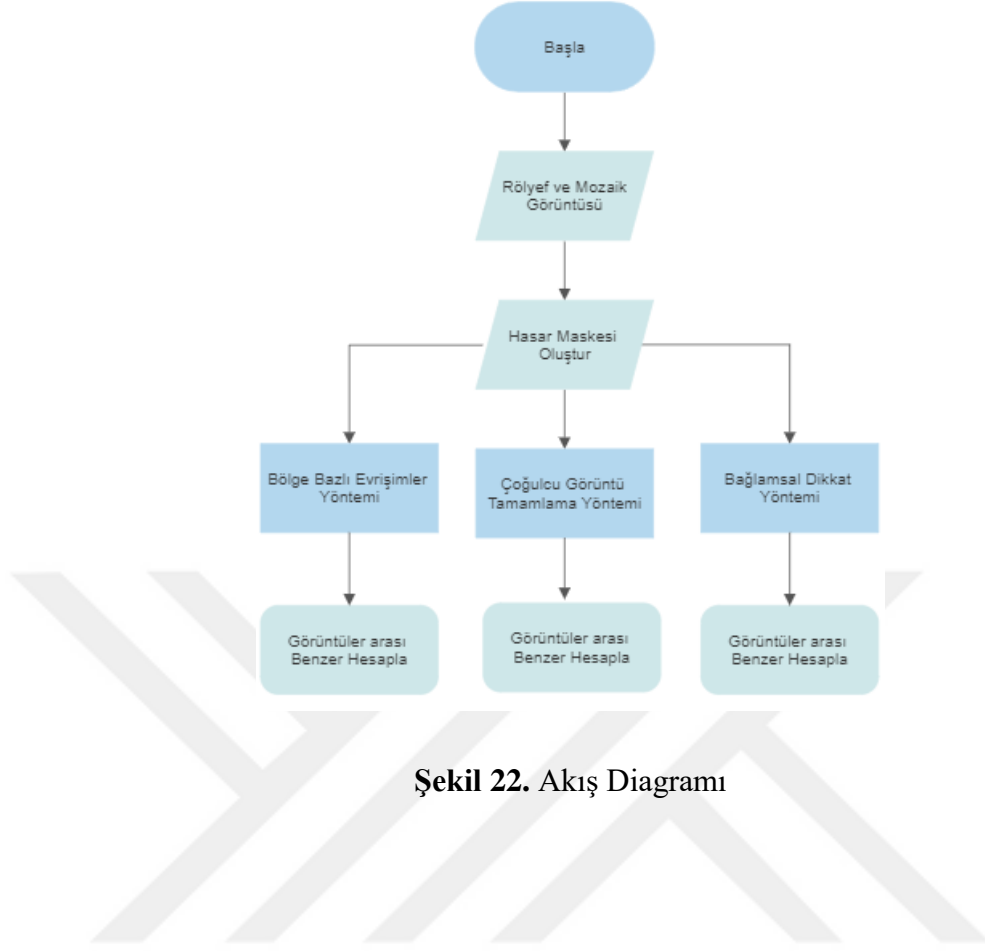
Adım 2: **for** i = 1, ... ,5 **do**

Adım 3: x eğitim verilerinden örnek görüntüler

- Adım 4: m, x için rastgele maskeler oluşturur
- Adım 5: $z \leftarrow x \odot m$ girişleri oluşturulur
- Adım 6: $\tilde{x} \leftarrow z + G(z, m) \odot (1-m)$ tahminler alınır
- Adım 7: $t \sim U[0,1]$ ve $\hat{x} \leftarrow (1-t)x + t\tilde{x}$ örnek olsun;
- Adım 8: \tilde{x} ve \hat{x} , x ile güncellenir
- Adım 9: **end for**
- Adım 10: x Eğitim verilerinden örnek görüntü
- Adım 11: m x için rastgele maskeler üretir;
- Adım 12: G ağı l_1 kaybı ve iki çekişmeli kritik kayıp ile günceller.
- Adım 14: **end while**

3.7 Gerçekleştirilen Çalışma

Bu tez çalışmasında çeşitli illerdeki müzelerde bulunan tarihi eserlerin fotoğraf görüntüleri toplanmıştır. Bu görüntülerden rölyef ve mozaik veri setleri oluşturulmuştur. Bu veri setleri üzerinde bölge bazlı evrişimler, çoğulcu görüntü ve bağlamsal dikkat yöntemleri kullanılarak görüntü tamamlama modelleri eğitilmiştir.



Şekil 22. Akış Diagramı

Ön eğitilmiş model olarak CelebaHQ, Paris ve Places2 veri setlerinden yararlanılmıştır. Görüntü boyutu olarak 256 x 256 ve 512 x 512 kullanılmıştır. Küme boyutu 32 ve döngü sayısı 40 ile 60 arasında değişkenlik göstermektedir. Eğitilmiş modellerin test sonuçlarına ait karşılaştırmalar, bulgular ve tartışma bölümünde incelenmiştir.

4. BULGULAR VE TARTIŞMA


Derin öğrenme temelli modeller ile birçok farklı alanda, yüksek performansların elde edildiği görülmektedir (Toğaçar ve Ergen, 2019). Çalışmada farklı derin öğrenme yöntemleri ile mozaik ve rölyef veri seti üzerinde model eğitimi yapılmıştır. Veri setindeki görüntülerden eğitim için toplam veri setinin %60'ı kullanılırken doğrulama için %20'si ve test için %20'si kullanılmıştır. Yapılan deneysel çalışmalarda Intel i7 8250U model işlemci, NVIDIA GeForce 940MX model ekran kartı ve 16 GB hafızalı bir bilgisayar üzerinde gerçekleştirilmiştir. Görüntü karşılaştırma değerlendirmesi yapabilmek için başarımlı ölçüm metriği olarak SSIM, RMSE ve PSNR sonuçlarına bakılmıştır.

Bu bölümde arkeolojik eserlere ait görüntülerin farklı çekişmeli üretici ağ modelleri ile elde edilen bulgulara ve bulgulara ait karşılaştırmalı başarı çıktılara yer verilmiştir. Yapılan deneysel çalışmada orijinal görüntü alınarak görüntü üzerinde deformasyon maskeleri yapılmıştır. Yapılan görüntü deformasyon maskeleri sabit tutularak tüm yöntemlere aynı şekilde uygulanmıştır. Ayrıca deneysel testlerde deformasyon miktarı, az hasarlı ve çok hasarlı olmak üzere iki sınıfa ayrılmıştır. İki sınıfa toplanan test veri seti, geliştirilmiş olan modele verilerek hasarı giderilmiş görüntü çıktıları alınmıştır. Bu çıktılar mozaik ve rölyef olmak üzere iki ayrı veri setinde de uygulanarak sonuçlar gözlenmiştir.

4.1 Az Hasarlı Görüntülerde Görüntü Tamamlama


Mozaik veri seti ile eğitilmiş modele eğitim, doğrulama ve test kümesinde olmayan üç adet görüntü verilmiş ve çıkan sonuçlar aşağıdaki gibidir.

Şekil 23'de orijinal mozaik görüntüsü ve bu görüntü üzerindeki az hasar maskesi gösterilmektedir.




Şekil 23. Mozaik 1 Orijinal – Az Hasarlı Görsel

Mozaik 1 görüntüsü ve bu görüntünün az hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 24’de, bağlamsal dikkat yöntemine ait çıktı şekil 25’de ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 26’da verilmektedir.



Şekil 24. Mozaik 1 Üzerinde Gerçekleştirilen Bölge Bazlı Evrişimler Yöntemi



Şekil 25. Mozaik 1 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi




Şekil 26. Mozaik 1 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi

Aynı maskeye sahip mozaik 1 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 2’de verilmiştir.

Tablo 2. Az Hasarlı Mozaik 1 Görüntü Tamamlama Başarı Kıyaslama


	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.92073	20.54330	23.95384	0.93796	28.71191	7.85285
<i>Bağlamsal Dikkat Yöntemi</i>	0.92073	20.54330	23.95384	0.95884	30.14687	6.92859
<i>Çoğulcu Görüntü Yöntemi</i>	0.92073	20.54330	23.95384	0.90341	25.45902	8.64872
	0.92073	20.54330	23.95384	0.90264	25.51360	8.53017
	0.92073	20.54330	23.95384	0.90167	25.66895	8.61923

Mozaik 1 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.95, RMSE değeri olarak 30.14 ve RMSE değeri 6.92 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir. Şekil 27’de orijinal mozaik görüntüsü ve bu görüntü üzerindeki az hasar maskesi gösterilmektedir.



Şekil 27. Mozaik 2 Orijinal – Az Hasarlı Görsel


Mozaik 2 görüntüsü ve bu görüntünün az hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 28’de, bağlamsal dikkat yöntemine ait çıktı şekil 29’da ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 30’da verilmektedir.



Şekil 28. Mozaik 2 Üzerinde Gerçekleştirilen Bölge Bazlı Evrişimler Yöntemi



Şekil 29. Mozaik 2 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 30. Mozaik 2 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi


Aynı maskeye sahip mozaik 2 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 3’de verilmiştir.

Tablo 3. Az Hasarlı Mozaik 2 Görüntü Tamamlama Başarı Kıyaslama

	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.90730	15.68418	41.91130	0.92254	29.08909	7.04813
<i>Bağlamsal Dikkat Yöntemi</i>	0.90730	15.68418	41.91130	0.92998	30.20820	6.83344
<i>Çoğulcu Görüntü Yöntemi</i>	0.90730	15.68418	41.91130	0.90110	28.11918	7.95391
	0.90730	15.68418	41.91130	0.90144	28.68092	7.45579
	0.90730	15.68418	41.91130	0.900146	28.42362	7.67995


Mozaik 2 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.93, PSNR değeri olarak 30.20 ve RMSE değeri 6.83 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

Şekil 31’de orijinal mozaik görüntüsü ve bu görüntü üzerindeki az hasar maskesi gösterilmektedir.




Şekil 31. Mozaik 3 Orijinal – Az Hasarlı Görsel

Mozaik 3 görüntüsü ve bu görüntünün az hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 32’de, bağlamsal dikkat yöntemine ait çıktı şekil 33’de ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 34’de verilmektedir.



Şekil 32. Mozaik 3 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi



Şekil 33. Mozaik 3 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 34. Mozaik 3 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi

Aynı maskeye sahip mozaik 3 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 4’de verilmiştir.

Tablo 4. Az Hasarlı Mozaik 3 Görüntü Tamamlama Başarı Kıyaslama

	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.92237	20.67265	23.59974	0.95254	31.08909	7.80210
<i>Bağlamsal Dikkat Yöntemi</i>	0.92237	20.67265	23.59974	0.97514	33.94061	6.91912
<i>Çoğulcu Görüntü Yöntemi</i>	0.92237	20.67265	23.59974	0.93971	30.21914	7.96290
	0.92237	20.67265	23.59974	0.93935	29.93372	8.12557
	0.92237	20.67265	23.59974	0.93931	30.01431	8.05053

Mozaik 3 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.97, PSNR değeri olarak 33.94, RMSE değeri olarak 6.91 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

Şekil 35’de orijinal rölyef görüntüsü ve bu görüntü üzerindeki az hasar maskesi gösterilmektedir.



Şekil 35. Rölyef 1 Orijinal – Az Hasarlı Görsel

Rölyef 1 görüntüsü ve bu görüntünün az hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 36’da, bağlamsal dikkat yöntemine ait çıktı şekil 37’de ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 38’de verilmektedir.



Şekil 36. Rölyef 1 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi



Şekil 37. Rölyef 1 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 38. Rölyef 1 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi

Aynı maskeye sahip rölyef 1 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 5’de verilmiştir.

Tablo 5. Az Hasarlı Rölyef 1 Görüntü Tamamlama Başarı Kıyaslama

	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.89663	17.17148	35.31554	0.93313	30.89531	7.27482
<i>Bağlamsal Dikkat Yöntemi</i>	0.89663	17.17148	35.31554	0.94473	31.35296	6.90068
<i>Çoğulcu Görüntü Yöntemi</i>	0.89663	17.17148	35.31554	0.91415	29.05463	7.74181
	0.89663	17.17148	35.31554	0.91357	29.77429	7.87607
	0.89663	17.17148	35.31554	0.91496	29.22125	7.70612

Rölyef 1 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.94, PSNR değeri olarak 31.35, RMSE değeri olarak 6.90 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

Şekil 39’da orijinal rölyef görüntüsü ve bu görüntü üzerindeki az hasar maskesi gösterilmektedir.



Şekil 41. Rolyef 2 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 42. Rolyef 2 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi


Aynı maskeye sahip rölyef 2 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 6’da verilmiştir.

Tablo 6. Az Hasarlı Rölyef 2 Görüntü Tamamlama Başarı Kıyaslama

	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.91805	16.76343	37.01420	0.95689	32.83663	5.22292
<i>Bağlamsal Dikkat Yöntemi</i>	0.91805	16.76343	37.01420	0.96628	33.44161	5.08778
<i>Çoğulcu Görüntü Yöntemi</i>	0.91805	16.76343	37.01420	0.94450	32.46604	5.41050
	0.91805	16.76343	37.01420	0.94476	32.51091	5.38262
	0.91805	16.76343	37.01420	0.94449	32.44329	5.42469

Rölyef 2 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.96, PSNR değeri olarak 33.44, RMSE değeri olarak 5.08 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

Şekil 43’de orijinal rölyef görüntüsü ve bu görüntü üzerindeki az hasar maskesi gösterilmektedir.




Şekil 43. Rölyef 3 Orijinal – Az Hasarlı Görsel

Rölyef 3 görüntüsü ve bu görüntünün az hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 44’de, bağlamsal dikkat yöntemine ait çıktı şekil 45’de ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 46’da verilmektedir.



Şekil 44. Rölyef 3 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi



Şekil 45. Rölyef 3 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 46. Rölyef 3 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi

Aynı maskeye sahip rölyef 3 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 7’de verilmiştir.

Tablo 7. Az Hasarlı Rölyef 3 Görüntü Tamamlama Başarı Kıyaslama

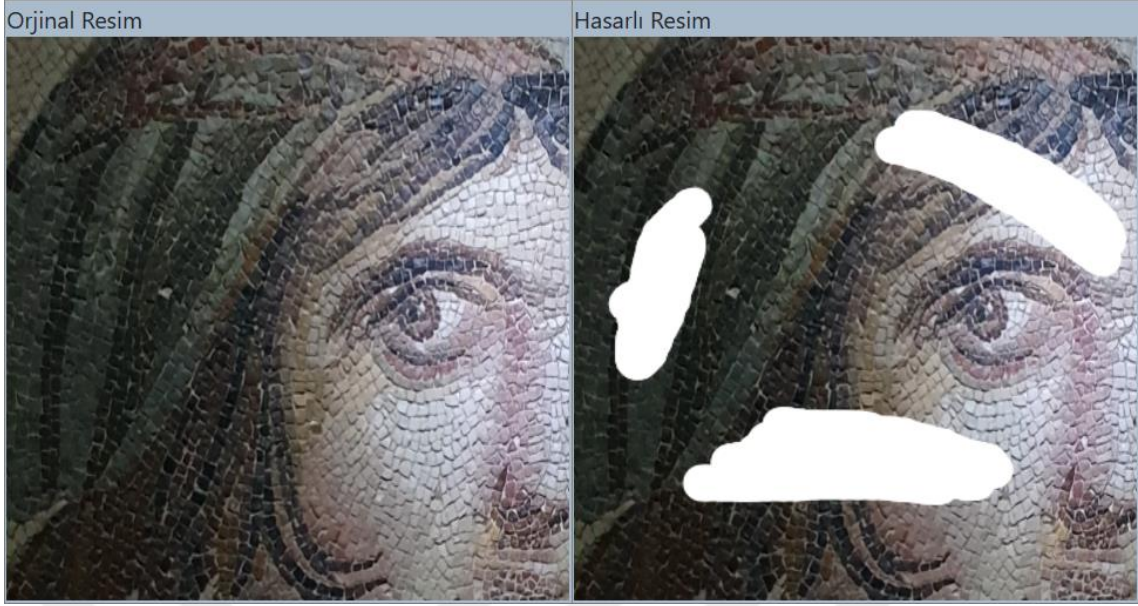
	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.92525	17.38319	34.46517	0.913070	30.57087	6.0659
<i>Bağlamsal Dikkat Yöntemi</i>	0.92525	17.38319	34.46517	0.94868	32.84321	5.317783
<i>Çoğulcu Görüntü Yöntemi</i>	0.92525	17.38319	34.46517	0.90158	30.66822	6.93101
	0.92525	17.38319	34.46517	0.89185	30.63732	6.95215
	0.92525	17.38319	34.46517	0.89184	30.61683	6.96620

Rölyef 3 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.94, PSNR değeri olarak 32.84 ve RMSE değeri olarak 5.31 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

4.2 Çok Hasarlı Görüntülerde Görüntü Tamamlama

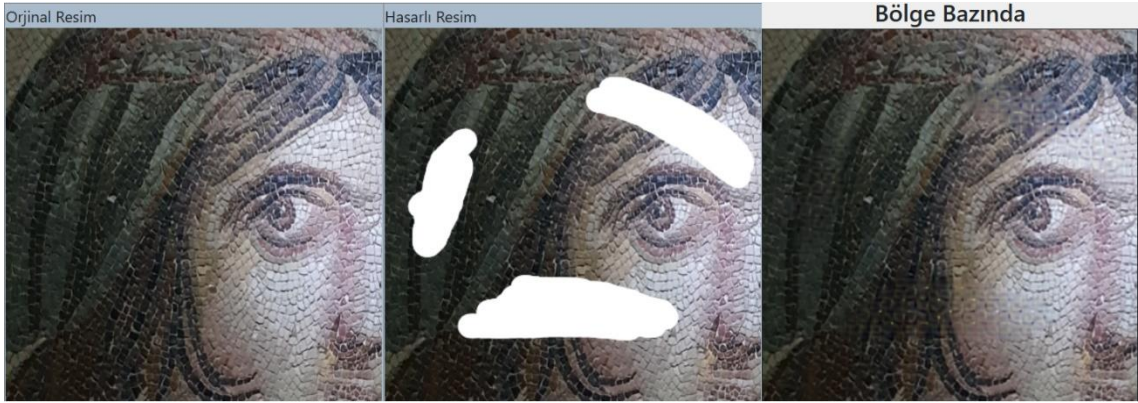
Mozaik veri seti ile eğitilmiş modele eğitim, doğrulama ve test kümesinde olmayan iki adet görüntü verilmiş ve çıkan sonuçlar aşağıdaki gibidir.

Şekil 47’de orijinal mozaik görüntüsü ve bu görüntü üzerindeki çok hasar maskesi gösterilmektedir.




Şekil 47. Mozaik 1 Orijinal – Çok Hasarlı Görsel

Mozaik 1 görüntüsü ve bu görüntünün çok hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 48’de, bağlamsal dikkat yöntemine ait çıktı şekil 49’da ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 50’de verilmektedir.



Şekil 48. Mozaik 1 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi



Şekil 49. Mozaik 1 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 50. Mozaik 1 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi


Aynı maskeye sahip mozaik 1 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 8’de verilmiştir.

Tablo 8. Çok Hasarlı Mozaik 1 Görüntü Tamamlama Başarı Kıyaslama

	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.77579	11.21087	60.14492	0.81902	26.10690	12.62394
<i>Bağlamsal Dikkat Yöntemi</i>	0.77579	11.21087	60.14492	0.82714	26.88159	15.53651
<i>Çoğulcu Görüntü Yöntemi</i>	0.77579	11.21087	60.14492	0.80732	25.13682	14.11558
	0.77579	11.21087	60.14492	0.80708	24.25099	14.63113
	0.77579	11.21087	60.14492	0.80686	24.47971	14.22489


Mozaik 1 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.85, PSNR değeri olarak 26.88 ve RMSE değeri olarak 15.53 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

Şekil 51’de orijinal mozaik görüntüsü ve bu görüntü üzerindeki çok hasar maskesi gösterilmektedir.




Şekil 51. Mozaik 2 Orijinal – Çok Hasarlı Görsel

Mozaik 2 görüntüsü ve bu görüntünün çok hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 52’de, bağlamsal dikkat yöntemine ait çıktı şekil 53’de ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 54’de verilmektedir.



Şekil 52. Mozaik 2 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi



Şekil 53. Mozaik 2 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 54. Mozaik 2 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi


Aynı maskeye sahip mozaik 2 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 9’da verilmiştir.

Tablo 9. Çok Hasarlı Mozaik 2 Görüntü Tamamlama Başarı Kıyaslama

	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.87751	16.95011	36.22717	0.89420	24.42026	15.32946
<i>Bağlamsal Dikkat Yöntemi</i>	0.87751	16.95011	36.22717	0.93855	25.80019	13.67339
<i>Çoğulcu Görüntü Yöntemi</i>	0.87751	16.95011	36.22717	0.90837	25.46969	13.58487
	0.87751	16.95011	36.22717	0.91014	25.80106	13.07636
	0.87751	16.95011	36.22717	0.91135	26.16366	12.54171


Mozaik 2 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.93, PSNR değeri olarak 25.80 ve RMSE değeri olarak 13.67 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

Şekil 55’de orijinal rölyef görüntüsü ve bu görüntü üzerindeki çok hasar maskesi gösterilmektedir.




Şekil 55. Rölyef 1 Orijinal – Çok Hasarlı Görsel

Rölyef 1 görüntüsü ve bu görüntünün çok hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 56’da, bağlamsal dikkat yöntemine ait çıktı şekil 57’de ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 58’de verilmektedir.



Şekil 56. Rölyef 1 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi



Şekil 57. Rolyef 1 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 58. Rolyef 1 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi


Aynı maskeye sahip rölyef 1 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 10’da verilmiştir.

Tablo 10. Çok Hasarlı Rölyef 1 Görüntü Tamamlama Başarı Kıyaslama

	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.80963	12.54249	60.17488	0.88159	28.50749	13.52588
<i>Bağlamsal Dikkat Yöntemi</i>	0.80963	12.54249	60.17488	0.89847	30.19217	7.84976
<i>Çoğulcu Görüntü Yöntemi</i>	0.80963	12.54249	60.17488	0.86262	28.87011	9.18405
	0.80963	12.54249	60.17488	0.86317	29.05729	8.98825
	0.80963	12.54249	60.17488	0.86506	29.27681	8.76394

Rölyef 1 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.89, PSNR değeri olarak 30.19 ve RMSE değeri olarak 7.84 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

Şekil 59’da orijinal rölyef görüntüsü ve bu görüntü üzerindeki çok hasar maskesi gösterilmektedir.



Şekil 59. Rölyef 2 Orjinal – Çok Hasarlı Görsel


Rölyef 2 görüntüsü ve bu görüntünün çok hasar maskesine ait model çıktı sonuçları verilmiştir. Bölge bazlı evrişimler yöntemine ait çıktı şekil 60'da, bağlamsal dikkat yöntemine ait çıktı şekil 61'de ve çoğulcu görüntü tamamlama yöntemine ait çıktı şekil 62'de verilmektedir.



Şekil 60. Rölyef 2 Üzerinde Gerçekleştirilen Bölge Bazında Evrişimler Yöntemi



Şekil 61. Rölyef 2 Üzerinde Gerçekleştirilen Bağlamsal Dikkat Yöntemi



Şekil 62. Rölyef 2 Üzerinde Gerçekleştirilen Çoğulcu Görüntü Yöntemi

Aynı maskeye sahip rölyef 2 görüntüsünden oluşan çıktılarda görsel olarak en iyi sonuç bağlamsal dikkat yönteminde olduğu tespit edilmiştir. Görüntü tamamlama çıktıları orijinal – hasarlı görüntü ve orijinal – hasarı giderilmiş görüntü olmak üzere SSIM ve RMSE sonuçları Tablo 11’de verilmiştir.

Tablo 11. Çok Hasarlı Rölyef 2 Görüntü Tamamlama Başarı Kıyaslama

	Orijinal – Hasarlı Görüntü			Orijinal–Hasarı Giderilmiş Görüntü		
	SSIM	PSNR	RMSE	SSIM	PSNR	RMSE
<i>Bölge Bazlı Yöntemi</i>	0.80725	13.56866	53.46960	0.84998	27.08585	10.93116
<i>Bağlamsal Dikkat Yöntemi</i>	0.80725	13.56866	53.46960	0.86969	28.88515	9.54203
<i>Çoğulcu Görüntü Yöntemi</i>	0.80725	13.56866	53.46960	0.84932	26.28862	10.81993
	0.80725	13.56866	53.46960	0.84847	26.13949	10.98999
	0.80725	13.56866	53.46960	0.84806	26.00341	10.14774

Rölyef 2 görüntüsüne ait sonuçlar incelendiğinde SSIM değeri olarak 0.86, PSNR değeri olarak 28.88 ve RMSE değeri olarak 9.54 ile en başarılı yöntemin bağlamsal dikkat yöntemi olduğu tespit edilmiştir.

Test kümesinden daha fazla görsel üzerinde bağlamsal dikkat yöntemi uygulanılarak elde edilen çıktılar görsel olarak incelendiğinde başarılı sonuçlar alınmıştır.



Şekil 63. Deneysel Çalışma 1

Şekil 63'de görüntünün orijinali solda, tamamlanacak alan maskeli hali ortada ve sağ tarafta modelin çıktı sonucu gösterilmektedir. Orijinal rölyef görüntüsünün sol tarafında büyük bir hasar oluşmuş ve çıktı görüntü başarılı şekilde tamamladığı görülmektedir.



Şekil 64. Deneysel Çalışma 2

Şekil 64'de görüntünün orijinali solda, tamamlanacak alan maskeli hali ortada ve sağ tarafta modelin çıktı sonucu gösterilmektedir. Orijinal rölyef görüntüsünün sol çaprazdan bir hasar oluşmuş ve çıktı görüntü başarılı şekilde tamamladığı görülmektedir.



Şekil 65. Deneysel Çalışma 3

Şekil 65’de görüntünün orijinali solda, tamamlanacak alan maskeli hali ortada ve sağ tarafta modelin çıktı sonucu gösterilmektedir. Orijinal rölyef görüntüsünün sol üst tarafında sol alt tarafa doğru bir hasar oluşmuş ve çıktı görüntü başarılı şekilde tamamladığı görülmektedir.



Şekil 66. Deneysel Çalışma 4

Şekil 66’da görüntünün orijinali solda, tamamlanacak alan maskeli hali ortada ve sağ tarafta modelin çıktı sonucu gösterilmektedir. Orijinal rölyef görüntüsünde çapraz bir hasar oluşmuş ve çıktı görüntü başarılı şekilde tamamladığı görülmektedir.




Şekil 67. Deneysel Çalışma 5

Şekil 67’de görüntünün orijinali solda, tamamlanacak alan maskeli hali ortada ve sağ tarafta modelin çıktı sonucu gösterilmektedir. Orijinal mozaik görüntüsünün üst tarafında hasar oluşmuş ve çıktı görüntü başarılı şekilde tamamladığı görülmektedir.



Şekil 68. Deneysel Çalışma 6

Şekil 68’de görüntünün orijinali solda, tamamlanacak alan maskeli hali ortada ve sağ tarafta modelin çıktı sonucu gösterilmektedir. Orijinal mozaik görüntüsünde çeşitli küçük hasarlar oluşmuş ve çıktı görüntü başarılı şekilde tamamladığı görülmektedir.



Şekil 69. Deneysel Çalışma 7

Şekil 69'da görüntünün orijinali solda, tamamlanacak alan maskeli hali ortada ve sağ tarafta modelin çıktı sonucu gösterilmektedir. Orijinal mozaik görüntüsünde sağ alt tarafta hasar oluşmuş ve çıktı görüntü başarılı şekilde tamamladığı görülmektedir.



Şekil 70. Deneysel Çalışma 8

Şekil 70'de görüntünün orijinali solda, tamamlanacak alan maskeli hali ortada ve sağ tarafta modelin çıktı sonucu gösterilmektedir. Orijinal mozaik görüntüsünün orta tarafında hasar oluşmuş ve çıktı görüntü başarılı şekilde tamamladığı görülmektedir.

5. SONUÇ ve ÖNERİLER

Tez çalışmasında mozaik ve rölyef görüntülerinden oluşan bir veri seti üzerindeki doğal veya doğal olmayan nedenlerle oluşan hasarlı bölgelerin düzeltilmesi sağlanmıştır. Bunun için literatürde daha önce bulunmayan, Türkiye'ye ait mozaik ve rölyef eserler görüntülerinden bir veri seti oluşturulmuştur. Oluşturulan veri setleri ile farklı algoritmalar ile modellerin eğitimleri yapılmıştır. Her yöntem için model çıktılarının oluşması beklenen görüntüleri ile SSIM, PSNR ve RMSE metriklerine bakılarak başarı sonuçları değerlendirilmiştir. Çoğulcu görüntü tamamlama yöntemi gereği birden fazla model çıktıları üretilmiş ve üretilen bu çıktıların karşılaştırma metrik değerleri ve oluşan görüntülerin gerçekten en uzak görüntüler olduğu tespit edilmiştir. Bu algoritmanın oluşturduğu görsellerde oluşması beklenmeyen farklı yamalar ile dolgu yapmaya çalıştığı çok hasarlı mozaik ve rölyef örneklerinde tespit edilmiştir. Bölge bazlı evrişimler yöntemine göre az hasarlı mozaik ve rölyef görüntülerinde SSIM değerinin 0.91 - 0.95 arasında PSNR değerinin 28.7 – 32.8 arasında RMSE değerinin 5.2 – 7.8 arasında olduğu tespit edilmiştir. Çok hasarlı mozaik ve rölyef görüntülerinde SSIM değerinin 0.81 - 0.89 arasında PSNR değerinin 24.4 – 28.5 arasında RMSE değerinin 10.9 – 15.3 arasında olduğu tespit edilmiştir. Bölge bazlı görüntü tamamlama yönteminde az hasarlı resimlerde iyi sonuçlar vermesine rağmen bağlamsal dikkat yönteminin gerisinde kalmıştır. Bağlamsal dikkat yöntemine göre az hasarlı mozaik ve rölyef görüntülerinde SSIM değerinin 0.92 - 0.97 arasında PSNR değerinin 30.1 – 33.9 arasında RMSE değerinin 5.0 – 6.9 arasında olduğu tespit edilmiştir. Çok hasarlı mozaik ve rölyef görüntülerinde SSIM değerinin 0.82 - 0.93 arasında PSNR değerinin 25.8 – 30.1 arasında RMSE değerinin 7.8 – 15.5 arasında olduğu tespit edilmiştir.

Çalışmada eğitilen modeller ile hasarlı mozaik ve rölyef görüntülerinin otomatik olarak tamamlanması sağlanabilmektedir. Mozaik ve rölyef görüntülerinin tamamlanması üzerine literatürde herhangi bir çalışma bulunmamış ve ilk yapılan çalışma özelliğini taşımaktadır. Bu çalışma ile derin öğrenme yöntemlerinin arkeoloji gibi farklı bir alanda kullanılması ile arkeoloji alanında da yeni çalışmaların önünü açacaktır.

KAYNAKLAR

- Alpaydin, E. (2020). *Introduction to machine learning*. Cambridge: MIT press.
- Andrew, A. M. (1991). Continuity and artificial intelligence. *Kybernetes*, 20(6), 69-80. doi:10.1108/eb005905
- Arjovsky, M., Chintala, S., ve Bottou, L. (2017). Wasserstein generative adversarial networks. International conference on machine learning. doi:10.48550/arXiv.1701.07875
- Atlam, H. F., Walters, R. J., ve Wills, G. B. (2018). Intelligence of things: opportunities & challenges. *3rd Cloudification of the Internet of Things*, 1-6.
- Aydın, S., ve Özkul, A. E. (2015). Veri madenciliği ve Anadolu Üniversitesi açık öğretim sisteminde bir uygulama. *Journal of Research in Education Teaching*, 4(3), 36-44.
- Ba, J. L., Kiros, J. R., ve Hinton, G. E. (2016). Layer normalization. arXiv preprint arXiv:1607.06450. doi :10.48550/arXiv.1607.06450
- Ballester, C., Bertalmio, M., Caselles, V., Sapiro, G., ve Verdera, J. (2001). Filling-in by joint interpolation of vector fields and gray levels. *IEEE transactions on image processing*, 10(8), 1200-1211. doi:10.1109/83.935036.
- Barnes, C., Shechtman, E., Finkelstein, A., ve Goldman, D. B. (2009). PatchMatch: A randomized correspondence algorithm for structural image editing. *ACM Trans. Graph.*, 28(3), 24. doi:10.1145/1531326.1531330.
- Bassier, C. (1974). Weiterentwicklung der Konsenierungsmethoden für Mosaiken. *Arbeitsblaetter für Restauratoren*(7 1), 43-52.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations trends® in Machine Learning*, 2(1), 1-127. doi:10.1561/22000000006.
- Bertalmio, M., Sapiro, G., Caselles, V., ve Ballester, C. (2000). Image inpainting. *Proceedings of the 27th annual conference on Computer graphics and interactive techniques*. doi:10.1145/344779.344972.

- Bertalmio, M., Vese, L., Sapiro, G., ve Osher, S. (2003). Simultaneous structure and texture image inpainting. *IEEE transactions on image processing*, 12(8), 882-889. doi:10.1109/TIP.2003.815261.
- Brownlee, J. (2019). Applications of Deep Learning for Computer Vision.21.01.2023, tarihinde, <https://machinelearningmastery.com/applications-of-deep-learning-for-computer-vision/>. adresinden indirildi.
- Buslaev, A., Iglovikov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M., ve Kalinin, A. A. (2020). Albuementations: fast and flexible image augmentations. *Information*, 11(2), 125. doi:10.48550/arXiv.1809.06839.
- Copeland, J. (1993). *Symbolic Computation. Artificial Intelligence: A Philosophical Introduction*. Oxford: Blackwell.
- Criminisi, A., Perez, P., ve Toyama, K. (2003). Object removal by exemplar-based inpainting. 2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2003. Proceedings. doi:10.1109/CVPR.2003.1211538.
- Domingos, P. (2015). *The master algorithm: How the quest for the ultimate learning machine will remake our world*. London: Penguin Books Ltd.
- Efros, A. A., ve Freeman, W. T. (2001). Image quilting for texture synthesis and transfer. Proceedings of the 28th annual conference on Computer graphics and interactive techniques. doi:10.1145/383259.383296.
- Efros, A. A., ve Leung, T. K. (1999). Texture synthesis by non-parametric sampling. Proceedings of the seventh IEEE international conference on computer vision. doi:10.1109/ICCV.1999.790383.
- Esedoglu, S., ve Shen, J. (2002). Digital inpainting based on the Mumford–Shah–Euler image model. *European Journal of Applied Mathematics*, 13(4), 353-370.
- Eskici, B. (1997). Taş Eserlerin Korunması Üzerine Notlar. *Türk Arkeoloji Dergisi*(51), 383-391.
- Goodfellow, I., Bengio, Y., ve Courville, A. (2016). *Deep learning*. Cambridge: MIT press.

- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., ve Bengio, Y. (2014). Advances in neural information processing systems. Curran Associates, Inc, 27, 2672-2680.
- Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., ve Courville, A. C. (2017). Improved training of wasserstein gans. Advances in neural information processing systems, 30. doi:10.48550/arXiv.1704.00028.
- Hinton, G. E., Osindero, S., ve Teh, Y.-W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554. doi:10.1162/neco.2006.18.7.1527
- Hinton, G. E., ve Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *science*, 313(5786), 504-507. doi:10.1126/science.1127647.
- Hore, A., ve Ziou, D. (2010). Image quality metrics: PSNR vs. SSIM. 2010 20th international conference on pattern recognition. doi:10.1109/ICPR.2010.579.
- Hua, G., ve Jégou, H. (2016). Computer Vision–ECCV 2016 Workshops: Amsterdam, The Netherlands, October 8-10 and 15-16, 2016, Proceedings, Part II (Vol. 9914): Springer. doi:10.1007/978-3-319-49409-8.
- Iizuka, S., Simo-Serra, E., ve Ishikawa, H. (2017). Globally and locally consistent image completion. *ACM Transactions on Graphics*, 36(4), 1-14. doi:10.1145/3072959.3073659.
- Ioffe, S., ve Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. International conference on machine learning. doi:10.48550/arXiv.1502.03167.
- Karakis, R., ve Guler, I. (2018). Steganography and medical data security. In *Cryptographic and Information Security* (pp. 627-660): CRC Press.
- Karasu, S., Altan, A., Saraç, Z., ve Hacıoğlu, R. (2018). Prediction of Bitcoin prices with machine learning methods using time series data. 2018 26th signal processing and communications applications conference (SIU). doi:10.1109/SIU.2018.8404760.

- Kizrak, M. A., ve Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286. doi:10.17671/gazibtd.419205
- Krizhevsky, A., Sutskever, I., ve Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. doi:10.1145/3065386.
- Kwatra, V., Essa, I., Bobick, A., ve Kwatra, N. (2005). Texture optimization for example-based synthesis. In *ACM SIGGRAPH 2005 Papers* (pp. 795-802). doi:10.1145/1073204.1073204.
- LeCun, Y., Bengio, Y., ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Levin, A., Zomet, A., ve Weiss, Y. (2003). Learning How to Inpaint from Global Image Statistics. *ICCV*. doi:10.1109/ICCV.2003.1238360.
- Li, W., Lin, Z., Zhou, K., Qi, L., Wang, Y., ve Jia, J. (2022). Mat: Mask-aware transformer for large hole image inpainting. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. doi:10.48550/arXiv.2203.15270.
- Ma, Y., Liu, X., Bai, S., Wang, L., Liu, A., Tao, D., ve Hancock, E. R. (2022). Regionwise generative adversarial image inpainting for large missing areas. *IEEE Transactions on Cybernetics*. doi:10.48550/arXiv.1909.12507.
- McCulloch, W. S., ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133.
- Minsky, M., ve Papert, S. (1969). An introduction to computational geometry. *Cambridge tiass., HIT*, 479, 480.
- Nabiyev, V. V. (2012). *Yapay zeka: insan-bilgisayar etkileşimi*. Ankara: Seçkin Yayıncılık.
- Ng, A. (2011). Sparse autoencoder. *CS294A Lecture notes*, 72(2011), 1-19.
- Öztemel, E. (2003). *Yapay sinir ağları*. İstanbul: Papatya Yayıncılık.

- Panofsky, E. J. İ. P. (2012). *İkonoloji Araştırmaları: Rönesans Sanatında İnsancıl Temalar*. İstanbul: Pinhan Yayıncılık.
- Paoletti, M., Haut, J., Plaza, J., Plaza, A., ve Sensing, R. (2019). Deep learning classifiers for hyperspectral imaging: A review. *ISPRS Journal of Photogrammetry*, 158, 279-317. doi:10.1016/j.isprsjprs.2019.09.006.
- Pathak, D., Krahenbuhl, P., Donahue, J., Darrell, T., ve Efros, A. A. (2016). Context encoders: Feature learning by inpainting. *Proceedings of the IEEE conference on computer vision and pattern recognition*. doi :10.1109/CVPR.2016.278.
- Patterson, J., ve Gibson, A. (2017). *Deep learning: A practitioner's approach: " O'Reilly Media, Inc."*. ISBN: 9781491914250 21.01.2023 tarihinde <https://www.oreilly.com/library/view/deep-learning/9781491924570/> adresinden indirildi.
- Popov, E. (1990). *Yapay Zekâ. Uzman Sitemler ve Doğal Dil İşleme*. Moskova: Radio i Svyaz, 461.
- Radford, A., Metz, L., ve Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. doi: 10.48550/arXiv.1511.06434.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Rosenblatt, F. (1960). Perceptron simulation experiments. *Proceedings of the IRE*, 48(3), 301-309.
- Rumelhart, D. E., Hinton, G. E., ve Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Silva, T. A. (2021). Beginner's Guide to Generative Adversarial Networks (GANs), 25.12.2021, tarihinde, <https://skymind.ai/wiki/generative-adversarial-network-gan>. adresinden indirildi.
- Toğaçar, M., ve Ergen, B. (2019). Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Firat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 109-121.

- Üstüner, A. C. (2002). *Mozaik sanatı*. İstanbul: Engin Yayıncılık.
- Wang, Z., Bovik, A. C., Sheikh, H. R., ve Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, 13(4), 600-612. doi:10.1109/TIP.2003.819861.
- Yang, C., Lu, X., Lin, Z., Shechtman, E., Wang, O., ve Li, H. (2017). High-resolution image inpainting using multi-scale neural patch synthesis. *Proceedings of the IEEE conference on computer vision and pattern recognition*. doi:10.48550/arXiv.1611.09969.
- Yeh, R. A., Chen, C., Yian Lim, T., Schwing, A. G., Hasegawa-Johnson, M., ve Do, M. N. (2017). Semantic image inpainting with deep generative models. *Proceedings of the IEEE conference on computer vision and pattern recognition*. doi:10.48550/arXiv.1607.07539.
- Yılmaz, A., ve Umut, K. (2021). *Derin Öğrenme*. İstanbul: Kodlab Yayın Dağıtım Yazılım Ltd. Şti.
- Yu, J., Lin, Z., Yang, J., Shen, X., Lu, X., ve Huang, T. S. (2018). Generative image inpainting with contextual attention. *Proceedings of the IEEE conference on computer vision and pattern recognition*. doi:10.48550/arXiv.1801.07892.
- Zheng, C., Cham, T.-J., ve Cai, J. (2019). Pluralistic image completion. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. doi:10.48550/arXiv.1903.04227.

ÖZGEÇMİŞ

Mehmet Kıvılcım KELEŞ

Eğitim

Derece	Yıl	Üniversite, Enstitü, Anabilim/Anasanat Dalı
Yüksek Lisans	2015	İstanbul Aydın Üniversitesi, Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği
Lisans	2011	Zonguldak Karaelmas Üniversitesi, Fen Edebiyat Fakültesi Matematik

İş/İstihdam (Varsa)

Yıl	Görev
2022 -	Birim Müdürü – Anadolu Sigorta İnovasyon ve Dijital Sigortacılık
2018 - 2022	Kıdemli Arge Uzmanı - Vakıfbank Arge İnovasyon Müdürlüğü
2010 - 2018	Yazılım Uzmanı – ETB Elektronik Bilgisayar Yazılım

Mesleki Birlik/Dernek Üyelikleri (Varsa)

Yıl	Kurum
2006 – ...	Tema Vakfı

Yayınlar ve Diğer Bilimsel/Sanatsal Faaliyetler

“Republic of Turkey Identity Card (TCKK) Banking Use Case in Authentication & Customer Onboarding”, 6th International Conference on Computer and Technology Applications (ICCTA 2020), 2020.

“24 Bit Renkli Dokümanların Farklı Biyometri Teknolojileri Kullanılarak Güvenliğinin Sağlanması”, VI. Uluslararası Bilgi Güvenliği ve Kriptoloji Konferansı (ISCTURKEY 2013) , 2013

