

**Atf İçin:** Keleş, M. K. ve Güvenoğlu, E. (2023). Çekişmeli Üretici Ağlar Kullanılarak Hasarlı Mozaik Görüntülerinin Tamamlanması. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(2), 736-746.

**To Cite:** Keleş, M. K. & Güvenoğlu, E. (2023). Damaged Mosaic Image Inpainting by Using Generative Adversarial Network. *Journal of the Institute of Science and Technology*, 13(2), 736-746.

## Çekişmeli Üretici Ağlar Kullanılarak Hasarlı Mozaik Görüntülerinin Tamamlanması

Mehmet Kıvılcım KELEŞ<sup>1\*</sup>, Erdal GÜVENOĞLU<sup>2</sup>

### **Öne Çıkanlar:**

- Mozaik Tamamlama
- Yapay Zeka

### **Anahtar Kelimeler:**

- Mozaik
- Görüntü tamamlama
- Derin öğrenme
- Çekişmeli üretici ağlar

### **ÖZET:**

Bilinen en eski sanat eserlerinden olan mozaikler tarih boyunca çok farklı uygarlıklar tarafından geliştirilmiş ve kullanılmışlardır. Geçmişten günümüze ulaşan mozaik eserlerinde tahribat sıklıkla rastlanmaktadır. Gerçekleşen doğa koşulları, insanların olumsuz etkileri veya nesnelerin doğası gereği yıpranmasından dolayı tahribata uğrayan eserler olabilmektedir. Bu eserlerdeki tahribatın onarılması ve orijinal görüntüsüne ulaşılması gerekliliği tüm tarih eserlerinde olduğu gibi mozaik eserlerinin de temel ihtiyacıdır. Görüntü tamamlama problemi literatürde farklı teknikler ile çözülmeye çalışılan güncel bir problemdir. Bu çalışmada görüntü tamamlama problemini derin öğrenme tabanlı yöntemlerle mozaik veri seti üzerindeki sonuçları incelenmiştir. Mozaik görüntüsündeki eksik bölgelerin düzeltilmesi bağlamsal dikkat ile görüntü tamamlama mimarisi kullanılmıştır. Bu mimari aynı veri seti kullanılarak farklı çekişmeli üretici ağ mimarileri ile karşılaştırılmalı sonuçları incelenmiştir. Öğrenme aktarımı kullanılarak mozaik veri seti ile yeniden model eğitilmiştir. Test edilen mozaik örneklerdeki orijinal görüntü ile hasarı giderilmiş görüntü arasındaki yapısal benzerlik indisinin yapılan hasar oranına göre az hasarlı görüntülerde 0.92 - 0.95 çok hasarlı görüntülerde ise 0.72 - 0.89 arasında olduğu gözlemlenmiştir. Gerçekleştirilen görüntü tamamlama modeli ile az hasarlı mozaik resimlerinde görüntü tamamlamada yüksek başarı elde edilmiştir.

## Damaged Mosaic Image Inpainting By Using Generative Adversarial Network

### **Highlights:**

- Mosaic Inpainting
- Artificial Intelligence

### **Keywords:**

- Mosaic
- Image inpainting
- Deep learning
- Generative adversarial networks

### **ABSTRACT:**

Mosaics, one of the oldest known works of art, have been developed and used by many different civilizations throughout history. Destruction is frequently encountered in mosaic works that have survived from the past to the present. Artifacts can be damaged due to the natural conditions, the negative effects of people or the nature of the objects. The necessity of repairing the damage in these artifacts and reaching their original appearance is the basic need of mosaic artifacts as in all historical artifacts. Image inpainting problem is a current problem that is tried to be solved with different techniques in the literature. In this study, the results of the image inpainting problem on the mosaic data set with deep learning-based methods were examined. Image inpainting architecture is used with contextual attention to correct missing regions in the mosaic image. Comparative results of this architecture with different adversarial generator network architectures were examined using the same data set. Model was retrained with the mosaic dataset using learning transfer. It was observed that the index of structural similarity between the original image and the repaired image in the tested mosaic samples ranged from 0.92 - 0.95 in lightly damaged images and between 0.72 - 0.89 in heavily damaged images, according to the damage ratio. With the implemented image inpainting model, high success was achieved in image inpainting in mosaic paintings with little damage.

<sup>1</sup> Mehmet Kıvılcım KELEŞ ([Orcid ID: 0000-0001-5358-8301](https://orcid.org/0000-0001-5358-8301)), Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul, Türkiye

<sup>2</sup> Erdal GÜVENOĞLU ([Orcid ID: 0000-0003-1333-5953](https://orcid.org/0000-0003-1333-5953)), Maltepe Üniversitesi, Meslek Yüksekokulu, Bilgisayar Programcılığı Bölümü, İstanbul, Türkiye

\*Sorumlu Yazar/Corresponding Author: Mehmet Kıvılcım KELEŞ, e-mail: kivilcim.keles@gmail.com

## GİRİŞ

Aynı veya farklı renklerdeki küçük parçacıkların yan yana getirilmesi ve birleştirilmesi yöntemiyle oluşturulan esere mozaik denir. Günümüze ulaşan tarihi eserlerden en sık karşılaşılan yapı örneklerinden biride mozaiklerdir. Bilinen sanat dallarından, en eski ve önemli olanların biride mozaik sanatıdır. Birçok farklı dönem ve uygarlıkta kullanılan mozaik sanatı Romalılar döneminde yer, duvar ve çatı kemeri süslemelerinde, Bizans İmparatorluğu'nda kamusal mimaride ve Hıristiyan kiliselerinde dış cephe süslemelerinde sıklıkla yer almıştır. Özellikle M.S. 4. yüzyılda İmparator sanatı Bizans'ta ise Psifidota olarak adlandırılan mozaik sanatı Konstantin döneminden itibaren yaygın olarak kullanılmaya başlandı (Ogan ve Mirmiroğlu, 1955). Mozaik sanatının ortaya çıkış döneminden itibaren zaman içinde bulunduğu dönem ve olaylardan etkilenmiş tarihsel ve sanatsal gelişim ve değişim geçirmiştir. Özellikle Roma, Bizans ve Antik Yunan dönemlerindeki oluşan stil farklılıkları ile birlikte birçok farklı eser günümüze kadar ulaşmıştır.

Anadolu'da gün yüzüne çıkarılan mozaik örneklerinde mitolojik, insan ve hayvan figürlü konulara rastlanmamakla birlikte, genellikle geometrik motiflerin kullanıldığı mozaikler göze çarpmaktadır. Eşyanın yapısı gereği eskimesi, onun görünüşü ve yapısı üzerindeki kaçınılmaz değişimleri "bozulmayı" gündeme getirmektedir. Şüphesiz bu değişimler, çeşitli maddelerin öz direncinin gücü, bozulma faktörlerinin cinsi, şiddeti ve süresiyle orantılıdır (Eskici, 1997). Mozaiklerin yapıldıkları yüzyıllar öncesi orijinal görünüşleri ile günümüzde kazılarda gün yüzüne çıkarıldıkları görünüşleri arasında farklar bulunabilmektedir. Günümüze ulaşan çoğu mozaikler de kısmen veya büyük oranda tahribata uğradığı görülmektedir. Bunun sebebi 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, İnsanların olumsuz etkilerinden veya mozaik yapısının özelliklerinden kaynaklanan bozulmalar olarak sıralanabilmektedir. Bu tahribatların genel sonucu olarak mozaiklerde eksik desen ve motifler olarak karşımıza çıkmaktadır. Mozaik görsellerindeki eksik parçaların tamamlanması, orijinal halinin nasıl olduğunun bilinmesi de önemli bir problemidir. Şekil 1' de hasarlı bir mozaik örneği verilmektedir.



Şekil 1. Hasarlı mozaik örneği

Hasarlı görüntülerin tamamlanması günümüzde makine öğrenmesi problemleri arasında çözülmeye çalışılan güncel bir problemidir. Bu problemin çözümünde geleneksel görüntü tamamlama yöntemlerinden difüzyon tabanlı (Barnes ve ark., 2009; Ballester ve ark., 2001; Levin ve ark., 2003) ve yama tabanlı (Criminisi ve ark., 2003; Bertalmio ve ark., 2003) çözümler uygulanmış özellikle tekdüze boyama da başarılı sonuçlar verirken karmaşık tekrar etmeyen yapılarda hatalı görüntüler oluşturmaktadırlar. Derin öğrenmenin de gelişmesi ile öğrenme tabanlı yöntemlerin görüntü tamamlama probleminde daha iyi sonuçları üretmek için kullanılmaya başlanmıştır.

## MATERYAL VE METOT

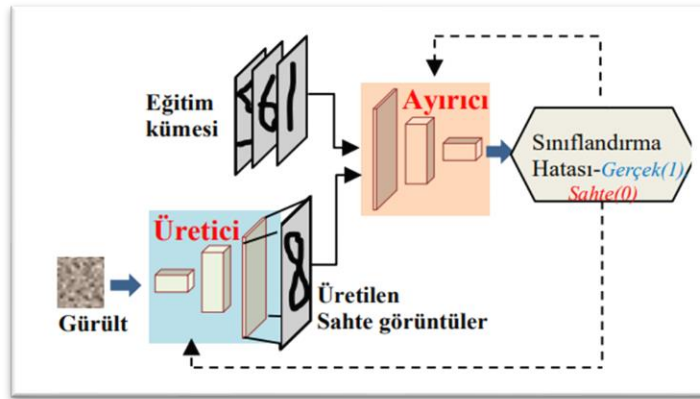
### Derin Öğrenme

Derin öğrenme ileri düzeyli ve çok katmanlı yapay sinir ağlarından oluşan bir makine öğrenme yöntemidir. Derin öğrenme algoritmaları temelde beyinde bulunan bir nöronun çalışma prensibinin bilgisayar diline çevrilmesidir. Bilgisayarlı görme, sinyal işleme, ses işleme, sınıflandırma gibi birçok alanda kullanılmaktadır. Özellikle sağlık alanında tanı ve teşhis konularında önemli çalışmalar bulunmaktadır (Pacal ve ark., 2022). Geleneksel makine öğrenmesi yöntemlerindeki gibi kodlanmış kurallar dışında resim, video, ses ve metinlerdeki verilerden otomatik olarak öğrenebilmektedirler (Kaya ve Yılmaz, 2019).

Derin öğrenme mimarilerinde ağın eğitimi esnasında denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme yöntemleri bulunmaktadır. Denetimli öğrenme yönteminde ağa bir girdi verisi ve girdiye göre çıktının ne olduğu bilgisi verilir. Ağın ağırlıkları aynı verinin tekrar tekrar ağa giriş verisi olarak verilmesi ile ağın ağırlıkları düzeltilir ve en az hataya ulaşana kadar ağ eğitilir (Makantasis ve ark. 2015). Denetimsiz öğrenmede ise giriş verisinin çıkışta ne olduğu bilgisi verilmeden, çıkışta en yakın bir kümenin üyesi olması beklenir (Radford ve ark. 2015; Higgins ve ark. 2016). Takviyeli öğrenmede ise ağda girdi verisinin çıkışta ne olduğu bilgisi verilmeden, çıkış sonucunun doğru ya da yanlış olduğu bilgisi verilerek ağın eğitimi gerçekleştirilir (Papernot ve ark. 2016).

### Çekişmeli Üretici Ağlar

Yapay zekâ ve makine öğrenmesi alanlarının güncel bir alt alanı olan derin öğrenme, son dönemde oldukça popüler olmuş bir araştırma alanıdır. Bu alanın önemli bir ağı olan çekişmeli üretici ağlar (Generative adversarial network-GAN) ise ilk ortaya çıktığı 2014 yılından günümüze sentetik görüntü üretmede, görüntü çözünürlük arttırmada, görüntü tamamlama gibi birçok farklı uygulama alanında kullanılmakta olan bir yaklaşımdır (Goodfellow ve ark, 2014). Çekişmeli üretici ağlar denetimsiz öğrenme tabanlı yöntemlerdir. Çekişmeli üretici ağ modellerinin çalışma temeli bir veri seti ile eğitilerek, eğitim sonrasında öğrendiği veriye göre yeni bir değer üretilmesi prensibine göre çalışmaktadır. Çekişmeli üretici ağlarının başlıca odağında model üretimi bulunmaktadır (Goodfellow ve ark, 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.



Şekil 2. Çekişmeli üretici ağ mimarisi (Silva, 2018; Langr ve Bok, 2018 )

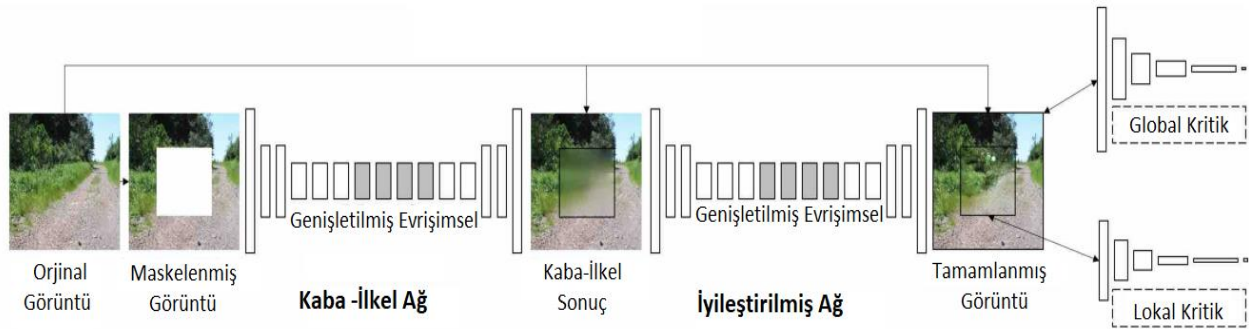
Ayrıcı model, geleneksel evrişimli sinir ağı ile oluşturulmuş evrişimsel bir sınıflandırıcıdır. Temel olarak yaptığı iş gelen görüntüleri sahte ya da gerçek olarak sınıflandırmaktır. Üretici model ise giriş olarak aldığı gürültü vektörü, her seferinde eğitim kümesindeki gerçek görüntülere benzetmeye

çalışmaktadır. Bu iki ağın birbirleri ile çekişmeli şekilde çalışmasıyla modellerin öğrenme başarısı artar ve modeller kendilerini geliştirerek daha iyi sonuçlar üretmektedirler. Şekil 3' te çekişmeli üretici ağ modeli gösterilmektedir.

### Bağlamsal Dikkat ile Görüntü Tamamlama

Geleneksel görüntü tamamlama yöntemleri çoğunlukla yama eşleştirmeye (Bertalmio ve ark., 2003; Barnes ve ark., 2009) veya doku sentezine (Efros ve Leung, 1999; Efros ve Freeman, 2001) dayanmaktadır. Derin öğrenme tabanlı yöntemlerin de zaman içinde gelişmesi ile çekişmeli üretici ağlar ile görüntü tamamlamada daha iyi sonuçları üretmek için kullanılmaya başlanmıştır.

Bu mimarilerin çoğunda ağ görüntü çevresindeki tamamlanacak alanlarda tutarsız, hatalı yapılar ve bulanık görüntüler oluşturduğu gözlemlenmektedir. Görüntü tamamlamanın temel zorluğu, mevcut görüntüdeki veri ile eksik bölgeler için görsel olarak tutarlı, gerçekçi ve anlamsal olarak makul piksellerin sentezlenememesinden kaynaklanmaktadır. Geleneksel çekişmeli üretici ağlarda, evrişimli sınır ağı (CNN) sıklıkla kullanılmaktadır. CNN tabanlı yöntemler genellikle çevredeki alanlarla tutarsız olan sınır eserleri, çarpık yapılar ve bulanık dokular oluşturmaktadır. Bunun, bağlamsal bilgi mesafesi ve tamamlanacak bölgeler arasındaki uzun vadeli korelasyonları modellemede evrişimli sınır ağlarının etkisizliğinden kaynaklandığını ortaya çıkmıştır (Yu ve ark., 2018). Şekil 4' te bağlamsal dikkat modelinin genel yapısı gösterilmektedir.

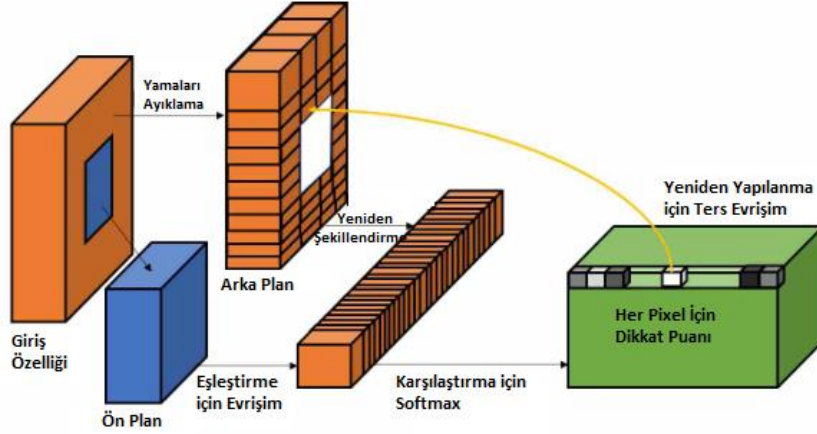


Şekil 3. Bağlamsal dikkat yöntemine genel bakış (Yu ve ark., 2018)

Bu yöntem, görüntüde eksik içerikleri düzeltmek için yeniden yapılandırma kaybıyla eğitilmiş bir genişletilmiş evrişimsel ağ ve bağlamsal dikkat aşaması olmak üzere iki aşamadan oluşmaktadır. Temel fikir, üreticinin ürettiği tamamlama yamaları işlemek için bilinen yamaların özelliklerini evrişimli filtreler olarak kullanmaktır. Bu mimaride, küresel ve yerel Wasserstein GAN(WGAN)' ları çekişmeli denetim için Derin Evrişimli Üretken Çekişmeli Ağ (DCGAN)'a (Radford ve ark., 2015) dayanır. Önceki üretken iç boyama ağlarından (Pathak ve ark., 2016; Li ve ark., 2017; Lizuka ve ark., 2017) farklı olarak, Eğitim kontrollü Wasserstein GAN (WGAN-GP)'nin (Arjovsky ve ark. 2017; Gulrajani ve ark., 2017) değiştirilmiş bir sürümüdür. Sezgisel olarak, görüntü boyama yapılacak sınırlardaki eksik pikseller, görüntü tamamlama yapılacak alanın merkezine daha yakın olan piksellerden çok daha az belirsizliğe sahiptir. Bağlamsal dikkat yönteminde bir ağırlık maskesi (M) kullanarak uzamsal olarak indirgenmiş yeniden oluşturma kaybı tanıtılmıştır (Yu ve ark., 2018). Oluşturulan Maskelerdeki her pikselin ağırlığı  $\gamma$  olarak hesaplanmaktadır. Burada  $l$ , pikselin bilinen en yakın piksele olan mesafesi ve  $\gamma$  tüm deneylerde 0.99'a ayarlanmıştır (Yu ve ark., 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 ve ark., 2018). Ayrıca bağlamsal dikkat modülü uzaysal uyumu da teşvik edebilmek için uzaysal yayılma katmanına sahiptir. Bağlamsal dikkat ağı



mimarisinde, geleneksel ağlara göre model eğitimi daha hızlıdır. Şekil 5' te bağlamsal dikkat katmanının bir modeli verilmiştir.



Şekil 4. Bağlamsal dikkat katmanı modeli (Yu ve Ark)

Şekil 5' 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 ile Görüntü Tamamlama yönteminde, bağlamsal dikkat katmanına sahip bir ileri beslemeli çekişmeli üretici ağ fikrine dayanmaktadır. Mozaik veri setindeki görüntüler incelendiğinde bu probleme özel bağlamsal dikkat ile görüntü tamamlama mimarisinin iyi sonuç verebileceği ön görülmüş ve deneysel sonuçlar gözlemlenmiştir.

### Verilerin Elde Edilmesi

Türkiye, bulunduğu coğrafya itibari ile çeşitli medeniyetlere ev sahipliği yapmış özel bir konumdadır. Günümüze kadar ulaşan çok sayıda tarihi eser ve mozaikler bulunmaktadır. Gün yüzüne çıkarılan bu eserlerden en önemlileri Hatay ve Gaziantep müzelerde bulunmaktadır. Veri seti oluşturulurken dünyanın en büyük iki mozaik müzesi olan Gaziantep Zeugma Mozaik Müzesi ve Hatay Arkeoloji müzesindeki eserler kullanılmıştır. Zeugma Mozaik müzesinde Doğu Roma Dönemi'ne ait 35 adet eserden 3.000 metrekare mozaığın 1.260 Farklı açılarda fotoğrafı çekilmiştir. Hatay Arkeoloji müzesinde ise çoğu roma dönemine ait 136 adet eserden 1.340 metrekare mozaığın 1.550 adet farklı açıdan fotoğrafı çekilmiştir. Hazırlanan veri setinde Zeugma Mozaik müzesi ve Hatay arkeoloji müzesinden 56 Esere ait toplam 2.810 adet farklı açılardan mozaik resmi kullanılmıştır. Şekil 2' de oluşturulan mozaik veri setinden bir örnek verilmiştir.



Şekil 5. Mozaik veri setinden örnek görüntüler

Resim boyutları farklılık gösterip ortalama olarak 1024x768 boyutlarından oluşmaktadır. Mozaik resimlerinde ön işleme olarak veri arttırma teknikleri kullanılmıştır. Bunun için Albumentations açık

kaynak kütüphanesinden yararlanılmıştır (Buslaev ve ark, 2016). Kullanılan veri arttırma teknikleri; görüntüyü yatay çevirme, görüntüyü büyütme veya küçültme, görüntüyü belirli açılar ile döndürme işlemlerinden oluşmaktadır.

### Öğrenme Aktarımı

Öğrenme aktarımı, bir alanda elde edinilmiş bilginin başka bir alana aktarılmasını sağlayan bir yöntemdir (Weiss ve Ark,2016). Transfer öğrenme, bir alanda eğitilen bir modelin ağırlıklarını farklı bir alana aktarma işlemidir (Pacal, 2022). Bu yöntem ile büyük veriler ile eğitilmiş modellerin öğrenim bilgisini başka modellere transfer edilmektedir. Derin öğrenmede öğrenme aktarımı çok sık başvurulan bir yöntemdir. Bir ağı ön eğitilmiş ağırlık parametreleri ile eğitmek zaman avantajı ve performans artışı sağlamaktadır. Öğrenme aktarımında, ön eğitilmiş ağı parametreleri uyum sorunlarına neden olmaması için dondurulmaktadır. Bu çalışmada 2.9 milyon parametre ile ön eğitilmiş Places2 veri seti kullanılmıştır (Yu ve ark, 2018). Ön eğitilmiş modelden, mozaik veri setine öğrenme aktarımı uygulanmıştır.

### Değerlendirme Kriterleri

Görüntü tamamlama için üretilen görüntünün başarısını sayısal ölçümlemek için yapısal benzerlik indisi (SSIM) ve Tepe Sinyal Gürültü Oranı (PSNR) metrikleri görüntü karşılaştırmada kullanılan metriklerdendir.  $x$  ve  $y$  yi birer görüntü kabul edersek,  $x$  ve  $y$  arasındaki karşılaştırma,

$$SSIM(x, y) = [I(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \text{ . şeklinde gösterilir.} \quad (1)$$

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

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (3)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (4)$$

$\mu_x$  ve  $\mu_y$  yaklaşık parlaklığı,  $\sigma_x$  ve  $\sigma_y$  kontrastı ölçer,  $\mu_x = \mu_y$  veya  $\sigma_x = \sigma_y$  olduğu durumda maksimum değer olan 1 değerini alır.

Model çıktılarının değerlendirilmesi sürecinde veri seti iki ye bölünmüş, hiçbir hasarı bulunmayan görüntülerden oluşan veri seti kullanılmıştır. Bu veri setinde yapay hasar oluşturulmuş ve iki görüntünün karşılaştırılması yöntemleri ile orijinal resim ve üretici modelin ürettiği çıktı görüntüler karşılaştırılarak sonuç değerleri paylaşılmıştır. SSIM, iki resim arasındaki benzerliği korelasyon kaybı, parlaklık bozulması ve kontrast bozulması olmak üzere üç faktörün bir kombinasyonunu modelleyerek ölçmektedir. SSIM, [0, 1] aralığındadır (Horé ve Ziou, 2010). İki resim arasında az korelasyon var ise 0, çok korelasyon var ise 1 dir.

PSNR, iki görüntü arasındaki desibel cinsinden benzerlik hata oranını hesaplamaktadır. PSNR değeri ne kadar yüksek olursa, yeniden oluşturulmuş görüntünün kalitesi o kadar iyi olur. PSNR değeri küçüldükçe, görüntüler arasında yüksek sayısal farklılıklar anlamına gelmektedir.

$$PSNR = 10 \log_{10} \left( \frac{l_{max}^2}{MSE} \right) \quad (5)$$

$l_{max}$  PSNR değeri hesaplanacak görüntünün en büyük gri ton değeridir. Bu değer en yüksek gri seviye değeri olduğu için genellikle 255 olarak kullanılır. MSE ortalama hata karesi değerini ifade etmektedir.

### BULGULAR VE TARTIŞMA

Günümüzde, derin öğrenme temelli modeller ile birçok farklı alanda, en yüksek performansların elde edildiği görülmektedir (Toğaçar ve Ergen, 2019). Özellikle en ilgi çekici konularından biride




çekişmeli üretici ağ modellerinin görüntü tamamlamada kullanılmasıdır. Bu modellerden bazılarını çalışmamızda mozaik veri seti üzerinde eğitilerek sonuçları gözlemlenmiştir. Veri setindeki görüntülerden eğitim için toplam veri setinin %60'ı kullanılırken doğrulama için %20'si ve test için %20'si kullanılmıştır. Yapılan deneysel çalışmalar Intel i7 8250U model işlemci, NVIDIA GeForce 940MX model ekran kartı ve 16 GB hafızalı Windows 10 işletim sistemine sahip bir bilgisayar üzerinde gerçekleştirilmiştir. Bir resim için ortalama görüntü tamamlama işlem zamanını 3.9 saniye olarak bulunmuştur. Oluşturulan modelin başarımlı ölçüm metriği olarak iki görüntünün SSIM ile PSNR oranları kullanılmıştır. Yöntemden elde edilen bir sonuç görüntüsü Şekil 6, Şekil 7 ve Şekil 8' de verilmiştir.



Şekil 6. Az hasarlı Mozaik 1 yöntem çıktı örnekleri



Şekil 7. Az hasarlı Mozaik 2 yöntem çıktı örnekleri



Şekil 8. Az hasarlı Mozaik 3 Yöntem çıktı örnekleri



Yapılan deneysel çalışmada orijinal görüntü alınarak görüntü üzerinde deformasyon yapılmıştır. Bu deformasyon, 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. Az hasarlı görüntülerde, orijinal görüntü ile hasarlı görüntü arasındaki SSIM değeri 0.88 - 0.91 arasında olup bu görüntülerdeki PSNR değeri 15.3 - 22.7 arasındadır. Az hasarlı mozaik görüntülerinde verilen tahribat miktarına bağlı olarak orijinal görüntü ile hasarı giderilmiş görüntü arasındaki SSIM değerinin 0.92 - 0.95 arasında değişkenlik gösterdiği gözlemlenmiştir. Bu oranın mozaik desenine göre değişiklik gösterdiği görüşmüştür. Orijinal ve hasarı giderilmiş görüntü arasındaki PSNR değeri 28.01 - 32.38 arasında değişkenlik gösterdiği tespit edilmiştir. Elde edilen test sonuçları Çizelge 1' de verilmiştir.



**Çizelge 1.** Az hasarlı mozaik görüntü tamamlama başarısı sonuçları

	Orijinal – Hasarlı Görüntü		Orijinal – Hasar Giderilmiş Görüntü	
	SSIM	PSNR	SSIM	PSNR
Mozaik 1	0.9128	22.7607	0.9566	32.3801
Mozaik 2	0.8847	17.7475	0.9225	28.0124
Mozaik 3	0.8970	15.3690	0.9340	28.3353

Yöntem çok fazla miktarda bozulmaya uğratılmış görüntüler üzerinde de test edilmiştir. Çok fazla miktarda bozulmaya uğramış örnek görüntüler ve düzeltme sonuçları Şekil 9, Şekil 10 ve Şekil 11’ de verilmiştir.

**Şekil 9.** Çok hasarlı Mozaik 1 Yöntem çıktı örnekleri**Şekil 10.** Çok hasarlı Mozaik 2 Yöntem çıktı örnekleri**Şekil 11.** Çok hasarlı Mozaik 3 Yöntem çıktı örnekleri

Çok hasarlı görüntülerde, orijinal görüntü ile hasarlı görüntü arasındaki SSIM değeri 0.67 - 0.81 arasında olup bu görüntülerdeki PSNR değeri 8.13 - 15.77 arasındadır. Çok hasarlı mozaik görüntülerinde verilen tahribat miktarına bağlı olarak orijinal görüntü ile hasarı giderilmiş görüntü arasındaki SSIM değeri 0.72 - 0.89 arasında değişkenlik gösterdiği gözlemlenmiştir. Bu oranın mozaik desenine göre değişiklik gösterdiği tespit edilmiştir. Orijinal ve hasarı giderilmiş görüntü arasındaki PSNR değeri 21.95 - 23.78 arasında değişkenlik gösterdiği gözlemlenmiştir. Çok hasarlı görüntüler üzerinde elde edilen test sonuçları Çizelge 2’ de verilmiştir.



**Çizelge 2.** Çok hasarlı mozaik görüntü tamamlama başarısı sonuçları

	Orijinal – Hasarlı Görüntü		Orijinal – Hasar Giderilmiş Görüntü	
	SSIM	PSNR	SSIM	PSNR
Mozaik 1	0.8316	15.4354	0.8917	23.2681
Mozaik 2	0.8173	15.7708	0.8522	23.7827
Mozaik 3	0.6729	8.1381	0.7265	21.9521

Yapılan çalışmanın deneysel sonuçlarına bakıldığında, mozaik desenlerinde süreklilik var ise modelin başarılı olduğu gözlemlenmiştir. Karmaşık desenli modellerde modelin başarısız olduğu tespit edilmiştir. Test sonuçlarına göre aynı görüntü üzerinde bağlamsal dikkat ile görüntü tamamlama yönteminde az hasarlı görüntülerde SSIM değeri 0.92 - 0.95 arasında değişkenlik göstermiş olup 1' e çok yakınsadığı tespit edilmiştir. Çok hasarlı resimlerde bu oranın 0.72 - 0.89 arasına düştüğü gözlemlenmiştir.

Literatürde görüntü tamamlama ile ilgili çoğul görüntü tamamlama yöntemi (Zheng ve ark., 2019) ve bölgesel konvolüsyon ve yerel olmayan korelasyon yoluyla Görüntü tamamlama yöntemi (Ma ve ark. 2019) gibi daha güncel çeşitli mimariler bulunmaktadır. Bu yöntemlerde çoğul görüntü tamamlama yönteminde tamamlanması istenen görüntünün, yalnızca tek bir tahmin üretmeye çalışan yaklaşımların aksine birden fazla ve çeşitli makul sonuçlarını üretme esasına dayanır. Bölgesel konvolüsyon ve yerel olmayan korelasyon yoluyla Görüntü tamamlama yöntemi ise en basit şekliyle bölge bazlı evrişimler kullanılarak en yakın sağlam olana göre tamamlanması esasına dayanır.

Veri kümesi aynı şartlarda çoğul görüntü tamamlama yöntemi ve bölgesel konvolüsyon ve yerel olmayan korelasyon yoluyla görüntü tamamlama yöntemi ile orijinal görüntüler ile hasarlı görüntüler arasındaki SSIM değerlerine bakılarak deneysel çalışmalar yapılmıştır. Yapılan deneysel çalışmaların aritmetik ortalaması alınarak elde edilen sonuçlar Çizelge 3'te verilmiştir.

**Çizelge 3.** Farklı yöntemler ile karşılaştırma sonuçları

	Az Hasarlı Görüntü	Çok Hasarlı Görüntü
	SSIM	SSIM
Çoğul Görüntü Tamamlama	0.7691	0.6248
Bölgesel Konvolüsyon ve Yerel Olmayan Korelasyon ile Görüntü Tamamlama	0.9071	0.8043
Bağlamsal Dikkat ile Görüntü Tamamlama	0.9487	0.8512

Çizelge 3'te görüldüğü üzere aynı veri seti üzerinde az ve çok hasarlı görüntülerde çoğul görüntü tamamlama yöntemi uygulanmış görüntülerde SSIM değerlerinin aritmetik ortalaması en düşük olurken, bağlamsal dikkat ile görüntü tamamlama yönteminin diğer yöntemlere göre daha iyi başarı gösterdiği gözlemlenmiştir.

## SONUÇ

Günümüze ulaşan mozaik eserlerindeki tahribatlardan dolayı eserlerin orijinal görüntüsünün nasıl görüldüğünün anlaşılmasına ihtiyaç duyulmaktadır. Bu çalışmada Türkiye'de bulunan mozaik eserlerindeki tahribatların derin öğrenme mimarisi kullanılarak görüntüdeki hasarların giderilmesi ele alınmıştır. Ülkemizdeki en önemli ve en büyük iki mozaik müzesindeki eserlere ait yeni bir mozaik veri seti oluşturulmuştur. Bu veri seti literatüre restorasyon alanında yapay zeka tabanlı yeni çalışmaların yapılmasının önünü açacaktır. Son yıllarda literatürde görüntü tamamlama problemi üzerine yapılan çalışmalarda en etkili sonuçlar çekişmeli üretici ağ mimarisi ile yapılmıştır. Mozaik veri setindeki görüntülerde eksik bölgelerin tamamlanmasında çekişmeli üretici ağ mimarisindeki bağlamsal dikkat yöntemi uygulanmıştır. Aynı veri seti üzerinde bölgesel konvolüsyonlar ve yerel olmayan korelasyon yöntemi, çoğul görüntü tamamlama yöntemi ve bağlamsal dikkat yöntemi ile

başarı karşılaştırılması yapılmıştır. Bağlamsal dikkat yönteminin mozaik veri seti üzerinde daha başarılı sonuçlar verdiği tespit edilmiştir. Bağlamsal dikkat yöntemi kullanılarak orijinal görüntü, hasarlı görüntü ve hasarı düzeltilmiş görüntü üzerinde SSIM ile PSNR karşılaştırılmıştır. Bu deneysel çalışmanın sonucu karmaşık motifli olmayan mozaik görüntüleri için tatmin edicidir. Mozaik görüntülerindeki tahribatın düzeltilmesi hem hızlı, hem de herhangi bir uzmana ihtiyaç duymadan eserin orijinal görüntüsüne ulaşma olanağı sağlamaktadır. Devam eden çalışmalarda, modelin daha karmaşık yapılı mozaik görüntüler için geliştirilmesi hedeflenmektedir.

### Çıkar Çatışması

Makale yazarları arasında herhangi bir çıkar çatışması olmadığını beyan ederler.

### Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan ederler.

### KAYNAKLAR

- Arjovsky M, Chintala S, Bottou L, 2017. Wasserstein Gan. arXiv 2017. arXiv preprint arXiv:1703.10785, 30(4).
- Barnes C, Shechtman E, Finkelstein A, Goldman D. B, 2009. PatchMatch: A Randomized Correspondence Algorithm for Structural Image Editing. ACM Transactions on Graphics, 28(3), 24.
- Bassier C, 1974. Weiterentwicklung der Konservierungsmethoden für Mosaiken. Arbeitsblätter für Restauratoren(7 1), 43-52.
- Ballester C., Bertalmio M., Caselles V., Sapiro G., Verdera J., 2001, Filling-in by joint interpolation of vector fields and gray levels, 10(8):1200–1211.
- Bertalmio M, Vese L, Sapiro G, Osher S, 2003. Simultaneous Structure and Texture Image Inpainting. IEEE Transactions on Image Processing, 12(8), 882-889.
- Buslaev, A., Iglovikov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M., & Kalinin, A. A., 2020. Albumentations: Fast and Flexible Image Augmentations. Information, 11(2), 125.
- Criminisi A., Perez P., Toyama K., 2003. Object removal by exemplar-based inpainting. In Computer Vision and Pattern Recognition, 2003 IEEE Computer Society Conference on, volume 2, pages II– II. IEEE.
- Efros A. A, Freeman W. T, 2001. Image Quilting for Texture Synthesis and Transfer. 28th Annual Conference on Computer Graphics and Interactive Techniques, New York, August 12-17, 2001.
- Efros A. A., Leung T. K, 1999. Texture Synthesis by Non-Parametric Sampling. Seventh IEEE International Conference on Computer Vision, Kerkyra, September 20-27, 1999.
- Eskici B, 1997. Taş Eserlerin Korunması Üzerine Notlar. Türk Arkeoloji Dergisi, 31, 338-392.
- Goodfellow I, Bengio Y, Courville A, 2016. Deep Learning: MIT Press, United States.
- Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S and Bengio Y, 2014. Generative adversarial nets. In Advances in Neural Information Processing Systems (NIPS), 8-13 December 2014; Montréal/Canada
- Gulrajani I, Ahmed F, Arjovsky M, Dumoulin V, Courville A. C, 2017. Improved Training of Wasserstein Gans. Advances in Neural Information Processing Systems, 30.
- Higgins, I., Matthey, L., Glorot, X., Pal, A., Uria, B., Blundell, C., Lerchner, A., 2016. Early visual concept learning with unsupervised deep learning. arXiv preprint arXiv:1606.05579.

- Hore A, Ziou D, 2010. Image Quality Metrics: PSNR vs. SSIM. 20th International Conference on Pattern Recognition, İstanbul, August 23-26, 2010.
- Iizuka S, Simo-Serra E, Ishikawa H, 2017. Globally and Locally Consistent Image Completion. ACM Transactions on Graphics, 36(4), 1-14.
- Kaya U., Yılmaz A., 2019. Derin Öğrenme, 1-2, ISBN:978-605-2118-399.
- Langr J, Bok V, 2019. GANs in Action (MEAP Edition Ed.). Manning Publications, United States.
- Levin A., Zomet A., Weiss Y, 2003. Learning how to inpaint from global image statistics. In null, page 305. IEEE.
- Li Y, Liu S, Yang J, Yang M.H, 2017. Generative Face Completion. IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, July 21-26, 2017.
- Ma Y., Liu X., Bai S., Wang L., He D., Liu A., 2019. Coarse-to-Fine Image Inpainting via Region-wise Convolutions and Non-Local Correlation, Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence, August 2019.
- Makantasis K., Karantzas K., Doulamis A., Doulamis N., 2015. Deep supervised learning for hyperspectral data classification through convolutional neural networks. In Geoscience and Remote Sensing Symposium , 2015 IEEE International, pp. 4959- 4962.
- Ogan A, Mirmiroğlu V, 1955. Kaariye Camii Eski Hora Manastiri. Türk Tarih Kurumu Yayınları,6.
- Pacal I., 2022, Deep Learning Approaches for Classification of Breast Cancer in Ultrasound (US) Images, Journal of the Institute of Science and Technology, 12(4): 1917 – 1927.
- Pacal I., Karaman A., Karaboga D., Akay B., Basturk A., Nalbantoglu U., Coskun S., 2022. An efficient real-time colonic polyp detection with YOLO algorithms trained by using negative samples and large datasets, Computers in Biology and Medicine, 141(September 2021):105031.
- Pathak D, Krahenbuhl P, Donahue J, Darrell T, Efros A. A, 2016. Context Encoders: Feature Learning by Inpainting. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, June 27-30, 2016.
- Papernot N., Abadi M., Erlingsson U., Goodfellow I., Talwar K., 2016. Semi-supervised knowledge transfer for deep learning from private training data. arXiv preprint arXiv:1610.05755.
- Radford A, Metz L, Chintala S, 2015. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. arXiv Preprint arXiv:.06434.
- Silva T. A, 2022. Beginner's Guide to Generative Adversarial Networks (GANs), <https://wiki.pathmind.com/generative-adversarial-network-gan> (Erişim Tarihi: 16.09.2022).
- Toğaçar M., Ergen B., 2019. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması, Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 31(1), 109-121.
- Yu J, Lin Z, Yang J, Shen X, Lu X, Huang T S, 2018. Generative Image Inpainting with Contextual Attention. IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, June 18-23, 2018.
- Weiss, K., Khoshgoftaar, T. M., & Wang, D., 2016. A survey of transfer learning. Journal of Big data, 3(1), 1-40.
- Zheng C., Cham T., Cai J., 2019. Pluralistic Image Completion, arXiv preprint arXiv: 1903.04227.