

## ESRGAN ile Medikal Görüntüleme Süper Çözünürlük

Elif Işılay ÜNLÜ<sup>1\*</sup>, Ahmet ÇINAR<sup>2</sup>

<sup>1</sup> Bilgisayar Mühendisliği, Fırat Üniversitesi, TÜRKİYE

<sup>2</sup> Bilgisayar Mühendisliği, Fırat Üniversitesi, TÜRKİYE

\*(eiunlu@firat.edu.tr)

(Received: 15 January 2025, Accepted: 21 January 2025)

(2nd International Conference on Modern and Advanced Research ICMAR 2025, January 15-16, 2025)

**ATIF/REFERENCE:** Ünlü, E. I. & Çınar, A. (2025). ESRGAN ile Medikal Görüntüleme Süper Çözünürlük. *International Journal of Advanced Natural Sciences and Engineering Researches*, 9(1), 64-76.

**Özet** – Medikal görüntüler, doğru tanı ve etkin tedavi süreçleri için kritik öneme sahiptir; ancak düşük çözünürlük, tanısal doğruluğu ve detaylı analiz kabiliyetini sınırlandırabilir. Bu çalışmada, MR (Manyetik Rezonans), X-ray (Röntgen), CT (Bilgisayarlı Tomografi) ve OCT (Optik Koherens Tomografi) teknikleriyle elde edilen diş, göğüs, beyin, kemik, böbrek ve retina görüntülerinin çözünürlüğünün artırılması amacıyla ESRGAN (Enhanced Super-Resolution Generative Adversarial Network) modeli kullanılmıştır. ESRGAN modeli ile düşük çözünürlüklü MR, X-ray ve CT görüntülerinin iyileştirilmesi hedeflenmiş ve elde edilen sonuçlar PSNR (Peak Signal-to-Noise Ratio) ve SSIM (Structural Similarity Index Measure) metrikleri kullanılarak değerlendirilmiştir. Elde edilen bulgular, ESRGAN'ın dental, göğüs, beyin, kemik, böbrek ve retina görüntülerinde belirgin bir çözünürlük iyileştirmesi sağladığını ve bu sayede medikal görüntülerin tanısal değerinin artırılabilirliğini göstermektedir. Yapılan değerlendirmelerde ortalama olarak yüksek PSNR ve SSIM değerleri elde edilmiştir. ESRGAN'ın MR, X-ray ve CT görüntüleme teknikleriyle elde edilen verilerde güvenilir ve etkili bir çözünürlük artırma aracı olarak kullanılabilirliği ortaya konmuştur.

**Anahtar Kelimeler** – ESRGAN, Medikal Görüntü İyileştirme, Süper Çözünürlük, Dental Radyografi, Göğüs XRay, Beyin MR, Kemik XRay, Böbrek BT, Retina OCT.

### I. GİRİŞ

Medikal görüntüleme, hastalıkların erken teşhisi, tedavi planlaması ve hastalık seyrinin izlenmesi için modern tıbbın vazgeçilmez bir parçası haline gelmiştir. MR (Manyetik Rezonans), X-ray (Röntgen) ve CT (Bilgisayarlı Tomografi) gibi görüntüleme teknikleri, vücudun içyapılarının detaylı görselleştirilmesini sağlayarak klinik karar verme süreçlerini büyük ölçüde destekler. Ancak bu tekniklerle elde edilen görüntülerde çözünürlük ve detay kaybı, özellikle küçük ve ince dokuların değerlendirilmesinde tanısal doğruluğu sınırlandırabilir. Düşük çözünürlüklü görüntülerde oluşan bu eksikliklerin giderilmesi, görüntü işleme tekniklerinin önemli çalışma alanlarından biri olmuştur.

Son yıllarda, derin öğrenme tabanlı yöntemler, görüntü iyileştirme çalışmalarında büyük başarılar elde etmiştir. Özellikle ESRGAN (Enhanced Super-Resolution Generative Adversarial Network) modeli, düşük çözünürlüklü görüntülerin yüksek kaliteli ve detaylı hale getirilmesinde etkili sonuçlar sunmaktadır. ESRGAN, klasik süper çözünürlük yöntemlerine kıyasla daha gerçekçi ve keskin detaylar üretebilmektedir[1].

Bu çalışmada, ESRGAN yöntemi kullanılarak MR, X-ray ve CT teknikleriyle elde edilen dental, göğüs, beyin, kemik, böbrek ve retina görüntülerinin çözünürlüğü iyileştirilmiştir. Görüntü kalitesinin değerlendirilmesi için objektif metrikler olan PSNR (Peak Signal-to-Noise Ratio) ve SSIM (Structural Similarity Index Measure) kullanılmıştır. PSNR, görüntü kalitesini matematiksel olarak değerlendirirken; SSIM, insan görsel algısını taklit ederek yapısal bütünlüğü ve detay korunumunu analiz etmektedir. Bu çalışma, ESRGAN'ın medikal görüntü iyileştirmede güvenilir ve etkili bir yöntem olduğunu kanıtlamayı ve iyileştirilmiş görüntülerin tanısal doğruluğa katkısını vurgulamayı amaçlamaktadır. Elde edilen sonuçlar, bu yöntemin medikal görüntü işleme alanında önemli bir potansiyele sahip olduğunu göstermektedir.

Farklı görüntüleme teknikleriyle elde edilen medikal görüntülerin çözünürlüğünü artırmak amacıyla, Generative Adversarial Network (GAN) tabanlı modellerin etkinliği literatürde kapsamlı bir şekilde incelenmiştir. Bu çalışmalar, düşük çözünürlüklü görüntülerin tanısal doğruluğu artırmaya yönelik iyileştirilmesi için GAN tabanlı yaklaşımların güçlü bir potansiyel taşıdığını göstermektedir.

Çelik ve arkadaşları, dental panoramik radyografların çözünürlüğünü artırmak amacıyla Super-Resolution Convolutional Neural Network (SRCNN), Efficient Sub-Pixel Convolutional Neural Network, Super-Resolution Generative Adversarial Network (SRGAN) ve Autoencoder gibi dört farklı model incelemiştir. SSIM değerlerinin 0.82 ile 0.98, PSNR değerlerinin ise 28.7 ile 40.2 arasında değiştiği görülmüştür[2]. Mohammad-Rahimi ve arkadaşları, panoramik radyografların çözünürlüğünü iyileştirmek için süper çözünürlük (SR) algoritmalarını karşılaştırmıştır. SRCNN, SRGAN, U-Net, SwinIR ve LTE modelleri incelenmiş en yüksek performansı LTE modeli göstermiştir [3]. Moran ve ekibi tarafından, SRGAN ve transfer öğrenimi kullanılarak periapikal görüntülerin kalitesi artırılmıştır. Sonuçlar, SRGAN modellerinin transfer öğrenimi ile kullanıldığında, MSE, PSNR, SSIM ve MOS metriklerinde daha üstün olduğunu göstermektedir[4].

Xu ve arkadaşlarının önerdiği yöntemde, düşük çözünürlüklü (LR) CXR görüntülerinden yüksek çözünürlüklü (HR) CXR görüntülerini doğru bir şekilde geri kazanmak için denetimli bir üretken düşman ağı (GAN) yaklaşımı sunulmuştur[5]. Nicel ve nitel değerlendirme sonuçları, önerilen yöntemin, göğüs röntgeni süper çözünürlüğünde (SR) mevcut en son yöntemlerle karşılaştırıldığında daha otantik iyileştirme sağladığını göstermektedir. Önerilen yöntem, iki farklı veri setinde sırasıyla FSIM'de %13,0 ve %12,2, MSIM'de ise %13,7 ve %12,5'lik ortalama iyileşme sağlamıştır. Bir diğer çalışmada, bir CNN modeli hem düşük çözünürlüklü orijinal görüntüler hem de ESRGAN ile iyileştirilmiş yüksek çözünürlüklü görüntüler üzerinde eğitilmiş ve bu iki veri seti üzerindeki performansı karşılaştırılmıştır. sonuçlar, ESRGAN ile iyileştirilmiş görüntüler üzerinde eğitilen CNN'in, düşük çözünürlüklü görüntülerle eğitilen modele göre daha yüksek performans gösterdiğini ortaya koymuştur[6]. Song ve arkadaşları tarafından yayımlanan çalışma yapay zeka tekniklerinin göğüs röntgeni (CXR) görüntü kalitesini artırmadaki uygulamalarını incelemektedir[7]. Yazarlar, derin öğrenme modellerinin, özellikle evrişimli sinir ağları (CNN'ler) ve üretken düşman ağların (GAN'lar), bu iyileştirmelerdeki potansiyelini vurgulamaktadır. Çalışma, yüksek kaliteli CXR görüntülerinin doğru teşhis ve tedavi planlamasında oynadığı kritik role dikkat çekmekte ve yapay zeka tabanlı görüntü iyileştirme tekniklerinin, radyologlara daha net görüntüler sunarak hasta sonuçlarını iyileştirme potansiyeline sahip olduğunu belirtmektedir. Sharma ve arkadaşları, Real-ESRGAN modelini kullanarak X-ray görüntülerinde düşük çözünürlükten yüksek kaliteli görüntülere geçişi optimize eden bir yaklaşım sunmaktadır. Model, Residual-in-Residual Dense Blocks (RRDB) ve algısal/adversaryal kayıp fonksiyonlarını entegre ederek üstün görüntü iyileştirme sağlamıştır[8].

Do ve ekibinin çalışmasında düşük çözünürlüklü manyetik rezonans görüntülerinden (MRI) yüksek çözünürlüklü görüntüler elde etmek için iki farklı GAN tabanlı modelin kullanımı incelenmiştir[9]. Bu çalışmada, CycleGAN modeli, eşlenmemiş MRI verileriyle süper çözünürlük sağlamak için modifiye edilmiş, ESRGAN ise referans olarak kullanılmıştır. Yapılan deneyler, 3T ve 7T MRI görüntülerinde farklı çözünürlük ölçeklerinde yüksek çözünürlüklü, zengin dokulara sahip görüntüler elde edilmiştir. Ünlü ve Çınar'ın çalışmasında, SRCNN, SRGAN ve ESRGAN modelleri kullanılarak beyin MRI görüntülerinin çözünürlüğü artırılmış ve ESRGAN modelinin daha keskin detaylar ve gerçekçi görüntüler ürettiği tespit edilmiştir[10]. Tan ve arkadaşlarının çalışmasında[11], SRGAN tabanlı bir mimari kullanılarak beyin MRI görüntüleri üzerinde keyfi ölçeklerde süper çözünürlük elde edilmiştir. Önerilen

yöntem, farklı ölçek faktörleri için genel bir çözüm sunarak, geleneksel yöntemlere göre %20'ye varan yapısal benzerlik indeksi (SSIM) iyileşmeleri sağlamıştır. Zhou ve arkadaşları, ESRGAN'dan türetilen MRBT-SR-GAN ın beyin tümörü MRI görüntülerinin çözünürlüğünü iyileştirmedeki performansını inceledi[12]. MRBT-SR-GAN, çözünürlüğü artırarak Dice oranını 0.724'ten 0.786'ya yükseltti. Bu yöntem, beyin tümörü tespiti, prognoz değerlendirmesi ve cerrahi planlama için umut verici sonuçlar gösterdi.


Ramprashath ve arkadaşları, kemik kırıklarının tespitinde derin öğrenme tabanlı bir yöntem önermektedir. Önerilen yöntem, simülasyon sonuçlarına göre, mevcut kenar algılama tekniklerine kıyasla daha üstün bir performans sergilemiştir. Gürültüyle başa çıkmada ve gerekli veriyi çıkarma, işleme gibi işlemlerde daha dayanıklı olduğu görülmüştür[13]. Wang ve arkadaşları, bilek ve parmak kırıklarının tespitindeki zorluklara çözüm önermiştir. Bu amaçla, 4346 anteroposterior, lateral ve oblik el röntgeninden oluşan ve çok sayıda saç teli kırık içeren bir veri seti oluşturulmuştur. Çalışma kapsamında, kırık tespit performansını artırmak için Generative Adversarial Network (GAN) tabanlı otomatik bir ön işleme yöntemi ve WrisNet adlı bir tespit ağı tasarlanmıştır. Üretici ve ayırt edici ağı, manuel ayar gerektirmeksizin %93 yapısal benzerlik (SSIM) oranı sağlamıştır[14]. Nguyen ve ekibi, KUB X-ray görüntülerinde böbrek taşı tespiti için Süper Çözünürlük (Super Resolution) teknikleri ve yeniden tasarlanmış YOLOv7 mimarisini birleştirmektedir. Bu çalışmada, EDSR, FSRCNN, LapSRN, ESPCN, ESRGAN ve GFPGAN gibi Süper Çözünürlük yöntemleri YOLOv7 mimarisine entegre edilmiştir. Süper Çözünürlük yöntemleri kullanılarak modellenin doğruluğu ve duyarlılığı önemli ölçüde artmıştır; en yüksek hassasiyet %97,3, en yüksek duyarlılık ise %91,7 olarak ölçülmüştür[15].

Qiu ve arkadaşları retina görüntülerinin süper çözünürlük rekonstrüksiyonu için geliştirilen bir İyileştirilmiş Generatif Adversarial Ağ (IGAN) algoritması önermektedir. Deneysel sonuçlar, önerilen yöntemin PSNR (Peak Signal-to-Noise Ratio) ve SSIM (Structural Similarity) gibi objektif değerlendirme göstergelerini önemli ölçüde iyileştirdiğini, elde edilen görüntülerin zengin doku detayları sunduğunu ve görsel deneyimi artırdığını göstermektedir[16]. Çınar ve Ünlü SRGAN (Super-Resolution Generative Adversarial Network) kullanılarak OCT görüntülerinin süper çözünürlüğü ele almıştır. Bu çalışmada, SRGAN mimarisi kullanılarak OCT görüntülerinin çözünürlüğü artırılmış ve elde edilen yüksek çözünürlüklü görüntülerin kalitesi değerlendirilmiştir [17]. Mahapatra ve ekibi, , düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntüler elde etmek için kullanılan, aşamalı bir generatif adversarial ağ (P-GAN) tabanlı süper çözünürlük yöntemi önermektedir. Bu yöntem, özellikle retinal görüntülerdeki küçük anatomik işaretler ve patolojiler gibi zorluklarla karşılaşılan durumlarda daha doğru tespitler yapmayı sağlamıştır[18].

## II. MATERYAL VE YÖNTEM

### A. Veri Setleri

Bu çalışmada kullanılan veri setleri, MR (Manyetik Rezonans), X-ray (Röntgen), CT (Bilgisayarlı Tomografi) ve OCT (Optik Koherens Tomografi) görüntülerini içermektedir. Tüm görüntüler anonimleştirilmiş hasta verilerinden alınmış ve çeşitli hastalıkların teşhisinde kullanılmak üzere toplanmıştır. Bu halka açık veri setleri, yüksek çözünürlükteki medikal görüntüler (ground truth) içermektedir. Dental radyografi veri seti, eğitim, test ve doğrulama olmak üzere 1272 adet görüntüden oluşmaktadır. Göğüs röntgeni veri seti 3 klasöre (eğitim, test, doğrulama) ayrılmıştır ve her görüntü kategorisi (Pnömoni/Normal) için alt klasörler içerir. 5.863 X-Ray görüntüsü (JPEG) ve 2 kategori (Pnömoni/Normal) vardır. Beyin MR veri seti, 4 sınıfa ayrılmış(glioma - meningioma - no tumor and pituitary)7023 adet insan beyni MR görüntüsü içermektedir. Kemik görüntüleri veri seti, 10 sınıflı, çeşitli kemik kırıkları tespiti için kullanılan 1129 adet X-ray görüntüsünden oluşan bir veri setidir. Böbrek taşı veri seti, farklı taş boyutlarını, şekillerini ve üriner sistemdeki pozisyonlarını kapsayan BT taramalarından 1300 adet çeşitli böbrek taşı görüntüleri içerir. Optik koherens tomografi (OCT) ile elde edilen retina görüntüleri 3 klasöre (eğitim, test, doğrulama) ayrılmıştır ve her görüntü kategorisi (NORMAL, CNV, DME, DRUSEN) alt klasörler içermektedir. Toplamda 84,495 adet OCT görüntüsü (JPEG) bulunmaktadır. Veri seti örnekleri şekil 1'de verilmiştir.



Şekil 1. Veri Seti Örnekleri

### B. Veri Önışleme

Tüm görüntüler, ESRGAN modeline uygun hale getirilmeden önce aşağıdaki işlemlerden geçirilmiştir:

- Görüntüler, standartlaştırma işlemi ile sıfır-ortalama, birim-standart sapma (zero-mean, unit-std) olarak normalize edilmiştir.
- Düşük çözünürlüklü (LR) görüntüler, yüksek çözünürlüklü (HR) görüntülerin boyutları ile aynı olacak şekilde bilerek alt örnekleme (4x downsampling) yapılmıştır. Düşük çözünürlüklü görüntüler oluşturmak için bicubic downsampling yöntemi uygulanmıştır. Böylece yüksek çözünürlüklü orijinal görüntülerin düşük çözünürlüklü versiyonları elde edilmiştir.

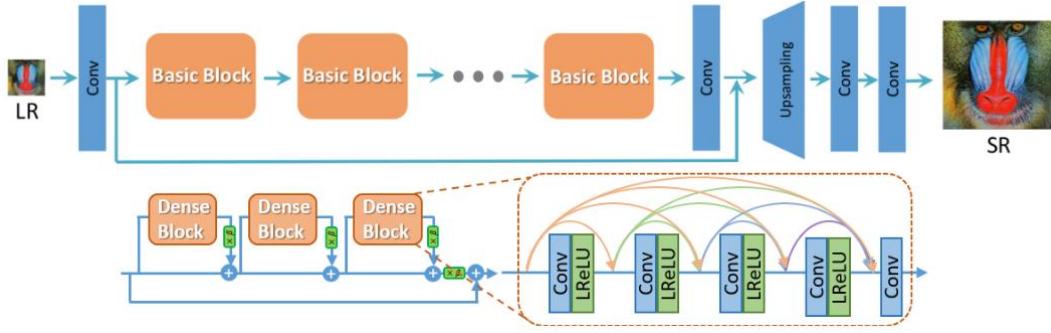
### C. ESRGAN Modeli

ESRGAN, generative adversarial network (GAN) tabanlı bir model olup, yüksek kaliteli süper çözünürlüklü görüntüler elde etmek için geliştirilmiştir[1]. Bu model, iki ana bileşenden oluşmaktadır:

**Generatör (Generator):** Düşük çözünürlüklü görüntüleri alarak yüksek çözünürlüklü görüntüler üretir. Bu ağ, residual dense block (RDB) yapıları kullanarak detaylı özellik çıkarımı yapar ve düşük çözünürlüklü görüntülerdeki bilgileri yeniden yapılandırır.

**Diskriminatör (Discriminator):** Üretilen yüksek çözünürlüklü görüntülerin gerçekçi olup olmadığını değerlendirir. Bu, görüntülerin kalitesini artırarak modelin doğruluğunu iyileştirir.

Model, düşük çözünürlüklü ve yüksek çözünürlüklü (ground truth) görüntüler arasındaki farkı minimize etmek amacıyla perceptual loss fonksiyonu ve adversarial loss fonksiyonunu birleştirerek eğitilmiştir.



Şekil 2. ESRGAN Mimarisi

#### D. Değerlendirme Metrikleri

Bu çalışmada, görüntü süper çözünürlüğü ve kalite değerlendirmesi için çeşitli metrikler kullanılmıştır:

- PSNR (Peak Signal-to-Noise Ratio): Orijinal ve yeniden oluşturulan görüntü arasındaki piksel farklılıklarını ölçerek kaliteyi değerlendiren bir metriktir. İki görüntü arasındaki farkın MSE (Mean Squared Error - Ortalama Kare Hatası) ile ölçüldüğü bir yöntemdir. Yüksek PSNR değeri daha iyi bir görüntü kalitesine işaret eder.

$$PSNR = 10 \log_{10} \frac{M^2}{MSE} \quad (1)$$

- SSIM (Structural Similarity Index): Görüntülerin yapısal benzerliğini değerlendirir. SSIM, görüntülerin birbirine ne kadar benzer olduğunu belirlemek için açıklık, kontrast ve yapı gibi üç ana özellikten yararlanır. Değerler 0-1 arasında olup, 1 mükemmel benzerliği temsil eder.

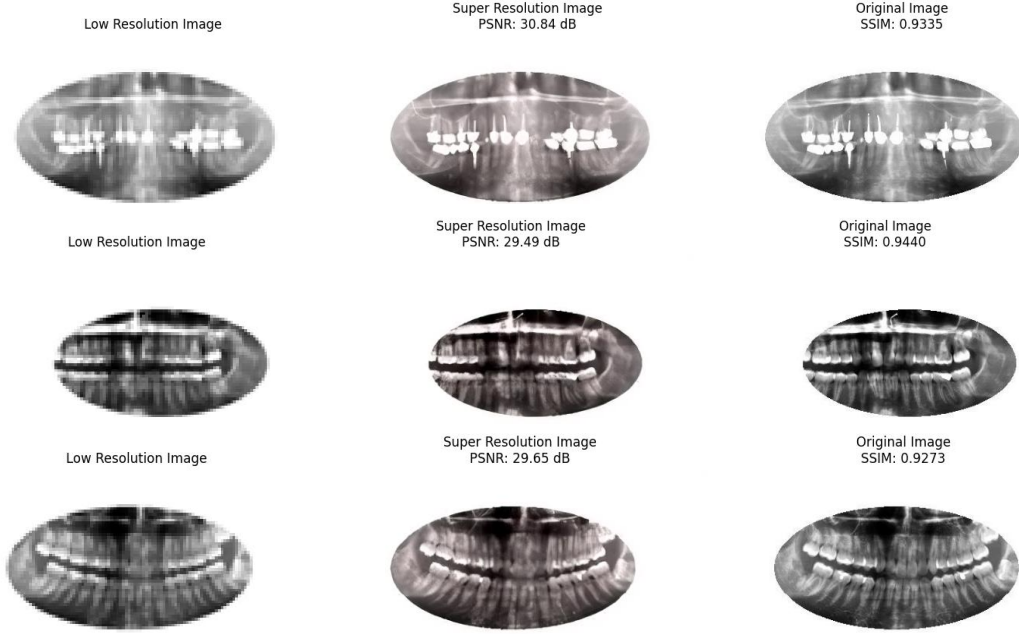
$$SSIM(I, \bar{I}) = \frac{(2\mu_I \mu_{\bar{I}} + c1)(2\sigma_{I\bar{I}} + c2)}{(\mu_I^2 + \mu_{\bar{I}}^2 + c1)(\sigma_I^2 + \sigma_{\bar{I}}^2 + c2)} \quad (2)$$

### III. BULGULAR

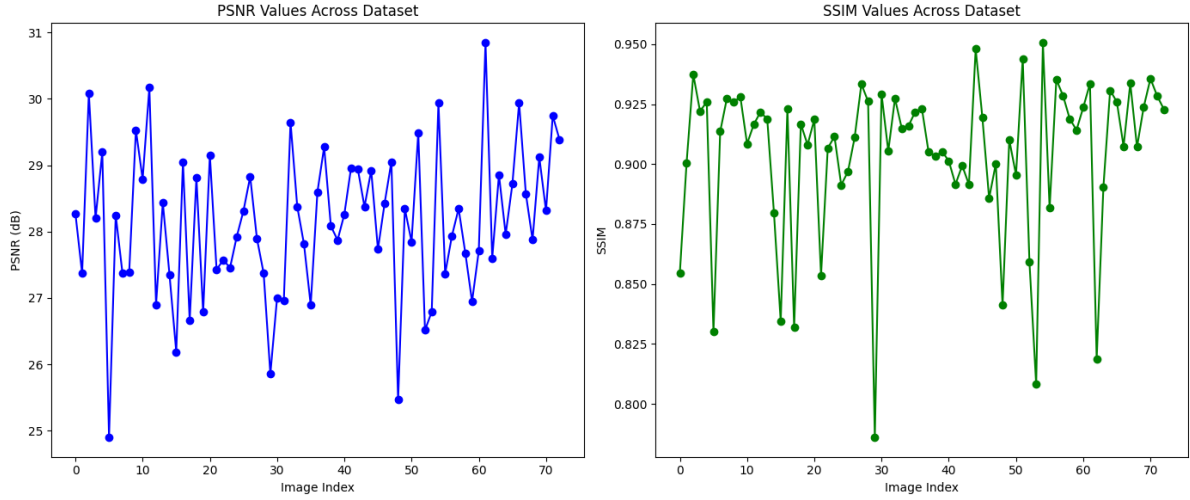
Bu çalışmada önceden eğitilmiş ESRGAN modeli ile MR, X-ray, CT ve OCT teknikleriyle elde edilen dental, göğüs, beyin, kemik, böbrek ve retina görüntülerinin çözünürlüğü artırılmıştır. Veri setleri ayrı ayrı eğitime tabi tutulmuştur. Modelin doğruluğu, peak signal-to-noise ratio (PSNR) ve structural similarity index (SSIM) gibi metrikler ile değerlendirilmiştir.

#### A. Dental Radyografi

74 adet dental radyografi görüntüsü ESRGAN modeli ile eğitilmiştir. Görüntülerin her biri ve tüm veri seti için PSNR ve SSIM metrikleri elde edilmiştir. Elde edilen görüntüler ve metrik değerleri şekil 3 ve şekil 4'de sunulmuştur.




Şekil 3. Dental Radyografi - Düşük Çözünürlüklü Görüntüler(LR),ESRGAN ile Üretilen Süper Çözünürlüklü Görüntüler (SR), Yüksek Çözünürlüklü Orjinal Görüntüler(HR)




Şekil 4. PSNR Ve SSIM Metrikleri

## B. Göğüs XRay

624 adet göğüs röntgen görüntüsü ESRGAN modeli ile eğitilmiştir. Normal ve Pneumonia sınıflarına ait görüntülerin her biri için PSNR ve SSIM metrikleri elde edilmiştir. Elde edilen görüntüler ve metrik değerleri şekil 5 ve şekil 6'da sunulmuştur.




Şekil 5. Göğüs Xray - Düşük Çözünürlüklü Görüntüler(LR),ESRGAN ile Üretilen Süper Çözünürlüklü Görüntüler (SR), Yüksek Çözünürlüklü Orjinal Görüntüler(HR)




Şekil 6. PSNR Ve SSIM Metrikleri

### C. Beyin MR

4 sınıflı (glioma, meningioma, pituitary ve no tumor) 1311 adet beyin mr görüntüsü ESRGAN modeli ile eğitilmiştir. her biri için PSNR ve SSIM metrikleri elde edilmiştir. Elde edilen görüntüler ve metrik değerleri şekil 7 ve şekil 8’de sunulmuştur.



Şekil 7. Beyin MR - Düşük Çözünürlüklü Görüntüler(LR),ESRGAN ile Üretilen Süper Çözünürlülü Görüntüler (SR), Yüksek Çözünürlüklü Orijinal Görüntüler(HR)




Şekil 8. PSNR Ve SSIM Metrikleri


#### D. Böbrek BT

123 adet böbrek BT görüntüsü ESRGAN modeli ile eğitilmiştir. Görüntülerin her biri için PSNR ve SSIM metrikleri elde edilmiştir. Elde edilen görüntüler ve metrik değerleri şekil 9 ve şekil 10'da sunulmuştur.





Şekil 9. Böbrek BT - Düşük Çözünürlüklü Görüntüler(LR),ESRGAN ile Üretilen Süper Çözünürlüklü Görüntüler (SR), Yüksek Çözünürlüklü Orjinal Görüntüler(HR)



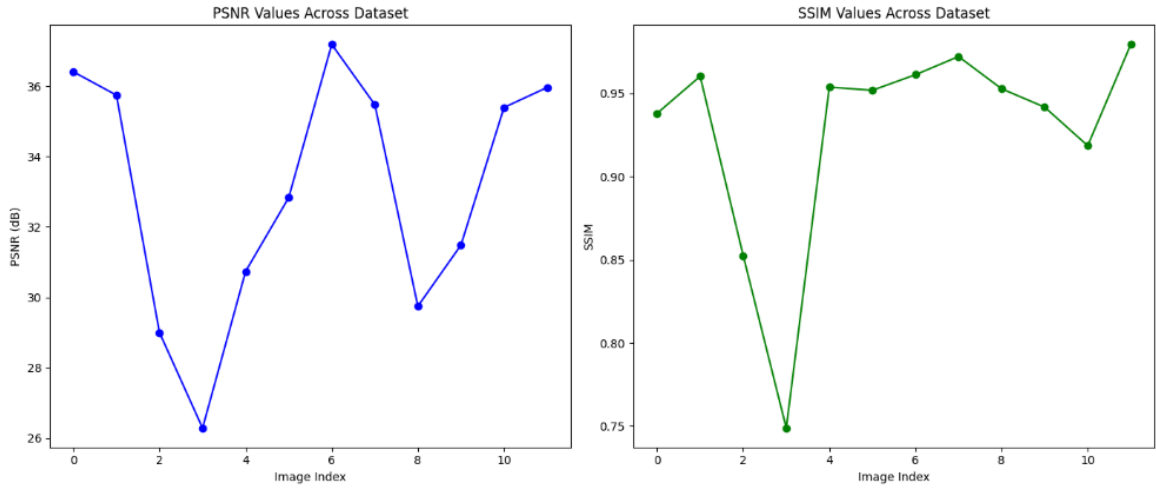
Şekil 10. PSNR Ve SSIM Metrikleri

### E. Kemik XRay

10 sınıfa ait 140 adet kemik Xray görüntüsü ESRGAN modeli ile eğitilmiştir. Görüntülerin her biri için PSNR ve SSIM metrikleri elde edilmiştir. Elde edilen görüntüler ve metrik değerleri şekil 11 ve şekil 12’de sunulmuştur.




Şekil 11. Kemik XRAY - Düşük Çözünürlüklü Görüntüler(LR),ESRGAN ile Üretilen Süper Çözünürlüklü Görüntüler (SR), Yüksek Çözünürlüklü Orjinal Görüntüler(HR)




Şekil 12. PSNR Ve SSIM Metrikleri

#### F. Retina OCT

4 sınıflı (CNV, DME, DRUSEN ve Normal) 968 adet retina görüntüsü ESRGAN modeli ile eğitilmiştir. Görüntülerin her biri için PSNR ve SSIM metrikleri elde edilmiştir. Elde edilen görüntüler ve metrik değerleri şekil 13 ve şekil 14'te sunulmuştur.



Şekil 13. Retina OCT - Düşük Çözünürlüklü Görüntüler(LR), ESRGAN ile Üretilen Süper Çözünürlüklü Görüntüler (SR), Yüksek Çözünürlüklü Orjinal Görüntüler(HR)



Şekil 14. PSNR Ve SSIM Metrikleri

Tablo 1. Veri Setleri ve Değerlendirme Metrikleri

Veri Seti	PSNR		SSIM	
	Ort.	Max.	Ort.	Max.
Dental Radyografi	28.14	30.84	0.9	0.95
Göğüs XRay	34.6	37.57	0.89	0.94
Beyin MR	30.91	33.13	0.86	0.92
Böbrek BT	29.53	30.46	0.85	0.89
Kemik XRay	33.02	37.19	0.92	0.97
Retina OCT	26.43	30.06	0.56	0.77

#### IV. TARTIŞMA VE SONUÇ

Bu çalışmada, ESRGAN tabanlı süper çözünürlük yönteminin MR, X-ray, CT ve OCT görüntüleme teknikleriyle elde edilen medikal görüntülerdeki çözünürlüğü artırma performansı değerlendirilmiştir. Görüntü kalitesinin değerlendirilmesi için objektif metrikler olan PSNR (Peak Signal-to-Noise Ratio) ve SSIM (Structural Similarity Index Measure) kullanılmıştır. Elde edilen metrikler Tablo 1’de sunulmuştur. Sonuçlar, ESRGAN’ın, düşük çözünürlüklü medikal görüntülerde detayları yeniden yapılandırma ve görsel kaliteyi artırmada etkili olduğunu göstermiştir. Yöntem, özellikle ince anatomik yapılar ve patolojilerin daha net bir şekilde gözlemlenmesini sağlamıştır.

ESRGAN, doku ve kenar ayrıntılarını koruyarak tanı süreçlerini destekler. Bu özellik, özellikle düşük radyasyon seviyelerinde elde edilen X-ray görüntüleri için kritik önem taşır. Yöntemin, retinal taramalar gibi hassas tanılama gerektiren alanlarda kullanım potansiyeli yüksektir. Ancak, büyük görüntü boyutlarında işlem süresi ve veri çeşitliliği gibi sınırlamalar bulunmaktadır. ESRGAN modelinin düşük kaliteli görüntülerde gürültüyü artırma ve aşırı düzleştirme gibi sınırlamalarına rağmen, sağladığı iyileştirmeler, görüntülerin tanısal bilgi içeriğini güçlendirmiştir. Bu, klinik teşhis sürecinde netlik ve doğruluk açısından önemli bir fayda sağlamaktadır.

ESRGAN, medikal görüntü çözünürlüğünün artırılması için umut vadeden bir yöntemdir. Yöntemin daha geniş veri setleri ve farklı hastalık grupları üzerinde test edilmesi, klinik doğrulama süreçlerini hızlandırabilir. Gelecekteki çalışmalar, modelin gerçek zamanlı işleme uygun hale getirilmesine, gürültü kaynaklı sorunların giderilmesine ve daha geniş veri setlerinde doğrulanmasına odaklanmalıdır. ESRGAN’ın klinik iş akışlarına entegre edilmesi, görüntü tabanlı teşhis süreçlerini dönüştürerek sağlık hizmetlerinin daha erişilebilir ve verimli olmasına katkıda bulunabilir.

#### KAYNAKLAR

- [1] X. Wang *et al.*, “ESRGAN: Enhanced super-resolution generative adversarial networks,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11133 LNCS, pp. 63–79, 2019, doi: 10.1007/978-3-030-11021-5\_5.
- [2] M. E. Çelik, M. Mikaeili, and B. Çelik, “Improving resolution of panoramic radiographs: super-resolution concept,” *Dentomaxillofac. Radiol.*, vol. 53, no. 4, pp. 240–247, 2024, doi: 10.1093/dmfr/twae009.
- [3] H. Mohammad-Rahimi *et al.*, “Super-Resolution of Dental Panoramic Radiographs Using Deep Learning: A Pilot Study,” *Diagnostics*, vol. 13, no. 5, pp. 1–10, 2023, doi: 10.3390/diagnostics13050996.
- [4] M. B. H. Moran, M. D. B. Faria, G. A. Giraldi, L. F. Bastos, and A. Conci, “Using super-resolution generative adversarial network models and transfer learning to obtain high resolution digital periapical radiographs,” *Comput. Biol. Med.*, vol. 129, no. November 2020, p. 104139, 2021, doi: 10.1016/j.combiomed.2020.104139.
- [5] L. Xu, X. Zeng, Z. Huang, W. Li, and H. Zhang, “Low-dose chest X-ray image super-resolution using generative adversarial nets with spectral normalization,” *Biomed. Signal Process. Control*, vol. 55, p. 101600, 2020, doi: 10.1016/j.bspc.2019.101600.
- [6] P. Sharma, B. Mohanram, J. Vijayashree, J. Jayashree, and A. R. Sahoo, “Image Enhancement using ESRGAN for CNN based X-Ray Classification,” *2022 5th Int. Conf. Contemp. Comput. Informatics*, no. 2, pp. 1965–1969, 2022, doi: 10.1109/IC3I56241.2022.10072472.

- [7] L. Song *et al.*, “Journal Pre f,” *Radiat. Med. Prot.*, 2024, doi: 10.1016/j.radmp.2024.12.003.
- [8] R. K. Sharma, “Efficient Medicinal Image Transmission and Resolution Enhancement via GAN,” pp. 1–11, 2024.
- [9] H. Q. Do *et al.*, “7T MRI super-resolution with Generative Adversarial Network To cite this version : HAL Id : hal-03003045 7T MRI super-resolution with Generative Adversarial Network,” 2021.
- [10] E. I. Ünlü and A. Çınar, “Derin Öğrenme ile Beyin MRI Görüntülerinde Süper Çözünürlük : SRCNN , SRGAN ve ESRGAN Yaklaşımları,” pp. 825–835, 2024.
- [11] C. Tan, J. Zhu, and P. Lio’, “Arbitrary scale super-resolution for brain MRI images,” *IFIP Adv. Inf. Commun. Technol.*, vol. 583 IFIP, pp. 165–176, 2020, doi: 10.1007/978-3-030-49161-1\_15.
- [12] Z. Zhou *et al.*, “Super-resolution of brain tumor MRI images based on deep learning,” no. June, pp. 1–13, 2022, doi: 10.1002/acm2.13758.
- [13] J. Hemapriyadharshini, A. Vigneshwar, G. Akash, and G. Kirubakaran, “Deep Learning Analysis of Bone Fracture Using Images Processing Techniques,” vol. 10, pp. 1592–1608, 2023.
- [14] W. Wang and W. Huang, “Attention mechanism-based deep learning method for hairline fracture detection in hand X-rays,” *Neural Comput. Appl.*, vol. 34, no. 21, pp. 18773–18785, 2022, doi: 10.1007/s00521-022-07412-0.
- [15] M. Tai, P. Nguyen, V. T. Le, H. T. Duong, and V. T. Hoang, *Detection of Kidney Stone Based on Super Resolution Techniques and YOLOv7 Under Limited Training*. Springer Nature Switzerland. doi: 10.1007/978-3-031-46749-3.
- [16] D. Qiu, Y. Cheng, and X. Wang, “Computer Methods and Programs in Biomedicine,” *Comput. Methods Programs Biomed.*, vol. 225, p. 106995, 2022, doi: 10.1016/j.cmpb.2022.106995.
- [17] A. Çınar and E. I. Ünlü, “Araştırma Makalesi SRGAN ile Süper Çözünürlüklü OCT Görüntüleri Oluşturma,” pp. 109–114, 2023.
- [18] D. Mahapatra, B. Bozorgtabar, and R. Garnavi, “Computerized Medical Imaging and Graphics Image super-resolution using progressive generative adversarial networks for medical image analysis,” *Comput. Med. Imaging Graph.*, vol. 71, pp. 30–39, 2019, doi: 10.1016/j.compmedimag.2018.10.005.