

Derin Öğrenme ile Beyin MRI Görüntülerinde Süper Çözünürlük: SRCNN, SRGAN ve ESRGAN Yaklaşımları

Elif Işılay ÜNLÜ^{1*}, Ahmet ÇINAR²

¹Bilgisayar Mühendisliği, Fırat Üniversitesi, TÜRKİYE

²Bilgisayar Mühendisliği, Fırat Üniversitesi, TÜRKİYE

*(eiunlu@firat.edu.tr)

(Received: 11 December 2024, Accepted: 29 December 2024)

(5th International Conference on Scientific and Academic Research ICSAR 2024, December 23-24, 2024)

ATIF/REFERENCE: ÜNLÜ, E. I. & ÇINAR, A. (2024). Derin Öğrenme ile Beyin MRI Görüntülerinde Süper Çözünürlük: SRCNN, SRGAN ve ESRGAN Yaklaşımları. *International Journal of Advanced Natural Sciences and Engineering Researches*, 8(11), 825-835.

Özet – Tıbbi görüntüleme teknolojileri, hastalıkların doğru teşhis ve tedavisinde hayati bir öneme sahiptir. Beyin MRI görüntüleri, nörolojik hastalıkların tanı ve takibinde detaylı anatomik bilgi sunar. Ancak, teknik sınırlamalar ve donanım kapasiteleri nedeniyle elde edilen MRI görüntüleri çoğu zaman düşük çözünürlüklü olmaktadır. Bu çalışmanın amacı, düşük çözünürlüklü beyin MRI görüntülerini iyileştirmek için SRCNN (Super-Resolution Convolutional Neural Network), SRGAN (Super-Resolution Generative Adversarial Network) ve ESRGAN (Enhanced Super-Resolution Generative Adversarial Network) yöntemlerinin uygulanması ve karşılaştırılmasıdır. Modellerin performansları, görsel kalite, yapısal benzerlik indeksi (SSIM) ve tepe sinyal-gürültü oranı (PSNR) gibi ölçütlerle değerlendirilmiştir. Elde edilen bulgular, ESRGAN modelinin daha keskin detaylar ve daha gerçekçi görüntüler ürettiğini ortaya koymaktadır. Bu çalışma, derin öğrenme tabanlı süper çözünürlük tekniklerinin tıbbi görüntüleme sunduğu yenilikçi olanaklara dikkat çekmektedir.

Anahtar Kelimeler – Süper Çözünürlük, Beyin MRI Görüntüleri, SRCNN, SRGAN, ESRGAN, Derin Öğrenme, Tıbbi Görüntüleme

I. GİRİŞ

Tıbbi görüntüleme teknikleri, modern tıbbın hastalıkların teşhisi, tedavi planlaması ve hasta takibindeki en önemli araçlarından biridir. Özellikle Manyetik Rezonans Görüntüleme (MRI), non-invaziv yapısı ve yumuşak doku kontrastını yüksek hassasiyetle sunabilme yeteneği sayesinde nörolojik hastalıkların incelenmesinde yaygın olarak kullanılmaktadır. Ancak, MRI cihazlarının teknik sınırlamaları, uzun tarama süreleri ve donanım kısıtlamaları, çoğu zaman düşük çözünürlüklü görüntülerin elde edilmesine yol açmaktadır[1]. Düşük çözünürlüklü MRI görüntüleri, ince anatomik yapılar ve patolojik değişimlerin doğru bir şekilde analiz edilmesini zorlaştırarak teşhis ve tedavi süreçlerini olumsuz etkileyebilir[2].

Geleneksel görüntü iyileştirme teknikleri, genellikle interpolasyon yöntemlerine dayanmakta ve görüntüdeki detay kayıplarını yeterince geri kazanamamaktadır[3]. Bu eksiklikleri gidermek amacıyla Derin Öğrenme (Deep Learning) tabanlı Süper Çözünürlük (Super-Resolution, SR) yöntemleri son yıllarda büyük ilgi görmüştür. Süper çözünürlük, düşük çözünürlüklü bir görüntüyü yüksek çözünürlüklü bir görüntüye dönüştürerek detayların ve netliğin artırılmasını hedefler[4].

Bu alanda öne çıkan yaklaşımlardan biri olan SRCNN (Super-Resolution Convolutional Neural Network), süper çözünürlük problemini doğrudan evrişimli sinir ağları (CNN) kullanarak çözmeyi amaçlar[3]. SRCNN, düşük çözünürlüklü görüntüleri doğrudan yüksek çözünürlüklü versiyonlarına çevirebilen ilk derin öğrenme tabanlı modellerden biridir. Ancak, SRCNN'nin ağ mimarisi oldukça basit olduğundan karmaşık ve ince dokusal ayrıntıları doğru bir şekilde yeniden oluşturmakta yetersiz kalabilir[5]. Ayrıca, modelin eğitim süreci uzun süre alabilir ve büyük veri setleriyle çalışırken performansında belirgin sınırlamalar ortaya çıkabilir. Bu durum, özellikle karmaşık beyin MRI görüntülerinde belirgin hale gelir ve detay kayıplarının önüne geçilemez.

SRCNN'deki bu eksiklikleri gidermek için geliştirilen SRGAN (Super-Resolution Generative Adversarial Network) modeli, süper çözünürlük problemini daha ileri bir seviyeye taşımıştır[4]. SRGAN, görüntülerin daha doğal ve gerçekçi detaylarla yeniden yapılandırılmasını sağlamak için Üretici Ağ (Generator) ve Ayırtıcı Ağ (Discriminator) olmak üzere iki rekabetçi ağ kullanır. Üretici ağ, düşük çözünürlüklü görüntüleri yüksek çözünürlüklü görüntülere dönüştürürken, ayırtıcı ağ ise üretilen görüntülerin gerçek olup olmadığını değerlendirmektedir. Ancak SRGAN'ın da bazı sınırlamaları mevcuttur. Model, bazen ince detayların yeniden yapılandırılmasında yapay etkiler ve tutarsızlıklar üretebilir[2]. Ayrıca, SRGAN'ın kayıp fonksiyonu (loss function) belirli durumlarda görüntüdeki yüksek frekanslı detayları yeterince koruyamaz ve bu durum, özellikle MRI görüntülerinde kritik olan hassas anatomik yapıların netliğini etkileyebilir [6].

SRGAN'daki bu sınırlamaları gidermek amacıyla daha gelişmiş bir model olan ESRGAN (Enhanced Super-Resolution Generative Adversarial Network) önerilmiştir[2]. ESRGAN, SRGAN'a kıyasla daha derin bir ağ mimarisi, daha gelişmiş kayıp fonksiyonları ve ayrıntılı ince yapıların daha gerçekçi rekonstrüksiyonunu sağlayan yöntemler içermektedir. ESRGAN, özellikle tıbbi görüntülerdeki ince dokuların korunması ve yapay görsel artefaktların azaltılması konularında önemli iyileştirmeler sunmaktadır.

Elsaid ve arkadaşları, SRCNN kullanarak düşük çözünürlüklü difüzyon tensor görüntülerinin yüksek çözünürlüklü hale getirilmesini ele almıştır. Sonuçlar, önerilen derin öğrenme yönteminin, yalnızca yüksek çözünürlüklü difüzyon görüntüleriyle tespit edilebilen anatomik detayları yeniden üretmede başarılı olduğunu göstermektedir[7]. Thurnhofer-Hemsi ve diğerleri[8], SRCNN'i Düzenli Aralıklı Kaydırma (RegSS) stratejisiyle birleştirir. Bu model, SR işlemeden önce giriş görüntüsüne düzenli bir desende kaydırmalar uygulayarak öne çıkar. Düzenli aralıklı kaydırmanın kullanımı, bilgi kaybını en aza indirmeye yardımcı olur ve yeniden oluşturulan görüntülerin genel kalitesini artırır.

Sánchez ve arkadaşları[9], SRGAN modeline dayalı bir mimari kullanılarak düşük çözünürlüklü beyin MRI görüntülerinden yüksek çözünürlüklü görüntüler üreten bir çalışma yapmıştır. 3D konvolüsyonlar kullanılarak hacimsel bilgilerden yararlanılmış ve eğitim sırasında kararlılığı artırmak için en küçük kareler adversaryal kaybı uygulanmıştır. Sonuçlar, klasik interpolasyon yöntemlerine göre belirgin iyileşmeler göstermektedir. Tan ve arkadaşlarının çalışmasında[10], 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. Ankitha ve arkadaşları[11], Generative Adversarial Networks (GANs) kullanarak beyin MRI görüntülerinin çözünürlüğünü artırmayı amaçlamaktadır. Çalışmada, GAN tabanlı modellerin özellikle SRGAN'ın ince anatomik detayları ve görüntü kalitesini önemli ölçüde iyileştirdiği gösterilmiştir. Geleneksel süper çözünürlük yöntemlerine kıyasla GAN'lar daha net ve doğru görüntüler sunarak tanı güvenilirliğini artırmaktadır. Jiang ve arkadaşları[12], CT görüntülerinin çözünürlüğünü artırmak için geliştirilmiş bir Süper Çözünürlük Generatif Adversarial Ağ (SRGAN) önermiştir. Çalışmada, yazarlar ağ mimarisine, CT görüntülerindeki ince özellikleri daha iyi yakalamak amacıyla kalıntı bloklar ve genişletilmiş konvolüsyonlar eklenmiştir. Ayrıca, yeniden yapılandırılan görüntülerin görsel kalitesini artırmak için algısal kayıp (perceptual loss) fonksiyonu da kayıp fonksiyonuna dahil edilmiştir. Deneysel sonuçlar, geliştirilmiş SRGAN'ın geleneksel interpolasyon yöntemlerine ve standart SRGAN modellerine kıyasla daha yüksek kaliteli süper çözünürlüklü CT görüntüleri sunduğunu göstermektedir. Bharathi Mohan ve diğerleri[13], beyin tümörü MRI görüntülerinin kalitesini artırmak için Generatif Adversarial Ağlar (GAN'lar) kullanımı üzerine


odaklanmaktadır. Yöntem, rastgele gürültüden görüntüler oluşturan bir üretici ve gerçek ile üretilen görüntüleri ayıran bir ayırt edici kullanarak eğitim yapılmıştır. Yöntem, yüksek bir yapısal benzerlik indeksi (SSIM) ve %86 piksel doğruluğu ile değerlendirilmiştir. Ayrıca, üretilen görüntüler, önceden eğitilmiş bir modele eklenerek doğruluk %84'ten %91'e çıkarılmıştır.

Bu çalışmada, literatürdeki çalışmalara benzer olarak SRCNN, SRGAN ve ESRGAN modelleri kullanılarak düşük çözünürlüklü beyin MRI görüntülerinin süper çözünürlük teknikleri ile iyileştirilmesi amaçlanmaktadır. Ayrıca, bu modellerin performansları çeşitli metrikler (PSNR, SSIM vb.) kullanılarak detaylı bir şekilde karşılaştırılacaktır. Elde edilen sonuçların, tıbbi görüntüleme alanında süper çözünürlük tekniklerinin etkinliğini ve klinik uygulamalardaki potansiyelini ortaya koyması hedeflenmektedir.

II. MATERYAL VE YÖNTEM

A. Veri Seti

Bu çalışmada halka açık BraTS 2020 veri seti kullanılmıştır [14]. BraTS 2020 (Brain Tumor Segmentation Challenge 2020) veri seti, beyin tümörü segmentasyonu üzerine yapılan araştırmalara katkı sağlamak amacıyla oluşturulmuştur. Veri seti, yüksek çözünürlüklü MRI görüntülerinden oluşur ve glioma (iyi huylu ve kötü huylu beyin tümörleri) içeren 3D beyin görüntüleri içerir. BraTS 2020, beyin tümörlerinin farklı türlerini, büyüklüklerini ve yapılarının doğru bir şekilde tespit edilmesini sağlayacak segmentasyon görevleri için kullanılır. Veri seti, 4 farklı modalitede (T1, T1c, T2, FLAIR) MRI görüntüleri sağlar. Veri seti görüntü örnekleri Şekil 1'de verilmiştir.




Şekil 1. BraTS 2020 Veri Seti

B. SRCNN Mimarisi

SRCNN, bir kilometre taşı olarak adlandırılabilir sinir ağı modelini kullanan ilk süper çözünürlüklü teknolojidir. SRCNN, süper çözünürlük alanında önemli bir dönemeç oluşturmuş ve daha sonraki modellerin geliştirilmesine ilham vermiştir. SRCNN fikri, seyrek kodlama tabanlı süper çözünürlük yöntemlerinden esinlenmiştir SRCNN, her katmanın filtre boyutlarının $64 \times 1 \times 9 \times 9$, $32 \times 64 \times 5 \times 5$ ve $1 \times 32 \times 5 \times 5$ olduğu üç katmanlı bir CNN'dir. Önerilen mimari kavramsal olarak 3 bileşenden oluşmaktadır: Özellik çıkarıcı, doğrusal olmayan haritalama, yeniden yapılandırma. Her biri düşük çözünürlüklü özelliklerin çıkarılmasından, yüksek çözünürlüklü özelliklere eşlemeden ve yeniden yapılanmadan sorumludur. Yama çıkarma katmanı, girişten yoğun yamaları çıkarmak ve bunları evrişimli filtreler kullanarak temsil etmek için kullanılır. Doğrusal olmayan haritalama katmanı, kanal sayısını değiştirmek ve doğrusal olmama eklemek için kullanılan 1×1 evrişimli filtrelerden oluşur. Son yeniden yapılandırma katmanı, yüksek çözünürlüklü görüntüyü yeniden oluşturur. Ağı eğitmek için MSE kaybı işlevi kullanılır ve sonuçları değerlendirmek için PSNR kullanılır [15].

SRCNN, çözünürlük artırma alanında büyük bir yenilik olsa da, bazı sınırlamalara sahiptir. En önemli sınırlamalardan biri, modelin genellikle daha yüksek doğruluk oranları için çok daha derin ağlara ihtiyaç

duymasıdır. Bunun sonucu olarak, SRCNN'nin eğitim süreci hesaplama açısından oldukça maliyetlidir. Ayrıca, SRCNN'nin performansı daha karmaşık görüntülerde ve çok büyük ölçekli verilerde sınırlı kalmaktadır. SRCNN'nin sınırlamaları, daha derin ağ yapılarının kullanılmasını teşvik etmiştir. SRCNN mimarisi Şekil 2'de verilmiştir.



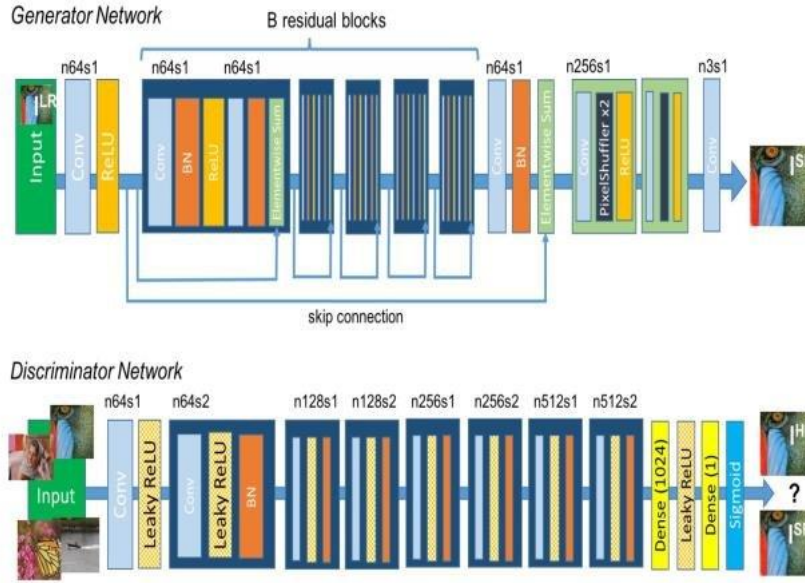
Şekil 2. SRCNN Mimarisi

C. SRGAN Mimarisi

SRCNN'deki eksiklikleri gidermek için geliştirilen SRGAN (Super-Resolution Generative Adversarial Network) modeli, süper çözünürlük problemini daha ileri bir seviyeye taşımıştır. SRGAN, düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntüler elde etmek için GAN mimarisini kullanan ilk model olarak dikkat çekmektedir [4]. SRGAN, temel olarak Generative Adversarial Network (GAN) mimarisine dayanmaktadır. GAN, bir üretici (generator) ve bir ayırmacı (discriminator) olmak üzere iki ana bileşenden oluşur. SRGAN'nin üretici, düşük çözünürlüklü bir görüntüyü yüksek çözünürlüklü bir görüntüye dönüştürmek için tasarlanmıştır. Üretici, derin öğrenme tabanlı bir konvolüsyonel ağ (convolutional neural network, CNN) kullanarak giriş görüntüsünü işleyerek daha ayrıntılı ve net bir görüntü üretir. SRGAN'deki üretici, residual block adı verilen özel yapılar içerir. Bu yapılar, ağın daha derin olmasına rağmen daha verimli öğrenmesini sağlar. Isola[16] tarafından önerilen üretici mimarisi, dekonvolüsyon katmanları (deconvolutional layers) kullanarak düşük çözünürlüklü görüntüyü daha yüksek çözünürlüklü hale getirir. Dekonvolüsyon, görüntüyü genişletmek (upsampling) için kullanılan bir tekniktir ve bu sayede görüntünün boyutu artırılır. Üretici, yüksek çözünürlüklü görüntüdeki detayları öğrenmek için çok sayıda katman içerir ve sonunda daha doğru ve keskin bir görüntü elde edilir.

SRGAN'nin ayırmacı ağı, üretilen yüksek çözünürlüklü görüntünün gerçek olup olmadığını değerlendiren bir ağıdır. Ayırmacı, üreticinin oluşturduğu görüntüleri gerçek yüksek çözünürlüklü görüntülerle karşılaştırarak gerçek ve sahte arasındaki farkı anlamaya çalışır. Bu, adversarial loss (karşıt kayıp) fonksiyonunun bir parçası olarak çalışır. Ayırmacı ağı, yüksek çözünürlüklü görüntülerdeki gerçekçi detayları ve yapıları ayırt etmek için eğitim alır. SRGAN, yüksek çözünürlüklü görüntüleri üretmek için sadece adversarial kayıp kullanmaz. Aynı zamanda içerik kaybı (content loss) fonksiyonu da kullanılır. İçerik kaybı, üretilen görüntü ile gerçek yüksek çözünürlüklü görüntü arasındaki farkı ölçer ve genellikle VGG ağı (Visual Geometry Group Network) katmanlarından birinin özellik haritalarını kullanarak hesaplanır. VGG ağı, görüntü tanıma ve sınıflandırma gibi görevlerde başarılı bir şekilde eğitilmiş bir ağ olduğundan, bu özellik haritaları görüntünün daha yüksek düzeydeki yapısını anlamak için kullanılır. SRGAN, yüksek çözünürlükte görüntü üretme konusunda önemli başarılar elde etmiş olsa da, bazı sınırlamalara sahiptir. Örneğin, modelin eğitimi yüksek hesaplama gücü gerektirir ve eğitim süresi uzundur. Ayrıca, SRGAN'in ürettiği görüntüler, bazen detaylar açısından aşırıya kaçabilir veya

bazı yapısal hatalar içerebilir. Bu sınırlamaları aşmak için, ESRGAN (Enhanced Super-Resolution Generative Adversarial Network) gibi geliştirilmiş modeller ortaya çıkmıştır.



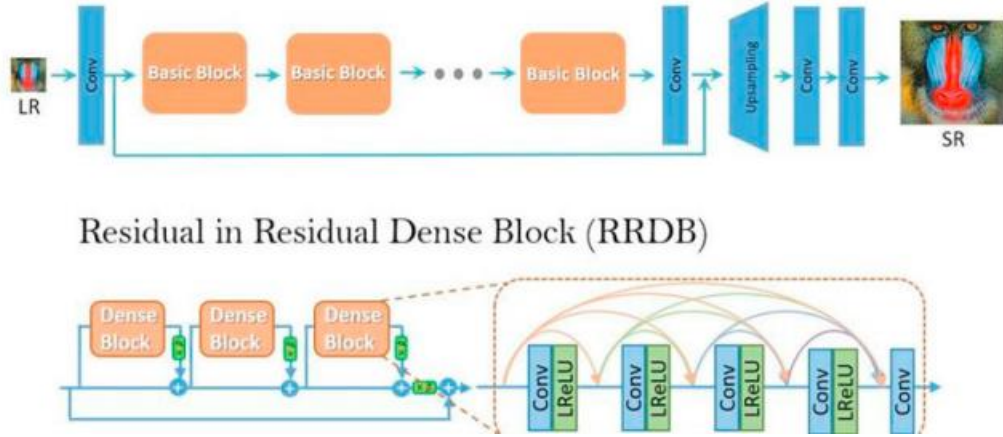
Şekil 3. SRGAN Mimarisi

D. ESRGAN Mimarisi

ESRGAN, SRGAN'in temel mimarisini geliştirerek daha kaliteli ve tutarlı yüksek çözünürlüklü görüntüler üretmeye odaklanır. SRGAN'den daha verimli ve daha yüksek kaliteli sonuçlar elde etmek için birkaç önemli iyileştirme içerir. ESRGAN'in mimarisi, temel olarak residual dense block yapısını ve daha gelişmiş adversarial kayıp fonksiyonlarını içermektedir. ESRGAN'in üretici, daha derin ve güçlü bir ağ yapısına sahiptir. ESRGAN, SRGAN'den farklı olarak, üretici kısmında Residual Dense Blocks kullanır. RDB, birden fazla residual bağlantı içeren yoğun yapılar olup, her bir katman önceki katmanların çıktısını alır ve bu sayede daha verimli bilgi akışı sağlar. Bu yapı, derin ağların öğrenmesini kolaylaştırarak daha kaliteli özelliklerin öğrenilmesine yardımcı olur[2]. Ayrımcı, üretilen yüksek çözünürlüklü görüntülerin gerçek mi yoksa sahte mi olduğunu belirler. ESRGAN, ayrımcı mimarisinde de bazı iyileştirmeler sunmaktadır. PatchGAN mimarisi, her görüntü parçasının gerçek mi sahte mi olduğunu belirlemek için kullanılır. Bu yaklaşım, görüntüdeki dokuların daha doğru bir şekilde ayırt edilmesini sağlar. Ayrımcı, hiyerarşik yapısı ile, küçük görüntü parçalarını değerlendirerek, her bir parçada yüksek kaliteli ve doğal görünümler elde edilmesini sağlar. Bu yapılar, daha tutarlı ve detaylı ayırım yapabilen bir ağ oluşturur.

ESRGAN, SRGAN'e kıyasla birkaç önemli iyileştirme sunar:

- Daha yüksek çözünürlükte görüntü kalitesi: ESRGAN, daha fazla detay ve dokuyu öğrenmeye olanak tanır, bu da daha keskin ve doğal görsellerin üretilmesini sağlar.
- Gelişmiş Yapı: Residual Dense Blocks ve dilate edilmiş konvolüsyonlar, modelin daha derin ve güçlü öğrenmesini sağlayarak, daha tutarlı sonuçlar elde edilmesini mümkün kılar.
- Gerçekçilik ve Görsel Doğallık: ESRGAN, özellikle görsel gerçekçilik konusunda önemli ilerlemeler kaydetmiştir ve daha doğal, kaliteli görüntüler üretir.



Şekil 4. ESRGAN Mimarisi

E. Değerlendirme Metrikleri

SRCNN, SRGAN ve ESRGAN modellerinin performansı, yüksek çözünürlüklü (HR) ve SR (Super-Resolution) görüntülerinin kalitesini değerlendirmek için farklı metrikler kullanılarak değerlendirilmiştir. Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index (SSIM) ve gözlem değerlendirmeleri gibi metrikler kullanılarak model başarıları ölçülmüştür.

Peak Signal-to-Noise Ratio (PSNR), görüntü kalitesini değerlendirmek için sıklıkla kullanılan bir metriktir. PSNR, mümkün olan maksimum sinyal gücü ile bozucu gürültünün gücü arasındaki orandır. İki görüntü arasındaki farkın MSE (Mean Squared Error - Ortalama Kare Hatası) ile ölçüldüğü bir yöntemdir. MSE, her pikselin orijinal ve yeniden yapılandırılmış görüntü arasındaki farkın karesinin ortalamasıdır. PSNR, MSE değerinin logaritması olarak hesaplanır ve genellikle desibel (dB) biriminde ifade edilir[17].

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

M: bir görüntü sinyalinin mümkün olan maksimum gücü
MSE: piksel piksel ortalama kare hatası

Structural Similarity Index (SSIM), iki görüntü arasındaki yapısal benzerliği ölçen bir ölçümdür ve özellikle görüntü kalitesinin objektif olarak değerlendirilmesinde yaygın olarak kullanılır. SSIM, görüntülerin birbirine ne kadar benzer olduğunu belirlemek için açıklık, kontrast ve yapı gibi üç ana özellikten yararlanır. SSIM, orijinal ve yeniden yapılandırılmış görüntü arasındaki parlaklık, kontrast ve yapısal benzerlik farklarını ölçer. Bu farklar, bir Gauss dağılımı ile ağırlıklı olarak hesaplanır ve sonunda bir tek bir SSIM değeri elde edilir[17].


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

III. BULGULAR


Bu çalışmada, beyin manyetik rezonans görüntüleri (MRI) üzerinde SRCNN, SRGAN ve ESRGAN modelleri kullanılarak süper çözünürlük (super-resolution, SR) işlemi gerçekleştirilmiştir. Amacımız, bu derin öğrenme tabanlı modellerin, düşük çözünürlüklü (LR) beyin MRI görüntülerinden yüksek çözünürlüklü (HR) görüntüler elde etme başarısını karşılaştırmak ve her bir modelin çözünürlük artırma sürecinde sunduğu iyileştirmeleri incelemektir. Deneyler, her bir modelin çıktılarının kalite

değerlendirmesi için Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index (SSIM) ve görsel kalite analizleriyle yapılmıştır.

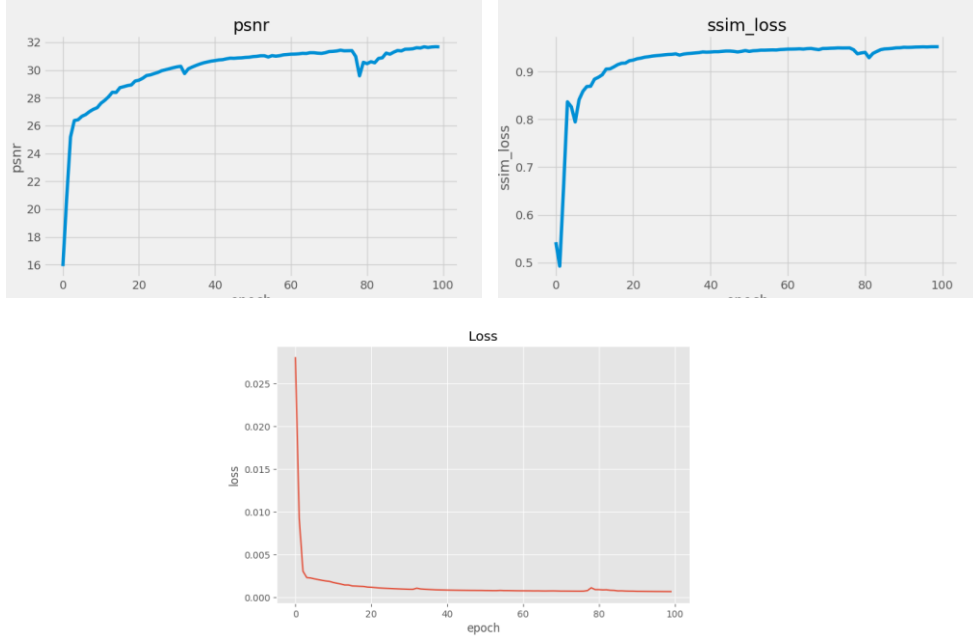
SRCNN modeli ile eğitim aşamasında ilk olarak, görüntüler 64x64 boyutuna küçültülür. Daha sonra tekrar 128x128 boyutuna büyütülür. Amaç küçültme ve büyütme işlemleri ile görüntüde bilgi kaybı veya bulanıklaşma gibi etkiler yaratarak orijinal görüntülerin düşük çözünürlüklü versiyonlarını oluşturmaktır. Orijinal MR görüntüsü ve yeniden boyutlandırılan düşük çözünürlüklü versiyon örneği şekil 5'te verilmiştir. Model mimarisi, çekirdek boyutları 9-1-5 olan 3 katmanlı bir CNN'dir. Her epochta görüntüler yeniden kırılarak yeni görüntü örnekleri oluşturulur. 1000 iterasyon ,0.0020 öğrenme oranı ile eğitim sonrası elde edilen görüntüler ve PSNR, SSIM metrik değerleri şekil 6' da sunulmuştur. PSNR değeri 31,5 SSIM indeksi 0.95, kayıp değeri 0.0010 olarak elde edilmiştir (Şekil 7).



Şekil 5. Orijinal Görüntü (Sol) , Düşük Çözünürlüklü Görüntü(Sağ)

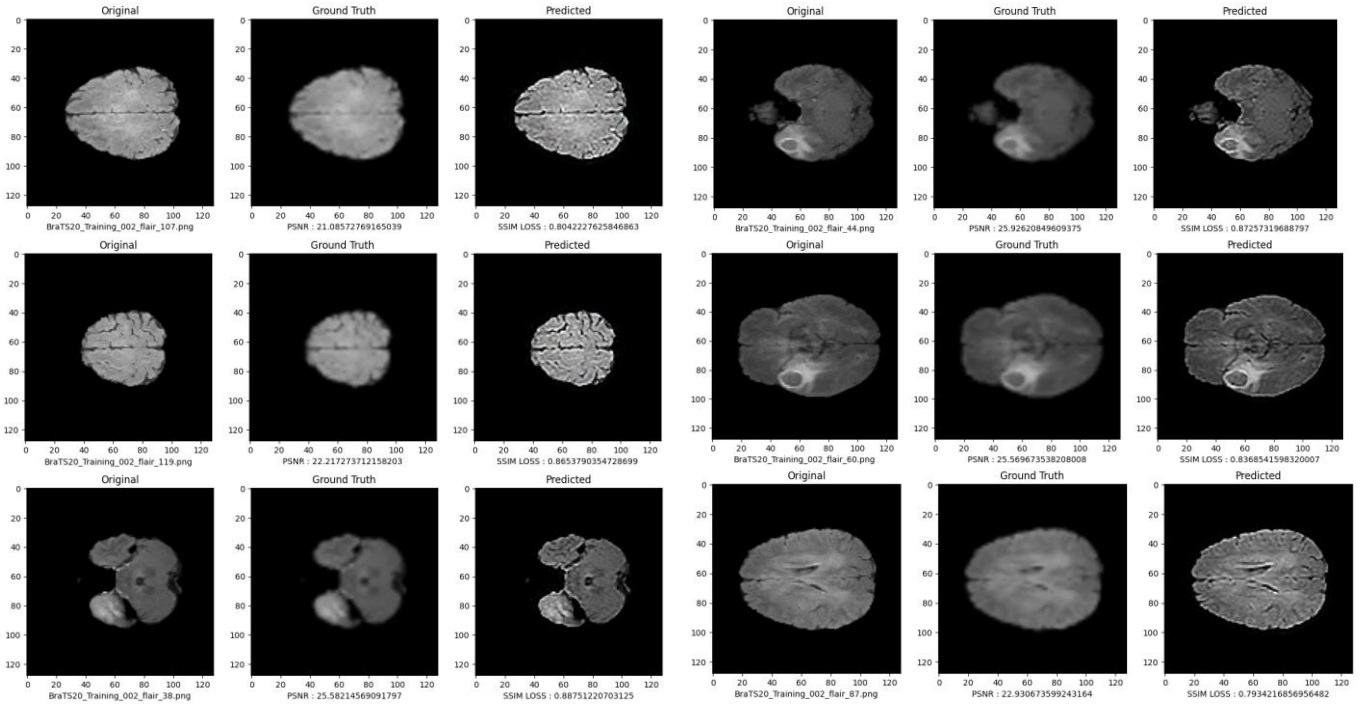


Şekil 6. SRCNN Sonuçları -Yüksek Çözünürlüklü Orijinal Görüntüler(HR), Düşük Çözünürlüklü Görüntüler(LR), SRCNN ile Üretilen Görüntüler (SR)

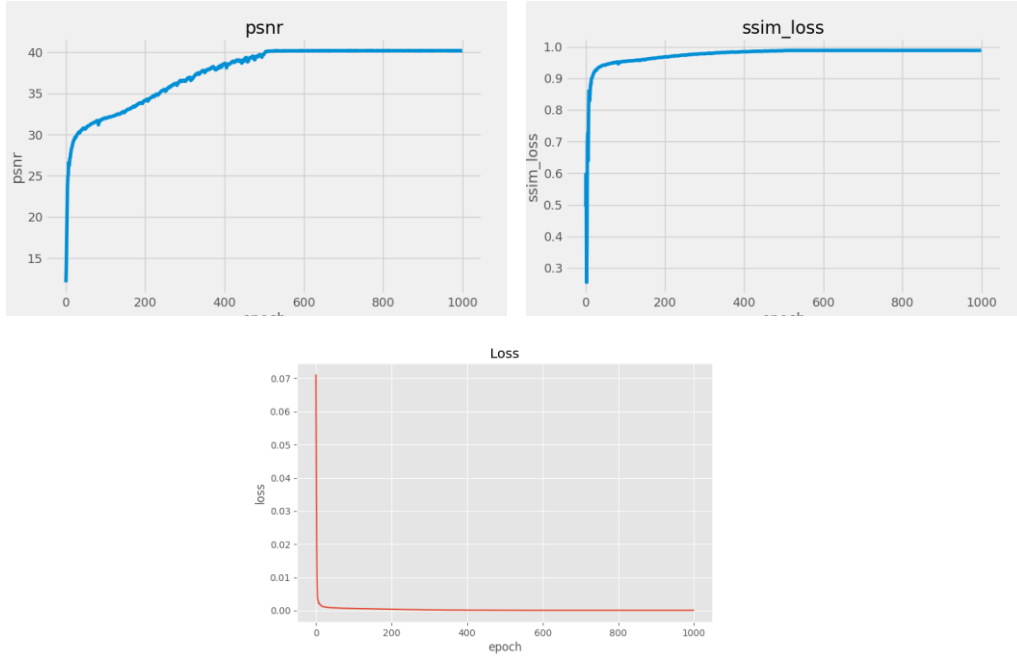


Şekil 7. PSNR, SSIM ve Loss değerleri- SRCNN

SRGAN modeli ile eğitim aşamasında MR görüntüleri önce yüksek çözünürlüklü ve düşük çözünürlüklü versiyonlarına yeniden boyutlandırılır. %50 olasılıkla görüntüler yatay olarak rastgele çevrilir. 1000 iterasyon ,0.0020 öğrenme oranı ile eğitim sonrası elde edilen görüntüler ve PSNR, SSIM metrik değerleri şekil 8 ve şekil 9’da sunulmuştur. PSNR değeri 40.2 SSIM indeksi 0.98, kayıp değeri 0.00009 olarak elde edilmiştir.

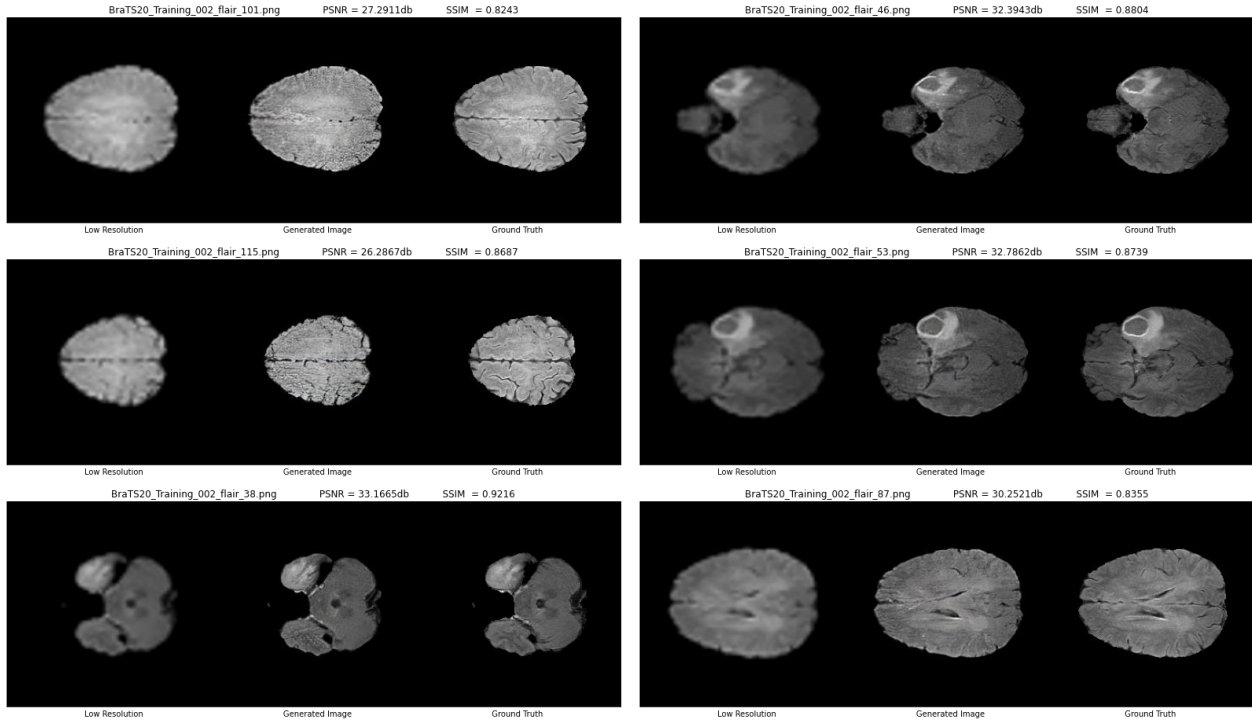


Şekil 8. SRGAN Sonuçları -Yüksek Çözünürlüklü Orijinal Görüntüler(HR), Düşük Çözünürlüklü Görüntüler(LR), SRCNN ile Üretilen Görüntüler (SR)




Şekil 9. PSNR, SSIM ve Loss değerleri- SRGAN

ESRGAN modeli ile eğitim aşamasında MR görüntüleri öncelikle biküçük entropolasyon ile dörtte bir boyuta küçültülerek düşük çözünürlüklü hale dönüştürülmüştür. ESRGAN, perceptual loss, adversarial loss ve mean squared error (MSE) kombinasyonu ile eğitilmiştir. Eğitim sürecinde VGG19 modeli, özellik haritalarını çıkarmak için kullanılır ve kayıp fonksiyonları optimize edilir. 1000 iterasyon , 0.0002 öğrenme oranı ile eğitim sonrası elde edilen görüntüler ve PSNR, SSIM metrik değerleri şekil 10 ve şekil 11’de sunulmuştur.




Şekil 10. ESRGAN Sonuçları - Düşük Çözünürlüklü Görüntüler(LR),ESRGAN ile Üretilen Görüntüler (SR), Yüksek Çözünürlüklü Orijinal Görüntüler(HR)



Şekil 11. PSNR ve SSIM değerleri- ESRGAN

Tablo 1. Görüntü kalitesi metriklerinin karşılaştırılması

Model	PSNR	SSIM
SRCNN	31.5	0.95
SRGAN	40.2	0.98
ESRGAN	42	0.99



Şekil 12. Süper Çözünürlük Modellerinin Karşılaştırılması

IV. TARTIŞMA VE SONUÇ

Bu çalışmada, SRCNN, SRGAN ve ESRGAN modelleri kullanılarak beyin MRI görüntülerinin çözünürlük iyileştirmesi karşılaştırmalı olarak incelenmiştir. SRCNN, doğrudan düşük çözünürlüklü görüntülerin detaylarını geri kazanarak temel düzeyde iyileştirme sağlamıştır. SRGAN, daha karmaşık yapıları ve doku detaylarını yakalayarak görsel olarak daha tatmin edici sonuçlar elde etmiştir. Ancak en başarılı sonuçlar ESRGAN modeliyle elde edilmiştir; ESRGAN, özellikle keskin kenarlar ve küçük detayların korunmasında üstün performans göstermiştir.

Değerlendirme metriklerine göre PSNR ve SSIM değerleri SRGAN ve ESRGAN modellerinde yakın değerlere ulaşmıştır. Ayrıca, görsel değerlendirme sonucunda ESRGAN ile elde edilen süper çözünürlüklü görüntülerin orijinal görüntülere son derece benzer ve net olduğu görülmüştür. Eğitim ve değerlendirme sürecinde az sayıda veri kullanılmış olmasına rağmen son derece umut verici sonuçlar elde edilmiştir.

Ancak, bu çalışmada uygulanan modellerin başarısı bazı sınırlamalara tabidir. Bu sınırlamalar, eğitim veri kümesinin boyutu ve çeşitliliği, modelin hiperparametreleri ve kullanılan özellik çıkarıcının seçimi gibi faktörlere bağlı olabilir. Daha geniş veri setleriyle eğitilen modellerin daha geliştirilebilir ve güvenilir sonuçlar üretebileceği düşünülmektedir. Bu araştırma, süper çözünürlük tekniklerinin beyin

MRI görüntülerinin analizinde önemli bir katkı sağladığımı ve klinik uygulamalarda geniş bir kullanım potansiyeline sahip olduğunu ortaya koymaktadır.

KAYNAKLAR

- [1] Y. Zhang, Y. Tian, Y. Kong, B. Zhong, and Y. Fu, "Residual Dense Network for Image Super-Resolution," *2018 IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, pp. 2472–2481, Dec. 2018, doi: 10.1109/CVPR.2018.00262.
- [2] 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/FIGURES/10.
- [3] C. Dong, C. C. Loy, K. He, and X. Tang, "Image Super-Resolution Using Deep Convolutional Networks," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 38, no. 2, pp. 295–307, Feb. 2016, doi: 10.1109/TPAMI.2015.2439281.
- [4] C. Ledig *et al.*, "Photo-realistic single image super-resolution using a generative adversarial network," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 105–114, 2017, doi: 10.1109/CVPR.2017.19.
- [5] C. Dong, C. C. Loy, and X. Tang, "Accelerating the super-resolution convolutional neural network," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9906 LNCS, pp. 391–407, 2016, doi: 10.1007/978-3-319-46475-6_25/FIGURES/7.
- [6] J. Liu, F. Chen, X. Wang, and H. Liao, "An Edge Enhanced SRGAN for MRI Super Resolution in Slice-Selection Direction," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11846 LNCS, pp. 12–20, 2019, doi: 10.1007/978-3-030-33226-6_2.
- [7] N. M. H. Elsaid and Y. C. Wu, "Super-Resolution Diffusion Tensor Imaging using SRCNN: A Feasibility Study," *Conf. Proc. ... Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. IEEE Eng. Med. Biol. Soc. Annu. Conf.*, vol. 2019, p. 2830, Jul. 2019, doi: 10.1109/EMBC.2019.8857125.
- [8] K. Thurnhofer-Hemsi, E. López-Rubio, E. Domínguez, R. M. Luque-Baena, and N. Roé-Vellvé, "Deep learning-based super-resolution of 3D magnetic resonance images by regularly spaced shifting," *Neurocomputing*, vol. 398, pp. 314–327, Jul. 2020, doi: 10.1016/J.NEUCOM.2019.05.107.
- [9] I. Sanchez and V. Vilaplana, "Brain MRI super-resolution using 3D generative adversarial networks," no. Midl, pp. 1–8, 2018, [Online]. Available: <http://arxiv.org/abs/1812.11440>
- [10] 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.
- [11] B. Ankitha, C. Srikanth, D. Venkatesh, D. Badrinath, G. Aditya, and S. Akila Agnes, "Enhancing the resolution of Brain MRI images using Generative Adversarial Networks (GANs)," *Proc. Int. Conf. Comput. Intell. Sustain. Eng. Solut. CISES 2023*, pp. 19–25, 2023, doi: 10.1109/CISES58720.2023.10183400.
- [12] X. Jiang, Y. Xu, P. Wei, and Z. Zhou, "CT image super resolution based on improved SRGAN," *2020 5th Int. Conf. Comput. Commun. Syst. ICCCS 2020*, pp. 363–367, 2020, doi: 10.1109/ICCCS49078.2020.9118497.
- [13] G. Bharathi Mohan *et al.*, "Enhancing Brain Tumor Diagnosis with Generative Adversarial Networks," *Proc. 14th Int. Conf. Cloud Comput. Data Sci. Eng. Conflu. 2024*, no. January, pp. 846–851, 2024, doi: 10.1109/Confluence60223.2024.10463384.
- [14] B. H. Menze *et al.*, "The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS)," *IEEE Trans. Med. Imaging*, vol. 34, no. 10, pp. 1993–2024, Oct. 2015, doi: 10.1109/TMI.2014.2377694.
- [15] C. Dong, C. C. Loy, K. He, and X. Tang, "Learning a Deep Convolutional Network for Image Super-Resolution," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 8692 LNCS, no. PART 4, pp. 184–199, 2014, doi: 10.1007/978-3-319-10593-2_13.
- [16] P. Isola, J. Y. Zhu, T. Zhou, and A. A. Efros, "Image-to-image translation with conditional adversarial networks," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-January, pp. 5967–5976, Nov. 2017, doi: 10.1109/CVPR.2017.632.
- [17] S. M. A. Bashir, Y. Wang, M. Khan, and Y. Niu, "A comprehensive review of deep learningbased single image super-resolution," *PeerJ Comput. Sci.*, vol. 7, pp. 1–56, 2021, doi: 10.7717/PEERJ-CS.621/SUPP-3.