Uluslararası İleri Doğa Bilimleri ve Mühendislik Araştırmaları Dergisi Sayı 9, S. 114-121, 6, 2025 © Telif hakkı IJANSER'e aittir **Araştırma Makalesi**



International Journal of Advanced Natural Sciences and Engineering Researches Volume 9, pp. 114-121, 6, 2025 Copyright © 2025 IJANSER **Research Article**

https://as-proceeding.com/index.php/ijanser ISSN:2980-0811

R-ESPCN ile Medikal Görüntülemede Süper Çözünürlük

Muhammed Fatih AĞALDAY^{1*}, Ahmet ÇINAR²

¹Bilgisayar Mühendisliği / Fen Bilimleri Enstitü, Fırat Üniversitesi, Türkiye (ORCID: <u>https://orcid.org/0000-0002-2635-0661</u>)

²Bilgisayar Mühendisliği / Fen Bilimleri Enstitü, Fırat Üniversitesi, Türkiye (ORCID: https://orcid.org/0000-0003-4324-4964)

*(fatihagalday@gmail.com)

(Received: 02 June 2025, Accepted: 04 June 2025)

(5th International Conference on Contemporary Academic Research ICCAR 2025, May 30-31, 2025)

ATIF/REFERENCE: Ağalday, M. F. & Çınar, A. (2025). R-ESPCN ile Medikal Görüntülemede Süper Çözünürlük. *International Journal of Advanced Natural Sciences and Engineering Researches*, 9(6), 114-121.

Özet – Hastalıkların erken teşhisinde Manyetik Rezonans (MR), Bilgisayarlı Tomografi (BT) ve Pozitron Emisyon Tomografisi (PET), ultrason ve röntgen gibi tıbbi görüntüleme teknikleri uzun yıllardır hastalıkların tanısı ve tedavisinde kullanılmaktadır. Tıbbi görüntüler üzerinde doğru tanı konulabilmesi ve sonrasında tedavi süreçleri için kritik öneme sahip iken düşük çözünürlüklü tıbbı görüntüler tanının doğruluğunu ve detaylı analiz yeteneğini sınırlayabilmektedir. Bu çalışmada, MR ve BT teknikleri ile elde edilen beyin görüntülerinin çözünürlüğünü artırmak amacıyla R-ESPCN (Yenilenen ESPCN) modeli kullanılmıştır. R-ESPCN modeli ile düşük çözünürlüklü MR görüntülerinin iyileştirilmesi amaçlanmış ve elde edilen sonuçlar PSNR (Tepe Sinyal Gürültü Oranı) ve SSIM (Yapısal Benzerlik İndeksi Ölçümü) metrikleri kullanılarak değerlendirilmiştir. Sonuçlara göre R-ESPCN'in beyin görüntülerinde önemli bir çözünürlük iyileştirmesi sağladığını ve böylece tıbbi görüntülerin tanı değerinin artırılabileceğini göstermektedir. Model karşılaştırıldığında ortalama olarak yüksek PSNR ve SSIM değerleri elde edilmiştir. R-ESPCN 'ın MR ve BT görüntüleme teknikleri ile elde edilen verilerde güvenilir ve etkili bir çözünürlük iyileştirme aracı olarak kullanılabileceği gösterilmiştir.

Anahtar Kelimeler – R-ESPCN, Süper Çözünürlük, Görüntü Yeniden Yapılandırma, Tıbbi Görüntü İyileştirme, Derin Öğrenme.

I. GİRİŞ

Tıbbi görüntüleme, hastalıkların erken tanısında, tedavisinde ve hastalık seyrinin izlenmesinde için modern tıbbın önemli bir parçası haline gelmiştir. Manyetik Rezonans, Bilgisayarlı Tomografi, Pozitron Emisyon Tomografisi, Ultrason ve Röntgen gibi tıbbi görüntüleme teknikleri , insan vücudunun içyapısını görüntülenmesini sağlayarak uzun yıllardan beri hastalıkların teşhisi, tanısı ve tedavisi için klinik karar alma süreçlerine büyük ölçüde destek sağlar. Fakat bu teknikle elde edilen görüntülerde çözünürlük kaybı, özellikle küçük ince dokulara ait detayların değerlendirilmesinde tanının doğruluğunu sınırlayabilmektedir. Düşük çözünürlüklü görüntülerde oluşan bu eksikliklerin giderilmesi, görüntü işleme tekniklerinin önemli çalışma alanlarından biri olmuştur. Hastalıkların daha erken teşhis edilmesi için uzmanların yoğunluğunu azaltılması, farklı uzman görüşlerinin çözümlenmesi gibi nedenlerle bu alanda makine öğrenmesi yöntemleri kullanılmaktadır. Veri miktarlarının her geçen gün artmasıyla birlikte görüntü işleme alanında makine öğrenmesi yöntemleri yetersiz kalırken, matematiksel modellerin ve donanımsal cihazların gelişmesi sayesinde derin öğrenme, görüntü işleme alanında geniş bir yer bulmuştur.

Uzun yıllardır hastalıkların erken teşhisi, tanısı ve tedavisi amacıyla manyetik rezonans görüntüleme, bilgisayarlı tomografi ve röntgen gibi tıbbi görüntüleme teknikleri kullanılmaktadır. Kliniklerde tıbbi görüntülerin yorumlaması radyolog uzman hekimler tarafından yapılır. Uzman hekimlerin yorgunluğu, insan kaynaklı hatalar ve uzmandan uzmana farklı bakış açılarından dolayı değişiklik gösterebilen durumlar dikkate alındığında, bilgisayar destekli müdahalelerden faydalanmak oldukça önemlidir. Bu alanda geleneksel makine öğrenme yöntemlerini kullanmak karmaşık problemlerin çözümünde yetersiz kalmaktadır. Hızlı işlemecilerin gelişmesi birlikte bu alanda derin öğrenme yöntemlerinden faydalanılarak tıbbi görüntülerin doğru ve verimli bir şekilde kullanılması ile hastalık tanısın konması, tedavisi ve önlenmesi gibi alanlarda doktorlara destek sağlanması mümkün hale gelmektedir. Gelişmiş derin öğrenme algoritmaları sayesinde makineler de desenleri tanıyıp yorumlayabiliyor. Son yıllarda oldukça popüler olan derin öğrenme, makine öğrenmesinin bir alt dalı olup makine öğrenmesi ise yapay zekânın bir alt dalıdır. Yapay zekâ, makinelerin insan beyninin işleyişini taklit ederek karar alma ve tahmin etme gibi zor olan problemlerin çözmesini sağlayan bilim dalıdır. Bu nedenle, yapay zekadaki gibi derin öğrenme, aslında beynin yapısından ve işleyişinden esinlenen bir dizi algoritmaya dayanmaktadır. Derin öğrenme, tıp, robotik, görüntü tanıma ve görüntü oluşturma, otonom araçlar, doğal dil işleme gibi birçok alanda kullanılan veri bilimindeki en popüler alanlardan biridir. Derin öğrenme, insan çabası olmadan verilerden otomatik olarak çıkaran derin bir sinir ağı kullanarak bir yapının özelliklerini öğrenir. Burada önemli olan yeterli miktarda veri olmasıdır. Derin öğrenme sistemleri klasik makine öğrenmesi yöntemlerine kıyasla daha fazla deneyimle oldukça büyük miktarda veri üzerinde çalışır ve yüksek performans sunar. Bu çalışmada derin öğrenme yöntemlerinden Etkili Alt Piksel Sinir Ağı modelinin iyileştirilmiş modeli (R-ESPCN) ile medikal görüntü işleme alanında uygulanması incelenmiştir.

II. MATERYAL VE YÖNTEM

ESPCN modelinde, düşük çözünürlüklü görüntüler doğrudan özellik haritalarını çıkarmak için kullanılır. Model, önceki özellik haritasından gelen özellik görüntü kümesini son katmanda girdi olarak birleştirir ve her kanaldaki aynı noktaya karşılık gelen pikseller, yeni görüntüdeki pikseller kaydırılarak yeni görüntüyü oluşturmak üzere bir araya getirilir. ESPCN modelinde, ilk olarak evrişim katmanı için 5 × 5 boyutunda 64 evrişim çekirdeği kullanılır. 5 × 5 boyutunda çekirdeklere sahip ilk alt piksel evrişim katmanına girdikten sonra, veri kümeleri 64 kanallı veri kümelerine dönüştürülür. Daha sonra, 3 × 3 boyutunda çekirdeklere sahip ikinci veri kümesi grubu 32 kanallı veri kümelerine dönüştürülür ve alt piksel evrişim katmanı son olarak 9 kanallı veri kümeleri üretir, bu da görüntü verilerinin uzunluğunun ve genişliğinin sırasıyla 3 kat artırılması anlamına gelir. Son katman, her özellik haritası için bir yükseltme filtresi ile düşük çözünürlüklü özellik haritalarından doğrudan yüksek çözünürlüklü bir görüntü üretir. 1 … N yüksek çözünürlüklü görüntü örneğinden oluşan bir eğitim seti verildiğinde, karşılık gelen düşük çözünürlüklü görüntüler üretilir ve yeniden yapılanmanın piksel bazında ortalama kare hatası, ağı eğitmek için bir amaç fonksiyonu olarak hesaplanır.

$$l(W_{1:L}, b_{1:L}) = \frac{1}{r^2 H W} \sum_{x=1}^{rH} \sum_{x=1}^{rW} (I_{x,y}^{HR} - f_{x,y}^{LR} (I^{LR}))^2$$
(1)

Modelde, aktivasyon fonksiyonu deneysel sonuçlardan esinlenmiştir ve relu yerine tanh kullanılır. Modelin eğitiminde 100 epok kullanılarak hiçbir gelişme gözlemlenmediğinde, işlemler durdurulur. Modelin başlangıç öğrenme oranı 0,01 olarak belirlenir, eğitim son öğrenme oranına 0,0001 olarak güncellenir ve gelişme bir eşik değerinden küçük olduğunda maliyet fonksiyonu kademeli olarak güncellenir. Pik sinyal-gürültü oranı (PSNR) ve yapısal benzerlik endeksi ölçüsü (SSIM), modeli değerlendirmek için performans ölçütleri olarak kullanılır. Bu çalışmada, üç katmanlı ESPCN modelinden esinlenerek, R-ESPCN adını verdiğimiz alt piksel evrişimli sinir ağlarına dayalı bir süper çözünürlüklü görüntü yeniden yapılandırma yöntemi, modeli derin bir ağ ile yeniden modelleyerek önerilmiştir [1]. Şekil 1, ESPCN modelinin akış şemasını göstermektedir.



Şekil 1. ESPCN'nin akış şeması [2]

Yenilen model, şekil 2'de de gösterildiği gibi beş katmanlı olup son güçlendirme katmanı da dahil olmak üzere 6 katmandan oluşur. İlk olarak, ağ sistemine düşük çözünürlüklü bir görüntü verilir. Görüntülerden daha fazla bilgi elde etmek için, ilk bölümde özellik çıkarımı için 2 evrişim katmanı, ikinci bölümde 2 doğrusal olmayan eşleme katmanı ve son katmanda düşük çözünürlüklü bir görüntüden yüksek çözünürlüklü görüntü elde etmek için bir alt piksel evrişim katmanı modellenir. Yenilen model 5 katmandan oluşur ve her katmanın giriş ve çıkış kanal numaraları tanımlanır. Katmanlar arasında parantez içinde tanımlanan bir diğer parametre, şekil 2'de de filtre evrişim çekirdeğinin boyutunu belirtir. Yenilen modelimizde, ESPCN modelinden farklı olarak, evrişim katmanı için 3 x 3 boyutunda 32 evrişim çekirdeği kullanılır. Bu şekilde, ESPCN modeline kıyasla hesaplama maliyeti düşürülmeye çalışılır. Modelde aktivasyon fonksiyonu olarak Tanh tercih edilmiştir. Modelin eğitiminde 100 epok kullanılmış, başlangıç öğrenme oranı 0,01 olarak belirlenmiş ve eğitim süresince öğrenme oranı 0,0001 olarak güncellenmiştir. Modeli değerlendirmek için performans ölçütleri olarak yapısal benzerlik indeksi ölçüsü (SSIM) ve tepe sinyal-gürültü oranı (PSNR) kullanılmıştır.



Şekil 2. Yenilen R-ESPCN'nin akış şeması [1]

Genellikle süper çözünürlüklü görüntüler elde eden ağ modelleri, giriş olarak düşük çözünürlüklü görüntüleri kullanmaz ve bu durum, evrişim hesaplama sürecini artırdığı için ağı olumsuz etkiler. Bu durumu önlemek için yenilenen modele giriş olarak düşük çözünürlüklü bir görüntü verilir. Modelde, düşük çözünürlüklü görüntü sinir ağına giriş olarak verilir ve özellik çıkarma işlemleri 32 evrişim çekirdeği ile başlatılır.

A. R-ESPCN Mimari Yapısı

Ağ yapısının özellik çıkarma işleminin ilk aşamasında 2 evrişim katmanı bulunur. İlk 2 katmandan başlayarak, hesaplama maliyetleri nedeniyle boyutu düşük tutmak için 3×3 boyutunda 32 evrişim çekirdeği belirlendi. Bu katmanlardaki hesaplama karmaşıklığını azaltmak için, daha önce bilinen ESPCN modellerinde 5×5 boyutunda 64 evrişim çekirdeği yerine 3×3 boyutunda 32 evrişim çekirdeği tercih

edildi. Ağ, evrişim katmanı 1'e giriş olarak düşük çözünürlüklü bir görüntü alır ve özellik çıkarma işlemi Denklem 2' e göre gerçekleştirilir.

$$f^{1} (I^{LR}; W_{1}, b_{1}) = \phi W_{i} \times I^{LR} + b_{1}$$
(2)

Denklem 2' de kullanılan ifadelerde, düşük çözünürlüklü görüntü girişi I^{LR} olarak gösterilir, ağın ağırlığı W_i ve önyargı B_i 'dir. Ağın ağırlığının boyutu, W_i , giriş görüntüsündeki kanal sayısı, çıkış kanalının evrişim çekirdeği sayısı ve çekirdek boyutunun çarpılmasıyla bulunur. Ağın tüm evrişim katmanlarında aktivasyon fonksiyonu olarak Tanh kullanılır. Aktivasyon fonksiyonu f_i değerini kontrol ederek nöronun aktif olup olmamasına karar vermek için kullanılmaktadır. Aktivasyon fonksiyonları bu görevlerinden dolayı derin sinir ağları için önemli bir özelliktir. Yenilen R-ESPCN modelinin özellik çıkarma süreçleri Şekil 3'te gösterildiği gibi modellenmiştir.

Sigmoid, tanh, ReLu ve leaky Relu gibi birçok aktivasyon fonksiyonu derin sinir ağlarında kullanılır. Bunlardan en popüler olanı aldığı değerleri 0 ile 1 arasında sınırlayan sigmoid fonksiyonudur. Yüksek bir değer geldiğinde 1'e yakınken, düşük bir değer geldiğinde 0'a yakındır. Bu nedenle aktivasyon sonucu 0 ile 1 arasında herhangi bir değer aralığında değildir. Sigmoid fonksiyonunun dezavantajları yüksek bir eğim ölçümüne sahip olması, 0 yönelimli bir fonksiyon olmaması ve exp() hesaplamalarının oldukça yavaş olmasıdır [3]. Kısaca tanh olarak bilinen hiperbolik tanjant fonksiyonu sigmoide benzerliğiyle bilinir. Her ikisi de belirli bir aralıkta sıkıştırmaya sahiptir, ancak tanh aktivasyon fonksiyonu gelen değerleri -1 ile 1 arasında sınırlar. 0 yönelimli olduğu için sigmoid fonksiyonuna kıyasla daha iyi sonuçlar elde edilebilir. Diğer en popüler aktivasyon fonksiyonu olan ReLu, ilk olarak 2012 yılında kullanılmış ve popülaritesi günümüze kadar artmıştır. Ayrıca, ReLu fonksiyonu biyolojik nöronlara benzerliğiyle bilinir. ReLu aktivasyon fonksiyonunun çalışma mantığı gelen değerlerin pozitif mi negatif mi olduğuna bakar ve ardından gelen değer negatifse işlemin sonucunun 0 olduğuna karar verir [4]. Ancak gelen değer pozitifse herhangi bir sıkıştırma veya değişiklik işlemi uygulamaz ve olduğu gibi geçer. Bilgisayarlar tanh ve sigmoidde karmaşık hesaplamalar yaparken, ReLu yalnızca pozitiflik ve negatiflik durumuna bakar. Bu nedenle, bilgisayar bu denklemi çok daha hızlı hesaplar. Ancak, bu fonksiyon 0 yönelimli olmadığı için bazı nöronlar ölebileceğinden muhteşem bir fonksiyon olduğunu söyleyemeyiz. Yenilen modelde aktivasyon fonksiyonu olarak tanh kullanmamızın nedeni karmaşık hesaplamalar yapabilmektir.



Şekil 3. Yenilen R-ESPCN modelinin yapısı [1]

Evrişimsel sinir ağlarında yaygın olarak kullanılan iki farklı havuzlama yöntemi vardır. Yerel havuzlama, örnek olarak küçük yerel bölgelerden 3×3 verileri bir araya getirerek özellik haritalarını görüntülemek için kullanılan bir yöntemdir. Diğer yöntem olan küresel havuzlama, özellik haritası boyunca her bir özellik için özellik vektöründen gelen görüntüyü temsil eden bir skaler değerdir [5]. Bu çalışmada 3×3 yerel

havuzlama yöntemi kullanılmıştır. Şekil 3'te verilen R-ESPCN modelinde, evrişimsel katman 1 düşük çözünürlüklü bir görüntüyü giriş olarak kabul ederken, evrişimsel katman 2 F₁ özellik kümesini giriş olarak alır. Evrişimsel katman 3, F₁ özellik görüntü kümesini F₂ sürecinin bir parçasıymış gibi giriş olarak alır ve F₃ görüntü kümesini elde etmek için 3 × 3 boyutunda 16 evrişim çekirdeği kullanır. Benzer şekilde, evrişimsel katman 4, evrişimsel katman 2'deki gibi F₃ özellik haritasını girdi olarak alır ve F₄ görüntü kümesini elde etmek için 3 × 3 boyutunda 16 evrişim çekirdeği ile eşleştirilir. Son katmana, alt piksel evrişimsel katmana doğru zenginleştirilen görüntü kümesi, F₃ ve F₄ ile eşleştirilir. İlk işlemde olduğu gibi, evrişimsel 3 katmanından elde edilen F₃ özellik haritası, F₄ özellik haritasının bir dalı olarak, alt piksel evrişimsel katmanla girdi olarak eşleştirilir. Evrişimsel katman 3'e ve alt piksel evrişimsel katmanlara gelen özellik haritaları için formül daha sonra verilir. Formülde verilen i değeri katman numarasını, k₁ ve k₂ değerleri ise i-1 ve i-2 katman özellik haritalarının oranını gösterir.

$$f^{l}(\mathbf{I}^{LR}; \mathbf{W}_{1:l}, \mathbf{b}_{1:l}) = \varphi \mathbf{W}_{l} \times (k_{1} \times f^{l-1}(\mathbf{I}^{LR}) + k_{2} \times f^{l-2}(\mathbf{I}^{LR})) + \mathbf{b}_{l}$$
(3)

Alt piksel evrişimsel katmanda eşleştirilen özellik haritaları sonunda yüksek çözünürlüklü süper çözünürlüklü bir görüntü (I^{SR}) oluşturacaktır. Evrişim işlemleri sonucunda, amplifikasyon katsayısına göre son katmanda r² kadar bir kanal sayısı oluşturulur. Bu görüntüler yeniden oluşturulacak görüntüleri temsil eder. Bu işlem aşağıdaki formülle ifade edilebilir. Alt piksel evrişim işlemini temsil eden PS ile görüntü, her bir görüntü haritası pikselinin konumuna göre düzenlenir ve yüksek çözünürlüklü bir görüntü temsil eder.

Derin öğrenme yöntemlerinde ağ yapısını iyileştirmek için kullanılan yöntemlerden biri de ağı derinleştirmektir. Ağ yapısının katman sayısının artırılması, görüntülerden daha fazla özellik elde edilmesini ve içerik hakkında daha fazla ayrıntı çıkarılmasını sağlar. Bu işlemde, ağ yapısının derinliği arttıkça gradyan kayıpları meydana gelir. Ağ yapısını derinleştirmek için yeniden yapılandırma işlemini iyileştirmek amacıyla, önceki ağ yapısı doğrusal olmayan haritalamaya aktarılır. Kısayol bağlantısı ve önceki ağ yapısının Tanh aktivasyon fonksiyonuna sahip bir evrişim katman ağı Şekil 2'de gösterilmiştir. Evrişim sonucu oluşan gradyanın neden olduğu bilgi kaybını önlemek amacıyla, önceki katman bilgisi alınır. Düşük çözünürlüklü ağ kısayol bağlantısı olan LR, bir sonraki evrişim aşamasının çıkış katmanına bağlanır. Önceki katman özellikleri, F = F + F (LR) formülüne uygun olarak yeniden kullanılacak şekilde aktarılır. Bu durumda artan derinlik, ağ yapısındaki kaybolan özellik yapısının korunarak bir sonraki aşamaya taşınmasını sağlar. Ağ yapısının son katmanı olan alt piksel evrişim katmanında, r büyütme oranının karesi olan r^2 (r × r) ile görüntü kanalı özellik haritası oluşturulur. Bu katmanda oluşan görüntü kanallarındaki pikseller, belirli kurallara göre r × r boyutlarında görüntüye dönüştürülür. Görüntü katmanı H × W × C r²'deki düşük çözünürlüklü gerçek özellik haritaları, rH × rW × C boyutlarında yüksek çözünürlüklü görüntüye dönüştürülür. Görüntü kanallarında aynı konumdaki pikseller, yüksek çözünürlüklü görüntüye karşılık gelen bir blok oluşturacak şekilde düzenlenir. H görüntünün yüksekliğini, W ise genişliğini belirtir. Yenilen modelin görüntü büyütme ölçek oranı 3 olarak belirlendi ve çalışmadaki tüm karşılaştırmalı sonuçlar bu orana göre yapıldı. Son katmanda, süper çözünürlüklü bir görüntü oluşturmak için büyütme oranı r'nin karesi (r²) ile 9 görüntü haritası oluşturulur. Görüntü haritalarının aynı noktasındaki pikseller süper çözünürlüklü haritada 3×3 matris düzenlemesinde oluşturulur.

III. BULGULAR

Süper çözünürlük işleminin amacı, görüntü çözünürlüğünü mümkün olduğunca artırmak ve görüntünün ayrıntılarının mümkün olduğunca net olmasını sağlamaktır. Süper çözünürlük yöntemi ile oluşturulan yeni görüntüyü ve orijinal görüntüyü değerlendirmek için yaygın olarak kullanılan bazı yöntemler vardır. Kantitatif değerlendirme için en yaygın kullanılan yöntemler yapısal benzerlik indeksi ölçümü (SSIM) [6] ve tepe sinyal-gürültü oranıdır (PSNR) [7]. SSIM, görüntünün parlaklığını, kontrastını ve yapısını ölçmek için tasarlanmıştır. PSNR değeri ne kadar büyükse, görüntüdeki bozulma derecesi o kadar küçük olur [8] ve görüntünün yeniden yapılandırılması o kadar iyi olur.

Bu çalışmada, yenilenen R-ESPCN modelini Windows 11 işletim sistemi altında test etmek için bir MSI GF65 model bilgisayar, bir Intel i7 10750H 2.60 GHz destekli işlemci, 24 GB RAM ve bir NVIDIA GeForce GTX 1660 Ti grafik kartı kullanıldı. Yenilen R-ESPCN modelinin eğitimi için kütüphane olarak Python 3.9.13 kodlama dili ve Pytorch çerçevesi kullanılmıştır. R-ESPCN modeli, ESPCN modelinde olduğu gibi 0.01 öğrenme oranı, 64 parti boyutu ve 100 eğitim turu epok değeri ile set5 ve set14 eğitim setleri kullanılarak eğitilmiştir. ESPCN modelinin eğitim değerleri 25 dB iken, R-ESPCN modelinin eğitim değerinin 28.39 dB civarında olduğu ve ESPCN modelinden yaklaşık 0.3 dB daha iyi eğitildiği bulunmuştur. Yenilen R-EPSCN modelinin kayıp fonksiyonunun 0'a yaklaşarak iyileştirildiği ve aynı şekilde yenilen modelin doğrulama sürecinde ESPCN modeline kıyasla PSNR ve kayıp değerinde daha kararlı bir iyileştirmeye sahip olduğu gözlemlenmiştir. R-ESPCN modelinin eğitim sonuçları Şekil 4'te verilmiştir.



Şekil 4. (a) ESPCN modelinin ve (b) R-ESPCN modelinin eğitim sonuçları [1]

Bikübik, ESPCN ve yenilenen R-ESPCN modelleri, herkese açık veri seti görüntülerinde test edilmiştir. Yenilenen modelin ne ölçüde iyileştirildiğini belirlemek için yapısal benzerlik endeksi ölçüsü (SSIM) ve tepe sinyal-gürültü oranı (PSNR) değerlerinin karşılaştırmaları tablolarda verilmiştir.

Bu çalışmada, klasik veri kümeleri dışında dicom uzantılı tıbbi görüntüler üzerinde de testler yapıldı. Test verileri kanser görüntü arşivi olarak bilinen TCIA (The Cancer Image Archive) veri tabanından alınmıştır. Öncelikle, dicom uzantılı görüntüleri jpeg ve png gibi bilinen görüntü formatlarına dönüştürdük. Şekil 5'te dicom uzantılı tıbbi görüntü verilerine göre, görüntülerdeki PSNR değerleri sırasıyla 1,58 dB, 4,55 dB, 6,70 dB, 12,56 dB, 10,74 dB ve 7,17 dB arttı. Benzer şekilde, görüntülerdeki SSIM değerleri sırasıyla %0,64, %26,6, %13,05, %44,29, %28,95 ve %25,57 arttı. Tıbbi görüntüler için yapılan test sonuçlarına göre, R-ESPCN modelinin ESPCN modeline göre önemli ölçüde daha iyi sonuçlar verdiği ve PSNR ve SSIM değerlerinin daha yüksek olduğu görülmektedir. PSNR değerleri incelendiğinde, ortalama 7,22 dB'lik bir artış olduğu ve SSIM değerlerindeki ortalama artış oranının %23,18 olduğu bulunmuştur. Kapsamlı etiketli verilere ihtiyaç duymadan tıbbi görüntüler üzerinde klinik tanı koymayı kolaylaştırmak için, tahmin yoluyla görüntü verilerinin doğal yapısını öğrenen kendi kendine denetlenen öğrenme sistemleri geliştirilebilir [9].

		Bicubic	ESPCN	R-ESPCN
	SSIM	78.36	98.61	99.25
	PSNR	32.75	35.54	37.12
Contraction of the second	SSIM	67.92	70.53	97.13
	PSNR	29.61	32.58	37.13
	SSIM	78.56	83.96	97.01
	PSNR	32.56	35.85	42.55
	SSIM	56.25	47.79	92.08
	PSNR	30.24	33.08	45.64
	SSIM	65.44	66.27	95.22
	PSNR	31.78	34.60	45.34
	SSIM	68.70	69.94	95.51
	PSNR	36.21	37.01	44.18

Şekil 5. Tıbbi görüntü verileri üzerinde ESPCN ve R-ESPCN modellerinin karşılaştırılması

IV. SONUÇLAR

Yenilen R-ESPCN modeli, derin öğrenme ağlarında oluşan eğim kaybını, hesaplama karmaşıklığını ve diğer sorunları aşar ve süper çözünürlüklü görüntüler elde eder. Düşük çözünürlüklü görüntüleri doğrudan ağa girdi olarak vererek hesaplama karmaşıklığı önlenir. Görüntülerden daha fazla özellik çıkarmak için iki katmanlı bir evrişimli ağ kullanılır. Ağdaki kaybolan eğim sorununu önlemek için kalıntı ağı kullanılır. Yenilen model, derin öğrenmeye dayalı klasik görüntü süper çözünürlük yöntemlerine kıyasla alt piksel düzeyinde doğrudan işlemler gerçekleştirerek hesaplama miktarını azaltır. ESPCN yöntemine kıyasla, derin kalıntı ağı yöntemini kullanarak görüntünün daha sağlam bir temsilini sağlar ve ağın derinliğini kısaltmak için yeni fikirler sunar. Alt piksel evrişim katmanıyla, görüntünün özellik bilgisinin korelasyonu korunur ve inşa süresi azaltılır. Yenilen R-ESPCN modeli farklı veri kümelerinde karşılaştırmalı olarak test edildi ve daha iyi performans gösterdiği gösterildi. Önerdiğim model tıbbi görüntü çözünürlüğünü arttırmak için umut vadeden bir tekniktir. Yöntemin daha büyük veri kümeleri ve farklı hastalık türleri üzerinde test edilmesi, klinik doğrulama süreçlerini hızlandıracaktır. R-EPSCN yöntemi ile klinik iş akışlarına entegre

edilmesi, görüntü tabanlı teşhis süreçlerini dönüştürülebilir ve sağlık hizmetlerinin daha erişilebilir olmasına yardımcı olacaktır.

KAYNAKLAR

- [1] M. F. Ağalday and A. Çinar, "Improvement of a Subpixel Convolutional Neural Network for a Super-Resolution Image," *Appl. Sci.*, vol. 15, no. 5, 2025, doi: 10.3390/app15052459.
- [2] W. Shi *et al.*, "Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 1874–1883, 2016, doi: 10.1109/CVPR.2016.207.
- [3] I. S. Isa, Z. Saad, S. Omar, M. K. Osman, K. A. Ahmad, and H. A. M. Sakim, "Suitable MLP network activation functions for breast cancer and thyroid disease detection," *Proc. - 2nd Int. Conf. Comput. Intell. Model. Simulation, CIMSim 2010*, pp. 39–44, 2010, doi: 10.1109/CIMSiM.2010.93.
- [4] and G. E. H. A. Krizhevsky, I. Sutskever, "ImageNet Classification with Deep Convolutional Neural Networks," *Adv. Neural Inf. Process. Syst.*, pp. 1097–1105, 2012, doi: 10.1016/B978-0-12-374105-9.00493-7.
- [5] A. Zafar *et al.*, "A Comparison of Pooling Methods for Convolutional Neural Networks," *Appl. Sci.*, vol. 12, no. 17, pp. 1–21, 2022, doi: 10.3390/app12178643.
- [6] J. Guo, F. Lv, J. Shen, J. Liu, and M. Wang, "An improved generative adversarial network for remote sensing image super-resolution," *IET Image Process.*, vol. 17, no. 6, pp. 1852–1863, 2023, doi: 10.1049/ipr2.12760.
- [7] Q. Huynh-Thu and M. Ghanbari, "Scope of Validity of PSNR in Image/Video Quality Assessment," *Electron. Lett.*, vol. 44, no. 13, pp. 800–801, 2008, [Online]. Available: https://doi.org/10.1049/el:20080522
- [8] F. A. Fardo, V. H. Conforto, F. C. de Oliveira, and P. S. Rodrigues, "A Formal Evaluation of PSNR as Quality Measurement Parameter for Image Segmentation Algorithms," no. 0, pp. 1–11, 2016, [Online]. Available: http://arxiv.org/abs/1605.07116
- [9] M. M. Abdulrazzaq *et al.*, "Consequential Advancements of Self-Supervised Learning (SSL) in Deep Learning Contexts," *Mathematics*, vol. 12, no. 5, 2024, doi: 10.3390/math12050758.