

SRGAN ile Süper Çözünürlüklü OCT Görüntüleri Oluşturma

Ahmet ÇINAR^{1*}, Elif Işılay ÜNLÜ²

¹ Bilgisayar Mühendisliği, Fırat Üniversitesi, TÜRKİYE

² Bilgisayar Mühendisliği, Fırat Üniversitesi, TÜRKİYE

*(acinar@firat.edu.tr)

(Geliş Tarihi: 29 Temmuz 2023, Kabul Tarihi: 09 Ağustos 2023)

(1st International Conference on Modern and Advanced Research ICMAR 2023, July 29-31, 2023)

.ATIF/REFERENCE: Çınar, A. & Ünlü, E. I. (2023). SRGAN ile Süper Çözünürlüklü OCT Görüntüleri Oluşturma. *International Journal of Advanced Natural Sciences and Engineering Researches*, 7(7), 109-114.

Özet – Günümüzde, retina bozuklukları ciddi bir sağlık problemi olarak önemli bir artış göstermiştir. Retina bozuklukları, genellikle yavaş ilerleyen ve belirgin belirtiler olmadan gelişen hastalıklardır. Her yıl, dünya genelinde milyonlarca kişi retina hastalığı teşhisi almaktadır. Optik Koherens Tomografi (OCT), hasta retina katmanlarında nicel ayrımı analiz edebilen ve belirleyebilen yüksek çözünürlüklü bir tanı teknolojisi olarak önemli bir rol oynamaktadır. Optik Koherens Tomografi (OCT), invaziv olmayan bir görüntüleme prosedürüdür ve ışık dalgalarını kullanarak retinanın enine kesit fotoğraflarını çeker. Ancak bazı durumlarda, elde edilen OCT görüntüleri düşük çözünürlüklü olabilir, bu da teşhis ve tedavi süreçlerini olumsuz etkileyebilir. Bu çalışmada, görüntülerin çözünürlüğünün iyileştirilmesi için süper çözünürlük yöntemlerinden biri olan Super-Resolution GAN(SRGAN) kullanılmıştır. Bu mimari, önceden eğitilmiş bir VGG-19 özellik çıkarıcısını kullandı ve büyük (4 kat) ölçeklendirilmiş düşük çözünürlüklü görüntülerde fotorealistik sonuçlar verdi.

Anahtar Kelimeler – Retina Hastalıkları, OCT Görüntüleri, Süper Çözünürlük, SRGAN

I. GİRİŞ

Optik Koherens Tomografi (OCT), modern tıp alanında önemli bir rol oynayan güçlü bir görüntüleme tekniğidir. Retina ve diğer göz dokularının detaylı ve yüksek çözünürlüklü görüntülerini elde etme konusundaki yeteneği, göz hastalıklarının teşhisi ve tedavisi açısından kritik bir öneme sahiptir. Ancak, bazı durumlarda, düşük çözünürlüklü OCT görüntüleri elde edilmesi kaçınılmaz olabilir ve bu da teşhis sürecini olumsuz yönde etkileyebilir[1].

Son yıllarda derin öğrenme tabanlı yöntemlerin gelişimi, görüntü süper çözünürlüğü konusunda büyük bir ilerleme kaydetmiştir. Bu bağlamda, Super-Resolution Generative Adversarial Network (SRGAN), düşük çözünürlüklü görüntüleri yüksek çözünürlüklü görüntülere dönüştürmek için

kullanılan etkili bir yapay zeka yöntemi olarak öne çıkmaktadır[2].

Bu çalışmada, SRGAN yönteminin Optik Koherens Tomografi (OCT) görüntülerinin çözünürlüğünü artırmak için nasıl kullanıldığına odaklanacağız. SRGAN'ın temel çalışma prensiplerini anlamak ve bu yöntemin OCT görüntülerinde nasıl uygulandığını keşfetmek, görüntüleme alanında önemli bir adım olarak değerlendirilmektedir. Ayrıca, SRGAN ile elde edilen sonuçların fotorealistik ve teşhis açısından güvenilir olma potansiyeli göz önünde bulundurulacaktır.

SRGAN, OCT görüntülerinin çözünürlüğünü artırmak için verimli bir yöntem olarak kabul edilir. Yapay sinir ağlarının öğrenme kabiliyetleri sayesinde düşük çözünürlüklü OCT görüntüleri

daha net ve detaylı hale getirilir, böylece teşhis ve tedavi süreçlerinde daha güvenilir sonuçlar elde edilir. Bu, oftalmolojik tıp alanında önemli bir ilerleme ve daha iyi hasta bakımı sağlama potansiyeline sahiptir. Ancak, gerçek dünya uygulamalarında SRGAN veya benzeri yöntemlerin kullanımı için daha fazla araştırma ve doğrulama gerekmektedir.

Jiang ve arkadaşları, Geliştirilmiş SRGAN'a dayalı CT görüntüsü süper çözünürlüğü algoritması önerdi. Genel veri kümeleri üzerinde yapılan deneyler, önerilen yöntemin görüntü kalitesi değerlendirme göstergelerinde temel yöntemle göre daha üstün olduğunu ve yapaylık üretmediğini göstermiştir[3].

Ahmad ve arkadaşları, tıbbi görüntüler için GAN tabanlı bir görüntü süper çözünürlük yöntemi önerdi. Bu yöntemde farklı ölçeklerde öznelikler çıkarmak için jeneratör ağının yapısını değiştirdiler. Retinal görüntü, cilt lezyonu görüntüleri, beyin MR görüntüleri ve kardiyak ultrason görüntülerinden oluşan veri kümeleri üzerinde değerlendirdikleri model diğer son teknoloji süper çözünürlüklü mimarilere kıyasla üstün doğruluk sağlamıştır[4]. Moran ve arkadaşları, daha yüksek kalite ve çözünürlükte periapikal görüntüler elde etmek için süper çözünürlüklü üretken çekişmeli ağ (SRGAN) modeli ve transfer öğrenimi kullandı. Diğer süper çözünürlüklü yöntemlerle karşılaştırılan deneyler sonucunda transfer öğrenmeli SRGAN'ın sonuçlarının daha iyi olduğunu gördüler[5]. Tan ve arkadaşları, COVID-19 tespiti için süper çözünürlüklü yeniden yapılandırılmış görüntülere ve konvolüsyonel sinir ağına dayanan bir algoritma sundu. SRGAN kullanarak elde ettikleri süper çözünürlüklü göğüs BT görüntülerini VGG16 ağı ile sınıflandırdılar ve yüksek doğruluk değerine ulaştılar [6].

Das ve ark. düşük çözünürlüklü görüntülerden yüksek çözünürlüklü retina optik koherens tomografi (OCT) görüntülerini yeniden yapılandırmak için bir yöntem tasarlamıştır. Yöntem, teşhis bilgisine dayalı ağırlıklı seyrek temsil çerçevesi ve 2D-variational mode decomposition tabanlı bir OCT teşhis bozulma ölçümü kullanarak, yeniden yapılandırılan OCT görüntülerindeki teşhis bozulmasını nicelendirmektedir. Sonuçlar, önerilen yöntemin tanısız bozulmayı PSNR'den daha iyi ölçtüğünü göstermektedir[7]. Düşük çözünürlüklü görüntülerdeki speckle gürültü sorununu çözmek

için, OCT görüntülerinde aynı anda gürültüyü gideren ve görüntü çözünürlüğünü artıran bir GAN tabanlı yöntem önerildi. Bu yöntem, süper çözünürlük yöntemi olarak kullanılarak gürültüyü gideren bir teknik olarak da uygulandı ve gürültüsüz görüntüler üzerindeki retinal katman segmentasyon performansını artırdı[8].

Cao ve arkadaşları, düşük optik ve düşük dijital çözünürlük (L2R) görüntüsünden yüksek çözünürlüklü (HR) OCT görüntüsü oluşturma sorununu ele almak için bir derin öğrenme yöntemi önerdi. Bu amaçla, mevcut süper çözünürlük (SRGAN) modelini OCT görüntü yeniden yapılandırması için değiştirdiler. OCT görüntülerinden elde edilen deneysel sonuçlar, yüksek derecede sıkıştırılmış verilerden elde edilen yeniden yapılandırılmış görüntülerin HR görüntülerle karşılaştırıldığında yüksek yapısal benzerlik ve doğruluk elde edebildiğini gösterdi[9].

Dehzangi ve arkadaşları [10], retinal tabaka segmentasyon görevi için bir sinir mimarisi arama (NAS) çerçevesi kullanarak NAS-U-Net yöntemini önermiştir. Bu önerilen yöntemde, NAS, U-Net mimarisinin içinde en iyi aşağı ve yukarı örnekleme bloklarını bulmak için kullanılmış ve en yüksek olası segmentasyon performansına ulaşılmıştır. Buna ek olarak, süper çözünürlük GAN (SRGAN) görüntü geliştirme tekniği olarak kullanılmış ve bu ön işleme adımı olmadan yapılan segmentasyon performansı ile karşılaştırılmıştır. Sonuçları karşılaştırmak için geleneksel bir U-Net'in performansı da değerlendirilmiş ve en iyi sonuçların NAS-U-Net'i SRGAN adımıyla birlikte kullandığında elde edildiği gözlemlenmiştir.

Literatürdeki çalışmalara benzer olarak, bu çalışmanın amacı, SRGAN'ın OCT görüntülerinin kalitesini artırmadaki etkinliğini ve potansiyel klinik uygulamalarını tartışmak, bu teknolojinin oftalmolojik tıp alanındaki önemini vurgulamak ve daha iyi hasta bakımı sağlamak için süper çözünürlük yöntemlerinin gelecekteki olası katkılarını araştırmaktır.

II. MATERYAL VE YÖNTEM


A. Veri Seti

Bu çalışmada halka açık bir OCT görüntü veri seti kullanılmıştır [14]. Veri kümesi 3 klasöre (eğitim, test, doğrulama) ayrılmıştır ve her görüntü kategorisi için (NORMAL, CNV, DME, DRUSEN) alt klasörler içermektedir. Toplamda 84,495 adet X-ray görüntüsü (JPEG formatında) bulunmaktadır ve

4 farklı kategori (NORMAL, CNV, DME, DRUSEN) içermektedir. Tablo 1'de verilerin dağılımı gösterilmiştir. Veri setindeki dört sınıfa ait görüntü örnekleri Şekil 1'de verilmiştir.

Tablo 1. Veri Setindeki Görüntülerin Dağılımı

Sınıf	Eğitim	Test	Doğrulama
CNV	37,205	242	8
DME	11,348	242	8
DRUSEN	8616	242	8
NORMAL	26,315	242	8



Şekil 1. Veri Seti[14]

B. SRGAN Mimarisi


Görüntü Süper Çözünürlüğü (SR), aynı sahnenin tek veya birden fazla düşük çözünürlüklü (LR) gözlemlerinden yüksek detaylı, yüksek çözünürlüklü (HR) görüntüler elde etme sürecidir. Görüntü işleme alanındaki hızlı gelişmeler ve görsel iletişim için sahne tanıma uygulamalarının kullanımı, yüksek çözünürlüklü görüntülere olan ihtiyacı artırmıştır. Bu ihtiyaç, sadece daha iyi görselleştirme sağlamakla kalmayıp aynı zamanda ekstra bilgi ayrıntılarının çıkarılmasında da önemli rol oynamaktadır. Yüksek çözünürlüklü görüntüler, çok spektralli uzaktan algılama görüntülerinde bölgelerin izole edilmesi veya görüntülere dayalı tanısal kararlar alırken radyologlara yardımcı olması gibi durumlarda kullanışlıdır[11].

Derin öğrenmeye dayalı SR çalışmaları son on yılda klasik yöntemlerden daha üstün performans göstermiştir ve DL yöntemleri SR elde etmek için yaygın olarak kullanılmaktadır. SR'yi araştırmak için ilk Evrimsel Sinir Ağından (CNN) [12] en son Üretken Çekişmeli Ağlara (GAN) [2] kadar çeşitli yöntemler kullanılmıştır.

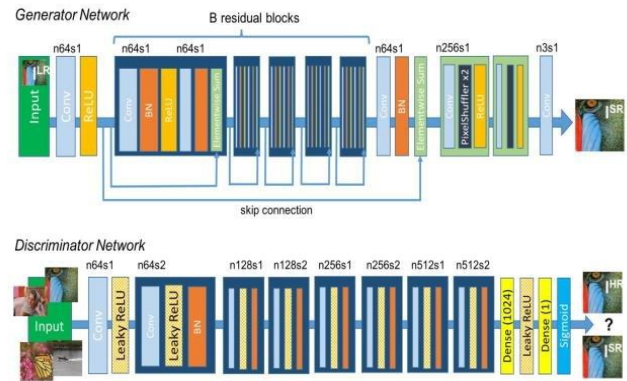
SRGAN ilk GAN tabanlı SR yöntemi olarak bilinmektedir. Bu yöntem, süper çözünürlüğü elde etmek için gelişmiş bir yapay sinir ağı mimarisini kullanır ve fotorealistik sonuçlar elde etmek için Generative Adversarial Network (GAN) yapısını kullanır. Bu yöntem, iki ana bileşeni içerir: üretici (generator) ve ayırt edici (discriminator). Üretici, düşük çözünürlüklü görüntüleri yüksek çözünürlüklü görüntülere dönüştürmek için

öğrenilmiş bir modeldir. Ayırt edici ise, üreticinin oluşturduğu görüntüleri gerçek ve yüksek çözünürlüklü görüntülerden ayırt etmeye çalışır. GAN mimarisi Şekil 2'de verilmiştir. SRGAN, bu iki bileşen arasındaki rekabeti kullanarak süper çözünürlük elde eder. Üretici, ayırt edici tarafından oluşturulan yüksek çözünürlüklü görüntülere benzer görüntüler üretmeye çalışırken, ayırt edici de gerçek yüksek çözünürlüklü görüntülerle üreticinin çıktılarını karşılaştırarak daha doğru ayırım yapmaya çalışır.

SRGAN, geleneksel süper çözünürlük yöntemlerine kıyasla daha iyi sonuçlar elde etmek için GAN'ların avantajlarından yararlanır. Bu yöntem, düşük çözünürlüklü görüntüleri gerçekçi ve yüksek çözünürlüklü görüntülere dönüştürerek fotorealistik sonuçlar üretme potansiyeline sahiptir. Bu özelliği nedeniyle, özellikle tıbbi görüntüleme ve yüksek kaliteli fotoğraf restorasyonunda önemli bir uygulama alanı bulunmaktadır. SRGAN mimarisi Şekil 2'de verilmiştir.



Şekil 2. GAN Mimarisi



Şekil 3. SRGAN Mimarisi[2]

C. Eğitim

Bu çalışmada, orijinal SRGAN'a sadık kalınan bir SRGAN tasarımı kullanılmıştır. Öncelikle yüksek çözünürlüklü (HR) OCT görüntülerini 4 kat küçültülmüş ve sentetik olarak düşük çözünürlüklü

(LR) eğitim verisi oluşturulmuştur. Bu, eğitim veri seti için HR ve LR görüntü çiftleri elde etmemizi sağlamıştır. Üretici, LR görüntülerini 4 kat büyütür ve SR (süper çözünürlüklü) görüntülerini üretmek için eğitilir. Ayırt edici, HR/SR görüntüleri arasında ayırım yapmak için eğitilir; GAN kaybı ayırt ediciye geri yayılır ve üreticiye de aktarılır.

D. Değerlendirme Metrikleri

SRGAN modelinin 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 insan gözlemcilerin subjektif değerlendirmeleri gibi metrikler kullanılarak SRGAN yönteminin başarısı ölçülmüştür.

D.1. PSNR - Peak Signal-to-Noise Ratio

Peak Signal-to-Noise Ratio (PSNR), görüntü kalitesini değerlendirmek için sıklıkla kullanılan bir metriktir. Bu metrik, orijinal ve yeniden yapılandırılmış bir görüntü arasındaki kalite farkını ölçmek için kullanılır. Yüksek PSNR değeri, orijinal ve yeniden yapılandırılmış görüntü arasındaki farkın düşük olduğunu ve böylece daha iyi bir yeniden yapılandırma kalitesi olduğunu gösterir.

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[13].

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

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

D.2. SSIM - Structural Similarity Index

İki görüntü arasındaki benzerliği ve yapısal benzerliği ölçmeye yönelik bir indekstir. SSIM, insan görsel algısını daha iyi yansıtmak için tasarlanmıştır ve piksel tabanlı metriklerin (örn. PSNR veya MSE) bazı sınırlamalarını aşmak için kullanılır. 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[13].

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


III. BULGULAR

SRGAN modeli, eğitim veri kümesi üzerinde eğitilmiş ve modelin 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 insan gözlemcilerin subjektif değerlendirmeleri gibi metrikler kullanılarak SRGAN yönteminin başarısı ölçülmüştür.

SRGAN modeli, düşük çözünürlüklü (LR) OCT görüntülerini yüksek çözünürlüklü (HR) süper çözünürlüklü (SR) görüntülere dönüştürme yeteneğini başarılı bir şekilde öğrenmiştir. Eğitim veri kümesindeki HR ve LR görüntü çiftleri kullanılarak modelin öğrenme süreci tamamlanmıştır. Model, eğitim sırasında GAN kaybı ve algısal kayıp (perceptual loss) kullanarak optimize edilmiştir. Eğitim süreci boyunca, model LR görüntüleri 4 kat büyütür SR görüntülerini oluşturmuştur.

PSNR değeri ortalaması 23.5 dB elde ederek düşük çözünürlüklü LR görüntülerle karşılaştırıldığında önemli bir kalite artışı sağlamıştır. Bu sonuç, SRGAN yönteminin yüksek çözünürlüklü SR görüntülerin oluşturulmasında etkili olduğunu göstermektedir. SRGAN modeli, SSIM değeri ortalaması 0.7 elde ederek düşük çözünürlüklü LR görüntülerle karşılaştırıldığında yapısal benzerlik açısından yüksek bir benzerlik göstermiştir. Bu sonuç, SRGAN yönteminin, yüksek çözünürlüklü görüntülerin oluşturulmasında yapının korunmasında etkili olduğunu göstermektedir.

Ayrıca, görsel değerlendirme sonucunda SRGAN ile elde edilen süper çözünürlüklü görüntülerin orijinal görüntülere son derece benzer ve net olduğu görülmüştür. Önerilen model veri seti üzerinde değerlendirildiğinde elde edilen örnek çıktılar Şekil 4'te gösterilmektedir.



Şekil 4. Yüksek Çözünürlüklü Görüntüler(HR), Düşük Çözünürlüklü Görüntüler(LR), SRGAN ile Üretilen Görüntüler

IV. SONUÇLAR VE TARTIŞMA

SRGAN yöntemi, Optik Koherens Tomografi (OCT) görüntülerinin çözünürlüğünü artırmada başarılı sonuçlar elde etmiştir. Eğitim sürecinde SRGAN modeli, eğitim veri kümesindeki HR ve LR görüntü çiftleri kullanılarak optimize edilmiş ve GAN kaybı ve algısal kayıp (perceptual loss) kullanılarak eğitilen model, LR görüntülerini 4 kat büyütürken SR görüntülerini başarıyla oluşturmuştur. Eğitim süreci boyunca modelin GAN kaybı kullanılarak öğrenmesi, düşük çözünürlüklü OCT görüntülerini fotorealistik ve yüksek çözünürlüklü görüntülere dönüştürmede etkili olduğu görülmüştür. Elde edilen sonuçlar, PSNR, SSIM ve görsel değerlendirmeler ile doğrulanmış ve SRGAN yönteminin OCT görüntülerinde çözünürlük artırma konusunda başarılı bir temel yöntem olduğu gösterilmiştir.

Ancak, bu çalışmada elde edilen SRGAN modelinin başarısı bazı sınırlamalara tabidir. Bu sınırlamalar, eğitim veri kümesinin boyutu ve çeşitliliği, modelin hiperparametreleri ve kullanılan özellik çıkarıcının seçimi gibi faktörlere bağlı olabilir. Daha büyük ve daha çeşitli veri

kümelerinin kullanılması, modelin genelleme yeteneğini artırabilir ve daha farklı görüntü örneklerine uyum sağlamasına yardımcı olabilir.

Ayrıca, bu çalışmada sadece SRGAN yöntemi değerlendirilmiştir. Farklı süper çözünürlük yöntemlerinin de değerlendirilmesi önemlidir. Farklı yöntemlerin karşılaştırılması ve performanslarının değerlendirilmesi, daha kapsamlı bir sonuç elde etmek için gereklidir. Bu şekilde, en uygun süper çözünürlük yönteminin seçilmesi ve belirli uygulamalara en iyi sonuçları verecek yöntemin belirlenmesi daha sağlam bir değerlendirme sağlayacaktır.

Sonuç olarak, bu çalışma SRGAN yönteminin OCT görüntülerinin çözünürlüğünü artırmada etkili olduğunu göstermiştir. Ancak, ileride daha geniş ve çeşitli veri kümeleri, farklı özellik çıkarıcılar ve diğer süper çözünürlük yöntemlerinin kullanılmasıyla yapılacak olan detaylı analizlerle yöntemin güvenilirliği ve performansı daha iyi anlaşılacaktır.

KAYNAKLAR

- [1] R. L. Shelton, S. Shrestha, J. Park, and B. E. Applegate, "Optical Coherence Tomography," *Biomed. Technol. Devices, Second Ed.*, vol. 254, no. 5035, pp. 247–266, 2013, doi: 10.1201/b15085-15.
- [2] 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.
- [3] 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.
- [4] W. Ahmad, H. Ali, Z. Shah, and S. Azmat, "A new generative adversarial network for medical images super resolution," *Sci. Rep.*, vol. 12, no. 1, pp. 1–20, 2022, doi: 10.1038/s41598-022-13658-4.
- [5] M. B. H. Moran, M. D. B. Faria, G. A. Giraldo, 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. July 2020, p. 104139, 2021, doi: 10.1016/j.compbiomed.2020.104139.
- [6] W. Tan *et al.*, "Classification of COVID-19 pneumonia from chest CT images based on reconstructed super-resolution images and VGG neural network," *Heal. Inf. Sci. Syst.*, vol. 9, no. 1, pp. 1–12, 2021, doi: 10.1007/s13755-021-00140-0.

- [7] V. Das, S. Dandapat, and P. K. Bora, "Computerized Medical Imaging and Graphics A diagnostic information based framework for super-resolution and quality assessment of retinal OCT images," *Comput. Med. Imaging Graph.*, vol. 94, no. October 2020, p. 101997, 2021, doi: 10.1016/j.compmedimag.2021.101997.
- [8] Y. Huang *et al.*, "Simultaneous denoising and super-resolution of optical coherence tomography images based on generative adversarial network," *Opt. Express*, vol. 27, no. 9, p. 12289, 2019, doi: 10.1364/oe.27.012289.
- [9] S. Cao *et al.*, "Super-resolution technology to simultaneously improve optical & digital resolution of optical coherence tomography via deep learning," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, vol. 2020-July, pp. 1879–1882, 2020, doi: 10.1109/EMBC44109.2020.9175777.
- [10] O. Dehzangi, S. H. Gheshlaghi, A. Amireskandari, N. M. Nasrabadi, A. Rezai, and V. Sciences, "OCT Image Segmentation Using Neural Architecture Search and SRGAN," pp. 6425–6430, 2021.
- [11] J. S. Isaac and R. Kulkarni, "Super resolution techniques for medical image processing," *Proc. - Int. Conf. Technol. Sustain. Dev. ICTSD 2015*, pp. 4–9, 2015, doi: 10.1109/ICTSD.2015.7095900.
- [12] S. Lawrence, C. L. Giles, A. C. Tsoi, and A. D. Back, "Face recognition: A convolutional neural-network approach," *IEEE Trans. Neural Networks*, vol. 8, no. 1, pp. 98–113, 1997, doi: 10.1109/72.554195.
- [13] 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.
- [14] Kermany, Daniel; Zhang, Kang; Goldbaum, Michael (2018), "Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification, Mendeley Data, v2