

Cilt Kanseri Görüntülerinde Gürültü Temizliği ve Lezyonun Dört Sınıfa Ayrılması

*Makale Bilgisi / Article Info

Alındı/Received: 29.11.2022

Kabul/Accepted: 08.03.2024

Yayımlandı/Published: 29.04.2024

Noise Removal in Skin Cancer Images and Classification of Lesions into Four Classes

Cihan AKYEL^{1*}, Nursal ARICI²

¹ Millî Eğitim Bakanlığı, İnşaat ve Emlak Genel Müdürlüğü, Ankara, Türkiye

² Gazi Üniversitesi, Uygulamalı Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Ankara, Türkiye

© Afyon Kocatepe Üniversitesi

Öz

Günümüzde cilt kanseri güneş gibi çevresel koşulların da etkisiyle artış göstermektedir. Cilt kanserinin birçok farklı türü olmasına rağmen melanom (MEL), kötü huylu ve en ölümcül olanıdır. Bazal hücre karsinomu (BHK) ve skuamöz hücre karsinomu (SHK) ise diğer organlara yayılım eğilimi gösteren türlerdir. Cilt kanserinde erken teşhis tedavi sürecinde çok önemlidir. Cilt kanseri lezyondaki renk geçişleri, yapısal durum gibi özelliklere bakılarak sınıflandırılabilir. Kanser teşhisinde derin öğrenme ve görüntü işleme algoritmalarının kullanımı yüksek başarı oranından ve insan hatasını bertaraf etmesinden dolayı kullanımı yaygınlaşmaktadır. Lezyon görüntülerinde bulunan kıl, mürekkep izi gibi gürültüler lezyonun bu yöntemlerle sınıflandırılmasında başarıyı düşürmektedir. Çalışmada LinkNet-RCB7 modeli ve görüntü işleme algoritmaları ile lezyon görüntülerinde gürültü temizliği yapılmıştır. Bu aşamada %94.87 eğitim başarıları elde edilmiştir. Sınıflama aşamasında BHK, SHK, MEL ve iyi huylu olmak üzere görüntüler ISIC 2019'a ait veri seti ile dört sınıfa ayrılmıştır. Bu aşamada %96.90 doğruluk değeri gözlemlenmiştir.

Anahtar Kelimeler: Karar Destek Sistemi, Cilt kanseri; Sınıflama; LinkNetB7; ResNet; Dermoskopik Görüntüler.

Abstract

Today, skin cancer is increasing with the effect of environmental conditions as sun. Although there are many different types of skin cancer, melanoma (MEL) is the most malignant and the most deadly. Basal cell carcinoma (BCC) and squamous cell carcinoma (SHC) are types tend to spread to other organs. Early diagnosis of skin cancer is very important in the treatment process. Skin cancer can be classified by looking at features such as color transitions on lesion and structural status. The use of deep learning and image processing algorithms in cancer diagnosis is becoming widespread due to its high success rate and elimination of human error. Noises such as hair and ink traces in the lesion images reduce the success in classifying the lesion with these methods. In the study, noise cleaning was performed on lesion images with the LinkNet-RCB7 model and image processing algorithms. At this stage, 94.87% educational success was achieved. In the classification phase, the images were divided into four classes with the data set of ISIC 2019: BHK, SHK, MEL and benign. At this stage, 96.90% accuracy was observed.

Keywords: Decision Support System; Skin Cancer; Classification; LinkNetB7; ResNet; Dermoscopic Images.

1. Giriş/Introduction

Cilt kanseri özellikle güneş gibi çevresel etkiler sonucu artan bir insidans göstermektedir. Cilt kanseri dünyada sık görülen kanser türleri arasındadır. Örneğin ABD'de ve her yıl yaklaşık 5000 ölümcül vaka görülmektedir. Cilt kanserinin birçok farklı türü olmasına rağmen melanom en ölümcül olanıdır. Melanom cilde rengini veren melanin pigmentinin kontrolsüz çoğalmasıyla ortaya çıkmaktadır. Cilt kanseri zamanla cildin alt katmanlarına ve oradan da diğer doku ve organlara yayılım gösterebilmektedir (Bassel vd. 2022).

Cilt kanserinin teşhisi için kullanılan birçok yöntem bulunmaktadır. Bu yöntemler arasında dermatologlar tarafından yapılan gözle muayene kolaylığı sebebiyle en

sık kullanılanlar arasında yer almaktadır. Bu tür klasik yöntemler uzmanın becerisine bağlı olarak %75-84 arasında değişen başarı oranları göstermektedir (Kahia vd. 2022).

Diğer kanser türlerinde olduğu gibi cilt kanserinin tedavi süreci sağlık sistemlerine ciddi maliyetler getirmektedir. Örneğin, ABD'de 2002-2006 yılları arasında cilt kanserinin tedavisi için yaklaşık 8 milyar dolar harcanmıştır (Machlin vd. 2015). Bu sebeple cilt kanserinin erken teşhisi tedavi edilebilme ihtimalini artırmakta ve maliyetleri düşürmektedir. Çağımızın hemen her alanda kullanılan teknoloji aracı bilgisayar ile desteklenen yöntemler ile başarı oranı artmakta ve tedavi maliyetleri azalmaktadır (Lee vd. 2022).

Melanom dışında kalan bazal hücre karsinomu (BHK) ve skuamöz hücre karsinomu (SHK) da diğer dokulara yayılım gösterebilen ve tedavi edilmediğinde ölümcül olabilen cilt kanseri türlerindedir. BHK bazal hücrelerde görülen ve vakaların %80'ini oluşturan türdür. Erken teşhis edildiğinde tedavisi mümkündür. SHK ise BHK gibi epidermis tabakasında etkilidir. Tüm cilt kanseri vakalarının yaklaşık %16'sını oluşturur. Erken teşhiste tedavisi mümkündür. Aksi durumda diğer dokulara yayılım eğilimi gösterebilmektedirler (Grignaffini vd. 2022).

Melanom cilt kanseri kötü huylu cilt kanseri olarak bilinmektedir. Melanom cilt kanseri tüm cilt kanseri vakalarının yaklaşık %4'ünü oluşturmaktadır. Ölümcül ve en sık yayılım gösteren cilt kanseri türüdür. Yayılım gösteren melanom vakalarında 5 yıllık süreç içinde hastaların yaşayabilme oranı yalnızca %14 olabilmektedir (Grignaffini vd. 2022).

Lezyon üzerindeki kıl vb. gürültüler lezyon sınırlarını kesebilmekte ve bu durum hem gözle muayene hem de bilgisayar destekli sistemlerle yapılan sınıflamada başarıyı düşürebilmektedir. Cilt kanserine ait lezyon görüntüleri üzerindeki gürültülerin temizlenmesi konusunda literatürdeki en eski yöntemlerden birisi DullRazor algoritmasıdır. Bu algoritmada gri seviyeli görüntü üzerinde, morfolojik kapama ile kıl gürültüsünün lokasyonu belirlenir. Daha sonra ince uzun yapıya sahip kıl görüntüsüne ait pikseller belirlenerek, bu piksellerin değerleri doğrusal bilinear interpolasyon yöntemi ile değiştirilir. Son olarak ortanca filtresi (median filter) ile görüntüdeki gürültüler azaltılır. Bu yöntem ince kıl gürültüsü ve diğer gürültü türlerinde düşük başarı gösterir. Buna rağmen basit yapısı sebebiyle tercih edilmektedir (Lee vd. 1997). Bu algoritmanın tercih edildiği güncel çalışmalardan biri Şahin ve Alpaslan (2020)'a aittir. Çalışmada DullRazor algoritmasının gürültü temizliği konusunda yetersiz kaldığı görülmektedir. Optimum bir eşik değerinin olmamasından dolayı görüntü işleme algoritmaları tek başına gürültü temizliğinde yeterli olamamaktadır (Şahin ve Alpaslan 2020).

Cilt kanserinin teşhisinde kullanılan yöntemler arasında kodlayıcı çözücü mimarisine sahip modeller sıklıkla tercih edilmektedir. Bu modeller görüntü bazında yapılan bölütleme çalışmalarında yüksek başarı göstermektedirler. Bu çalışmalardan biri Bardou vd. (2022) tarafından sunulmuştur. Çalışmada kıl gürültüsünün lezyonlardan kaldırılması için kodlayıcı, çözücü mimarisine sahip VAE yöntemi kullanılmıştır. Bu

yöntemin kıl gürültüsünün görüntüden kaldırmayı öğrendiği belirtilmiştir. HAM10000 veri setinden kıl gürültüsü içeren 3000 seçildiği çalışmada kıl gürültüsü içeren görüntüler algoritmaya verilerek gürültüsüz görüntülerin çıktı olarak çözücü bloğun sonunda elde edilmesi amaçlanmıştır.

Literatüre incelendiğinde sadece gürültü temizliği aşamasını içeren çalışmalar çok az görülmektedir. Bunun sebebi bu aşamanın, sonraki aşamalar olan bölütleme ve sınıflama başarısını artırmak adına bu tercih edilen bir ön aşama olmasıdır.

Lezyon görüntülerinde gürültü temizliği aşamasında dullrazor gibi görüntü işleme temelli algoritmaların yanı sıra derin öğrenme algoritmaları da kullanılabilir. Fakat derin öğrenme algoritmalarının kullanılabilmesi için gürültü maskelerini içeren veri setleri gereklidir. Cilt kanseri teşhisi için ISIC ve PH2 gibi birçok halka açık veri seti bulunmaktadır (Cassidy vd. 2022). Bu veri setleri gürültü temizliğinde mevcut durumda kullanılamamaktadır. Çünkü bu veri setleri gürültü maskelerini içermemektedir. Bu duruma çözüm olarak, mevcut veri setlerindeki gürültü içeren görüntülerden gürültü maskelerinin oluşturulduğu çalışmalar literatürde görülmektedir.

Kıl gürültüsü lezyonlarında doğru bölütlenmesi engelleyebilmez. Bu sebeple cilt kanseri görüntülerinin bölütlenmesini içeren çalışmada gürültü temizliği aşaması da yer almaktadır. Gürültü temizliği için kendi veri setini oluşturan çalışmaların bir örneği Liv vd. (2021) tarafından sunulmuştur. Çalışmada ISIC2018 veri setine ait 306 görüntü seçilerek bunlara ait gürültü maskeleri oluşturulmuştur. UNvdgoritmasının kullanıldığı bu çalışmada %96,88 zar katsayısı (dice coefficient) değeri elde edilmiştir. Veri setinin sayıca çok az olması ve sadece kıl gürültüsü içeriyor oluşu çalışmanın güvenilirliğini düşürmektedir. Bölütleme aşamasında %86,5 zar katsayısı değeri elde edilmiştir. Gürültü temizliği başarıyla yapılmış bir veri setinin kullanıldığı bölütleme işleminde başarının daha yüksek olması mümkündür. Kendi veri setini oluşturan diğer bir çalışma Talavera-Martínez vd. (2020) tarafından sunulmuştur. Bu çalışmada kıl gürültüsü içeren görüntüler için gürültü maskeleri simule edilerek oluşturulmuştur. Çalışmada elde edilen toplam 618 maske sadece kalın kıl gürültüsü içermekte ve koyu renktedir. Bu durumdaki gürültülerin tespiti daha kolay olmaktadır. Gerçekte ise daha farklı renkte ve daha ince kıl gürültülerini içeren lezyonlar bulunmaktadır. Bu durumda çalışmada eğitilen model başarısız olacaktır.

Derin öğrenme ve görüntü işleme gibi bilgisayar destekli yöntemler ile cilt kanserinin teşhisinde son aşama lezyonun sınıflandırılmasıdır. Cilt kanserinin sınıflandırılmasının genel olarak iyi huylu ve kötü huylu şeklinde yapıldığı görülmektedir. Lezyonun sınıflandırılmasında düşük kontrast geçişleri, lezyon üzerindeki parlamalar gibi birçok zorluk vardır. Rehman vd. (2022) çalışmalarında lezyonlar, iki sınıfa ayrılmıştır. Bu çalışmada modifiye edilmiş MobileNetV2 ve DenseNet201 algoritmaları kullanılmış ve gürültü temizliği yapılmamıştır. Veri setindeki görüntüler üzerinde, eğitim aşamasından önce kontrast iyileştirme ve veri artırma uygulanmıştır. Kontrast iyileştirme ile zemin ve lezyon arasında ayrışma sağlanarak sınıflama başarısında artış hedeflenmektedir. Veri artırma ise aşırı öğrenme sorununa çözüm olarak çalışmalarda yer almaktadır. Toplam 660 görüntünün yer aldığı ISIC'a ait görüntülerin yer aldığı kaggle veri seti kullanılmış ve %91.86 doğruluk değeri elde edilmiştir. Kaur vd. (2022) tarafından sunulan ISIC2020 veri seti kullanılarak lezyon melanom ve normal olarak iki sınıfa ayrılmıştır. DCNN modelinin tercih edilmiş ve %90,4'lük bir doğruluk değeri gözlemlenmiştir. Bu çalışmada da gürültü temizliği aşaması yer almamaktadır. Lezyon sınıflandırmasında sık kullanılan yöntemlerde birisi de SVM (Support Vector Machine-Destek Vektör Makinesi)'dir. Genellikle iki sınıfa ayırma söz konusu olduğunda tercih edilen yöntemlerden biridir. Suresh ve Seeja (2019) bölütlenmiş lezyon görüntülerini renk, kenar histogramı gibi özelliklerini SVM kullanarak iyi ve kötü huylu şeklinde iki sınıfa ayırmışlardır. %85,19 zar katsayısı değeri elde edilmiştir. MobileNetV2 kullanılan bir diğer çalışma Indraswari vd. (2022) tarafından sunulmuştur. Sadece sınıflandırma aşamasının yer aldığı çalışmada ISBI2016 veri setinde %83 doğruluk değeri elde edilmiştir. Bu çalışmada da lezyonlar kötü ve iyi huylu olarak ikiye ayrılmıştır.

Literatürde cilt kanserinin sınıflandırılmasında ikiden fazla sınıfın kullanıldığı çalışmalar da mevcuttur. Kausar vd. (2021) çalışmalarında cilt kanseri lezyon görüntüleri sekiz sınıfa ayrılmıştır. Farklı modellerin kullanıldığı çalışmada ResNet, DenseNet, VGG16 ve InceptionV3 algoritmaları tercih edilmiştir. Lu ve Zadeh (2022) lezyonu iyi huylu, kötü huylu ve karsinom olarak üç sınıfa ayırmışlardır. Modifiye edilmiş XceptionNvdgoritması ile %100 doğruluk değeri elde edildiği belirtilmiştir. VGG16 kullanılarak yapılan diğer bir çalışmada lezyonlar iki sınıfa ayrılarak %78.66 doğruluk değeri elde edilmiştir (Lopez vd., 2017). Derin öğrenme yöntemleri ile birlikte kullanımı artan transfer öğrenme metodu sınıflandırma çalışmalarında da tercih edilmektedir. Transfer öğrenmede önceden büyük

veri setleri ile eğitilmiş modellerin kullanımı söz konusudur. Bu sayede eğitim süreleri azalmakta ve başarı artışı sağlanmaktadır. Cilt kanseri sınıflandırılmasında da transfer öğrenmenin kullanıldığı çalışmalar vardır. Jaisakthi vd. (2022) çalışmalarında ResNet, EfficientNetB6 gibi farklı modeller kullanmışlardır. En yüksek başarı EfficientNetB6 ile %96.81 AUC değeri elde edilmiştir.

Cilt kanserinin doğru teşhisi tedavi maliyetlerinin düşmesini, hastaların yaşama oranının artması adına oldukça önemlidir. Derin öğrenme ve görüntü işleme teknikleri ile yüksek başarı değerleri ve neredeyse sıfır maliyet ile teşhis süreci yürütülebilir.

Çalışmanın temel amacı, cilt kanserine ait dermoskopik lezyon görüntülerinin doğru şekilde sınıflandırılması ve elde edilen sınıflandırma sonucuna göre karar vericilere bir karar destek sistemi olarak karar verme sürecinde destek sağlanmasıdır. Lezyon görüntülerinde bulunan kıl gürültüsü, derin öğrenme ile yapılacak sınıflandırmanın başarısını düşürmektedir. Bu sebeple gürültü temizliği aşaması da çalışma için diğer bir önemli amaçtır. Bu çalışmada cilt kanseri görüntülerinde, gürültülerin temizlenerek cilt kanserinin yüksek doğruluk oranıyla sınıflandırılması amaçlanmıştır. Gürültü temizliği aşaması lezyonların doğru sınıflandırılabilmesi için bir ön süreç olarak kullanılmıştır. Çalışmanın temel amacı cilt kanseri lezyonlarının yüksek başarı değerleriyle dört sınıfa ayrılmasıdır.


Çalışmanın ikinci bölümünde, tercih edilen derin öğrenme ve görüntü işleme algoritmaları detaylandırılmıştır. Eğitim sonucunda elde edilen sonuçlara ve diğer çalışmalarla yapılan karşılaştırmalara üçüncü bölümde yer verilmiştir.

2. Materyal ve Metot / Materials and Methods

Çalışma gürültü temizliği ve lezyon sınıflandırma aşamalarından oluşmaktadır. Sınıflandırmada mevcut literatürde genellikle ikili sınıflandırma kullanılmasına rağmen, BHK, SHK, MEL ve iyi huylu olmak üzere dört sınıf tercih edilmiştir. Bunun sebebi BHK ve SHK türlerinin de diğer dokulara yayılabilmesi ve zamanla kötü huyluya dönüşebilmesidir. Bu şekilde potansiyel olarak kötü huyluya dönebilecek ve yayılım gösterebilecek türler tespit edilerek erken teşhis ve tedavi aşamasında başarı artırılacaktır.


Gürültü temizliği için ISIC2018' ait kıl, mürekkep izi, cetvel, su kabarcığı gürültülerini içeren toplam 3000 adet dermoskopik görüntü seçilerek gürültü maskeleri manuel olarak oluşturulmuştur (Codella vd., 2018). Öncelikle

görüntülere ait kıl maskeleri adaptif eşikleme yöntemi ile elde edilmiştir. Elde edilen maskeler sırasıyla ortanca filtresi, morfolojik işlemler ile gürültülerden temizlenmiştir. Son olarak maskeler üzerinde adobe fireworks programı ile manuel olarak gürültü temizleme uygulanmıştır. Bu veri seti Gürültü maske veri seti (GMV) olarak adlandırılmıştır. Şekil 1’de GMV’den setinden örnekler görülmektedir.



Şekil 1. (a) Görüntü, (b) Maske için GMV Örnekleri.

Çalışmada sınıflandırma aşaması için ISIC2019 ve ISIC2020 veri setleri kullanılmıştır. ISIC2019 veri seti etiketlenmemiş diğer adlı sınıf dahil 9 sınıftan oluşmaktadır (Tschandl vd., 2018). ISIC2020 ise BHK, SHK ve iyi huylu türlerini içermeyen 8 sınıftan oluşmaktadır (Rotemberg vd., 2021). Bu sebeplerden çalışmada kullanılacak dört sınıfı elde etmek için 2020’ye ait 2512 adet iyi huylu lezyon seçilmiş, BHK, SHK ve Melanom türleri için ISIC2019’a ait görüntülerle bir araya getirilmiştir. Dermoskopik görüntüler içeren bu veri seti sınıflama veri seti (SVS) olarak adlandırılmıştır. Kullanılan tüm veri setleri public (halka açık) olup, ticari amaçlar dışında kullanıma açıktır.




Şekil 2. ISIC2019 ve ISIC2020 Örnekleri.

2.1 Kontrast İyileştirme, Görüntü Dilimleme ve Veri Artırma

Çalışmada kullanılan tüm veri setlerine ait RGB görüntüler üzerinde kontrast farkını artırmak için kontrast iyileştirme uygulanmıştır. Gürültünün en net görüldüğü kanal olduğu

için yeşil kanal seçilmiş, ardından clahe (Contrast Limited Adaptive Histogram Equalization) uygulanmıştır. RGB renk uzayında yeşil renk kanalında, görüntü üzerinde yer alan kıl, damar gibi kısa ve uzun gürültüler zeminle daha çok ayrılmaktadır. Bu durum modelin başarısını artırabilmektedir (Tan vd. 2014). Kontrast iyileştirmeye ait örnek görüntüler şekil 3’ te görülebilmektedir. Bu yöntemle gürültü veri setinde kıl gürültüsü, sınıflama veri setlerinde ise lezyonla daha belirgin hale gelmişlerdir. Görüntüler 256x256x3 boyutuyla eğitime alınmışlardır.



Şekil 3. Kontrast İyileştirme Aşaması.

Veri artırma derin öğrenme ile yapılan eğitimlerde ortaya çıkabilen aşırı öğrenme (ezberleme) sorununa çözüm getirebilmektedir. Çalışmada yapılan sınıflandırma aşamasında ise diğer bir görevi daha vardır. Sınıflandırma veri seti içerisinde farklı sınıflara ait görüntü sayıları ciddi farklılık göstermektedir. Bu durum eğitim başarısını da etkileyecektir. Bu sebepten her sınıftan eşit sayıda seçilip veri artırma ile verilerin sınıflarda dağılımları da dengelenmeye çalışılmıştır (Yatay-dikey çevirme, 90-180 derece döndürme). Gürültü temizliği ve lezyon sınıflandırma aşamalarında kullanılan veri setlerinin dağılımları Çizelge 1’de verilmiştir.

Çizelge 1. Veri Setlerinin Dağılımları.

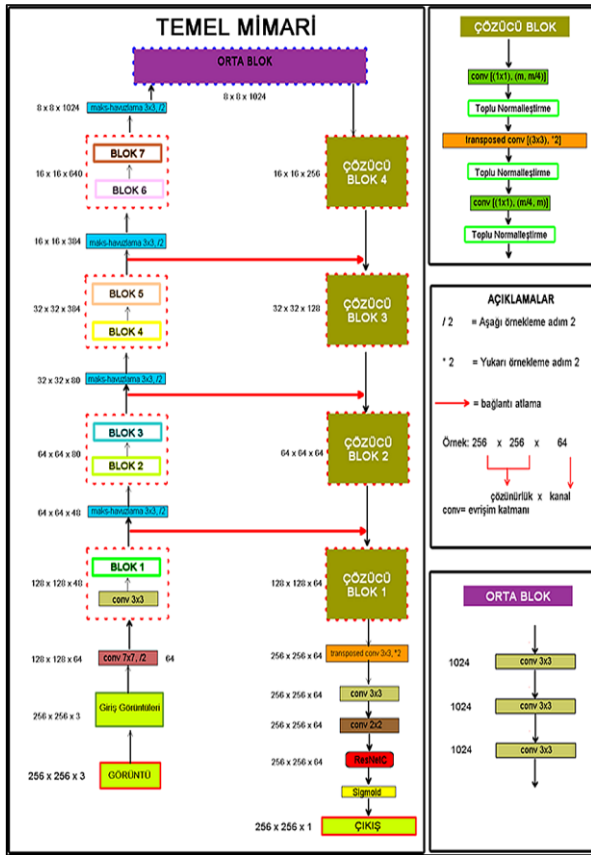
Aşama	Veri Seti	Tür	Sayı	Veri Artırma ile
Gürültü Temizliği	ISIC2018	-	3000	12000
	ISIC2019	MEL	2512	2512
Lezyon Sınıflandırma	ISIC2020	BHK	2512	2512
		SHK	628	2512
		İyi Huylu	2512	2512

Çizelge 1’de verilen veri setleri %70 eğitim %20 doğrulama ve %10 test olmak üzere ayrılmıştır. Ayırma işlemi veri artırma öncesinde yapılmıştır. Sonuç olarak GMV veri seti

8400 eğitim, 2400 doğrulama ve 1200 test; SVS veri seti ise 7033 eğitim, 2011 doğrulama ve 1004 test (0: 251, 1:251, 2:251, 3: 251) olarak ayrılmıştır (0: Melanom, 1: BHK, 2: SHK, 3: İyi Huylu).

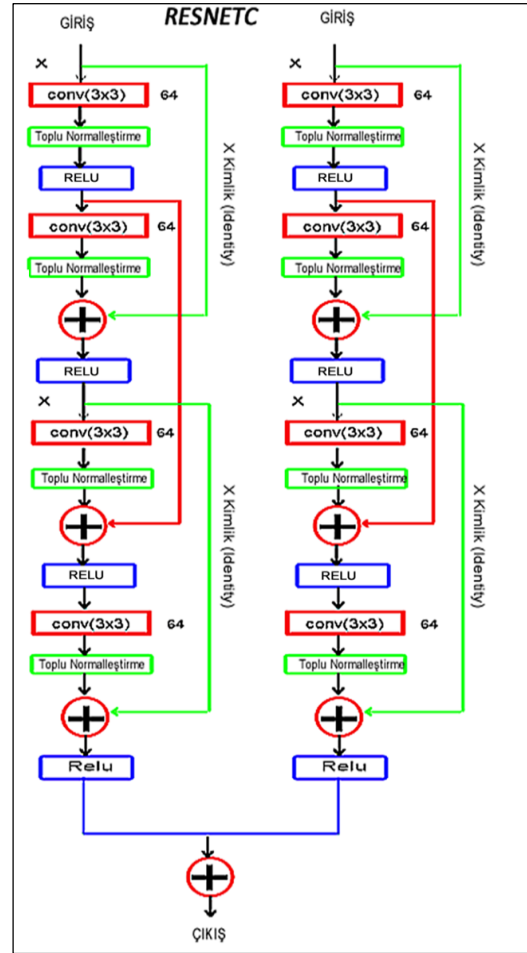
2.2. Gürültü Temizliği Modeli-LinkNet-RCB7

LinkNet-RCB7 modelinde LinkNet modelinde kodlayıcı bloklarda EfficientNetB7'e ait bloklar kullanılmıştır. Algoritmanın bitişin katmanından önce bir adet ResNetC eklenmiştir. Mevcut literatürde yer alan LinkNetB7 modeline göre tek farklılığı algoritmanın sonunda ResNet yerine, ResNetC'nin eklenmiş olmasıdır. ResNetC ResNet'e göre daha başarılı bir versiyondur (Akyel ve Arıcı, 2022). Bu model medikal görüntü bölütlemesinde yüksek başarı göstermesinden ötürü çalışmada tercih edilmiştir. Modele ait mimari Şekil 4'te görülmektedir (Akyel, 2022).



Şekil 4. LinkNet-RCB7 Mimarisi (Akyel, 2022).

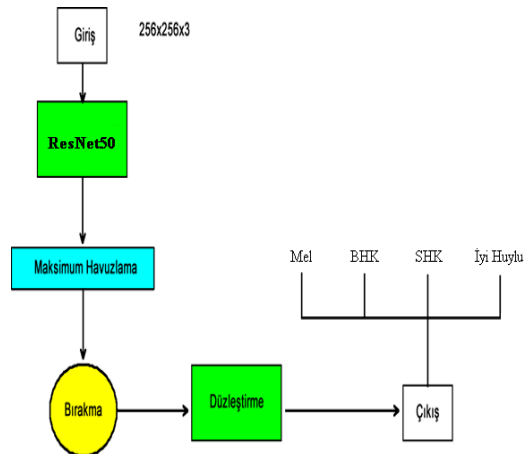
Şekil 5'te görülen ResNetC iki paralel bloкта dört adet ResNet bloğu içermektedir. Paralel yapı sayesinde herhangi bir bloкта özellik çıkarımı eksik kaldığında diğer bloklar bu açığı kapayabilmektedir. Ayrıca kullanılan kimlik bağlantıları ile giriş ve çıkış boyutlarının aynı kalması sağlanmaktadır. ResNetC modelinin standart ResNet'e göre daha başarılı olduğu belirtilmiştir (Akyel and Arıcı, 2022).



Şekil 5. ResNetC Mimarisi (Akyel and Arıcı, 2022).

2.3. Lezyon Sınıflama Modeli

Lezyon sınıflandırma aşaması için ResNet50 modelini temel alan bir algoritma tercih edilmiştir. Elde edilen yüksek başarı değerlerinden dolayı diğer ön eğitilmiş modellerle eğitim yapılmamıştır. Algoritmada kullanılan bırakma (dropout) katmanları ile aşırı öğrenme önlenmeye çalışılmıştır. Modele ait algoritma Şekil 6'da görülmektedir.



Şekil 6. Sınıflandırma Modeli Algoritma.

2.4. Performans Metrikleri

Çalışmada sınıflandırma alanında literatürde sıklıkla kullanılan doğruluk, duyarlılık, özgüllük, kesinlik ve f-skör performans parametreleri tercih edilmiştir. Bu metrikler kısaca açıklanmıştır.

Doğruluk: Doğruluk değeri modelde doğru tahmin edilen alanların toplam veri kümesine oranı ile hesaplanmaktadır (1) (Powers vd., 2011).

$$\text{Doğruluk} = (GP + GN)/(GP + GN + YP + YN) \quad (1)$$

Duyarlılık: Duyarlılık ise pozitif olarak tahmin edilmesi beklenenlerin hangi sayıda pozitif olarak tahmin edildiğini göstermektedir (2) (Sokolova, 2006).

$$\text{Duyarlılık} = GP/(GP + YN) \quad (2)$$

Özgüllük: Özgüllük, gerçek negatif oran olarak ifade edilir ve bir testte negatif sonuç veren gerçekten de negatif olan örneklerin oranıdır (3) (Sokolova, 2006).

$$\text{Özgüllük} = GN/(GN + YP) \quad (3)$$

Kesinlik: Kesinlik pozitif olarak tahminlenen değerlerin gerçekten kaç tanesinin pozitif olduğunun göstergesidir (4) (Sokolova, 2006).

$$\text{Kesinlik} = GP/(GP + YP) \quad (4)$$

F-Skor: F-puanı, bir sistemin kesinlik ve geri çağırma değerlerinin harmonik ortalamasıdır (Sokolova, 2006).

$$F - \text{Skor} = 2 * (\text{Kesinlik} * \text{Duyarlılık})/(\text{Kesinlik} + \text{Duyarlılık}) \quad (5)$$

Dice Coefficient (DC): Gerçek ve tahmin edilen değer arasındaki örtüşmenin bir ölçütüdür (Kaya and Önal, 2021).

$$DC = 2|A \cap B|/(|A| + |B|) = 2TP/(2TP + FP + FN) \quad (6)$$

3. Bulgular / Results and Discussions

Gürültü temizliği ve sınıflama aşamalarında algoritmalar 250 epoch koşurulmuştur. En iyileyici (optimizer) olarak adam seçilmiştir. Gürültü temizliğinde çıkış fonksiyonu sigmoid, dörtlü sınıflama aşamasında ise softmax seçilmiştir (Eğitim Başarısı: EB, Doğrulama Başarısı: DB, Test Veri Seti: TVS, DC: Dice Coefficient).


3.1. Gürültü Temizliği Aşaması

Bu aşamada eğitilen model ile tahmini yapılan maskeler üzerinde morfolojik işlemler ve ortanca filtresi ile düzeltme yapılmıştır. Elde edilen maskeler kullanılarak

opencv kütüphanesinde yer alan INPAINT fonksiyonu ile gürültüsüz görüntüler elde edilmiştir. Çizelge 2’de ve Şekil 7’de sonuçlar görülmektedir.

Çizelge 2. Gürültü Temizliği Eğitim Sonuçları.

Parametre (%)	UNet	LinkNet	LinkNet-B7	LinkNet-RCB7
EB	85,60	88,48	94,71	94,87
DB	80,42	83,60	89,78	89,54
meanIoU	83,22	85,44	90,21	90,41
DC	82,60	85,26	90,38	90,84
TVS Başarı	80,55	85,23	86,27	86,79
TVS DC	79,80	80,66	84,45	84,82



Şekil 7. Gürültü Temizliği Maske Tahmini (a: orijinal görüntü, b: gerçek maske, c: tahmin edilen maske).

3.2. Lezyon Sınıflandırma Aşaması

Bu aşamada lezyonlar dört sınıfa ayrılmıştır. Çizelge 4’te elde edilen sonuçlar verilmiştir. Çizelge 3’te test verisiyle elde edilen sonuçlar kesinlik (precision), duyarlılık (recall) ve f1 parametreleriyle verilmiştir. Bu durum sınıflar arası dağılımın dengeli olduğunu göstermektedir (0: Melanom, 1: BHK, 2: SHK, 3: İyi Huylu). Çizelge 4’te ise eğitim ve test veri setleriyle elde edilen sonuçlar görülmektedir.

Çizelge 3. Lezyon Sınıflandırma Test Verisi Sonuçları.


Sınıf	Kesinlik	Duyarlılık	F1 skor
0	0.85	0.95	0.90
1	0.82	0.89	0.85
2	0.90	0.74	0.81
3	1	1	0.99
Ağırlıklı ortalama	0.89	0.89	0.89
Makro ortalama	0.88	0.88	0.89

Çizelge 4. Lezyon Sınıflandırma Sonuçları.

Parametre		ResNet	MobileNetV2	Önerilen Model
<i>Dört sınıfa ayırma</i>	EB (%)	93,20	95,75	96.90
	DB (%)	88,85	91,07	87.56
	TVS Başarı (%)	87	89	89
	DB (%)	89,78	91,90	93,05
Gürültü Temizliği Yapılmadan Elde Edilen Sonuçlar				
<i>Dört sınıfa ayırma</i>	EB (%)	91,42	94,10	94.80
	DB (%)	86,95	89,25	86.15
	TVS Başarı (%)	86	89	88
	DC (%)	88,05	90,00	91,20

4. Sonuçlar ve Tartışma / Conclusions

Çizelge 5'te ve Çizelge 6'da yer alan sonuçlara göre çalışmada kullanılan modellerin başarılı olduğu görülmektedir. Li vd. 2021'de 306 adet sadece kıl gürültüsü içeren maskeden oluşan veri seti kullanılmıştır. Yine daha yüksek başarı gösteren Akyel ve Arıcı'nın çalışmalarında kıl ve mürekkep izi dışında başka gürültülere ait maskeler yer almamaktadır. Bu durumlar göz önüne alındığında önerilen yaklaşımın yüksek hassasiyete sahip ve başarılı olduğu görülmektedir. Şekil 8'de model ile yapılan gürültü temizliği örnekleri yer almaktadır. 2 numaralı görüntüde detay ile verilen alandaki kıl gürültüsü ince ve kontrastı az olduğu için model yeterince başarı sağlayamamıştır. 3 numaralı görüntüde ise beyaz tüylerden oluşan görüntü model tarafından tespit edilememiştir.

**Şekil 8.** Gürültü Temizleme Örnekleri (a: orijinal görüntü, b: temizlenmiş görüntü, c: detay).**Çizelge 5.** Gürültü temizliği aşamasında modellerin karşılaştırma sonuçları.

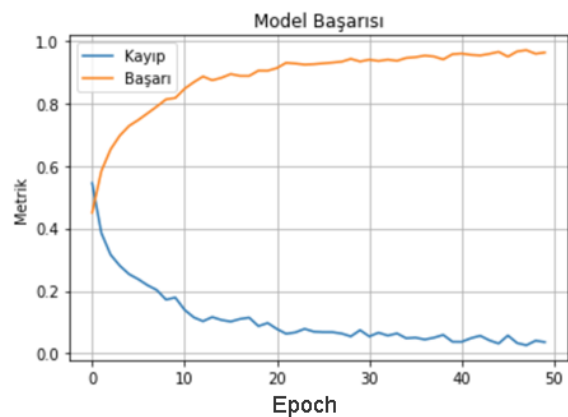
Çalışma	Yöntem	Veri Seti	Başarı
Li vd. 2021	UNet	ISIC-archive	99,08
Akyel ve Arıcı 2020	UNet	ISIC2018	88,58
Akyel ve Arıcı 2022	FCN8-ResNetC	ISIC2018	90,30
Akyel ve Arıcı 2022	LinkNet-B7	ISIC2018	95,72
Önerilen Yaklaşım	LinkNet-RCB7	ISIC2018	94.87


Sınıflama başarısının diğer çalışmalara göre yüksek olduğu Çizelge 6'da görülmektedir. Başarının yüksek olmasında gürültüsüz verilerin kullanılmış olmasının da etkisi vardır. Literatürde temel olarak cilt kanseri lezyonlarının iki sınıfa ayrıldığı görülmektedir.

Çizelge 6. Lezyon Sınıflandırma karşılaştırma sonuçları

Çalışma	Yöntem	Sınıf Sayısı	Veri seti	Doğruluk(%)
Rehman vd. 2022	MobileNetV2	2	Kaggle	91.86
Kaur vd. 2022	DCNN	2	ISIC2020	90.14
Suresh and Seeja 2019	SVM	2	ISBI2016	85.19
Indraswari vd. 2022	MobileNetV2	2	ISBI2016	83
Kausar vd. 2021	VGG19	8	ISIC2019	91.8
Lu and Zadeh 2022	XceptionNet	3	HAM10000	100
Lopez vd. 2015	VGG16	2	ISIC-Archive	95.95
Önerilen Yaklaşım	ResNet50	4	ISIC2019,20	96,90

Sonuç olarak derin öğrenme ve görüntü işleme algoritmalarını içeren önerilen yaklaşımların gürültü temizliği ve lezyon sınıflandırılmasında etkili olduğu görülmüştür. Gürültü aşaması için 3000 kıl vb. gürültüler içeren veri seti çalışma kapsamında hazırlanmıştır. Şekil 9'da 50 epoch sonunda sınıflandırma eğitiminde elde edilen değerler ve Şekil 10'da doğrulama başarısına ait değerler yer almaktadır.

**Şekil 9.** Sınıflama aşaması 50 epoch eğitim başarı grafiği.



Şekil 10. Sınıflama aşaması 50 epoch doğrulama başarı grafiği.

Test veri seti ile elde edilen karmaşıklık matrisi Şekil 11’de yer almaktadır. Buna göre iyi huylu lezyonların tespitinde yaklaşık %100’lük başarı elde edilmiştir. Diğer sınıflar için de elde edilen sonuçlar yüksek başarı değerleri göstermiştir. Sonuç olarak elde edilen sınıflama başarısında gürültü temizliği doğru yapılan ve sınıflar arası görüntü dağılımında denge sağlanmış olmasının etkisi görülmektedir.

Daha sonraki çalışmalarda farklı sınıf sayıları kullanılarak sınıflama eğitimi yapılabilir. Ayrıca sınıflama aşaması için görüntülerin GLCM benzeri teknikler ile öznelikleri çıkarılarak bunlar üzerinden sınıflama yapılabilir. Bu durum derin öğrenmeye kıyasla daha az kaynak kullanımına imkân verebilecektir.

		Karışıklık Matrisi			
		0	1	2	3
Gerçek Değerler	0	240	7	4	0
	1	3	237	11	0
	2	18	33	200	0
	3	0	0	0	251
		Tahminler			

Şekil 11. Sınıflama aşaması Karışıklık Matrisi.

Etik Standartlar Bildirgesi

Yazarlar tüm etik standartlara uyduklarını beyan ederler.

Yazarlık Katkı Beyanı

Yazar 1: Kaynaklar, Araştırma, Deney, Metodoloji, Yazma – orijinal taslak Görselleştirme, Eğitim Aşamaları

Yazar 2: Kaynaklar, Biçimsel analiz, Doğrulama, Görselleştirme,

Çıkar Çatışması Beyanı

Yazarların bu makalenin içeriğiyle ilgili olarak beyan edecekleri hiçbir çıkar çatışması yoktur.

Verilerin Kullanılabilirliği

Bu çalışma sırasında oluşturulan veya analiz edilen tüm veriler, yayınlanan bu makaleye dahil edilmiştir.

5. Kaynaklar / References

- Akyel, C., 2022. Görüntü işleme ve derin öğrenme yöntemleri ile cilt kanseri teşhisi için karar destek sisteminin geliştirilmesi. Doktora Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara, 79.
- Akyel, C., and ARICI, N., 2022. Hair Removal and Lesion Segmentation with FCN8-ResNetC and Image Processing in Images of Skin Cancer. *Bilişim Teknolojileri Dergisi*, **15(2)**, 231-238. <https://doi.org/10.17671/gazibtd.1060330>
- Akyel, C., and ARICI, N., 2022. LinkNet-B7: Noise Removal and Lesion Segmentation in Images of Skin Cancer. *Mathematics*, **10(5)**, 736-751. <https://doi.org/10.3390/math10050736>
- Bardou, D., Bouaziz, H., Lv, L., and Zhand, T., 2021. Hair removal in dermoscopy images using variational autoencoders. *Skin Research Technology*, **28**, 445-454. <https://doi.org/10.1111/srt.13145>
- Bassel, A., Abdulkareem, A. B., and Alyasseri, Z. A. A., 2022. Automatic Malignant and Benign Skin Cancer Classification Using a Hybrid Deep Learning Approach. *Diagnostics*, **12(2472)**, 1-15. <https://doi.org/10.3390/diagnostics12102472>
- Cassidy, B., Kendrick, C., Brodzicki, A., Jaworek-Korjakowska, J., and Yap, M. H., 2022. Analysis of the ISIC image datasets: Usage benchmarks and recommendations. *Medical Image Analysis*, **75**, 1-15. <https://doi.org/10.1016/j.media.2021.102305>
- Codella N., Rotemberg, V., Tschandl, P., Celebi, M. E., Dusza, S., Gutman, D., Helba, B., Kalloo, A., Liopyris, K., Marchetti, M., Kittler, H., Halpern, A., 2018. Skin Lesion Analysis Toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (ISIC), *Computer Vision and Pattern Recognition*, 2018, 1-12. <https://doi.org/10.48550/arXiv.1902.03368>
- Grignaffini, F., Barbuto, F., Piazza, L., Troiano, M., Simeoni, P., Mangini, F., Pellacani, G., Cantisani, C., and Frezza, F., 2022. Machine Learning Approaches for Skin Cancer Classification from Dermoscopic Images: A Systematic Review. *Algorithms*, **15**, 1-30. <https://doi.org/10.3390/a15110438>

- Indraswari, R., Rokhana, R., and Herulambang, W., (2022). Melanom image classification based on MobileNetV2 network. *Procedia Computer Science*, 197, 198–207.
<https://doi.org/10.1016/j.procs.2021.12.132>
- Jaisakthi S. M., Mirunalini, P., Chandrabose, A., and Rajagopal, A., 2022. Classification of skin cancer from dermoscopic images using deep neural network architectures. *Multimedia Tools and Applications*, 2022, 1-16.
<https://doi.org/10.1007/s11042-022-13847-3>
- Kahia, M., Echioui, A., Kallel, F., and Hamida, A. B., 2022. Skin Cancer Classification using Deep Learning Models. *ICAART 2022*, 1, 554-560.
<https://doi.org/10.5220/0010976400003116>
- Kaur, R., Gholamhosseini, H., Sinha, R., and Lindén, M., 2022. Melanom Classification Using a Novel Deep Convolutional Neural Network with Dermoscopic Images. *Sensors*, 22(3), 1-15.
<https://doi.org/10.3390/s22031134>
- Kausar, N., Hameed, A., Sattar, M., Ashraf, R., Imran, A. S., Abidin, M. Z., and Ali, A., 2021. Multiclass Skin Cancer Classification Using Ensemble of Fine-Tuned Deep Learning Models. *Applied Sciences*, 11, 1-20.
<https://doi.org/10.3390/app112210593>
- Kaya, B., and Önal, M., 2021. COVID-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi. *Avrupa Bilim Ve Teknoloji Dergisi*, 28, 1296-1303.
<https://doi.org/10.31590/ejosat.1015061>
- Lee, T., Ng, V., Gallagher, R., Coldman, A., and McLean, D., 1997. Dullrazor®: A software approach to hair removal from images, *Computers in Biology and Medicine*, 27(6), 533-543.
[https://doi.org/10.1016/S0010-4825\(97\)00020-6](https://doi.org/10.1016/S0010-4825(97)00020-6)
- Lee, J. R. H., Pavlova, M., Famouri, M., and Wong, A., 2022. S Cancer-Net SCA: tailored deep neural network designs for detection of skin cancer from dermoscopy images. *BMC Medical Imaging*, 22(143), 1-12.
<https://doi.org/10.1186/s12880-022-00871-w>
- Li, W., Raj, A. N. J., Tjahjadi, T., and Zhuang, Z., 2021. Digital hair removal by deep learning for skin lesion segmentation. *Pattern Recognition*, 117, 1-15.
<https://doi.org/10.1016/j.patcog.2021.107994>
- Lu, X., and Zadeh, Y. A. F. A., 2022. Deep Learning-Based Classification for Melanoma Detection Using XceptionNet. *Hindawi Journal of Healthcare Engineering*, 2022, 1-10.
<https://doi.org/10.1155/2022/2196096>
- Lopez A. R., Giro-i-Nieto X., Burdick J., Marques O., (2017). Skin Lesion Classification From Dermoscopic Images Using Deep Learning Techniques, 13th IASTED International Conference on Biomedical Engineering (BioMed), Manhattan, New York, U.S: Institute of Electrical and Electronics Engineers (IEEE), 49–54.
- Machlin, J., Machlin S. R., Ekwueme, D. U., Yabrof K. R., 2015. Prevalence and costs of skin cancer treatment in the U.S. *American Journal of Preventive Medicine*, 48, 183–187.
<https://doi.org/10.1016/j.amepre.2014.08.036>
- Powers, D., Powers A., 2011. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2, 2229-3981.
<https://doi.org/10.9735/2229-3981>
- Rehman, M., Ahmed, F., Alsuhibany, S. A., Jamal, S. S., Ali, M. Z., and Ahmad, J., 2022. Classification of Skin Cancer Lesions Using Explainable Deep Learning. *Sensors*, 22, 1–14.
<https://doi.org/10.3390/s22186915>
- Rotemberg, V., Kurtansky, N., Betz-Stablein, B., Caffery, L., Chousakos, E., Codella, N., Combalia, M., Dusza, S., Guitera, P., Gutman, D., Halpern, A., Helba, B., Kittler, H., Kose, K., Langer, S., Liopyrs, K., Malvey, J., Musthaq, S., Nanda, J., Reiter, O., Shih, G., Stratigos, A., Tschandl, P., Weber, J. and Soyer, P., 2021. A patient-centric dataset of images and metadata for identifying melanomas using clinical context. *Scientific Data*, 8(34), 1-8.
<https://doi.org/10.1038/s41597-021-00865-3>
- Sokolova, M., Japkowicz, N., Szpakowicz, S., 2006. Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation. *Advances in Artificial Intelligence*, 4304, 1015-1021.
https://doi.org/10.1007/11941439_114
- Suresh, A., and Seeja, R., 2019. Deep Learning Based Skin Lesion Segmentation and Classification of Melanom Using Support Vector Machine (SVM). *Asian Pacific Journal of Cancer Prevention*, 20(5), 1555-1561,
<https://doi.org/10.31557/APJCP.2019.20.5.1555>
- Şahin, N. ve Alpaslan, N., 2020. Seg-Net Mimarisi Kullanılarak Cilt Lezyon Bölütleme Performansının İyileştirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, special issue, 40-45.
<https://doi.org/10.31590/ejosat.araconf6>
- Talavera-Martínez, L., Bibiloni, P., and González-Hidalgo, M., 2020. Hair Segmentation and Removal in Dermoscopic Images Using Deep Learning. *IEEE Access*, 9, 2694–2704.
<https://doi.org/10.1109/ACCESS.2020.3047258>
- Tschandl P., Rosendahl C. And Kittler H., 2018. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific Data*, 5, 1-9.

<https://doi.org/10.1038/sdata.2018.161>

Tan, X., Lai, S., and Zhang, M., 2014. Green Channel Guiding Denoising on Bayer Image. The Scientific World Journal, 2014, 1-9.

<https://doi.org/10.1155/2014/979081>