



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



Cilt kanseri görüntülerinde kıl temizliği ve lezyon bölütlemesinde yeni bir yaklaşım

A new approach to hair noise cleansing and lesion segmentation in images of skin cancer

Yazar(lar) (Author(s)): Cihan AKYEL¹, Nursal ARICI²

ORCID1: 0000-0003-1792-8254

ORCID2: 0000-0002-4505-1341

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Akyel C. ve Arıcı N., "Cilt kanseri görüntülerinde kıl temizliği ve lezyon bölütlemesinde yeni bir yaklaşım", *Politeknik Dergisi*, 23(3): 821-828, (2020).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.645395

Cilt Kanseri Görüntülerinde Kıl Temizliği ve Lezyon Bölütlemesinde Yeni Bir Yaklaşım


A New Approach to Hair Noise Cleansing and Lesion Segmentation in Images of Skin Cancer

Önemli noktalar (Highlights)

- ❖ Cilt Kanseri Türleri / Skin Cancer Types
- ❖ Cilt Kanseri Görüntülerinde Kıl Temizliği / Hair Noise Cleansing in Images of Skin Cancer
- ❖ Cilt Kanserinde Görüntülerinde Lezyon Bölütlemesi / Lesion Segmentation in Images of Skin Cancer
- ❖ Derin Öğrenme ve Görüntü İşleme Algoritmaları / Deep Learning and Image Processing Algorithms
- ❖ Kıl ve Lezyon Maskelerinin tahmin edilmesi / Predicting Hair and Lesion Masks

Grafik Özet (Graphical Abstract)

Çalışmada cilt kanseri lezyonlarındaki kıl vb gürültülerin temizlenmesi ve lezyonun bölütlenmesi, derin öğrenme ve görüntü işleme algoritmalarıyla oluşturulan maskeler ile yapılmaktadır.



Şekil. Algoritmanın genel gösterimi / **Figure.** General representation of the algorithm

Amaç (Aim)

Bu çalışmada; derin öğrenme ile elde edilen maskeler, görüntü işleme algoritmaları ile optimize edilerek lezyon maskelerinin daha doğru tahmin edilmesi amaçlanmıştır./In this study; masks obtained by deep learning are optimized with image processing algorithms and it is aimed to predict the lesion masks more accurately.

Tasarım ve Yöntem (Design & Methodology)

ISIC 2018'e ait 10015 adet görüntü ve 13000 adet görüntü ve maske içeren iki adet veri seti kullanılmıştır. Yöntem olarak Unet tabanlı derin öğrenme algoritması ve görüntü işleme algoritmaları kullanılmıştır./Two data sets containing 10015 images of ISIC 2018 and 13000 images and masks were used. As a method, Unet based deep learning algorithm and image processing algorithms were used.

Özgünlük (Originality)

Literatürden farklı olarak, kıl maskeleri oluşturulmuş ve derin öğrenme ile sistem eğitilmiştir. Kıl ve lezyon maskelerinin eğitim aşamalarında, görüntüler 16'lık dilimlere ayrılarak öğrenme başarısı artırılmıştır. / Unlike literature, hair masks have been created and the system has been trained with deep learning. During the training stages of hair and lesion masks, images are divided into 16 slices and learning success is increased.

Bulgular (Findings)

Kıl temizliği aşamasında %91.68, lezyon bölütlemesinde %94 doğrulama başarısı elde edilmiştir./ 91.68% validation accuracy was achieved in the hair removal stage and 94% in lesion segmentation.

Sonuç (Conclusion)

Çalışmada oluşturulan orjinal maskelerle, Unet algoritması kullanılarak sistem eğitilmiş ve bu sayede gürültülerin temizlenmesi ve lezyon bölütlenmenin daha yüksek başarı oranında gerçekleştiği görülmüştür./ In the study, with the original masks created, the system was trained using the Unet algorithm, and thus it was observed that the cleaning of the noises and the lesion segmentation was at a higher success rate.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Cilt Kanseri Görüntülerinde Kıl Temizliği ve Lezyon Bölütlemesinde Yeni Bir Yaklaşım

Araştırma Makalesi / Research Article

Cihan AKYEL^{1*}, Nursal ARICI²

¹Bilişim Sistemleri Enstitüsü, Yönetim Bilişim Sistemleri Bölümü, Gazi Üniversitesi, Türkiye

²Teknoloji Fakültesi, Bilgisayar Müh. Bölümü, Gazi Üniversitesi, Türkiye

(Geliş/Received : 11.11.2019 ; Kabul/Accepted : 22.01.2020)

ÖZ

Dünya Sağlık Örgütüne göre kanser 9.8 milyon ile dünyadaki ikinci en yüksek ölüm nedenidir. Kanser türleri arasında en sık rastlanılandan biri ise cilt kanseridir. Cilt kanserinde de, diğer kanser türlerinde olduğu gibi erken tanı tedavi sürecinde hayati öneme sahiptir. Günümüzde cilt kanseri tanısında geleneksel yöntemlerin yanı sıra bilgisayar teknolojisi temelli Görüntü İşleme, Yapay Zekâ, Derin Öğrenme, Yapay Sinir Ağları gibi yöntemler sıklıkla kullanılmaktadır. Bu yöntemlerin en önemli avantajı, tanı sürecinde insan kaynaklı hataları barındırmamasıdır. Diğer yandan, en büyük sorunlardan birisi ise lezyondaki kıl temizliği ve lezyon bölütlemesinin doğru yapılamaması nedeniyle kanser tanısında yanlışlıklara yol açılmasıdır. Bu çalışma, cilt kanseri lezyonlarının kıl görüntülerinden temizlenmesi ve lezyon bölütlemesinde UNET tabanlı yeni bir yaklaşım sunmaktadır. Çalışma kapsamında International Skin Imaging Collaboration (ISIC)'e ait iki adet veri seti kullanılmıştır. Çalışma sonucunda kıl temizliğinde yaklaşık %92, lezyon bölütlemesinde yaklaşık %94 başarı oranı elde edilmiştir.

Anahtar Kelimeler: Derin öğrenme, kıl temizleme, cilt kanseri, unet.

A New Approach to Hair Noise Cleansing and Lesion Segmentation in Images of Skin Cancer

ABSTRACT

According to the World Health Organization, cancer is the second highest cause of death in the world with 9.8 million. One of the most common types of cancer is skin cancer. In skin cancer, as in other types of cancer, early diagnosis is vital in the treatment process. Today, in the diagnosis of skin cancer, besides traditional methods, computer technology based methods such as Image Processing, Artificial Intelligence, Deep Learning, Artificial Neural Networks are frequently used. The most important advantage of these methods is that they do not contain human errors during the diagnosis process. On the other hand, one of the biggest problems is the inaccuracy in the diagnosis of cancer due to the fact that the hair cleansing and lesion segmentation cannot be performed correctly. This study presents a new UNET-based approach to clearing skin cancer lesions from hair noises and lesion segmentation. Two data sets of International Skin Imaging Collaboration (ISIC) were used in the study. As a result of the study, a success rate of 92% in hair removal and approximately 94% in lesion segmentation was achieved.

Keywords: Deep learning, hair removal, skin cancer, unet.

1. GİRİŞ (INTRODUCTION)

Kanser farklı organlardaki hücrelerin, kontrolsüz çoğalmasından oluşan bir hastalık olarak tanımlanmaktadır [1]. Kanser dünyadaki en yüksek ikinci ölüm sebebidir. 2018 yılında tahmini 9.8 milyon insan kanser nedeniyle hayatını kaybetmiştir [2].

Dünya'da en yaygın görülen kanser türlerinden birisi de cilt kanseridir. Melanoma cilt kanseri ise en ölümcül olanıdır. Cilt kanseriyle ilgili ölümlerin yaklaşık %75'i melanoma kaynaklıdır [3]. American Cancer Society'e göre 2019 yılında yaklaşık 96.480 yeni melanoma cilt kanseri vakası görülecek ve 7230 insan bu nedenle hayatını kaybedecektir. Cilt kanseri tedavisinde erken tanı çok önemlidir. Tanı erken konulup tedaviye başlanırsa, beş yıllık süreçte hayatta kalma oranı %92 olmaktadır [4]. Melanoma türü cilt kanserleri metastaz yaparak diğer dokulara yayılma eğilimindedirler.

*Sorumlu Yazar (Corresponding Author)
e-posta : cihan.akyel1@gazi.edu.tr

İnvazyon derinliği 2mm'den fazla melanoma tümörlerde metastaz olasılığı yüksektir. Bu sebepten bu durumlarda ölüm oranı artmaktadır [5].

Günümüzde cilt kanseri tanısında gözle muayene, dermaskopi ve cerrahi tabanlı geleneksel yöntemlerin yanında görüntü işleme ve derin öğrenme algoritmaları sıklıkla kullanılmaktadır. Özellikle görüntülerdeki görüntülerin temizlenmesinde görüntü işleme ve yapay sinir ağları gibi yöntemler kullanılmaktadır [6, 7]. Derin Öğrenme ve Görüntü İşleme algoritmaları geleneksel yöntemlere kıyasla, insan faktörünü bertaraf ettiği için daha güvenilir sonuçlar verebilmektedirler. Bu algoritmalarla, bir uzman kadar başarılı sonuçlar alınabilmekte ve insan hatası ortadan kaldırılabilir. 1997 yılında ABD'de bir grup araştırmacı tarafından bu duruma vurgu yapan bir araştırma yapılmıştır. Çalışmada cilt kanseri görüntülerini ve diğer pigmentli kanser lezyonlarını bölütlemek için bir görüntü işleme algoritması

geliştirilmiştir. 20 adet görüntü test edilmiş ve bölütleme (segmentasyon) sonuçlarının uzmanların elde ettiğiyle aynı olduğu görülmüştür [8].

Derin Öğrenme ve Görüntü İşleme ile cilt kanseri türünü tespit etmede, lezyonun kıl gibi gürültülerden temizlenmiş olması ve lezyonun doğru bölütlenmesi önemlidir. Kıl temizleme doğru yapılmadığında lezyonun doğru bölütlenmesi ve sınıflandırılmasında başarı oranı düşecektir. Literatürde incelendiğinde, kıl temizliği sorununa çözüm sunan ilk çalışmalardan biri 1997 yılında Lee ve arkadaşlarının kıl gürültüsünün temizliği için geliştirdiği, DullRazor algoritması olarak görülmektedir. Bu algoritma thresholding (eşikleme) ve morfolojik işlemler ile lezyonda kıl temizliği yapmaktadır. Dullrazor algoritması hızlı ve basit olmasından dolayı bu alandaki bilimsel çalışmalara katkı sağlamaya devam etmektedir [9].

Cilt kanserinin Derin Öğrenme ve Görüntü İşleme ile tanısında kıl temizliğinden sonra bir diğer önemli aşama lezyonun doğru bölütlenmesidir. Burada esas sorun optimal eşiklemede, her lezyon için geçerli bir eşikleme işleminin mümkün olmamasıdır. Eşikleme doğru olmadığında lezyonun alanlarının doğru belirlenip bölütlenmesi mümkün olmamaktadır. Bu konuda, Celebi ve arkadaşları lezyonun kenarlarını tespit etmek ve doğru bölütleme için denetimsiz hızlı ve başarılı bir algoritma sunmuşlardır [10].

Faisal ve arkadaşlarının çalışmasında YUV renk uzayı kullanılarak kıl temizliği ve bölütleme için yeni bir yaklaşım sunulmuştur. Bu çalışma eşikleme ve morfolojik işlemler ile YUV renk uzayı üzerine temellenmektedir. 235 görüntü kullanılan çalışmada %98'lik başarı sağlanmıştır. Görüntü sayısının az olması başarı oranı hakkında soru işaretleri oluşturmaktadır [3].

Literatür incelendiğinde kıl temizleme ve bölütleme çalışmalarında sadece görüntü işleme algoritmalarının yeterli olmadığı görülmektedir. Alom ve arkadaşları tarafından yapılan çalışmada bu durum görülmektedir. Çalışmada vnet tabanlı derin öğrenme ile bölütleme yapılmıştır. Bu çalışmada 0.8949 dice başarı değeri elde edilmiştir [11].

Bu çalışmada; mevcut yöntemlerin avantajları ve dezavantajları irdelenerek, kıl temizleme ve lezyon bölütlemesi için UNET ve görüntü işleme algoritmalarını temel alan yeni bir yaklaşım sunulmuştur. Derin öğrenme ile elde edilen maskeler, görüntü işleme algoritmaları ile optimize edilerek lezyon maskelerinin daha doğru tahmin edilmesi amaçlanmıştır. Çalışma International Skin Imaging Collaboration (ISIC) 2018 veri setlerinde gerçekleştirilmiş olup, sonuçta, lezyon kıl temizliğinde %92, lezyon bölütlenmesinde %94'lük başarı elde edilmiştir [12].

Çalışmamızın bundan sonraki bölümleri şu şekilde ilerlemektedir. İkinci bölümde; Cilt kanseri ve türleri hakkında literatür bilgisine yer verilmekte, Üçüncü bölümde çalışma kapsamında kullanılan Materyal ve Yöntem, Dördüncü bölümde elde edilen bulgular ve beşinci bölümde sonuç ve tartışma yer almaktadır.

2. CİLT KANSERİ (SKIN CANCER)

Kanser çağımızın en ölümcül hastalıklarından biridir. Günümüzde kanser türleri arasında en yaygın olanlardan biri de cilt kanseridir [2].

2.1. Cilt Kanseri Türleri (Types of Skin Cancer)

Melanoma cilt kanserleri arasında en az görüleni olmakla birlikte en ölümcül olanıdır. Cilt kanseri üç sınıfa ayrılmaktadır [8].

2.3.1. Melanoma Dışı Cilt Kanseri (Non-Melanoma Skin Cancer)

Melanoma dışı kanserler genel olarak yayılma ve metastaz eğilimi göstermemektedirler. En sık görülen iki türü Bazal Hücreli Karsinom ve Skuamöz Hücreli Karsinom'dur [5].

2.3.1.1. Bazal Hücreli Karsinom (Basal Cell Carcinoma (BCC))

BCC yavaş ilerleyen ve çok yaygın görülen bir cilt kanseri türüdür. Yayılma eğilimi göstermezler. Genelde epiderminin altında görülmekle birlikte nadiren daha derinde kemiğe yakın yerlerde ortaya çıkabilmektedirler. Şekil 1'de BCC cilt kanserine ait örnek görüntüler yer almaktadır [8].




Şekil 1. BCC cilt kanseri örneği (BCC skin cancer example) [8]

2.3.1.2. Skuamöz Hücreli Karsinom

(Squamous Cell Carcinoma (SCC))

Lezyon pullu ve çıkıntılı bir yapıya sahiptir. SCC türü cilt kanserleri BCC'ye göre çok daha agresif şekilde yayılma eğilimindedirler. Lezyonlar üzerinde kanama görülebilir. SCC kanser türü yavaş gelişmesine rağmen tedavi edilmezse diğer dokulara yayılabilir [8].



Şekil 2. SCC ve melanoma cilt kanseri örneği (SCC and melanoma skin cancer example) [8]

2.3.2. Melanoma Cilt Kanseri (Melanoma Skin Cancer)

Melanoma, cilt kanserleri içinde en az görülen fakat en tehlikeli olanıdır. Tüm cilt kanserlerinin yaklaşık %5'ini oluştururlar [13]. Melanoma cilt kanserinin tedavisinde diğer kanser türlerinde olduğu gibi erken tanı çok önemlidir. Ülkemizde bu konuda atılan adımlara rağmen melanoma cilt kanserinde mortalite'nin yani cilt kanserine bağlı genel populasyon içindeki ölüm sayısını oranının arttığı görülmektedir [14].

Melanoma cilt kanserleri kan ve lenfatik sistemle diğer dokulara yayılabilirler. Bu sebeple melanoma cilt kanserinin erken teşhisi çok önemlidir. Şekil 2'de SCC ve melanoma cilt kanseri örneği görülmektedir. Melanoma SCC ve BCC'ye kıyasla çok hızlı yayılan bir cilt kanseri türüdür ve tedavi edilmezse ölümcül olabilir [15].

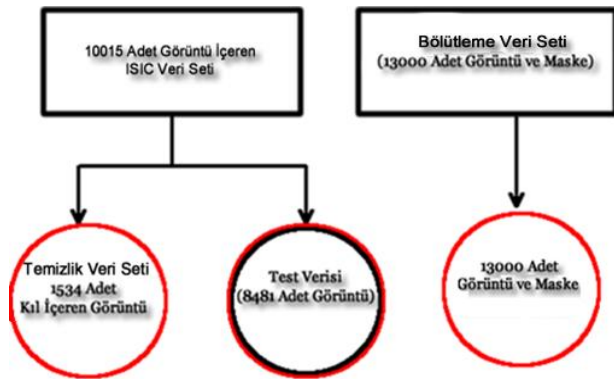
3. MATERYAL VE YÖNTEM (MATERIAL AND METHOD)

3.1. Materyal (Material)

Bu çalışmada ISIC challenge 2018'dan alınan iki adet ISIC veri seti kullanılmıştır [14]. Birinci veri setinde jpeg formatında lezyonları ve sınıflarını içeren 10015 adet RGB görüntü yer almaktadır. Bu veri setinden, kılı içeren 1534 tanesi rastgele seçilmiş ve kıl temizliği aşamasında kullanılmıştır. 1534 veri içeren bu veri grubu bundan sonra "Temizlik Veri Seti" olarak anılacaktır [16].

Lezyon bölütlemesi için ISIC challenge 2018'e ait 13000 adet png formatında RGB görüntü ve maske verisinden oluşan ikinci ISIC veri seti kullanılmıştır. Bu veri seti bundan sonra "Bölütleme Veri Seti" olarak anılacaktır [14].

Her iki aşamada da, öğrenme başarısını artırmak ve sistemin overfitting (ezberleme)'e düşmesini engellemek için veri setleri üzerinde 90 ve 180 derece döndürme ve yatay çevirme işlemleriyle veri artırma uygulanmıştır. Veri artırma ile veri sayısı, Temizlik Veri Seti'nde 4602'e, Bölütleme Veri Seti'nde ise 39000'e çıkarılmıştır. Şekil 3'te kullanılan veri setleri görülmektedir.



Şekil 3. Temizlik ve bölütleme veri setleri (Cleaning and segmentation data sets)

Çalışma kapsamında geliştirilen algoritma python dili kullanılarak, spyder yazılımı ile kodlanmıştır. Görüntü işleme aşamalarında fonksiyonların kolay kullanımından dolayı Matlab yazılımından faydalanılmıştır.

3.2. Yöntem (Method)

Bu çalışma; Kıl Temizleme ve Lezyon Bölütlemesi olmak üzere iki aşamadan oluşmaktadır. Her iki aşamada da veriler %80'i eğitim ve %20'si test kümesi olacak şekilde ayrılmıştır. Bu oranlar derin öğrenme çalışmalarında kullanılan kabul edilebilir değerlerdir. Bizim çalışmamızda sistem eğitim aşamasında bu oranlar ile eğitilmiş ve ezberleme durumu görülmemiştir. Bu sebeple eğitim ve test verisi için verilen oranlar kullanılmıştır.


3.2.1. Birinci Aşama: Kıl Temizleme Aşaması

(First Stage: Hair Removal Stage)

Bu aşamada; Temizlik Veri Seti'ndeki görüntülere ait kıl maskeleri oluşturulmuş ve sistem bu görüntü ve maskelerle eğitilmiştir. Kıl Temizleme Algoritması takip eden adımları içermektedir.

Adım 1: Temizlik Veri Seti gri seviyeli görüntülere çevrilmiştir. Görüntüler 128*128 şeklinde yeniden boyutlandırılmıştır.

Adım 2: Bu adımda adaptive threshold ile görüntüye ait kıl maskesi şekil 4'te görüldüğü gibi genel hatlarıyla çıkarılmıştır.



Şekil 4. Adaptive threshold işlemi (Adaptive threshold process)

Adım 3: Bu adımda medianfilter ile küçük kabarcık ve ince kıllar görüntüden temizlenmiştir. Daha sonra morfolojik işlemler (opening, closing) kıl maskesinin iç ve dışında kalan gürültülerin temizlenmesi için uygulanmıştır.



Şekil 5. Median filtresi ve morfolojik işlemler (Median filter and morphological processes)


Adım 4: İlk üç adımda ortaya çıkan kıl maskeleri lezyondaki kıl gürültüsü incelenerek, adobefireworks

programı kullanılarak düzeltilmiştir. Şekil 6'da bu adım özetlenmektedir.



Şekil 6. Fireworks ile maske düzeltme (Mask correction with fireworks)


Adım 5: Bu adımda görüntüler ve oluşturulan kıl maskeleri 16'lık dilimlere ayrılmış ve 128*128 şeklinde yeniden boyutlandırılmıştır. Görüntüler, eğitime girecek verideki ayrıntı düzeyini artırmak için 16'lık dilimlere ayrılmış ve bu sayede başarı oranının %80'den %92'e yükseldiği görülmüştür. Şekil 7'de 16'lık dilimlere ayrılmış görüntü ve maske görülmektedir.



Şekil 7. Dilimli görüntü ve kıl maskesi (Sliced image and hair mask)

Adım 6: Bu adımda 1534 görüntü ve oluşturulan 1534 kıl maskesi, veri artırma ile 4602'şer adete çıkarılmıştır. Veri artırma 90 ve 180 derece açılı döndürme ve yatay çevirme kullanılarak yapılmış ve görüntüler kaydedilmiştir.

Adım 7: Unet algoritması ile 4602 adet görüntü girdi, 4602 kıl maskesi çıktı olarak alınmış ve sistem 1500 epoch eğitilmiştir. Şekil 8'de Unet algoritmasının genel görünümü görülmektedir.



Şekil 8. Unet mimarisi (Unet architecture) [17]


Aktivasyon fonksiyonu relu, optimizör ise adadelta olarak belirlenmiştir. Çıkış fonksiyonu olarak sigmoid kullanılmıştır. VGG16 Imagenet ağırlıkları kullanılmıştır. Kernel boyutu 3*3 olarak belirlenmiştir. Unet için dice_coef ve mean_squared_error_dice_loss kullanılmıştır. Kullanılan parametreler ve elde edilen başarı sonuçları Çizelge 1'de görülmektedir.

Çizelge 1. Unet için kullanılan parametreler (Parameters used for unet)

Parametre	Değer
Batch size (Parti Boyutu)	5
Subdivisions (Alt Bölümler)	16
Learning rate (Öğrenme Katsayısı)	0.1
Epoch sayısı	1500
Boyut	128x128x16
Optimizör (En İyi Yönlendirici)	Adadelta
Training Accuracy (Eğitim Başarısı)	%88.580
Training Loss (Eğitim Kaybı)	%12.765
Validation Accuracy (Doğrulama Başarısı)	%91.680
Validation Loss (Doğrulama Kaybı)	%11.56

1500 epoch'tan sonra doğrulama kaybı değerinde kayda değer bir düşüş görülmediği için eğitim sonlandırılmıştır.

Adım 8: Test verisi üzerinde oluşturulan modelin denenmesi. Şekil 9'da test verisi kullanılarak tahmin edilen örnek maske ve temizlenmiş görüntüler görülmektedir. Maskeleme işleminde maskeler bitmap formatında kaydedilmiştir. Görüntüdeki kıl gürültüsü, tahmin edilen maske ve inpaint fonksiyonu temizlenmiştir.



Şekil 9. Test verisi sonuçları (Results of test data)

3.2.2. İkinci Aşama: Lezyon Bölütlemesi (Stage Two: Lesion Segmentation)


Bu aşamada 13000 adet görüntü ve maskelerinden oluşan Bölütleme Veri Seti kullanılarak, sistem Unet algoritması ile eğitilmiştir. Eğitim sonucunda yaklaşık %94'lük eğitim başarı oranı elde edilmiştir. Veri seti içerisindeki kıl, bant ve kabarcık gibi gürültüler de yer almaktadır. Bu veriler eğitimin farklı ve gürültü içeren görüntüleri de içermesi amacıyla, veri setinden çıkarılmamışlardır.

Görüntü ve maske verileri 16'lık dilimlere ayrılmıştır. Bu yöntemle eğitime alınacak görüntü verilerindeki ayrıntı düzeyi artırılarak başarı oranları yükseltilmiştir.

Giriş bölümünde belirtildiği gibi sadece görüntü işleme algoritmaları ile yapılan lezyon bölütlemesi, lezyonun doğru bölütlenmesinde yeterli olmamaktadır. Bu çalışmada lezyon bölütlemesi derin öğrenme ile yapılmış sonuçlar görüntü işleme algoritmaları ile optimize edilmiştir. Lezyon Bölütleme Algoritması aşağıdaki adımları içermektedir.

Adım 1: Görüntü ve maskeler Şekil 10'daki gibi 16'lık dilimlere ayrılmıştır.

Adım 2: Bu adımda görüntü ve maskeler 128*128 şeklinde yeniden boyutlandırılmıştır. 3000 epoch çalıştırılmıştır.

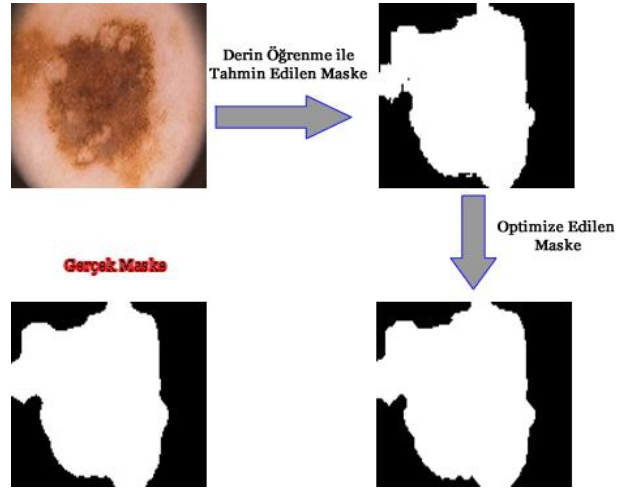


Şekil 10. Dilimli görüntü ve bölütleme maskesi (Sliced image and segmentation mask)

Adım 3: Sistem Çizelge 2'de görülen parametrelerle 3000 epoch koşturulmuştur. 3000 epoch'tan sonra doğrulama kaybı değerinde kayda değer bir düşüş görülmediği için eğitim sonlandırılmıştır.


Çizelge 2. İkinci aşama başarı sonuçları (Results of second stage)

Adım 4. Bölütleme sonuçlarının Morfolojik işlemler (medianfilter, opening, closing, dilate) ile gürültülerden temizlenmesi: Bu aşamada tahmin edilen maske, görüntü işleme ile optimize edilmiştir. Matlab yazılımı kullanılarak önce medianfilter ile maske üzerinde gürültü temizliği yapılmıştır. Daha sonra morfolojik işlemlerden opening (açma) ve closing (kapama), imopen ve imclose fonksiyonları ile uygulanarak sırasıyla bölütlemenin iç ve dışında kalan gürültüler temizlenmiştir. İmdilate fonksiyonu ile önceki işlemlerden dolayı oluşan alan küçülmeleri düzeltilmiştir. Şekil 11'de bu durum görülmektedir.



Şekil 11. Maske optimizasyonu (Mask optimization)

Adım 5. Modelin Bölütleme Veri Seti'nin Test Kümesi ile test edilmesi: Algoritmanın tüm aşamalarını içeren genel çalışma şekli şekil 12'de ifade edilmektedir.



Şekil 12. Algoritmanın genel gösterimi (General representation of the algorithm)

Parametre	Değer
Batch size (Parti Boyutu)	5
Subdivisions (Alt Bölümler)	16
Learning rate (Öğrenme Katsayısı)	0.1
Epoch sayısı	1500
Boyut	128x128x16
Optimizier(En İyileyici)	Adadelta
Training Accuracy (Eğitim Başarısı)	%92.60
Training Loss(Eğitim Kaybı)	%10.22
ValidationAccuracy (Doğrulama Başarısı)	%94.100
ValidationLoss (Doğrulama Kaybı)	%7.15

4. BULGULAR (RESULTS)


Bu çalışmada Kıl Temizliği için Unet algoritmasının belirtilen parametrelerle koşturulmasıyla yaklaşık %92'lik doğrulama başarı oranı elde edilmiştir. Algoritma 1500 epoch çalıştırılmıştır. Sonuçlar Çizelge 3'te görülmektedir.

Eğitim aşamasında algoritma 1500 epoch çalıştırılmıştır. 1500 epoch'tan sonra doğrulama kayıp oranında belirgin bir düşüş görülmediği için bu epoch sayısında eğitim sonlandırılmıştır.

Şekil 13'de gerçek maske, eğitilen model ile tahmin edilen maske ve görüntü verileri görülmektedir.

Çizelge 3. Algoritma Sonuçları (Results of Algorithm)


	Kıl Temizliği		Bölütleme	
Veri Seti	4602		39000	
Başarı Oranı(%)	Val_Acc	Val_Loss	Val_Acc	Val_Loss
	91.68	11.56	94.10	7.15



Şekil 13. Kıl temizleme test sonuçları (Hair removal test results)

Bölütleme aşamasında, belirtilen parametrelerle sistem 3000 epoch çalıştırılmıştır. Bölütleme sonuçları lezyon bölütleme başlığında belirtildiği gibi görüntü işleme algoritması ile görüntülerden temizlenmiştir.

Şekil 14'de gerçek maske, algoritma modeliyle tahmin edilen maske ve görüntü verileri sunulmaktadır.



Şekil 14. Bölütleme test sonuçları (Segmentation test results)

5. SONUÇ VE TARTIŞMA (CONCLUSION AND DISCUSSION)

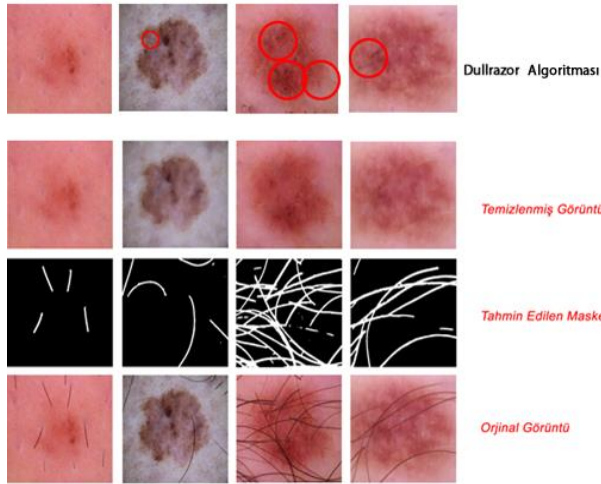
Literatür araştırmasında kıl temizliğinde, birçok çalışmada eşikleme ve görüntü işleme algoritmalarının kullanıldığı görülmüştür. Bu çalışmalarda karşılaşılan genel sorun kılmaskesinin doğru şekilde tahmin edilememesi ve kıl temizliği sonucunda veri kaybının oluşmasıdır. Bu duruma örnek oluşturan bir durum Kassam'ın çalışmasında görülmektedir.

Bu çalışmada Dullrazor algoritmasının kıl temizliğinde yetersiz kaldığı şekil 15'te görülmektedir.




Şekil 15. Dullrazor algoritması (Dullrazor algoritim) [8]

Bizim çalışmamızda kıl maskelerinin görüntü işleme ile çıkarılması yerine; oluşturulan orjinal maskelerle, Unet algoritması kullanılarak sistem eğitilmiş ve DullRazor algoritmasına göre daha başarılı sonuçlar elde edilmiştir. Maskenin daha doğru tahmin edilmesiyle birlikte görüntü üzerindeki veri kaybı en aza indirgenmiştir. Şekil 16'da çalışmadaki bazı sonuçlar görülmektedir.



Şekil 16. Kıl temizleme aşaması algoritma sonuçları (Hair removal stage algorithm results)

Literatürde bölütleme alanında derin öğrenme ve görüntü işleme algoritmalarını kullanan birçok çalışma mevcuttur. Bu çalışmalardan biri olan Alom ve arkadaşlarının çalışmasında gerçek ve tahmin edilen bölütleme arasındaki fark Şekil 17’de görülmektedir. Burada VN-NetAB algoritmasının daha başarılı sonuçlar elde ettiği görülmektedir. Şekil 18’de aynı verilerle algoritmamızın koşturulmasıyla elde edilen sonuçlar görülmektedir. Genel olarak VN-NetAB algoritmasına yakın sonuçlar elde edilebilmiştir.



Şekil 17. Gerçek ve tahmin edilen maske farkı örneği (Example of real and predicted mask difference) [11]

Görüntü	ISIC_0000001	ISIC_0000335	ISIC_0000312	ISIC_0000380	ISIC_0000000	ISIC_0000385
Gerçek Maske						
Tahmin Edilen Maske						
Maske Başarısı	0.8868560423688	0.94364332985022	0.9754791918494	0.9476287459	0.9664496745	0.7634028050


Şekil 20. Bölütleme aşaması algoritma sonuçları (Segmentation stage algorithm results)

ISIC_0000172				0.9570572776
ISIC_0000072				0.8749480681
ISIC_0000150				0.9291351935
ISIC_0000191				0.8445508982
Görüntü	Gerçek Maske	Tahmin Edilen Maske	Maske Başarısı	

Şekil 18. Bölütleme aşaması maske farkları (Segmentation stage mask differences)

Bizim çalışmamızda lezyon ve zemin arasındaki renk histogramı yakın olduğunda ve kıl vb. gürültü fazlalığında bölütleme sonuçlarının düştüğü görülmüştür. Test görüntülerindeki kıl gürültüsü “Kıl Temizleme Aşaması”nda eğitilen model ile temizlenerek bölütleme tahmini işlemine alınmıştır.

Şekil 19’da kıl temizliği yapılmadan model ile maske tahmini yapıldığında başarılı düştüğü görülmektedir. Şekil 20’de çalışma kapsamında yapılan bölütleme ve gerçek maske farkları görülmektedir.



Şekil 19. Kıl gürültüsünün bölütlemeye etkisi (The Effect of hair noise on segmentation)

Genel olarak, çalışma kapsamında oluşturulan algoritmanın yüksek doğruluk oranında lezyon sınırlarını tahmin ettiği görülmüştür. Çalışma kapsamında mevcut literatürden farklı olarak; lezyon bölütlemeye görüntü ve maskeler 16'lık dilimlere ayrılmış ve Unet tabanlı algoritma ile eğitilmiştir. Daha sonra elde edilen sonuçlar görüntü işleme algoritmaları ile optimize edilmiştir.

KAYNAKLAR (REFERENCES)

- [1] Baykara, O., "Kanser Tedavisinde Güncel Yaklaşımlar", *Balikesir Sağlık Bilimleri Dergisi*, 5(3): 154-165, (2016).
- [2] "Cancer", <https://www.who.int/news-room/fact-sheets/detail/cancer>, Erişim (5.11. 2019).
- [3] Faisal, Z., Abbadi, N., "New Segmentation Method for Skin Cancer Lesions", *Journal of Engineering and Applied Sciences*, 12(21): 5598-5602 (2017).
- [4] Ünver, H. M., Ayan, E., "Skin Lesion Segmentation in Dermoscopic Images with Combination of YOLO and GrabCut Algorithm", *Diagnostics*, 9(72): 1-21, (2019).
- [5] Güngör, K. H., "Metastaz Yapmamış Melanoma Ve Melanoma Dışı Deri Kanseri İçin Geliştirilmiş Olan Deri Kanseri İlişkili Yaşam Kalitesi Ölçeğinin (Dkyk) Türkçe Geçerlilik Ve Güvenilirliğinin Araştırılması", *Tıpta Uzmanlık Tezi*, Ankara Üniversitesi Tıp Fakültesi, Ankara, (2016).
- [6] Demirci, M., Yabanova, İ., "Model Tabanlı Tasarım Metotları Kullanılarak Gerçek Zamanlı Bir Görüntü İşleme Sisteminin Tasarımı ve Gerçekleşmesi", *Politeknik Dergisi*, 22(4): 827-838, (2019).
- [7]. Sağroğlu, Ş., Beşdok, E., "A Novel Approach for Image Denoising Based on Artificial Neural Networks", *Politeknik Dergisi*, 15(2): 71-86, (2012).
- [8]. Kassam, A., "Segmentation Of Skin Cancer By Using Image Processing Techniques", *Master Thesis*, Yıldız Technical University Department Of Computer Engineering, İstanbul, (2016).
- [9]. Lee, T., Ng V., Gallagher R., Coldman A., McLean D., "Dullrazor: A Software Approach to Hair Removal from Images", *Computers in biology and medicine*, 27(6):533-543, (1997).
- [10] Celebi, E.C., Aslandoğan, A.A., Stoecker WV, Iyatomi H, Oka H, Chen X., "Unsupervised Border Detection in Dermoscopy Images", *Skin Research and Technology*, 13(4): 454- 462, (2007).
- [11] Alom, M., Aspiras, T., Taha, T., Vijayan, K., "Skin Cancer Segmentation and Classification with NABLA-N and Inception Recurrent Residual Convolutional Networks", <https://arxiv.org/ftp/arxiv/papers/1904/1904.11126.pdf>, Erişim (5.11. 2019).
- [12] ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection", <https://challenge2018.isic-archive.com/>, Erişim (15.10.2019).
- [13] L'opez, A., "Skin Lesion Detection From Dermoscopic Images Using Convolutional Neural Networks", *A Degree Thesis*, Faculty of the Escola Tècnica d'Enginyeria de Telecomunicació de Barcelona Universitat Politècnica de Catalunya, Barcelona, (2017).
- [14] Sümen, A., "Denizcilik Lisesi Öğrencilerine Cilt Kanseri Konusunda Verilen Eğitimin Bilgi Ve Davranışlarına Etkisi", *Yüksek Lisans Tezi*, Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü, Antalya, (2014).
- [15] Kızılbey, K., Akdeste, Z., "Melanoma Cancer", *Journal of Engineering and Natural Sciences*, 31(4): 555-569, (2013).
- [16] "Task 3: Lesion Diagnosis: Training", <https://challenge2018.isic-archive.com/task3/training/>, Erişim (18.10. 2019).
- [17] "U-Net: Convolutional Networks for Biomedical Image Segmentation", <https://arxiv.org/pdf/1505.04597.pdf>, Erişim (18.10. 2019).