



Researches on Multidisciplinary Approaches

Multidisipliner Akademik Yaklaşım Araştırmaları 2022, 2(2): 1-10

**Yayına Geliş Tarihi / Article Arrival Date**


15.07.2022

**Yayına Kabul Tarihi / Date of Acceptance**

25.07.2022

## **Medikal Görüntüler Kullanılarak Derin Öğrenme Yöntemleriyle Cilt Kanseri Tespiti**

**Özgün Araştırma Makalesi**

**Mustafa Güler / Arş. Gör.** 

İstanbul Üniversitesi-Cerrahpaşa, Endüstri Mühendisliği Anabilim Dalı  
m.guler@iuc.edu.tr

**Ersin Namlı / Dr.Öğr.Üyesi** 

İstanbul Üniversitesi-Cerrahpaşa, Endüstri Mühendisliği Anabilim Dalı  
enamli@iuc.edu.tr

### **Özet**

Makine öğrenmesi ve derin öğrenme modellerinin gelişmesiyle birlikte son yıllarda özellikle biyomedikal görüntü işleme alanında çok başarılı sonuçlar alınmaya başlanmıştır. Bilgisayarlı tomografi (BT), Manyetik rezonans görüntüleme (MR), Mamografi, Röntgen, Ultrason gibi tıbbi görüntüleme teknikleri hastalıkların teşhis ve tedavisi için uzmanlara bir ön referans görevi görmektedir. Bununla birlikte hastalıkların daha erken teşhisi ve uzmanların yoğunluklarını azaltmak aynı zamanda teşhis ve tanı koymada yapılabilecek hataları en aza indirmek amacıyla son yıllarda sağlık alanında derin öğrenme tekniklerinden faydalanılmaktadır. Artan veri miktarı ve matematiksel modellerin gelişmesiyle birlikte derin öğrenme teknikleri çok fazla tercih edilmeye başlanmıştır. Bu çalışmada, derin öğrenme yöntemlerinin medikal görüntü işleme alanında uygulanması amaçlanmıştır. Veri kümesi olarak ele alınan cilt kanseri veri seti kullanılarak, sınıflandırma ve teşhis, görüntü oluşturma, iyileştirme ve dönüştürme işlemleri yapılmış, ön eğitilmiş dört farklı Evrişimsel sinir ağı mimarisisiyle (CNN) elde edilen sınıflandırma sonuçları incelenmiştir. Elde edilen sonuçlar ayrıca klasik makine öğrenmesi teknikleriyle sınıflandırılmıştır. Sonuç olarak CNN algoritmalarından ResNet ile yapılan sınıflandırmada %87'lik bir doğruluk oranı elde edilmiş, bununla birlikte makine öğrenmesi teknikleriyle yapılan sınıflandırmada en yüksek oranı Destek vektör makinaları (SVM) algoritması %0,848 doğruluk yüzdesiyle başarıya ulaşmıştır.

**Anahtar kelimeler:** Derin Öğrenme, Görüntü İşleme, Evrişimsel Sinir Ağları, Sınıflandırma

## **Skin Cancer Detection with Deep Learning Methods Using Medical Image**

### **Abstract**

With the development of machine learning and deep learning models, very successful results have been obtained in recent years, especially in the field of biomedical image processing. Medical imaging techniques such as computed tomography (CT), magnetic resonance imaging (MR), mammography, X-ray, and ultrasound serve as a preliminary reference for specialists for the diagnosis and treatment of diseases. However, in recent years, deep learning techniques have been used in the field of health in order to diagnose diseases earlier and to reduce the density of specialists, as well as to minimize the mistakes that can be made in diagnosis and diagnosis. With the increasing amount of data and the development of mathematical models, deep learning techniques have started to be preferred a lot. In this study, the application of deep learning methods in the field of medical image processing is examined. The skin cancer dataset, which is considered as a dataset, classification and disease diagnosis, image creation, improvement and transformation processes are examined, and the classification results obtained with four different pre-trained Convolutional neural network architectures (CNN) are examined. The results obtained are also classified by classical machine learning techniques. As a result, an accuracy rate of 87% was obtained in the classification made with ResNet, one of the CNN algorithms, and the Support vector machines (SVM) algorithm, which had the highest rate in the classification made with machine learning techniques, achieved success with an accuracy rate of 0.848%.

**Keywords:** Deep Learning, Image Processing, Convolutional Neural Network, Classification

## Giriş

Yapay zekâ, insan zekasına benzemeye çalışan, topladığı bilgilerle insanlığa yaratıcı çözümler sunabilen son derece akıllı programlar ve makinelerden oluşan bir teknolojidir. Yapay zekanın temel amacı insanlarda gözlemlenen akıllı davranışları bilgisayarlara ve makinalara uyarlamaktır. Son yıllarda savunma sanayide, ekonomide, sosyal yaşam ve özellikle sağlık sektöründe yapay zekâ teknolojileri sıklıkla kullanılmaya başlanmış ve günümüzde hayatımızın önemli bir parçası olmuştur.

Yapay zekanın bir alt kümesi olarak karşımıza çıkan Makine öğrenmesi, kendi kendine öğrenebilen modeller üzerinden tahmin yürütebilen akıllı algoritmaların mimarilerini oluşturan bir sistemdir. Makine öğrenmesi, içerisinde birçok farklı tipte ve alanda problemi çözmeye yardımcı farklı algoritmalar bulundurmaktadır. Bununla birlikte makine öğrenmesinin bir alanı olarak karşımıza çıkan Derin öğrenme ve Görüntü işleme konusunda literatürde yapılmış birçok çalışma ve tez bulunmaktadır. Yapılan bu çalışmalar öncelikle görüntülerden çıkarım, sınıflandırma ve nesne bulma üzerine yoğunlaşmıştır. Görüntüden doğru bir şekilde çıkarım yapılabilmesi için görüntünün doğru bir şekilde değerlendirilebilmesi gerekmektedir. Bu nedenle görüntü işleme ve doğru yorumlama yapabilmek için uzman yorumu şiddetle önemlidir. (Mathew vd, 2020).

Son yıllarda adından başarıyla söz ettiren yapay zekânın gelişimi bugün tıp alanında teşhis ve tedavi süreçlerinde başarıyla uygulanmaya devam ettiği bilinmektedir. Bu başarının en önemli sebebi yapay zekâ teknolojilerinin bir alt sınıfında bulunan ve beslendiği yer olan veri madenciliği ve onun bir kolu olan makine öğrenmesi algoritmalarının görüntüler arasında ki görünmeyen ilişkileri ortaya çıkartabilme yeteneğinden kaynaklanmaktadır. Bu sayede belirsizliklerin olduğu süreçlerde kısa sürede doğru sonuca ulaşmada etkin bir şekilde kullanılmaktadır. Özellikle insan sağlığının söz konusu olduğu alanlarda bu teknolojilerin kullanılması hem uzmanlara hem de hastalara birçok fayda sağlamaktadır. Biyomedikal görüntü işlemede özellikle çok yakın ve benzer verilerin iç içe olması sebebiyle teşhis ve tedavi noktasında belirsizlerin ayırt edilebilmesi hayati bir önem taşımaktadır.

Hastanelerde biyomedikal görüntülerin işlenmesi ve bunların yapay zekâ teknolojileri kullanılarak yorumlanması ve başarılı sonuçlar elde edilmesinde verilerin etkin ve bilinçli şekilde kullanılabilmesi çok önemlidir. Son iki yılda yaşanan koronavirüs (Covid-19) salgını gibi X-ray ve Bilgisayarlı tomografi görüntülerinin sık kullanıldığı hastalıklarda uzmanlara düşen sorumluluklar artmış, bununla birlikte radyolojik görüntülerin incelenmesi fazlasıyla zaman gerektiren bir hal almıştır. Bu durum sadece salgın hastalıklar için değil, X-ray görüntülerinin ya da bilgisayarlı tomografi gerektiren beyin tümörleri, akciğer enfeksiyonları, meme kanseri, cilt kanseri gibi birçok hastalıkta benzer durumlar doğurmuştur. Radyoloji alanı görsel dikkatin çok fazla olduğu bununla birlikte görüntüler üzerinden karar vermeyi gerektiren bir uzmanlık alanı olduğundan dolayı, yoğun çalışma ve iş yükü altında uzmanlar çoğu zaman hata yapmaktan kaçınamamaktadırlar.

Bu çalışmada derin öğrenme teknikleri kullanılarak cilt kanserine ait veri setleri için sınıflandırma ve teşhis uygulaması gerçekleştirilmiştir. Önerilen yöntemde Evrişimsel sinir ağları (CNN) mimarilerinden faydalanılarak, özellik çıkartma, birleştirme ve sınıflandırma işlemleri yapılmış ve hastalığın teşhisi yüksek hassasiyet içeren algoritmalarla tespit edilmeye çalışılmıştır. Ayrıca çalışmaya ait doğruluk kriterleri, parametre değerleri ve metrikler hesaplanarak benzer çalışmalarla karşılaştırılmıştır.

## Kavramsal Çerçeve

Yapay zekâ ile ilgili yapılan çalışmalar incelendiğinde son yıllarda tıp ve biyomedikal alanında yapılan çalışmaların hızla arttığı görülmektedir. Bunun en büyük sebebi bu alanda yeterli miktarda veri bulunmasıyla açıklanmaktadır. Beyin tümörü tespiti, meme kanseri, akciğer tümörü ve kanseri, böbrek tümörleri gibi hastalıklarla ilgili literatürde çok fazla çalışma yapılmıştır. Fakat bazı çalışmalarda makine öğrenmesi ve derin öğrenme yöntemlerinin bazı problemlerin çözümünde yetersiz kaldığı görülmektedir. Bunun en büyük sebebi verinin yeterli miktarda ve doğru şekilde işlenememesi ve kullanılamamasıdır.

Cilt kanseri tanısı ile ilgili literatürde çok fazla çalışma bulunmamasına rağmen yapılan çalışmalarda genellikle klasik makine öğrenmesi tekniklerinden faydalanılmıştır.

ISIC veri kütüphanesinden alınan 2150 adet veri setiyle yapılan çalışmada dermoskopi görüntüsünü eşikleme yöntemi kullanılarak segmentasyon işlemi yapılmıştır. Burada cilt kanserinin tespiti için boyut küçültme işlemi yapılmış ve en sonunda sınıflandırma işlemi için destek vektör makinaları algoritmasından faydalanılmış ve %84'lük bir başarı yüzdesi elde edilmiştir (Filali vd, 2018). ISIC kütüphanesinde gerçekleştirilen çalışmada alınan 3920 dermoskopi görüntüsü kullanılmıştır. Yüksek doğruluğa sahip modeller kullanılarak yapılan çalışmada AlexNet, VGGNet, ResNet gibi CNN temsilcileri klasik makine öğrenmesi yöntemleri ile karşılaştırılmıştır (ISDIS, 2017). Benzer bir çalışmada, mikroskopik görüntülerden oluşan pigmentli cilt lezyonlarını tespit etmek amacıyla olasılıksal sinir ağı sınıflandırma metodu kullanılmıştır. Sonuç olarak yüksek başarı sağlanmış ve araştırmacılar tarafından daha fazla geliştirilebileceği vurgulanmıştır (Kostopoulos vd, 2017). Bir diğer çalışmada avuç içlerindeki ve ayaklardaki renk pigmentasyonundan faydalanılarak çizgili ve düz olduğunun ayrılabilmesi için otomatik bir algoritma sunulmuş ve %99 oranında bir başarı yüzdesi elde edilmiştir (Yang vd, 2017).

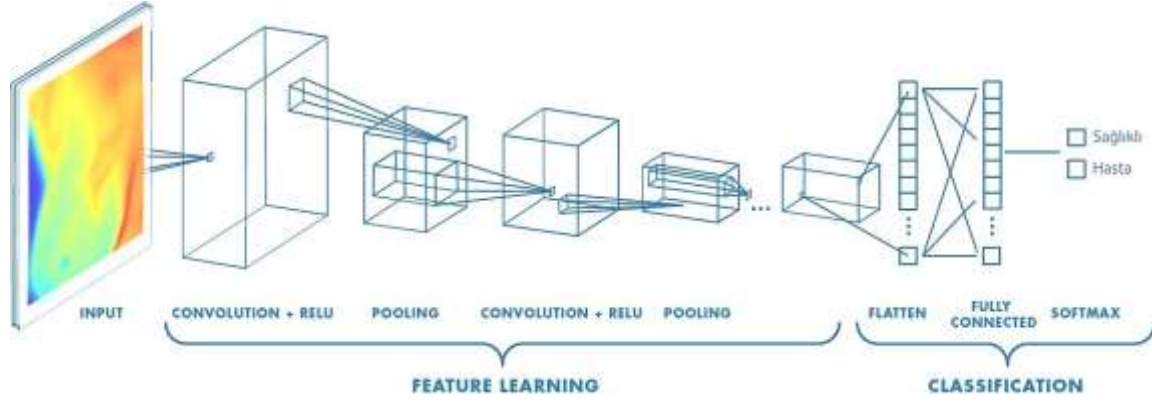
Monika ve arkadaşlarının yaptıkları çalışmada, 800 adet dermoskopi görüntüsüne hem segmentasyon işlemi uygulanmış aynı zamanda K-means algoritması kullanılarak cilt lezyonlarını sınıflandırma işlemi uygulanmıştır. Burada sonuç olarak %96,2'lik bir başarıya ulaşılmıştır (Monika vd, 2020). Yine cilt lezyonlarında bulunan doku, renk ve asimetrik özelliklerin çıkartılarak Naive Bayes algoritmasının uygulandığı bir çalışmada toplamda 2150 adet görüntü sınıflandırılmış ve %91,8'lik bir başarı yüzdesine ulaşılmıştır (Balaji vd, 2020).

Klasik makine öğrenmesi yöntemlerinden Destek vektör makinesi yöntemi kullanılarak yapılan çalışmada mikroskopik görüntüler kullanılarak pigmentli cilt lezyonlarını tespit etmek amacıyla bir çalışma yapılmıştır. Burada %74'lük bir başarı elde edilmiştir (Oliveira vd, 2016). Benzer bir çalışmada 200 adet dermoskopi görüntüsü renk ve doku özelliklerine göre ayrılarak sınıflandırılmıştır. Çıkarılan özellik kümesi destek vektör makinesi algoritması ile sınıflandırılmış ve %96'lık bir doğruluğa ulaşılmıştır (Waheed vd, 2017). ISIC kütüphanesinden alınan 1635 dermoskopi görüntüsü renk özellikleriyle birlikte ölçekle değiştirilemeyen özellikleri çıkartılmıştır. Burada sınıflandırma algoritması olarak rastgele orman algoritması kullanılmıştır (İsmail vd, 2020).

CNN mimarisi ve algoritmaları kullanılarak literatürde çok fazla segmentasyon ve tümör tespiti çalışması yapılmıştır. Cilt kanseri ve lezyon tespiti çalışmalarının başarı oranları yüksek olmasına rağmen yeterli miktarda verinin bulunmaması sebebiyle çok fazla çalışılmış bir medikal görüntü veri seti ve hastalık değildir. Burada kullanılan algoritmalar geliştirilmeye son derece açıktır.

## Yöntem

Görüntü işleme ve derin öğrenme problemlerinde en sık kullanılan ağ mimarisi CNN olmakla birlikte özellik ve kullanım alanı olarak birçok farklı algoritma bulunmaktadır. CNN algoritmaları ileri beslemeli bir yapay sinir ağı olduğu için özellikle iki boyutlu verilerin işlenmesinde oldukça başarılı sonuçlar vermektedir. Aşağıda Şekil-1'de CNN mimarilerinin genel yapısı basitçe ifade edilmektedir.



Şekil 1: CNN Mimarisi (medium.com)

CNN mimarileri temel olarak 3 katmandan oluşmaktadır. Bunlar Evrişimli katman (Convolutional Layer), Havuzlanma katmanı (Pooling Layer) ve Tam bağlantılı katman (Fully Connected Layer). CNN mimarisinin en büyük özelliklerinden biri görüntüleri ham girdi olarak ağ yapısına doğrudan aktarabilmeleridir. Bu sayede diğer standart algoritmalar gibi özellik elde etme prosedürlerine gerek kalmamaktadır. Özellikle son yıllarda CPU ve GPU'ların hızla gelişmesiyle birlikte CNN'ler daha aktif ve başarılı şekilde kullanılmaktadır (Goodfellow vd, 2016).

Derin öğrenme yöntemleri CNN mimarisi başta olmak üzere içerisinde birbirine benzer özellikte ve ağ yapısında birçok algoritma barındırmaktadır. Literatürde görüntü işleme problemleri incelendiğinde VGG, ResNet, DenseNet, SqueezeNet, Imagenet, U-Net gibi birçok farklı algoritma kullanılmış olduğu görülmekte ve uygulanan veri setine bağlı olarak yüksek başarı yüzdelere ulaşıldığı anlaşılmaktadır.

2015 yılında ILSVRC yarışmasını kazanan ResNet mimarisi, mikro modül mimari yapısıyla diğer yapılardan ayrılmakla birlikte bazı katmanlar arası geçişleri göz ardı etmekte ve alt katmanlara hızlı geçişler yapabilmektedir. ResNet mimarisini klasik modellerden ayıran en büyük özelliği doğrusal olması ve RELU katmanları arasındaki kalıntı değerlerinin sonraki katmanlara geçişlerinin daha hızlı bir şekilde gerçekleşmesidir (Brezdan vd, 2019).

Görüntü özelliklerinin daha etkin bir şekilde kullanılması amacıyla geliştirilen bir algoritma olan DenseNet, ağında sahip olduğu özellik yapısıyla her katmanı diğer katmanlara doğru ileri bir şekilde bağlamaktadır. Bu ağ yapısı kendinden önce gelen tüm katmanların özelliklerini girdi olarak kullanmakta ve kendinden sonra gelen tüm katmanlara da bu özelliklerle doğrudan aktarım yapabilmektedir. DenseNet algoritması bu yüzden özellik yayılımını sağlamak amacıyla parametre sayısını azaltmaktadır (Kumar vd, 2019).

Bir başka derin öğrenme algoritması olan ve AlexNet ile benzer özellikler gösteren VGG mimarisi ILSVRC-2014 yarışmasında ortaya çıkan, 13 evrişimsel ve 3 tam bağlı katmandan oluşan bir ağdır. Toplamda 41 katman bulunduran bu mimari, girdi katmanında yer alacak görüntü 224x224x3 boyutunda olmakla birlikte son katman yine sınıflandırma katmanıdır (Chen vd, 2016).

Çalışmada sonra olarak kullanılan SqueezeNet mimarisi, AlexNet ve diğer mimarilere kıyasla çok daha az parametre kullanması ve benzer oranlarda doğruluk yüzdesine ulaşmasından dolayı oldukça sık kullanılmaktadır. Bu mimarinin diğer algoritmalara göre çok daha hızlı çalışmasının ve başarılı olmasının sebebi verimli dağıtılmış katmanlar sayesinde sinir ağındaki iş yükünü azaltmasından dolayıdır (Özyurt vd, 2020).

Cilt kanseri sınıflandırılması için Kaggle kütüphanesinden "Skin Cancer: Malignant vs Bening" veri seti kullanılmıştır (Kaggle.com). Bu veri kümesi, iyi huylu cilt benleri ve kötü huylu cilt benlerinin görüntülerinin dengelenmiş bir veri kümesini içermektedir. Veri seti boyutları 224x224 olan toplamda 1800 görsel içermektedir. Veri setinde görsellerin 660'ı test setine bölünmüşken,

1140'ı eğitim setine bölünmüştür. Eğitim sırasında en iyi modelin seçilebilmesi için kullanılan değerlendirme seti için test setinin %40'ı değerlendirme seti, %60'ı eğitim sonunda modeli test etmek için test seti olarak kullanılmıştır. Burada veri seti kullanılarak dört farklı model eğitilmiştir. Bu dört model de ImageNet veri seti ile eğitilmiş olup, veri setleri için sınıflandırma katmanı eklenerek eğitilmiştir. Bu dört model için ResNet, DenseNet, VGG ve SqueezeNet mimarileri kullanılmıştır.

Aşağıda Şekil-2'deki figürde veri setinden alınan iyi ve kötü huylu örnekler gösterilmiştir.



**Şekil 2:** İyi ve Kötü Huylu Cilt Lezyonları

Bu çalışmada kullanılan tüm modeller PyTorch tarafından sağlanmakta olup ImageNet veri kümesi üzerinde eğitilmiştir. Araştırmacılar tarafından sıklıkla tercih edilen ImageNet mimarisi özellikle görme algoritmaları geliştirmek için tasarlanmış çok geniş bir kütüphanedir.

Çalışmada kullanılan algoritmalar her model için 30 tur eğitilmiştir. Model seçimi için eğitim sırasında değerlendirme setinde ki doğruluk oranları takip edilmiş ve eğitim sırasında en yüksek değerlendirme doğruluk oranını veren turdaki model seçilmiştir. Aynı zamanda modellerin seçimi için hiper parametre ayarlaması yapılmıştır. Burada parametre ayarları ve özellikleri seçilirken, öğrenme hızı, optimizasyon fonksiyonu, değerlendirme doğruluğu ve test doğruluğu parametreleri referans alınmıştır.

Cilt kanserine ait veri setinin CNN algoritmalarıyla sınıflandırmasının yanı sıra, klasik makine öğrenmesi yöntemleriyle de sınıflandırarak tahmin doğruluk yüzdesi incelenmiştir. Yapay sinir ağları eğitimindeki gibi bölünmüş olan veri setinin sınıflandırma katmanı öncesi öznitelikler kullanılarak LDA, SVM, KNN, karar ağacı (DT) ve Naive Bayes (NB) modelleri eğitilmiştir. Modeller Scikit-learn kütüphanesi kullanılarak uygulanmış olup, varsayılan hiper parametreler kullanılmıştır.

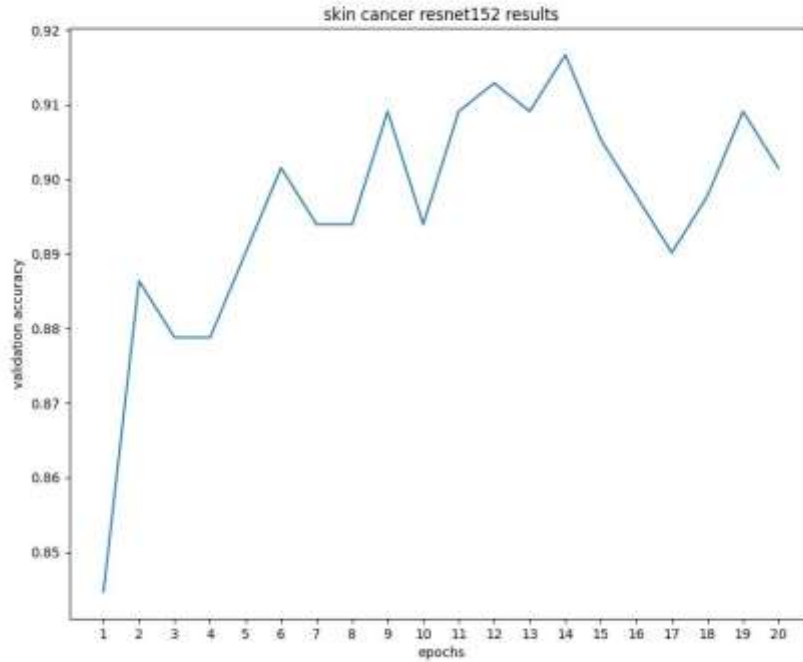
## **Bulgular ve Yorumlanması**


Python programlama dilinde tüm veri setinin girdisi ve analizi yapılmıştır. Programlama ve analiz kısmı Kaggle kütüphanesinden ayrıca beslenerek yeterli veri ve doğruluk oranına ulaşılmıştır. Önceden eğitilmiş ağlar, parametre optimizasyonu ve makine öğrenmesi algoritmalarının sınıflandırma sonuçları ayrı ayrı hesaplanarak verilmiştir. Tablo-1'de hiper parametre optimizasyonu gösterilmiştir.

**Tablo-1:** Hiper-Parametre Optimizasyonu

	Öğrenme Hızı	Optimizasyon Fonksiyonu	Değerlendirme Doğruluğu	Test Doğruluğu
SqueezeNet	0.0001	Adam	0.886	0.873
DenseNet	0.01	SGD	0.920	0.888
ResNet	0.01	SGD	0.924	0.883
VGG	0.01	SGD	0.918	0.878
Topluluk	-	-	-	0.906

Hiper parametre ayarlaması yapıldıktan sonra eğitilen modellerden ResNet için 0.92, DenseNet için 0.92, VGG için 0.91, SqueezeNet için 0.88 en yüksek değerlendirme doğruluk oranları alınmıştır. Aşağıda Şekil-3'te ResNet için değerlendirme doğruluk grafiği verilmiştir. En yüksek doğrulama değeri 13.turda görüldüğü için test aşamasında bu model kullanılmıştır. Bu model test seti uygulandığında %87 doğruluk oranı elde edilmiştir. Bununla birlikte Şekil-4'te ayrıca test seti için karmaşıklık matrisi verilmiştir.

**Şekil-3:** ResNet Doğruluk Yüzdesi



**Şekil-4:** ResNet Karmaşıklık Matrisi


Topluluk öğrenmesi yöntemi kullanılarak dört modelin verdiği kararlardan yumuşak oylama yöntemi ile tek karar çıkartılmıştır. Topluluk öğrenmesi yöntemi test seti üzerinde uygulandığında yüksek doğruluk oranı elde edilmiştir.

Ön eğitimli algoritmalarından alınan modellerin makine öğrenmesi algoritmalarında sınıflandırılması sonucunda en yüksek doğruluk oranını SqueezeNet mimarisinin destek vektör makinası algoritmasında sınıflandırılması sonucu bulunmuştur. Destek vektör makinaları sınıflandırmasına göre bulunan en yüksek doğruluk oranı 0.848'dir. Ayrıca Şekil-5'te makine öğrenmesi algoritması uygulanan modelin karmaşıklık matrisi verilmiştir.

**Tablo 2:** Makine Öğrenimi Sınıflandırıcıları

	LDA	SVM	KNN	DT	NB
SqueezeNet	0.780	<b>0.848</b>	0.815	0.762	0.785
DenseNet	0.838	0.848	0.714	0.661	0.818
ResNet	0.679	0.840	0.843	0.719	0.823
VGG	0.661	0.808	0.795	0.694	0.765





Şekil-5: Makine Öğrenmesi Karmaşıklık Matrisi

## Sonuç ve Tartışma

Bu makalenin amacı derin öğrenme yöntemlerini kullanarak cilt kanseri ve ona sebep olan lezyon oluşumlarının teşhisi amacıyla ön-eğitilmiş CNN algoritmalarını kullanarak bir derin öğrenme modeli oluşturmaktır. Biyomedikal görüntüleri işlemek için literatürde birçok yöntem bulunmaktadır. Ön eğitilmiş ağlar, sonradan geliştirilebilen algoritmalar, otomatik algoritmalar ve hazır modeller bu alanda yapılan çalışmalara katkı sağlamaktadırlar. Ayrıca Kaggle, Keras, Pandas gibi kütüphaneler içerlerinde buldukları açık erişimli veri kümeleri sayesinde bu alanda çalışan araştırmacılar için oldukça faydalı hizmetler sunmaktadırlar.

Bizim çalışmamızda önceden eğitilmiş dört farklı CNN algoritması kullanılarak en iyi sonucu veren algoritma ve yüksek doğruluk oranı bulunmaya çalışılmıştır. Bunun için modelin yüksek doğruluk vermesi amacıyla parametre optimizasyonu yapılmış ayrıca klasik makine öğrenmesi yöntemi kullanılarak aynı veri kümeleri sınıflandırılmış sonuçlar belirtilmiştir. Her veri kümesi için benzer algoritmalar farklı doğruluk oranları ortaya koysa da cilt kanseri gibi yüzeye dağılmış tümörlü lezyonlar için ön eğitilmiş CNN algoritmalarının oldukça başarılı sonuçlar verdiği ortaya koyulmuştur.

## Kaynakça

Balaji, V. R., Suganthi, S. T., & Rajadevi, R., Kumar, V. K., Balaji, B. S., Pandiyan, S. (2020). Skin Disease Detection and Segmentation Using Dynamic Graph Cut Algorithm and Classification Through Naive Bayes Classifier, **Measurement**, 107922.



Bezdan, T., & Džakula, N. B. (2019). **Convolutional Neural Network Layers and Architectures in Sinteza**, International Scientific Conference on Information Technology and Data Related Research, 445-451.

Chen, L. C., & Papandreou, G., Kokkinos, I., Murphy, K., Yuille, A. L. (2016). **Deeplab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution and Fully Connected Crfs**, Pre-Print Arxiv:1606.00915.

Filali, Y., & Ennoui, A., Sabri, M. A., Aarab, A. (2018). **A Study of Lesion Skin Segmentation, Features Selection and Classification Approaches**. *International Conference on Intelligent Systems and Computer Vision (ISCV)* (Pp.1-7). IEEE.

Goodfellow, I., & Bengio, Y., Courville, A. (2016). **Deep Learning**. England: MIT Press, 164-341.

The International Society for Digital Imaging of the Skin (ISDIS) Archive-<https://isic-archive.com/>. [Erişim Tarihi 14.12.2017]

İsmail, K. E., AbouRizka, M. A., & Maghraby, F. A. (2020). **Machine Learning Model for Multiclass Lesion Diagnoses**. *2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)* (pp. 397-402). IEEE.

Kaggle, <https://www.kaggle.com/datasets/fanconic/skin-cancer-malignant-vs-benign> [Erişim Tarihi 15.06.2022]

Kostopoulos, S. A., & Asvestas, P. A., Kalatzis, I. K., Sakellariopoulos, G. C., Sakkis, T. H., Cavouras, D. A., and Glotsos, D. T. (2017). Adaptable Pattern Recognition System for Discriminating Melanocytic Nevi from Malignant Melanomas Using Plain Photography Images from Different Image Databases. **International Journal of Medical Informatics**, 105:1-10.

Kumar R., (2019). **Adding Binary Search Connections to Improve Densenet Performance**, 5th International Conference On Next Generation Computing Technologies Dehradun: NGCT-2019 SSRN: <https://ssrn.com/abstract=3545071>

Mathew, A., Amudha, P., Sivakumari, S. (2020). **Deep Learning Techniques**, an Overview in International Conference on Advanced Machine Learning Technologies and Applications (pp. 599-608). Springer, Singapore.

Medium, <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> [Erişim tarihi 16.06.2022]

Monika, M. K., & Vignesh, N. A., Kumari, C. U., Kumar, M. N. V. S. S., Lydia, E. L. (2020). Skin Cancer Detection and Classification Using Machine Learning, **Materials Today: Proceedings**, 33, 4266-4270.

Oliveira, R. B., & Marranghello, N., Pereira, A. S., Tavares, J. M. R., (2016). A Computational Approach For Detecting Pigmented Skin Lesions in Macroscopic Images. **Expert Systems with Applications**, 61: 53-63.

Özyurt F., & Sert E., Avcı D. (2020). An Expert System for Brain Tumor Detection: Fuzzy C-Means with Super Resolution and Convolutional Neural Network with Extreme Learning Machine, **Medical Hypotheses**, 134,1-8.

Waheed, Z., & Waheed, A., Zafar, M., Riaz, F. (2017). **An Efficient Machine Learning Approach for the Detection of Melanoma Using Dermoscopic Images**, International Conference on Communication, Computing and Digital Systems (C-CODE) (pp. 316-319). IEEE.

Yang, S., & Oh, B., Hahm, S., Chung, K. Y., Lee, B. U., (2017). Ridge and Furrow Pattern Classification for Acral Lentiginous Melanoma Using Dermoscopic Images, **Biomedical Signal Processing and Control**, 32: 90-96.