



DERİN ÖĞRENME İLE ARTIRILMIŞ GÖRÜNTÜ SETİ ÜZERİNDEN CİLT KANSERİ TESPİTİ

Erhan ERGÜN¹, Kazım KILIÇ^{1*}

¹Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 55139, Samsun, Türkiye

Özet: Bu çalışmada, son yıllarda görüntü sınıflandırmada artan oranda ilgi gören derin öğrenme ve görüntü işleme yöntemleri kullanılarak kötü huylu (malignant) cilt lezyonlarının erken teşhisini kolaylaştırıcı yapay zekâ tabanlı sınıflandırma deneyleri gerçekleştirilmiştir. Melanom, en kötü huylu ve az görülen bir kanser türü olduğundan dolayı derin öğrenme mimarisini eğitmek için yeterli sayıda eğitim ve test görüntüsü bulmak zordur. Bu nedenle artırılmış veri seti oluşturulmuş ve 6 farklı derin öğrenme mimarisi ile eğitim yapılmıştır. Kötü huylu ve iyi huylu cilt lezyonlarını sınıflandırmak için popüler olan AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16 mimarileri kullanılmıştır. Deneyler HAM10000 veri seti üzerinde artırma yapılarak gerçekleştirilmiştir. Deneyler sonucunda en başarılı sonuçları veren Resnet-34 mimarisi ile ortalama %87,5 doğruluk oranı, %94 AUC skoru, %84,5 F-skoru, %87,6 kesinlik değeri elde edilmiştir. Diğer derin öğrenme mimarilerinden elde edilen sonuçlar ve karşılaştırmalı analizler de çalışmada ayrıca sunulmuştur.

Anahtar kelimeler: Derin öğrenme, Evrişimsel sinir ağları, Transfer öğrenme, Cilt kanseri, Sınıflandırma

Skin Cancer Detection via Augmented Image Set with Deep Learning


Abstract: In this study, artificial intelligence-based classification experiments were carried out to facilitate the early diagnosis of malignant skin lesions by using deep learning and image processing methods, which have received increasing attention in image classification in recent years. Because melanoma is the most malignant and rarest type of cancer, it is difficult to find enough training and test images to train the deep learning architecture. For this reason, augmented data set was created and training was conducted with 6 different deep learning architectures. Popular architectures AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet and VGGNet-16 were used to classify malignant and benign skin lesions. The experiments were carried out on the HAM10000 data set by augmented. As a result of the experiments, with the Resnet-34 architecture, which gave the most successful results, an average of 87.5% accuracy, 94% AUC score, 84.5% F-score, and 87.6% precision were obtained. The results and comparative analyzes obtained from other deep learning architectures are also presented in the study.

Keywords: Deep learning, Convolutional neural network, Transfer learning, Skin cancer, Classification

*Sorumlu yazar (Corresponding author): Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 55139, Samsun, Türkiye

E mail: kazimkiliç55@gmail.com (K. KILIÇ)

Erhan ERGÜN  <https://orcid.org/0000-0003-1446-2428>

Kazım KILIÇ  <https://orcid.org/0000-0003-2168-1338>

Gönderi: 17 Mayıs 2021

Received: May 17, 2021

Kabul: 07 Ağustos 2021

Accepted: August 07, 2021

Yayınlanma: 01 Ekim 2021

Published: October 01, 2021

Cite as: Ergün E, Kılıç K. 2021. Skin cancer detection via augmented image set with deep learning. BSJ Eng Sci, 4(4): 192-200.

1. Giriş

Cilt kanseri, hasar gören cilt hücrelerinin DNA yapılarının kontrolsüz çoğalmaları sonucu oluşmakta ve dünyada en sık görülen kanserler arasındadır (Rey-Barroso ve ark., 2021). En yaygın cilt kanseri türleri, bazal hücreli karsinom, skuamöz hücreli karsinom ve melanomdur. Bazal hücreli karsinom kanser vakalarının %80'ini, skuamöz hücreli karsinom %16'sını, melanom ise %4'ünü oluşturmaktadır. Melanom, melanositler olarak da bilinen pigment içeren hücrelerden gelişen kötü huylu bir tümördür. Seyrek görülmesine rağmen en kötü huylu (malignant) olan cilt kanseri türüdür ve ölüm sayıları giderek artmaktadır (Jerant ve ark., 2000; Garbe ve ark., 2010; Siegel ve ark., 2021a). Amerikan Kanser Derneğine 2020 yılında 100.350 adet yeni vaka tespit edildiği ve tahminen 6850 kişinin melanoma bağlı ölümünün gerçekleştiği bildirilmiştir (Siegel ve ark., 2021b). Hastalık oranının az oluşu, bu ölümcül hastalığa

ilişkin gerçek görüntü verilerinin de sınırlı olması sonucunu doğurmaktadır. Bu durum, görüntü işleme ve makine öğrenimi tekniklerinin uygulanışında çok önemli bir handikaptır.

Cilt kanseri, erken tespit edildiğinde, kesin tedavi yüksek olasılıkla mümkündür (Celebi ve ark., 2007; Capdehourat ve ark., 2011). Cilt kanseri taraması için optik yöntemler mevcuttur. Bu yöntemler yüzeysel ve hızlı yanıt vermektedir. Yüzeysel olmayan yöntemler arasında en yaygın kullanılan dermoskopik taramadır (Narayanamurthy ve ark., 2018; Xie ve ark., 2020). Dermoskopi, ciltte bulunan lekeli bölgenin doğru tanılanması için ilgili bölgenin büyütülmüş ve aydınlatılmış görüntüsünü elde etmeye yönelik görüntüleme tekniğidir. Cildin yüzey yansımalarını ortadan kaldırarak, daha derin cilt seviyelerinin görsel etkisini artırabilir ve cilt lezyonlarının daha detaylı görüntüsünü verir. Dermoskopi değerlendirmesi, çıplak gözle yapılan



değerlendirmeye göre çok daha yüksek doğruluk oranları vermektedir. Dermoskopik görüntüler, çoğunlukla görsel inceleme yoluyla analiz edilir (Binder ve ark., 1995; Kittler ve ark., 2012; Thomas ve Puig, 2017).

Geleneksel (Görsel inceleme, klinik tarama, dermoskopik analiz, biyopsi ve cilt lezyonunun histopatolojik incelenmesi gibi) yöntemlerin kullanılması, yüksek derecede beceri, konsantrasyon gerektirmekte ve zaman almaktadır. (Celebi ve ark., 2008; Abbas ve ark., 2013; Xie ve ark., 2020). Cilt kanseri teşhisi, uzman dermatologlar tarafından yapıldığında bile cilt lezyonlarında bulunan farklı şekiller, belirsiz sınırlar, düşük kontrast, cilt kılları, yağlar, hava kabarcıkları gibi faktörler nedeniyle hatalı olabilmektedir. Bu koşullar altında, cilt kanserinin tespiti ve sınıflandırılması için hızlı ve yüksek başarı oranına sahip bilgisayar destekli tanı sistemlerinin geliştirilmesi giderek önem kazanmaktadır.

Literatürde incelenen çalışmalarda, HAM10000 veri setinde bulunan 7 farklı hastalığın sınıflandırıldığı ve genellikle en kötü huylu olan melanom hastalığının tespit edilmeye çalışıldığı görülmektedir. Bu çalışmada, diğerlerinden farklı olarak tüm kötü huylu cilt kanserleri tespit edilmeye çalışılmıştır. İyi ve kötü huylu cilt lezyonlarını tespit etmek için son yıllarda görüntü sınıflandırma problemlerinde ve tıbbi görüntü analizinde iyi sonuçlar veren evrimsel sinir ağı (ESA) mimarileri tercih edilmiştir. Çalışmada 6 farklı popüler ESA mimarisi, HAM10000 veri seti ile eğitilmiş ve kötü huylu

cilt lezyonlarını sınıflandırma performansları analiz edilmiştir. ESA'ların eğitiminde en önemli sorunlardan biri olan veri seti yetersizliğine karşı bu çalışmada, iyi sonuç verdiği literatürde de belirtilmiş olan veri artırma yöntemi kullanılmıştır. Öte yandan, popüler ESA mimarileri aynı veri seti üzerinde test edilerek elde edilen sonuçlar bir karşılaştırma tablosunda sunulmuştur.

2. Materyal ve Yöntem

2.1. Veri Seti


Bu çalışmada, ISIC (Uluslararası Cilt Görüntüleme İşbirliği) 2018'de eğitim seti olarak kullanılan HAM10000 veri seti (Tschandl ve ark., 2018) kullanılmıştır. Bu veri seti 10015 adet dermoskopik cilt görüntüsü içermektedir. Bu görüntüler melanom (M), melanositik nevüs (MN), bazal hücreli karsinom (BHK), aktinik keratoz (AK), iyi huylu keratoz (İHK), dermatofibroma (DF) ve vasküler lezyon (VL) olarak kategorize edilmektedir. Tablo 1'de, veri setinde bulunan melanositik ve melanositik olmayan iyi ve kötü huylu lezyonlara ait hastalık türleri ve görüntü sayıları gösterilmektedir. Görüntüler 450x600 piksel boyutundadır (Tschandl ve ark., 2018).

Veri setinde toplam olarak 1954 adet kötü huylu, 8061 adet iyi huylu cilt lezyon görüntüsü bulunmaktadır. Şekil1'de örnek görseller verilmiştir.

Tablo 1. HAM10000 veri seti içerisindeki hastalık türleri ve görüntü sayıları

Melanositik			Melanositik olmayan			
İyi huylu	Kötü huylu		İyi huylu	Kötü huylu		
MN	M	VL	DF	İHK	AK	BHK
6705	1113	142	115	1099	327	514

MN= melanositik nevüs, M= melanom, VL= vasküler lezyon, DF= dermatofibroma, İHK= iyi huylu keratoz, AK= aktinik keratoz, BHK= bazal hücreli karsinom



Şekil 1. (a) kötü huylu cilt lezyonu (b) iyi huylu cilt lezyonu.

2.2. Veri Artırma

Veri artırma, işlenecek veri sayısının artması için veri ekleme işlemidir (Purnama ve ark., 2019). Yüksek hızda örnekleme ve yetersiz örnekleme yöntemleri dengesiz veri kümeleri üzerinde yaygın olarak kullanılmaktadır. Yapılan çalışmalar, derin öğrenme ağ mimarileri ile gerçekleştirilen sınıflandırma problemlerinde veri artırmanın başarıyı yükselttiğini göstermektedir (Lopez

ve ark., 2017; Ayan ve Ünver, 2018). Veri setinde bulunan sınıf dengesizliğini önlemek ve derin öğrenme mimarisinin performansını artırmak amacıyla görüntülere yatay ve dikey çevirmeler, maksimum 355 dereceye kadar açı değiştirme, maksimum 1,5 değerinde yakınlaştırma, maksimum 0,3 değerinde rastgele kontrast ve parlaklık artırma gibi teknikler uygulanarak veri setinde bulunan görüntü sayısı artırılmaktadır.

2.3. Derin Öğrenme

Derin öğrenme temelini yapay sinir ağları oluşturmaktadır. Derin öğrenme mimarileri verilerin temsilinden öğrenme gerçekleştirerek yüksek miktarda veri üzerinde işlem gerçekleştirebilmektedir. Bu sebeple geleneksel yapay sinir ağlarına kıyasla daha fazla gizli katmana sahiptirler (Deng ve Yu, 2014). Derin sinir ağlarında, belirli ağırlıklara sahip etiketli girdi değerleri, bir çıktı üretmek için doğrusal olmayan bir aktivasyon fonksiyonundan geçirilmektedir (Schmidhuber, 2015). Bu nedenle, bir derin sinir ağı eğitiminin amacı, ağı ağırlıklarını optimize etmektir, böylece hata değeri en aza

indirilmeye çalışılmaktadır. Bu çalışmada kullanılan derin öğrenme mimarileri aşağıda açıklanmıştır.

2.3.1. Evrişimsel sinir ağları

ESA, görüntülerin piksel matrislerinden ayırıcı özellikler elde eden ve bu özellikleri kullanarak tahminde bulunabilen derin öğrenme mimarisidir (LeCun ve ark., 1998). ESA'lar, görüntü sınıflandırma, nesne algılama, görüntü bölütleme, ses tanıma, metin, video işleme ve tıbbi görüntü analizi gibi birçok bilgisayarla görü uygulamasında kullanılmaktadır (Pacal ve ark., 2020). ESA, evrişim katmanları, havuz katmanları ve tamamen bağlantılı katmanlar olmak üzere üç katman içerir. Görüntüleri sınıflandırmak için kullanılan ESA mimarisi Şekil 2'de gösterilmektedir. Evrişim katmanında, giriş görüntüsü bazı özellik haritalarını oluşturmak için çekirdeklerden veya filtrelerden geçer. Havuzlama katmanında, ağırlıkların sayısını küçük tutmak için özellik haritalarının her birinin boyutu azaltılır. Bu süreç aynı zamanda alt örnekleme olarak da bilinir. Genel havuzlama, maksimum havuzlama ve ortalama havuzlama gibi çeşitli havuzlama yöntemleri vardır. Evrişim ve havuzlama katmanlarından sonra elde edilen özellik matrisi çok boyutlu olduğundan dolayı tam bağlı katmana aktarılmadan önce düzleştirme işlemi gerçekleştirilerek veriler tek boyutlu vektör formuna sokulur. Tam bağlı katmanda ise tek boyutlu vektöre dönüştürülen özelliklerle derin sinir ağı eğitilerek sınıflandırma işlemi gerçekleştirilir.

2.3.2. AlexNet

2012 yılında Khrizevsky ve arkadaşları bu mimari ile ImageNet (Büyük Ölçekli Görsel Tanıma) yarışmasında 1,2 milyon adet yüksek çözünürlüklü görüntüyü 1000 farklı sınıfa ayırmışlardır. Yarışmada AlexNet ile %15,4 hata oranı ile en başarılı performansı göstererek yarışmanın kazananı olmuşlardır. Bu mimari, 5 evrişim katmanı, 2 ReLU aktivasyon katmanı ve 3 maksimum havuzlama katmanı ile 3 tam bağlı katmandan oluşmaktadır. Sınıflandırma işlemi için softmax fonksiyonu kullanılmaktadır. Ağın giriş görüntü boyutu 224x224x3 olup 11x11 boyutunda evrişim filtreleri kullanılmaktadır (Khrizevsky ve ark., 2012).


2.3.3. VGGNet

VGGNet mimarisinin 16 ile 19 katmanlı olmak üzere iki versiyonu bulunmaktadır. VGGNet mimarisinde görüntülerden daha iyi özellikler çıkarabilmek için 11x11 yerine 3x3 lük daha küçük filtreler kullanılmıştır. Bu

mimari ağın genişliğini artırmak yerine daha küçük filtrelerle derinliğini artırmanın daha iyi sonuçlar verdiğini göstermiştir. 13 adet evrişim ve 3 adet tam bağlı katmandan oluşmaktadır. ReLU aktivasyon katmanı evrişim katmanları ile birlikte kullanılır. Ağın giriş görüntü boyutu 224x224x3'dür (Simonyan ve Zisserman, 2014).

2.3.4. ResNet

Bu mimarinin hata oranı oldukça düşüktür ve maksimum 152 katman olmak üzere 18-34-50-101 gibi farklı derinliklere sahip versiyonları bulunmaktadır. Residual bloklar ResNet'i diğer mimarilerden farklı kılmaktadır. ResNet mimarisinden önceki ESA mimarilerinde görüntüde bulunan piksel matrisleri evrişim katmanına giriş olarak verilmekte ve evrişim filtresinden elde edilen değerler aktivasyon fonksiyonundan geçirilerek çıktı elde edilmektedir. ResNet mimarisinde bulunan kalıntı (residual) blokta x girişi sırasıyla evrişim-ReLU-evrişim katmanlarından geçerek bir $F(x)$ sonucu elde edilmektedir. Elde edilen bu sonuç x girişine eklenerek $H(x)=F(x)+x$ çıktısı üretilmektedir. Bu durum bir önceki katmandan gelen artık değerlerin göz ardı edilmemesini sağlamaktadır ve Şekil 3'de verilmiştir (He ve ark., 2016).



Şekil 3. Kalıntı bloğun yapısı (He ve ark., 2016).

2.3.5. DenseNet

Ağıdaki katmanlar arasında maksimum bilgi akışı sağlayan DenseNet'te, her katman önceki katmanlardan ek girdiler alarak kendi özellik haritalarını sonraki katmana aktarmaktadır. DenseNet mimarisinin en büyük avantajı özellik yayılımını sağlayarak elde edilen özelliklerin yeniden kullanılmasını sağlar. Bu durum ağıdaki parametre sayısını da azaltır. Bu mimari yoğun bloklar ve üç adet geçiş katmanı ile toplamda 121 katmandan oluşmaktadır. DenseNet-121, DenseNet-169 ve DenseNet-201 gibi farklı katmanlara sahip versiyonları bulunmaktadır (Huang ve ark., 2017).



Şekil 2. Evrişimsel sinir ağı mimarisi (Anonymous, 2021).

2.3.6.SqueezeNet

Bu mimarinin amacı, evrişimli sinir ağlarında daha az sayıda parametre ile yüksek doğruluğa ulaşmaktır. AlexNet mimarisinden 50 kat daha az parametre sayısı ile aynı doğruluğa ulaşabilmektedir. SqueezeNet mimarisinin katmanları, evrişimli katmanlardan, yangın modüllerinden (sıkıştır ve genişlet), 2 adımlık maksimum havuzlama katmanlarından, genel ortalama havuzlama katmanından ve çıktı için softmax katmanından oluşmaktadır (Iandola ve ark., 2016).

2.4.Transfer Öğrenme

ESA mimarileri ile yapılan görüntü analizi çalışmalarında yeterli miktarda veri bulunmadığında ağı sıfırdan eğitmek yerine genellikle transfer öğrenme yaklaşımı kullanılır. Bu yaklaşım, benzer bir görevde eğitilmiş ağı parametrelerinin yeni görevde kullanılmasıdır. Yeni görev için kurulan ESA'nın eğitimi transfer edilen parametrelerle başlatılıp çalışmada kullan veri seti ile belirlenen sayıda tekrar eğitilerek parametreler güncellenir (Fırıldak ve Talu, 2019). Çalışmada, ESA mimarilerinin özellik çıkarıcı katmanları için ImageNet veri setiyle eğitilmiş ağların ağırlıkları kullanılmıştır. Sınıflandırma için mimarilerin son katmanında bulunan derin sinir ağı, görüntülerden elde edilen özellikler ile sıfırdan eğitilmiştir.

2.5. Deneysel Kurulum

Yapılan araştırma için kullanılan veri seti iyi ve kötü huylu cilt lezyonları olarak iki sınıfa ayrılmıştır. Kullanılan veri setinde kötü huylu cilt lezyonlarının sayısı az olduğundan dolayı veri dengesini sağlamak ve ağı performansını artırmak için eğitim setinde kullanılan görüntülerin sayısı artırılmıştır. Veri artırma işlemi yalnızca eğitim seti üzerinde gerçekleştirilmiştir. Tablo 2'de eğitimde kullanılan orijinal görüntülere ait veri sayıları ve aynı görüntülerden artırılmış eğitim verilerinin sayıları görülmektedir.

Tablo 2. Artırılmış ve orijinal iyi-kötü huylu cilt lezyonlarının sayısı

	Kötü huylu	İyi huylu
Eğitim verisi	1176	4739
Arttırılmış eğitim verisi	11495	14178
Doğrulama	778	1981

Veri setinde bulunan 450x600 piksel boyutundaki görüntüler kullanılan derin öğrenme mimarilerinin kabul ettiği giriş görüntü boyutu olan 224x224x3 piksel boyutuna göre yeniden boyutlandırılmıştır.

ESA mimarilerinin eğitiminde aktivasyon işlemi için ReLU aktivasyon fonksiyonu, optimizasyon işlemi için ise Adam algoritması kullanılmıştır. İşlenecek görüntülerin alt küme boyutu (Batch-size) değeri 64 olarak ayarlanmıştır. Öğrenme hızı için öğrenme hızı aralığı testi (LRRT) yöntemi kullanılmıştır. Transfer öğrenme yaklaşımı kullanılarak yapılan deneyler için evre (epoch) sayısı 20 olarak belirlenmiştir. Deneyler Google alt

yapısını kullanan Kaggle kernels (Kaggle çekirdekleri) bulut ortamında, Nvidia Tesla K80 ekran kartı üzerinde gerçekleştirilmiştir. Uygulamanın yazılımı için Python programlama dilinde fast.ai (Howard ve Gugger, 2020) kütüphanesi kullanılmıştır.

2.6.Değerlendirme Ölçütleri

Sınıflandırma görevinde mimarilerin performansını belirlemek için karmaşıklık matrisi yaygın olarak kullanılmaktadır. İkili sınıflandırma görevlerinde 2x2 boyutunda bir matristen oluşan karmaşıklık matrisi görüntülerin gerçek değerleri ile sınıflandırıcının tahmin ettiği değerleri göstermektedir. DP doğru tahmin edilen pozitif sonuçları, YP yanlış tahmin edilen pozitif sonuçları, DN doğru tahmin edilen negatif sonuçları ve YN ise yanlış tahmin edilen negatif sonuçları belirtmektedir.

Karmaşıklık matrisinden elde edilen DP, YP, DN, YN değerleri kullanılarak sınıflayıcının performansını ölçmeyi sağlayan metrikler hesaplanabilmektedir.

Doğruluk: Sınıflayıcının doğru tahmin ettiği örneklerin tüm örneklere oranıdır (eşitlik 1).

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN} \quad (1)$$

Hassasiyet: Doğru pozitif oranı olarak da bilinmektedir. Doğru olarak tahmin edilen pozitif örneklerin gerçekte pozitif olan tüm örneklere oranını vermektedir (eşitlik 2).

$$\text{Hassasiyet} = \frac{DP}{DP+YN} \quad (2)$$

Kesinlik: Doğru tahmin edilen pozitif örneklerin, pozitif olarak tahmin edilen tüm örneklere oranıdır (eşitlik 3).

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (3)$$

F-Skor (F-Score): Hassasiyet ve kesinlik değerlerinin ağırlıklı ortalamasını vermektedir (eşitlik 4).

$$\text{F-Skor} = \frac{2 \times \text{Kesinlik} \times \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} \quad (4)$$

ROC Eğrisi: Sınıflandırma mimarisinin performansını gösteren bir grafikdir. Grafiğin yatay ekseninde yanlış pozitif oranı, dikey ekseninde ise doğru pozitif oranı (hassasiyet) bulunmaktadır (Adegun ve Viriri, 2020).

Eğri Altındaki Alan (AUC): ROC Eğrisi altında kalan alanı temsil etmektedir. Sınıflandırma mimarisinin pozitif ve negatif örnekleri ne kadar ayırdığını göstermektedir. Alan arttıkça ayırım yeteneği artmaktadır.

Hata Oranı: Gerçek değer ile sınıflayıcının elde ettiği değer arasındaki mutlak farkın oranını belirtmektedir.

3. Bulgular


İyi ve kötü huylu cilt lezyonlarının sınıflandırılmasında kullanılan mimarilerin gösterdikleri performans Tablo 3'de gösterilmektedir. Deneyler artırılmış ve artırılmamış veri setleriyle gerçekleştirilmiştir. '*' simgesine sahip deneyler artırılmış veri seti ile yapılmıştır. Kalın yazılmış değerler ilgili ölçüt bakımından en iyi sonucu

göstermektedir. Tablo 3'de AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16'ya ait F-skor, kesinlik, hassasiyet ve hata oranı değerleri görülmektedir. AlexNet mimarisi ile yapılan 20 evrelik deneyde 16. evrede %83,03 oranında doğruluk ve %89,87 oranında AUC değeri elde edilmiştir.


Tablo 3. Derin öğrenme mimarilerinin 20 evre sonucunda elde ettikleri en başarılı değerler

	Doğruluk	AUC	F-Skor	Kesinlik	Hassasiyet	Hata-Oranı
AlexNet*	0,8303	0,8987	0,7866	0,8046	0,7693	0,1696
AlexNet	0,6438	0,7209	0,6545	0,6403	0,6695	0,3561
DenseNet-121*	0,8593	0,9292	0,8231	0,8494	0,7984	0,1406
DenseNet-121	0,7758	0,8526	0,7041	0,7495	0,6640	0,2241
ResNet-18*	0,8661	0,9303	0,8320	0,8590	0,8066	0,1338
ResNet-18	0,7709	0,8453	0,6985	0,7350	0,6655	0,2290
ResNet-34*	0,8751	0,9404	0,8438	0,8761	0,8137	0,1248
ResNet-34	0,8514	0,8980	0,8122	0,8460	0,7811	0,1485
SqueezeNet*	0,7687	0,8106	0,7281	0,7227	0,7336	0,2312
SqueezeNet	0,5690	0,6476	0,6061	0,5972	0,6154	0,4309
VGGNet-16*	0,8695	0,9385	0,8366	0,8602	0,8143	0,1305
VGGNet-16	0,8149	0,8808	0,7619	0,8021	0,7256	0,1850


DenseNet-121 mimarisi ile yapılan deneyde 17. evrede %85,93 doğruluk ile %92,92 oranında AUC değeri elde edilmiştir. ResNet-18 mimarisi ile yapılan deneyde 18.evrede %86,61 doğruluk ve %93,03 AUC değeri elde edilmiştir. Resnet-34 mimarisi ile yapılan deneyde 15. evrede %87,51 doğruluk ve %94,04 AUC değeri elde edilmiş olup 16. evreden 20. evreye kadar elde edilen değerler %87 ile %87,2 aralığında değişmiştir. SqueezeNet mimarisi ile 17. evrede %76,87 doğruluk ve %81,06 oranında AUC değeri elde edilmiştir. VGGNet-16 mimarisi ile yapılan deneyde ise 19. evrede %86,95 doğruluk ve %93,85 oranında AUC değeri elde edilmiştir. AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16 ile yapılan deneylerde 20 evre süresince elde edilen doğruluk, AUC skoru ve hata oranı değerleri sırasıyla Şekil 4, Şekil 5, Şekil 6'da gösterilmektedir.



Şekil 4. Derin öğrenme mimarilerinin 20 evre süresince doğrulama kümesi üzerinde elde ettikleri doğruluk değerlerinin grafiksel gösterimi.



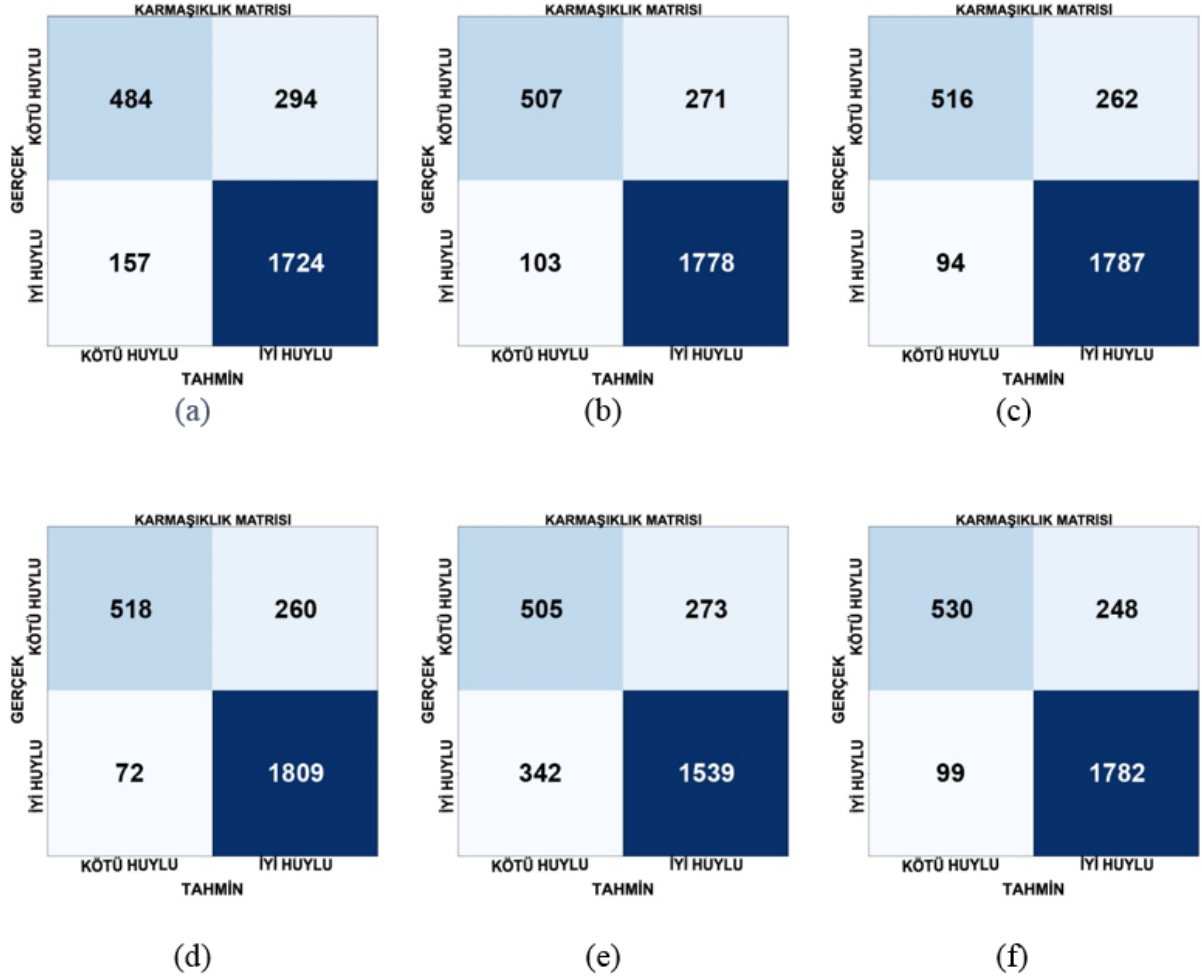
Şekil 5. Derin öğrenme mimarilerinin 20 evre süresince doğrulama kümesi üzerinde elde ettikleri AUC değerlerinin grafiksel gösterimi.




Şekil 6. Derin öğrenme mimarilerinin 20 evre süresince doğrulama kümesi üzerinde elde ettikleri hata oranı değerlerinin grafiksel gösterimi.

AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16 derin öğrenme mimarilerinin sınıflandırma işlemi sonucunda doğru ve yanlış tespit ettiği iyi ve kötü huylu cilt lezyonlarının sayıları Şekil 7'de gösterilmektedir. AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16 derin öğrenme mimarilerinin sınıflandırma işlemi sonucunda elde ettikleri doğru pozitif oranı ve yanlış pozitif oranını

gösteren ROC eğrisi Şekil 8'de gösterilmektedir. Şekil 8'de gösterilen ROC eğrisinde eğri altında kalan alan, derin öğrenme mimarilerinin sınıflandırma sonucu elde ettiği sınıflama başarı oranını göstermektedir. Yüzdeler olarak gösterilen bu oranlar AlexNet için %90, Densenet-121 için %93, Resnet-18 için %93, Resnet-34 için %94, SqueezeNet için %81 ve VGGNet-16 için ise %94'tür.



Şekil 7. Karmaşıklık matrisi (a) AlexNet (b) DenseNet-121 (c) ResNet-18 (d) ResNet-34 (e) SqueezeNet (f) VGGNet-16.



Şekil 8. Derin öğrenme mimarilerinin sınıflandırma performansını gösteren ROC eğri grafiği.

4. Tartışma

Cilt kanserlerinin belirlenmesi ve sınıflandırılması için literatürde çok sayıda çalışma ve yöntem bulunmaktadır (Premaladha ve Ravichandran, 2016; Balaji ve ark., 2020; Xie ve ark., 2020). Bunlar genellikle klasik makine öğrenimi ve derin öğrenmeye dayalı yöntemlerdir. Klasik makine öğrenimi yöntemlerinde cilt kanseri sınıflandırması genel olarak dört adımdan oluşmaktadır. Bu adımlar sırasıyla; görüntü ön işleme, lezyonun segmentasyonu, lezyondan öz niteliklerin çıkarılması ve öz nitelikleri öğrenip sınıflandırması için klasik makine öğrenimi algoritmalarının uygulanmasıdır (Oliveira ve ark., 2018; Cinarer ve Emiroglu, 2020). Sınıflandırma performansı ise ilgili bölgeden çıkarılan bu öz niteliklere bağlıdır. Deri lezyonlarında bulunan kıllar, bulanık sınırlar ve kabarcıklar öz niteliklerin çıkarılmasını, lezyon segmentasyonunu ve buna bağlı yapılan sınıflandırma

performansını olumsuz etkilemektedir (Oliveira ve ark., 2018). Derin öğrenme mimarileri verinin temsilinden öğrenme işlemini gerçekleştirerek sınıflandırma yapabilmektedir. (Russakovsky ve ark., 2015). Literatürde, evrimsel sinir ağlarının, deri lezyonu (Brinker ve ark., 2018), beyin tümörü (Deepak ve Ameer, 2019), meme kanseri (Khan ve ark., 2019) gibi birçok tıbbi görüntü analizi için kullanıldığı çalışmalar mevcuttur (Litjens ve ark., 2017).

Esteva ve ark. (2017) cilt kanseri tespiti için ESA modelini 129450 klinik görüntü ile sıfırdan eğitmiş ve sonuçları 21 kurul sertifikalı dermatolog sınıflaması ile karşılaştırmıştır. Önerdikleri model, dermatologlardan daha doğru sonuçlar vermiştir. Lopez ve ark. (2017) 1279 dermoskopi görüntüsünü sınıflandırmak için önce ESA modelini sıfırdan eğitmişlerdir. Yapılan deneyde elde edilen %66 doğruluk değeri yeterli sayıda veri olmadığında ESA'ları sıfırdan eğitmenin iyi fikir olmadığını göstermektedir. Aynı çalışmada transfer öğrenme ile yapılan farklı bir deneyde, ImageNet ağırlıkları kullanılarak oluşturulan ESA mimarisi ile %81,33 doğruluk değeri elde edilmiştir.

Kassani ve Kassani (2019) kötü huylu deri lezyonlarını tespit amacıyla transfer öğrenme algoritmalarını kullanmış ve karşılaştırmalı analizler sunmuşlardır. ISIC 2018 verileri kullanılan çalışmada veri seti ön işlemden geçirildikten sonra sınıf dağılımındaki dengesizliği gidermek için veri arttırma yöntemleri kullanılmıştır. Yapılan denemelerde ResNet-50 mimarisi ile %92,08'lik doğruluk değeri elde etmişlerdir. Ayan ve Ünver (2018) ISIC arşivinden elde ettikleri 500 iyi huylu ve 500 kötü huylu dermoskopi görüntüsü üzerinde veri arttırma yaparak ESA tabanlı sınıflandırma işlemi gerçekleştirmişlerdir.

Çalışma sonucunda aynı modelin artırılmamış verilerle %78, artırılmış verilerde ise %81 doğruluk değerine ulaştığı görülmüştür. Rashid ve ark. (2019) cilt lezyon sınıflandırması için ISIC 2018 veri seti üzerinde çekişmeli üretici ağ (GAN) tabanlı veri arttırma yöntemi kullanmışlardır. Görüntüleri ResNet ve DenseNet mimarileriyle sınıflandırmışlar ve sırasıyla %79 ve %89 doğruluk değerleri elde etmişlerdir. Yine çekişmeli üretici ağ yöntemi kullanılarak veri arttırma gerçekleştirilen ESA tabanlı sınıflandırma modelinde ise %86 doğruluk elde etmişlerdir. Quang (2017) ISIC 2017 yarışmasında kullanılan 2000 adet görüntüyü veri arttırma yöntemleri ile 6000 adete çıkararak sınıflandırma gerçekleştirmişlerdir. VGGNet-16 mimarisi kullanılan deneyde %87 ortalama doğruluk değeri elde edilmiştir. Harangi (2017) cilt kanseri sınıflandırması için GoogleNet, ResNet, AlexNet ve VGGNet mimarilerinin çıktılarını birleştiren hibrit bir model önermiştir. Veri setinde bulunan toplam 2000 adet görüntüyü veri arttırma yöntemleri ile 14300 adede çıkartmıştır. Yapılan deneyler sonucunda önerilen sistemin elde ettiği doğruluk değeri %86,6'dır. Kawahara ve ark. (2016) cilt görüntülerini sınıflandırmak için daha önceden eğitilmiş ESA modeli kullanarak ve veri arttırma yöntemini

kullanarak ikili sınıflandırmada %94,8 doğruluk elde etmişlerdir.

Bu çalışmada diğerlerinden farklı olarak yalnızca en kötü huylu melanom değil, tüm kötü huylu cilt kanseri türleri tespit edilmeye çalışılmıştır. Cilt kanserinin tespiti için 6 farklı derin öğrenme mimarisi ile yapılan deneyler sonucunda doğruluk kategorisinde %87,5, AUC skoru kategorisinde %94, F-skor kategorisinde %84 ve kesinlik kategorisinde %87 oranı ile Resnet-34 mimarisi en iyi performansı göstermiştir. Resnet-34 mimarisi, aynı zamanda en düşük hata oranına sahiptir. VGGNet-16 mimarisinin hassasiyet kategorisinde gösterdiği performans dikkat çekmektedir. AUC skorunda ise VGGNet-16 ve Resnet-34 mimarisin gösterdiği performans birbirine oldukça yakındır. Tüm kategorilerde en kötü performansı SqueezeNet mimarisi göstermiştir. Buna rağmen SqueezeNet'in gösterdiği %76 doğruluk ve %81 AUC skoru oranı, literatürdeki çalışmalarla karşılaştırıldığında iyi bir performans olarak not edilmelidir. ResNet-18 mimarisinin başarımı, DenseNet-121 mimarisinin başarımını az farkla da olsa geçmiştir.

Karmaşıklık matrislerine bakıldığında Resnet-34 mimarisinin iyi huylu ve kötü huylu cilt lezyonlarını ayırt etmede daha başarılı olduğu görülmektedir. VGGNet-16 mimarisinin doğru olarak tahmin ettiği kötü huylu lezyon sayısı ResNet-34 mimarisinden 12 adet daha fazladır. Fakat kötü huylu olarak tahmin ettiği ve gerçekte iyi huylu olan cilt lezyonlarının sayısının da 27 adet daha fazla olduğu görülmektedir.

Resnet-18 mimarisinin VGGNet-16'dan daha başarısız sonuçlar elde etmesine rağmen doğru tahmin ettiği iyi huylu görüntü sayısı VGGNet-16'dan fazladır. En başarısız sonuçları elde eden SqueezeNet mimarisinin ise doğru tahmin ettiği kötü huylu lezyonların sayısının AlexNet'den fazla olduğu görülmektedir. Fakat gerçekte iyi huylu olan lezyonların 342 tanesini kötü huylu tahmin ederek AlexNet'den daha başarısız sonuç elde etmiştir.

Deneyde kullanılan 6 derin öğrenme mimarisinin Şekil 8'de gösterilen ROC eğrilerine bakıldığında ResNet-34 mimarisinin en yüksek sınıflama başarımı gösterdiği görülmektedir. Sınıflama başarımında VGGNet-16 mimarisi ResNet-34 mimarisine yakın bir değer üretmiştir. DenseNet-121 ve Resnet-18 ise birbirlerine yakın sınıflama başarımına sahiptir. Sınıflama başarımı en düşük olan mimari ortalama %81 ile SqueezeNet olmuştur.

En kötü huylu olan melanomlar, melanositik pigmentlere sahiptir. Veri setinde aynı pigmentlere sahip olan melanositik nevüs görüntülerinin sayısı melanomların sayısının 4 katından fazladır. Bununla birlikte, 7 hastalığı iyi huylu ve kötü huylu olarak ayırdığımızda melanositik olmayan bazal hücreli karsinom ve aktinik keratoz hastalığına ait görüntülerin az olması ve melanositik olmayan iyi huylu cilt lezyonlarına benzemeleri sınıflandırma görevini zorlaştırmaktadır.

Literatürde cilt lezyonlarının sınıflandırılması ile ilgili yapılan çalışmalarda, verilere genellikle görüntü işleme

teknikleri kullanılarak ön-işlem uygulanmıştır (Kassani ve Kassani, 2019). Bazı çalışmalarda ise cilt lezyonlarında bulunan kıl, kabarcık, cetvel izi ve benzeri faktörler temizlenerek sınıflandırma yapılmıştır (Hameed ve ark., 2020).

Bu çalışmada, ham görüntüler sadece yeniden boyutlandırılarak iyi ve kötü huylu cilt lezyonları tespit edilmeye çalışılmıştır. Bununla birlikte elde edilen sınıflandırma sonuçları literatürle karşılaştırıldığında (Kawahara ve ark., 2016; Esteva ve ark., 2017; Lopez ve ark., 2017; Quang, 2017; Harangi, 2017; Ayan ve Ünver, 2018; Kassani ve Kassani, 2019b; Rashid ve ark., 2019) oldukça iyi ve kabul edilebilir düzeydedir.

5. Sonuç

Cilt kanseri dünyada en sık görülen kanserlerin başında yer almaktadır. Bu çalışmada, iyi ve kötü huylu cilt lezyonlarının tespit edilmesi için derin öğrenme tabanlı sınıflandırma gerçekleştirilmiş ve sınıflandırma için kullanılan mimarilerin performansları karşılaştırılmıştır. Derin öğrenme mimarileri verinin temsilinden özellikleri öğrenerek sınıflandırma yapmaktadır. Veri setinin büyüklüğü ve çeşitliliği sınıflandırma performansını artırmaktadır. Bu sebeple, verilerin %60'ı yatay ve dikey çevirmeler, açılı değiştirme, yakınlaştırma, rastgele kontrast ve parlaklık artırma teknikleri ile çoğaltılarak sınıflandırma mimarisinin performansını arttırmak ve aşırı uyumu engellemek amacıyla eğitim aşamasında kullanılmıştır. Deneyler için AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16 mimarileri kullanılmıştır.

Kullanılan veri seti üzerinde yapılan deneyler ResNet-34 mimarisi ile %87,51 sınıflandırma doğruluğu ve %94,04 AUC skoru elde edilmiştir. En başarısız sonuç ise %76,87 sınıflandırma doğruluğu ile SqueezeNet mimarisinden elde edilmiştir. Elde edilen bu sonuçlar, literatürde var olan örnekler ile karşılaştırıldığında tüm cilt kanseri türlerinin tespiti için oldukça başarılı bir performans elde edildiği söylenebilir.

Gelecek çalışmalarda, cilt kanseri tespiti için dermoskopi görüntülerinde bulunan gürültülerden dolayı lezyon bölgesi otomatik bölümlenerek derin öğrenme mimarilerinin ayırt edici özellikleri daha iyi görmesini sağlamak ve sınıflandırıcı hiper-parametrelerinde iyileştirmeler yaparak sınıflandırma başarısının artırılması hedeflenmektedir. Aynı zamanda veri setinde bulunan kötü huylu lezyonların sayısını arttırmak da performansı olumlu yönde etkileyecektir.

Katkı Oranı Beyanı

Tüm yazarlar çalışmaya eşit oranda katkı sağladı. Tüm yazarlar makaleyi inceledi ve onayladı.

Çatışma Beyanı

Yazarlar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Etik Onay

Bu çalışmada, ISIC (Uluslararası Cilt Görüntüleme İşbirliği) 2018'de eğitim seti olarak kullanılan HAM10000 veri seti kullanıldığı için etik kurul onayı gerekmemekte olup temin edilmemiştir.

Kaynaklar

- Abbas Q, Celebi ME, Serrano C, Garcia IF, Ma G. 2013. Pattern classification of dermoscopy images: A perceptually uniform model. *Pattern Recog*, 46(1): 86-97.
- Adegun AA, Viriri S. 2020. FCN-based DenseNet framework for automated detection and classification of skin lesions in dermoscopy images. *IEEE Access*, 8: 150377-150396.
- Anonymous, 2021. Convolutional Neural Networks. URL: <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html> (erişim Tarihi: 10 Mayıs 2021)
- Ayan E, Ünver HM. 2018. Data augmentation importance for classification of skin lesions via deep learning. In: *Proceedings of Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*, 18-19 April 2018, İstanbul, Turkey, pp. 1-4.
- Balaji VR, Suganthi ST, Rajadevi R, Kumar VK, Balaji BS, Pandiyan S. 2020. Skin disease detection and segmentation using dynamic graph cut algorithm and classification through Naive Bayes classifier. *Measurement*, 163: 107922.
- Binder M, Schwarz M, Winkler A, Steiner A, Kaider A, Wolff K, Pehamberger H. 1995. Epiluminescence microscopy: a useful tool for the diagnosis of pigmented skin lesions for formally trained dermatologists. *Archives Dermatol*, 131(3): 286-291.
- Brinker TJ, Hekler A, Utikal J S, Grabe N, Schadendorf D, Klode J, Von Kalle C. 2018. Skin cancer classification using convolutional neural networks: systematic review. *J Medical Internet Res*, 20(10): e11936.
- Capdehourat G, Corez A, Bazzano A, Alonso R, Musé P. 2011. Toward a combined tool to assist dermatologists in melanoma detection from dermoscopic images of pigmented skin lesions. *Pattern Recog Letters*, 32(16): 2187-2196.
- Celebi ME, Iyatomi H, Stoecker WV, Moss RH, Rabinovitz HS, Argenziano G, Soyer HP. 2008. Automatic detection of blue-white veil and related structures in dermoscopy images. *Comput Medical Imaging and Grap*, 32(8): 670-677.
- Celebi ME, Kingravi HA, Uddin B, Iyatomi H, Aslandogan YA, Stoecker WV, Moss RH. 2007. A methodological approach to the classification of dermoscopy images. *Comput Medical Imaging and Grap*, 31(6): 362-373.
- Cinarer G, Emiroglu BG. 2020. Classification of brain tumours using radiomic features on MRI. *New Trends and Issues Proc on Adv in Pure and App Sci*, 12: 80-90.
- Deepak S, Ameer PM. 2019. Brain tumor classification using deep CNN features via transfer learning. *Comp in Biol and Medicine*, 111: 103345.
- Deng L, Yu D. 2014. Deep learning: methods and applications. *Foundations and Trends in Signal Proc*, 7(3-4): 197-387.
- Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, Thrun S. 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639): 115-118.
- Fırıldak K, Talu MF. 2019. Evrimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi. *Bilgisayar Bil*, 4(2): 88-95.
- Garbe C, Peris K, Hauschild A, Saiag P, Middleton M, Spatz A, Eggermont A. 2010. Diagnosis and treatment of melanoma: European consensus-based interdisciplinary guideline. *European J Cancer*, 46(2): 270-283.
- Hameed N, Shabut A M, Ghosh M K, Hossain M A. 2020. Multi-

- class multi-level classification algorithm for skin lesions classification using machine learning techniques. *Expert Sys with App*, 141: 112961.
- Harangi B. 2018. Skin lesion classification with ensembles of deep convolutional neural networks. *J Biomed Informatics*, 86: 25-32.
- He K, Zhang X, Ren S, Sun J. 2016. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778, 27-30 June 2016, Las Vegas, USA.
- Howard J, Gugger S. 2020. Fastai: A layered API for deep learning. *Information*, 11(2): 108.
- Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. 2017. Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, 21-26 July 2017, Honolulu, HI, USA, pp. 4700-4708.
- Iandola FN, Han S, Moskewicz MW, Ashraf K, Dally WJ, Keutzer K. 2016. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*.
- Jerant, AF, Johnson JT, Sheridan CD, Caffrey TJ. 2000. Early detection and treatment of skin cancer. *American Family Physician*, 62(2): 357-368.
- Kassani SH, Kassani PH. 2019. A comparative study of deep learning architectures on melanoma detection. *Tissue and Cell*, 58: 76-83.
- Kawahara J, BenTaieb A, Hamarneh G. 2016. Deep features to classify skin lesions. In: *2016 IEEE 13th International symposium on biomedical imaging (ISBI)*, pp. 1397-1400, 13-16 April 2016, Prague, Czech Republic.
- Khan S, Islam N, Jan Z, Din IU, Rodrigues JJC. 2019. A novel deep learning based framework for the detection and classification of breast cancer using transfer learning. *Pattern Recog Letters*, 125: 1-6.
- Kittler H, Pehamberger H, Wolf K, Binder M. 2002. Diagnostic accuracy of dermoscopy. *The Lancet Oncol*, 3(3): 159-165.
- Krizhevsky A, Sutskever I, Hinton GE. 2012. Imagenet classification with deep convolutional neural networks. *Advances in Neural Inf Proc Sys*, 25: 1097-1105.
- LeCun Y, Bottou L, Bengio Y, Haffner P. 1998. Gradient-based learning applied to document recognition. *IEEE*, 86(11): 2278-2324.
- Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, van der Laak JAWM, van Ginneken B, Sánchez CI. 2017. A survey on deep learning in medical image analysis. *Medical Image Anal*: 42, 60-88.
- Lopez AR, Giro-i-Nieto X, Burdick J, Marques O. 2017. Skin lesion classification from dermoscopic images using deep learning techniques. In: *Proceedings of 13th IASTED International conference on biomedical engineering (BioMed)*, IEEE, February 20 – 21, 2017. Innsbruck, Austria, pp. 49-54.
- Narayanamurthy V, Padmapriya P, Noorasafrin A, Pooja B, Hema K, Nithyakalyani K, Samsuri F. 2018. Skin cancer detection using non-invasive techniques. *RSC Adv*, 8(49): 28095-28130.
- Oliveira RB, Papa JP, Pereira AS, Tavares JMR. 2018. Computational methods for pigmented skin lesion classification in images: review and future trends. *Neural Comput and App*, 29(3): 613-636.
- Pacal I, Karaboga D, Basturk A, Akay B, Nalbantoglu U. 2020. A comprehensive review of deep learning in colon cancer. *Comp in Biol and Medicine*, 126: 104003.
- Premaladha, J, Ravichandran KS. 2016. Novel approaches for diagnosing melanoma skin lesions through supervised and deep learning algorithms. *J Medical Sys*, 40(4): 1-12.
- Psaty EL, Halpern AC. 2009. Current and emerging technologies in melanoma diagnosis: the state of the art. *Clinics in Dermatology*, 27(1): 35-45.
- Purnama IKE, Hernanda AK, Ratna AAP, Nurtanio I, Hidayati AN, Purnomo MH, Rachmadi RF. 2019. Disease classification based on dermoscopic skin images using convolutional neural network in teledermatology system. In: *Proceedings of International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM)*, November 19 - 20, 2019, Surabaya, Cava, pp. 1-5.
- Quang NH. 2017. Automatic skin lesion analysis towards melanoma detection. In: *Proceedings of 21st Asia Pacific Symposium on Intelligent and Evolutionary Systems (IES)*, 15-17 November 2017, Hanoi, Vietnam, pp. 106-111.
- Rashid H, Tanveer MA, Khan HA. 2019. Skin lesion classification using GAN based data augmentation. In: *Proceedings of 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 23-27 July 2019, Berlin, Germany, pp. 916-919.
- Rey-Barroso L, Peña-Gutiérrez S, Yáñez C, Burgos-Fernández FJ, Vilaseca M, Royo S. 2021. Optical Technologies for the Improvement of Skin Cancer Diagnosis: A Review. *Sensors*, 21(1): 252.
- Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, Fei-Fei L. 2015. Imagenet large scale visual recognition challenge. *Int J Comp Vision*, 115(3): 211-252.
- Schmidhuber J. 2015. Deep learning in neural networks: An overview. *Neural Networks*, 61: 85-117.
- Siegel RL, Miller KD, Fuchs HE, Jemal A. 2021. *Cancer Statistics, 2021*. CA: a Cancer J Clinicians, 71(1): 7-33.
- Simonyan K, Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Thomas L, Puig S. 2017. Dermoscopy, digital dermoscopy and other diagnostic tools in the early detection of melanoma and follow-up of high-risk skin cancer patients. *Acta Dermato Venereologica*, 218: 14-21.
- Tschandl P, Rosendahl C, Kittler H. 2018. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific Data*, 5(1): 1-9.
- Xie Y, Zhang J, Xia Y, Shen C. 2020. A mutual bootstrapping model for automated skin lesion segmentation and classification. *IEEE Transact on Medical Imag*, 39(7): 2482-2493.