

Dengesiz Veri Kümelerinde Topluluk Yöntemlerine Dayalı Melanom Sınıflandırılması

Elif KANCA¹, Selen AYAS^{2*}

Öz

Dermoskopi görüntüleme, deri kanseri teşhisi için dermatolojistler tarafından yaygın bir biçimde kullanılan bir tanı metodudur. Dermatolojik değerlendirmenin uzman kişiye bağlı, zaman alıcı ve sübjektif olmasından dolayı otomatik sistemler dermatolojistler tarafından karar verme süreçlerine katkı sağlamaları için tercih edilmektedir. Deri lezyon görüntülerinden melanomların tespit edilmesi hastalığın erken teşhisi ile tedavi sürecini hızlandırarak hastalık ve ölüm oranlarını azaltmaktadır. Bu çalışmada cilt bölgesinden alınan görüntülerden oluşan erişime açık ISIC 2017 veri kümesindeki lezyon bölgelerinin öznitelikleri incelenerek görüntüler melanom ya da nevüs ve seboreik keratoz olarak sınıflandırılmıştır. Melanom verisine ait lezyon özniteliklerini temsil etmek için lezyon bölgesinin şekil, renk ve doku öznitelikleri elde edilmiştir. Çıkarılan öznitelikler k-en yakın komşuluk, destek vektör makineleri ve topluluk öğrenme yöntemlerinden kolay topluluk, RUSBoost, dengelenmiş torbalama ve dengelenmiş rastgele orman sınıflandırıcıları ile sınıflandırılmıştır. Elde edilen sonuçlara göre en iyi sınıflandırma sonuçları sırasıyla %100, %99.17, %99.33 ve %99.58 duyarlılık, özgüllük, doğruluk ve dengeli doğruluk değerleri ile RUSBoost sınıflandırıcısı ile elde edilmiştir. Ulaşılan sonuçlar önerilen öznitelik çıkarma ve sınıflandırma yönteminin lezyon bölgelerinden melanom sınıflandırması için büyük potansiyele sahip olduğunu göstermektedir.

Anahtar Kelimeler: Deri lezyonu sınıflandırma, Şekil ve doku öznitelikleri, Topluluk öğrenme sınıflandırıcıları.

Ensemble Methods-Based Melanoma Classification in Imbalanced Datasets

Abstract

Dermoscopy imaging is a diagnostic method widely used by dermatologists for the diagnosis of skin cancer. Since dermatological evaluation is dependent on the expert, timeconsuming and subjective, automated systems are preferred by dermatologists to contribute to the decision-making processes. Detection of melanomas from skin lesion images accelerates the treatment process together with the early diagnosis of the disease and reduces the morbidity and mortality rates. In this study, the features of the lesion areas in the public ISIC 2017 dataset consisting of images taken from the skin area were examined and the images were classified as melanoma and nevus or seborrheic keratosis. Shape, color and texture features of the lesion areas were obtained to represent the lesion features of the melanoma data. Extracted features were classified by k-nearest neighbor, support vector machines, and ensemble learning classifiers which are easy ensemble, RUSBoost, balanced bagging and balanced random forest classifier. According to the obtained results, the best classification results were obtained with the RUSBoost Classifier with 100%, 99.17%, 99.33% and 99.58% sensitivity, specificity, accuracy and balanced accuracy values, respectively. The achieved results show that the proposed feature extraction and classification method has great potential for melanoma classification from lesion areas.

Keywords: Skin lesion classification, Shape and texture features, Ensemble learning classifiers.

¹Karadeniz Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü, Trabzon, Türkiye, 407969@ogr.ktu.edu.tr

²Karadeniz Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü, Trabzon, Türkiye, selenguyen@ktu.edu.tr

¹<https://orcid.org/0000-0003-4273-9295> ²<https://orcid.org/0000-0002-8226-2359>

1. Giriş

Dünya Sağlık Örgütü'ne göre deri kanseri 2020 yılında yaklaşık 1.20 milyon yeni vaka sayısı ile dünyadaki en sık görülen kanser türleri arasındadır (WHO). Son yıllarda ise yeni vaka ve ölüm oranları hızla yükselmektedir (SCF). Erken teşhis edildiğinde birçok deri kanseri türü tedavi edilerek hastalık ve ölüm oranları önemli ölçüde azalmaktadır. Bu sebeple, doğru ve erken tanı uygun tedavi için oldukça önemlidir (CDC). Dermoskopi, deri lezyonlarının görsel incelenmesine olanak sağlayan, dermatolojistler tarafından yaygın bir biçimde tercih edilen ve müdahale gerektirmeyen bir tanı metodudur. Bu görüntüleme tekniği ile çıplak gözle görülmeyen deri alt yüzeylerinin polarizeli ışık ya da yağ/jel ara yüzü aracılığıyla bir büyütme aleti kullanılarak daha gelişmiş görüntülenmesi sağlanmaktadır (Goodson ve Grossman, 2009; Silveira ve ark. 2009). Dermoskopi görüntülemenin teşhis doğruluğunu artırdığı görülse de manuel görsel inceleme hala dermatolojistin eğitimine bağlı olmakla birlikte oldukça subjektif, hata yapmaya yatkın ve zaman alan bir durumdur (Binder ve ark., 1995; Celebi ve ark., 2008). Bu sebeple otomatik teşhis dermatolojistler tarafından karar verme süreçlerine katkı sağlamaları için sıklıkla tercih edilmektedir.

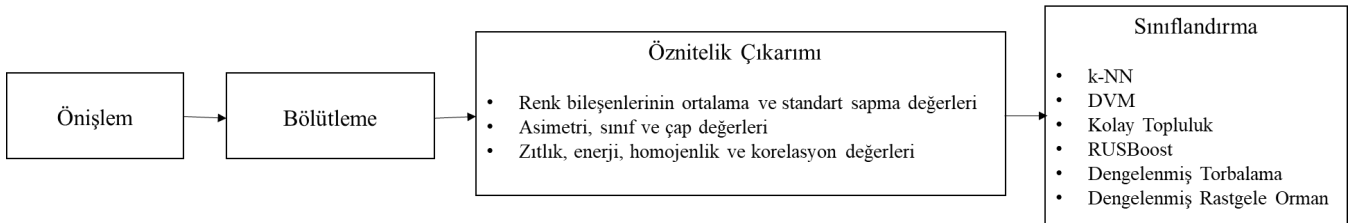
Deri lezyonu analizinde ilk önerilen yaklaşımlar lezyon bölgesi üzerinden el ile çıkartılmış şekil, simetri, renk ve doku gibi düşük seviyeli öznitelikler ile eş oluşum matrisi, ortalama ve varyans gibi istatistiksel doku özniteliklerinin kullanıldığı makine öğrenmesi tabanlı yaklaşımlardır (Celebi ve ark., 2019). Bir diğer çalışmada (Ganster ve ark., 2001) mikroskoptan alınan görüntüler üzerinde öncelikle basit bölütleme yöntemleri ile deri lezyonunun ikili maske görüntüsünü oluşturmuşlardır. Ardından, biçim ve radyometrik öznitelikler ile yerel ve global parametreleri hesaplayarak en belirleyici öznitelikleri öznitelik alt seçimi yöntemleriyle seçmişlerdir. Belirlenen öznitelikler k -en yakın komşuluk (k -NN) yöntemiyle sınıflandırılmıştır. Dermoskopi görüntülerindeki lezyonu arka dokudan ayırmak için otomatik sınır algılama yöntemi farklı bir çalışmada kullanılmıştır (Celebi ve ark., 2007). Elde edilen lezyon bölgesinin şekil, renk ve doku öznitelikleri çıkarılarak en uygun öznitelikler öznitelik seçim algoritmaları ile belirlenmiştir. Geleneksel renk, şekil ve doku öznitelikleri kullanarak lezyon bölgelerini Destek Vektör Makinaları (DVM) yöntemi ile iyi huylu ve kötü huylu olarak sınıflandıran bir başka çalışma literatürde bulunmaktadır (Chang ve ark., 2013).

Bu çalışmada ISIC 2017 (ISIC) yarışmasında açık kullanıma sunulmuş veri kümesi üzerinde verilen problemlerden 'Görev 3: Lezyon Sınıflandırması' üzerinde çalışılmıştır. Literatürde bu veri kümesi üzerinde yapılan çalışmaların büyük çoğunluğu derin öğrenme ağlarının çeşitli birleşimini önermektedir. Bunun yanı sıra, yine bu çalışmaların birçoğunda ISIC 2017 veri kümesinden farklı olarak eğitimde harici veri kümelerini kullanmışlardır. Literatürdeki benzer çalışmalardan farklı olarak çalışmamızda el ile çıkarılan öznitelikler kullanılarak lezyon sınıflandırması gerçekleştirilmiştir. Bu amaçla, veri kümesi görüntüleri üzerinde ön işlem uygulanıp artefaktlar

görüntüden kaldırıldıktan sonra ilgili lezyon bölgesinin doku bilgisinden ayrılması için görüntüler bölütlenmiştir. Daha sonra bölütlenmiş lezyon bölgelerinin şekil özniteliklerinden asimetri, sınır ve çap; renk özniteliklerinden kırmızı, yeşil ve mavi bileşenlerinin ortalama değerleri ve standart sapmaları; ve doku özniteliklerinden zıtlık, enerji, homojenlik ve korelasyon öznitelikleri çıkartılmıştır. Çıkartılan öznitelikler üzerinde k -NN, DVM (Cortes ve Vapnik, 1995) ve topluluk yöntemlerinden Kolay Topluluk (Liu ve ark., 2008), RUSBoost (Seiffert ve ark., 2009), Dengelenmiş Torbalama (Breiman, 1996) ve Dengelenmiş Rastgele Orman (Breiman, 2001) sınıflandırıcıları test edilmiş, sınıflandırıcıların başarısı duyarlılık, özgüllük, doğruluk ve dengeli doğruluk ölçütleri ile karşılaştırılmıştır.

Makalenin devamında, Materyal ve Metod bölümünde çalışma kapsamında kullanılan veri setinin tanıtımı, veri kümesindeki görüntüler üzerinde uygulanan ön işlem ve bölütleme adımları, görüntülerden çıkartılan şekil, doku, renk özniteliklerinin matematiksel tanımları ve ardından çalışmada kullanılan k -NN, DVM ve topluluk yöntemleri sınıflandırıcılarının teorik detayları açıklanmıştır. Daha sonra, Bulgular ve Tartışma başlığı altında sayısal karşılaştırma için kullanılan metrikler verildikten sonra sınıflandırıcılarla elde edilen sonuçlar verilmiştir. Sonuçlar ve Öneriler kısmında ise önerilen yöntemin verimliliği gösterilmiştir.

2. Materyal ve Metot




Şekil 1. Önerilen yöntemin akış diyagramı.

Topluluk yöntemlerine dayalı melanom sınıflandırmasına yönelik önerilen yöntemin akış diyagramı Şekil 1’de verilmektedir. Tüm süreçler bu bölümdeki alt başlıklarda detaylandırılacaktır.

2.1. Veri Seti Tanıtımı

ISIC 2017 yarışmasının sınıflandırma problemi, deri lezyonlarının 3 farklı teşhisini (melanom, nevüs ve seboreik keratoz) içeren 2 bağımsız ikili sınıflandırma problemini çözmek için 2000 eğitim verisi ve 600 test verisinden oluşmaktadır. Eğitim veri kümesi 374 melanom, 254 seboreik keratoz ve 1372 nevüs görüntüsünden oluşmaktadır. Sınıf bilgisi 0 olan görüntü sayısı 374 iken sınıf bilgisi 1 olan görüntü sayısı 1626 olduğundan veri kümesi dengesiz dağılmıştır. Birinci ikili sınıflandırma



Şekil 2. ISIC 2017 birinci ikili sınıflandırma problemindeki eğitim görüntüleri örnekleri: üst satır: melanom; alt satır: nevüs ve seboreik keratoz.

probleminde deri lezyonlarının melanom ile nevüs ve seboreik keratoz arasında sınıflandırılması istenirken ikinci sınıflandırma probleminde seboreik keratoz ile nevüs ve melanom ayrımı istenmektedir. Önerilen çalışma kapsamında ilk ikili sınıflandırma problemi ele alınmıştır. Sınıf etiketi 0 ise lezyon melanom, 1 ise lezyon nevüs ya da seboreik keratozdur. ISIC 2017 veri kümesindeki bazı örnek görüntüler Şekil 2’de verilmektedir.

2.2. Önışlem

Görüntülerin işlenmesi için gereken hesaplama karmaşıklığının düşürülmesi amacıyla öncelikle farklı ve yüksek boyutlara sahip tüm dermoskopi görüntüleri piksel alan ilişkisi kullanarak yeniden örnekleme ile 224×224 boyutuna ölçeklendirilmiştir.

Görüntülerin üzerindeki saç ve cetvel işaretlemeleri gibi artefaktlar bölütleme aşamasında doğru sonuçlar alınmasını engellemektedir. Bu sorunun giderilmesi için dullRazor algoritması (Lee ve ark., 1997) kullanılmıştır. DullRazor algoritmasının işlem adımları şu şekildedir: 1) Küçük detayları kaldırmak için gri seviyeye dönüştürülen görüntü üzerinde morfolojik kapatma işlemi uygulanır, 2) elde edilen görüntü ile gri seviye görüntü arasındaki fark alınır, 3) gürültüyü kaldırmak için fark görüntüsünün maskesine kapatma işlemi uygulanır, 4) artefaktların bulunduğu bölgeleri içeren ikili bir maske oluşturulur, 5) orjinal görüntüden, maskenin kapsadığı pikseller orjinal görüntüye karşılık gelen piksellerle değiştirilir (Messadi ve ark., 2009).

2.3. Bölütleme

Lezyon bölgelerinin görüntü içerisindeki yerlerinin belirlenmesi ve arka plan piksellerinden ayrılması amacıyla yapılan lezyon bölütlemesi melanom sınıflandırmasının en önemli adımını oluşturmaktadır. Dermoskopi görüntülerinde arka plandaki görüntü alımından kaynaklı bozucu gürültü etkilerini ortadan kaldırarak sadece ilgili lezyon bölgesinin sınır çizgilerini elde edebilmek için ön işlemleri tamamlanan RGB renk uzayındaki görüntü HSV renk uzayına dönüştürülmüştür. Bu dönüşüm için görüntünün her bir pikselinin R, G, B değerleri bulunur ve [0,1] arasında normalize edilir (R', G', B'). Normalize edilen değerler arasında maksimum olan değer C_{max} , minimum olan değer ise C_{min} olarak atanır. C_{max} ve C_{min} değerleri arasındaki fark ise Δ değerini oluşturur. Bulunan bu değerler yardımıyla H, S, V değerleri sırasıyla (1-3) eşitlikleriyle hesaplanır. Gauss bulanıklaştırma uygulanan görüntüyle HSV uzayındaki görüntünün ağırlıklı toplamları hesaplanarak yeni bir görüntü elde edilmiştir ve eşikleme uygulanması için gri seviyeye dönüştürülmüştür. Dönüştürülen görüntüye ikili eşikleme ve Otsu eşikleme birlikte uygulanmıştır. Otsu eşiklemede, gri seviyeye dönüştürülen görüntünün histogramı, tek eşik değeri için oluşan ön ve arka piksellerin ağırlığı ($w_{\bar{o}}, w_a$), ortalaması ve varyansları ($V_{\bar{o}}, V_a$) hesaplanır. Son olarak sınıf içi varyans eşitlik (4) ile hesaplanır (Bangare ve ark., 2015).

$$H = \begin{cases} 0^\circ & \Delta = 0 \\ 60^\circ \times \left(\frac{G' - B'}{\Delta} \bmod 6 \right), & C_{max} = R' \\ 60^\circ \times \left(\frac{G' - B'}{\Delta} + 2 \right), & C_{max} = G' \\ 60^\circ \times \left(\frac{R' - G'}{\Delta} + 4 \right), & C_{max} = B' \end{cases} \quad (1)$$

$$S = \begin{cases} 0, & C_{max} = 0 \\ \frac{\Delta}{C_{max}}, & C_{max} \neq 0 \end{cases} \quad (2)$$

$$V = C_{max} \quad (3)$$

$$\text{Sınıf içi varyans} = w_{\bar{o}} \times V_{\bar{o}} + w_a \times V_a \quad (4)$$

2.4. Öznitelik Çıkarımı

Bölütlenmiş görüntünün elde edilmesinden sonra lezyon bölgesinin bazı klinik öznitelikleri çıkarılarak melanom ile nevüs ve seboreik sınıfı birbirinden ayırt edilebilmektedir. Klinik öznitelikler

doku, şekil ve renk öznitelikleri olmak üzere 3 farklı kategoride incelenebilmektedir (Okur ve Turkan, 2018). Renk öznitelikleri bölütlenen lezyon bölgesinin maskesi ile RGB görüntüsü üzerinden her bir renk kanalı için hesaplanmıştır. Çalışma kapsamında renk öznitelikleri olarak RGB renk bileşenlerinin ortalama değerleri ve standart sapma değerleri kullanılmıştır. Şekil öznitelikleri olarak ABCD kuralı (Tsao ve ark., 2015) olarak bilinen ve lezyonun 4 farklı karakteristiğini ortaya koyan asimetri (A-asymmetry), sınır (B-border), renk (C-color) ve çap (D-Diameter) özniteliklerinden asimetri, sınır ve çap özelliği kullanılmıştır. Asimetri özelliği lezyon bölgesinin ikinci dereceden momentiyle aynıdır. Lezyonun en uzun eksen uzunluğu ile en kısa eksen uzunluğu arasındaki uzaklığın oranı olarak tanımlanmakta ve 0 ile 1 arasında değer almaktadır. Sınır özelliği, deri görüntüsü üzerindeki lezyonun sınırını tanımlamaktadır. Melanom oldukça düzensiz bir yapıda pürüzlü kenarlara ve dolayısıyla yüksek sınır değerine sahiptir. Sınır özelliği (5) eşitliği ile hesaplanmaktadır.

$$B = \frac{4 \times p_i \times A}{P^2} \quad (5)$$

Burada B, sınır özelliğini; A, lezyonun alanını ve P, lezyonun çevresini ifade etmektedir. Çap özelliği, lezyonun sınır bölgeleri elde edildikten sonra iki nokta arasında ($p_1 = (x_1, y_1)$ ve ($p_2 = (x_2, y_2)$)) öklid uzaklığı eşitliği kullanılarak hesaplanan en büyük mesafe olarak tanımlanmaktadır. Gri seviye eş oluşum matrisi piksellerin farklı açısız yönlerde ($0^\circ, 45^\circ, 90^\circ, 135^\circ$) uzamsal ilişkilerine dayalı oluşum olasılıklarını ifade eden görüntü öznitelik çıkarımı için kullanılan bir matristir (Sheha ve ark., 2012). Dokusal öznitelikler olarak çalışmada gri seviye eş oluşum histogramı oluşturulmuş ve sırasıyla (6-9) eşitlikleri kullanılarak zıtlık, enerji, homojenlik ve korelasyon öznitelikleri çıkartılmıştır.

$$\text{Zıtlık} = \sum_{i,j=0}^{l-1} P_{i,j} (i - j)^2 \quad (6)$$

$$\text{Enerji} = \sqrt{\sum_{i,j=0}^{l-1} P_{i,j}^2} \quad (7)$$

$$\text{Homojenlik} = \sum_{i,j=0}^{l-1} \frac{P_{i,j}}{1+(i-j)^2} \quad (8)$$

$$\text{Korelasyon} = \sum_{i,j=0}^{l-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (9)$$

Eşitliklerde P, gri seviye eş oluşum histogramını verirken P[*i, j, d, açt*] değeri j. gri seviyenin i. gri seviyeden belirli bir açt değerinde ve *d* uzaklığında meydana gelme sayısını vermektedir. *l* giriş görüntüsünün gri seviyesi sayısını göstermektedir.

2.5. Sınıflandırma

2.5.1. K-En Yakın Komşu Algoritması

k-NN algoritması uzaklık metriği kullanan parametrik olmayan bir danışmanlı öğrenme algoritmasıdır. Sınıflandırılacak olan bir lezyon görüntüsünden çıkarılan öznitelikler, benzer lezyonlarda birbirine yakın olacağı için yakınlık ilişkisi kullanılmaktadır. Yakınlık ilişkisi, eğitim örneklerinden çıkarılan öznitelikler ile yeni bir test örneğinden çıkarılan öznitelikler arasında matematiksel bir uzaklık hesaplaması yapılarak kurulur. Ardından, K tane en yakın komşu seçilerek bu örnekler üzerinde çoğunluk oylaması ile yeni örneğin sınıfı belirlenir. Bu çalışmada (10)'da verilen Öklid uzaklık metriği kullanılmıştır:

$$\text{Öklid uzaklığı} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (10)$$

Burada x_i ve y_i eğitim ve test örneklerinden çıkarılan öznitelik vektörünü ifade etmektedir.

2.5.2. Destek Vektör Makineleri

DVM genellikle sınıflandırma için kullanılan denetimli bir makine öğrenme algoritmasıdır. Bu algorithmada öznitelikler N boyutlu bir uzay (N- öznitelik sayısı) üzerine yerleştirilmiş noktalardır. Bir hiper düzlem ile iki sınıfın noktalarının birbirinden ayrılması ve hiper düzlemin iki sınıfa olan marj mesafesinin maksimum olması amaçlanır. Maksimum olmasındaki amaç ise yeni gelecek olan veri noktalarının daha güvenli bir şekilde sınıflandırılmasını sağlamaktır. Çekirdek fonksiyonları kullanılarak öznitelik vektörleri yüksek boyutlu bir öznitelik uzayına iz düşürülerek bu uzayda doğrusal olarak ayrılmaktadır. Çekirdek fonksiyonu kullanan karar fonksiyonu eşitlik (11) ile tanımlanmaktadır.

$$H(x) = \text{sgn} \left(\sum_{j=1}^l \alpha_j y_j K(x_i, x_j) + b \right) \quad (11)$$

Burada x , giriş vektörünü; y , çıkış sınıf bilgisini ve $K(x_i, x_j)$ çekirdek fonksiyonunu ifade etmektedir. α_i ve b katsayıları (13) eşitliğinde verilen α_i 'ye göre maksimize edilmesi gereken (12) eşitliğinden elde edilmektedir.

$$\max L_D = \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i,j=1}^L \alpha_i \alpha_j y_i y_j K(x_i x_j) \quad (12)$$

$$\text{öyle ki } 0 \leq \alpha_i \leq C, \forall i=1, \dots, L \text{ ve } \sum_{i=1}^L \alpha_i y_i = 0 \quad (13)$$

Burada $C > 0$ düzenleme parametresini ifade etmektedir.

2.5.3. Kolay Topluluk Sınıflandırıcısı

Kolay Topluluk Sınıflandırıcısı, dengesiz olarak dağılmış bir veri setinde azınlık olan sınıfın tüm örneklerini çoğunluk olan sınıfın ise bir alt kümesini seçerek eğitim veri setinde dengeli bir örnekleme oluşturur. Böylece, alt örnekleme yaklaşımları ile yok sayılan çoğunluk olan sınıftan da faydalanılmaktadır.

\mathcal{P} , azınlık olan sınıfın eğitim veri kümesi ve \mathcal{N} , çoğunluk olan sınıfın eğitim veri kümesi olarak verildiğinde alt örnekleme yaklaşımı \mathcal{N} kümesinden T adet \mathcal{N}' rastgele alt kümesi oluşturmaktadır. Her bir \mathcal{N}_i ($1 \leq i \leq T$) alt kümesi için \mathcal{N}_i ve tüm \mathcal{P} kümesi kullanılarak bir H_i sınıflandırıcısı eğitilmektedir. Bu sınıflandırıcıda her bir H_i sınıflandırıcısı AdaBoost (Schapire, 1999) algoritması kullanılarak (14) eşitliği ile eğitilmiştir.

$$H_i(x) = \text{sgn} \left(\sum_{j=1}^{s_i} \alpha_{i,j} h_{i,j}(x) - \theta_i \right) \quad (14)$$

Burada H_i , s_i adet $h_{i,j}$ zayıf sınıflandırıcısını ve bunlara karşılık gelen $\alpha_{i,j}$ ağırlıklı bir Adaboost topluluğunu göstermektedir. θ ise topluluğun eşik değerini göstermektedir. Oluşturulan tüm sınıflandırıcılar sonuç karar için (15) eşitliğindeki gibi birleştirilmektedir.

$$H(x) = \text{sgn} \left(\sum_{i=1}^T \sum_{j=1}^{s_i} \alpha_{i,j} h_{i,j}(x) - \sum_{i=1}^T \theta_i \right) \quad (15)$$

2.5.4. RUSBoost Sınıflandırıcı

RUSBoost dengesiz dağılım gösteren veri setlerinde eğitilen modellerin performansını geliştirmek için tasarlanan veri örnekleme ve yükseltme tabanlı bir algoritmadır. Yöntem temel olarak Adaboost algoritması ile çoğunluk olan sınıftan rastgele bazı örnekleri kaldıran veri örnekleme kavramını birleştiren bir yaklaşım sunmaktadır.

Veri kümesindeki m adet örnekten her birinin (x_i, y_i) ikilisi olarak temsil edildiğini, t 'nin 1 ile maksimum iterasyon sayısı T (topluluktaki sınıflandırıcı sayısı) arasındaki iteratif ilerlemeyi gösterdiğini, h_t 'nin t . adımdaki eğitilmiş zayıf hipotezi ifade ettiğini ve $D_t(i)$ 'nin t . iterasyondaki i . örneği gösterdiğini varsayalım. RUSBoost algoritması bu varsayımlar altında şu şekilde çalışmaktadır:

İlk olarak her örneğin ağırlığı $1/m$ olarak başlangıç değerine ayarlanır. Geçici oluşturulan bir eğitim veri kümesinin $\%N$ 'i (azınlık sınıf tarafından temsil edilecek toplam örneklerin istenen yüzdesi) azınlık sınıfına ait olana kadar çoğunluk sınıfı örneklerini kaldırmak için rastgele alt örnekleme veri kümesine uygulanır. Yeni oluşturulan veri kümesi ve ağırlık dağılımları h_t zayıf hipotezini oluşturacak olan temel sınıflandırıcıya gönderilir. Orijinal eğitim veri seti ve ağırlık dağılımları kullanılarak hata değeri hesaplandıktan sonra ağırlık güncelleme parametresi hesaplanarak sonraki iterasyon için ağırlık dağılımı güncellenir. Tüm bu adımlar T iterasyon sayısı kadar tekrarlandıktan sonra sonuç hipotezi zayıf hipotezlerin ağırlıklı oyu olarak (16) eşitliğindeki gibi döndürülür.

$$H(x) = \underset{y \in Y}{\operatorname{argmax}} \sum_{t=1}^T h_t(x, y) \log \frac{1}{\alpha_t} \quad (16)$$

2.5.5. Dengelenmiş Torbalama Sınıflandırıcısı

Torbalama yöntemi farklı yeniden örneklenmiş verilerden oluşturulmuş sınıflandırıcı oylarını birleştiren bir yaklaşımdır. Yeniden örneklenmiş veriler, orjinal eğitim veri kümesinden yer değiştirme tekniği ile birlikte oluşturulmuş örnekleme yoluyla elde edilir. Her örnek orijinal küme ile aynı boyutta olmaktadır, fakat bazı örnekler yeniden örneklendirilmiş veri kümesinde yokken bazıları birden fazla kez bulunabilir.

Algoritma, N örnekten oluşan bir D eğitim veri kümesi, k adet sınıflandırıcı ve bir öğrenme algoritması verildiğinde öncelikle D eğitim verisinden N boyutlu k yeniden örneklenmiş verileri oluşturmaktadır. Ardından, aynı öğrenme algoritması her bir alt örnek kümesine uygulanarak C_i sınıflandırıcıları oluşturulur ve sonuç topluluğunu oluşturmak için bu sınıflandırıcılar birleştirilir. Sınıflandırıcı sonucu çoğunluk oylamasına göre karar verilmektedir.

Dengelenmiş Torbalama sınıflandırıcısı, Torbalama algoritmasının ek bir dengeleme yaklaşımıyla birleştirilmiş halidir. Dengeleme yaklaşımı olarak, hedef sınıfı yeniden örnekleme için azınlık olan sınıf belirlenerek tüm sınıflar yeniden örneklenirken azınlık olan sınıfta yeniden örnekleme gerçekleştirilmemiştir.

2.5.6. Dengelenmiş Rastgele Orman Sınıflandırıcısı

Rastgele Orman ağaç sınıflandırıcısı topluluğundan oluşan bir topluluk öğrenme yaklaşımıdır. Rastgelelik özelliği eklenerek Torbalama yönteminin geliştirilmiş bir versiyonudur. Veri seti Torbalama yönteminde olduğu gibi orjinal veri kümesinden yer değiştirme tekniği ile üretilir ve her bir düğümde rastgele seçilen değişkenler kullanılarak ağaçlar oluşturulur. Tahmin topluluğun tahminlerinin çoğunluk oylaması şeklinde birleştirilmesiyle gerçekleştirilir.

Ağaç sayısı N ve her bir düğümü bölmek için kullanılan değişken sayısı m , bu yöntemde kullanıcı tarafından tanımlanmaktadır. N adet önyükleme örneği, eğitim veri setinden rastgele seçilir. Önyükleme örneklemede, var olan veri kümesinden rastgele örnekleme ile değiştirilerek yeni bir veri kümesi oluşturulur. Önyükleme örneklerinin büyük bir kısmı ağacı oluşturmak için, yani in-bag veriler, geri kalanı ise out-of-bag (OOB) verileri olarak adlandırılan, ağacın hatasını tahmin etmek için kullanılır. Bu veriler sırasıyla eğitim veri setinin üçte ikisine ve üçte birine karşılık gelirler. In-bag veriler seçildikten sonra ağaç, CART algoritması kullanılarak oluşturulur. Ağacın her bir düğümü için, bilgi kazancı kullanılarak m öznelikleri arasında en iyi bölünme seçilir. Bölünmenin hangi değişkene göre yapılacağına karar verildikten sonra söz konusu değişkenin Gini indeksi hesaplanır. Alt düğümün Gini indeksi bir üst düğümün Gini indeksinden daha az olduğunda o dal başarılı sayılmakta ve Gini indeksi sıfıra ulaştıkça ağaç dallanma işlemi sonlanmaktadır. Önerilen m değeri toplam öznelik sayısının kareköküne eşit olduğunda genel olarak optimum sonuca ulaşılmaktadır. OOB hatasına göre, en fazla OOB hatası veren ağaç en az ağırlık değerine sahip olacak şekilde, oluşturulan ağaca bir ağırlık değeri atanır. Test verilerini sınıflandırırken, her ağaç kendi uç düğümlerinde bir oy verir ve çoğunluk oylamasına göre bir sınıf tahmini yapılır.

Dengelenmiş rastgele orman sınıflandırıcısı yönteminde rastgele ormandaki her yineleme için azınlık sınıftan tüm örnekler alınırken çoğunluk sınıftan aynı sayıda rastgele alt örnekler alınmaktadır (Chen ve ark., 2004). Herhangi bir budama işlemi yapmadan maksimum boyutta bir ağaç oluşturulur ve her düğümde, optimal bölünme için tüm değişkenler arasında arama yapmak yerine rastgele olarak seçilmiş bir dizi değişkende arama yapılır. Bu iki adım istenilen sayıda tekrarlanır ve topluluğun tahminleri toplanarak son sınıf tahmin yapılmış olmaktadır.

3. Bulgular ve Tartışma

Bu çalışmada dengesiz melanom veri setinin topluluk öğrenme yöntemleriyle sınıflandırılması amaçlanmıştır. ISIC 2017 Görev 3 için yayımlanmış veri kümesindeki görüntüler şekil, renk ve doku öznelikleri kullanılarak analiz edilmiştir. Çalışma kapsamında kodlar Python programlama dili kullanılarak yazılmıştır.

3.1. Parametre Analizi

Sınıflandırıcılarda kullanılan parametreler ve parametrelerin değerleri Tablo 1’de verilmiştir. Kolay topluluk sınıflandırıcısında temel sınıflandırıcı olarak AdaBoost, RUSBoost ve Dengelenmiş Torbalama sınıflandırıcılarında ise Gradyan Arttırma kullanılmıştır. Seçilen tüm parametreler en yüksek doğruluğu verecek şekilde deneysel olarak seçilmiştir.

Tablo 1. Çalışma kapsamında kullanılan sınıflandırıcı yöntemlerine ait parametreler ve değerleri

Yöntem	Parametreler
k -NN	$k=2$, uzaklık metriği=öklid
DVM	$c=0.8$, sınıf ağırlığı= dengeli
Kolay Topluluk	Öğrenenlerin sayısı=200
AdaBoost	Öğrenme oranı=0.2, maksimum tahmin edici sayısı=200
RUSBoost	Öğrenme oranı=0.2
Gradyan Arttırma	Öğrenme oranı=0.2, maksimum derinlik=3, güçlendirme aşama sayısı=200
Dengelenmiş Torbalama	Öğrenenlerin sayısı=200
Gradyan Arttırma	Öğrenme oranı=0.2, güçlendirme aşaması s.=200, maksimum derinlik=1
Dengelenmiş Rastgele Orman	Ormandaki ağaç sayısı=705, sınıf ağırlığı= dengeli

k -NN için $k=2$ değeri seçilmiştir ve öklid uzaklık metriği kullanılmıştır. Veri seti dengesiz olarak dağıldığı için DVM yönteminde sınıf ağırlığı, sınıf frekanslarıyla ters orantılı olacak şekilde dengeli olarak ayarlanmıştır. C parametresi ise 0.8 olarak seçilmiştir. Kolay Topluluk Sınıflandırıcısında temel öğrenici olarak AdaBoost kullanılmıştır ve öğrenenlerin sayısı 200 olarak belirlenmiştir. AdaBoost’un öğrenme oranı 0.2 ve yükseltmenin sonlandığı maksimum tahmin edici sayısı 200’dir. RUSBoost Sınıflandırıcısında temel öğrenici Gradyan Arttırma ve öğrenme oranı 0.2 olarak belirlenmiştir. Gradyan Arttırma için öğrenme oranı 0.2, güçlendirme aşamalarının sayısı 200 ve tahmincilerin maksimum derinliği ise 3 seçilmiştir. Dengelenmiş Torbalama Sınıflandırıcısında öğrenenlerin sayısı 200 ve temel öğrenici Gradyan Arttırma olarak seçilmiştir. Gradyan Arttırma için öğrenme oranı 0.2, güçlendirme aşamalarının sayısı 200 ve tahmincilerin maksimum derinliği ise 1 seçilmiştir. Dengelenmiş Rastgele Orman Sınıflandırıcısı için ormandaki ağaç sayısı 705, sınıf ağırlığı dengeli olarak ayarlanmıştır. Seçilen tüm parametreler en yüksek doğruluğu verecek şekilde deneysel bir şekilde seçilmiştir.

3.2. Model Performans Ölçütleri

Önerilen çalışmanın performansını nicel olarak değerlendirmek için duyarlılık, özgüllük, doğruluk ve dengeli doğruluk ölçütleri kullanılmıştır. Duyarlılık, sistemin melanom sınıfını doğru bir şekilde sınıflandırmasını ifade ederken özgüllük, nevüs ve seboreik keratoz sınıfını doğru sınıflandırma ölçüsünü göstermektedir. Doğruluk ise melanom ile nevüs ve seboreik keratoz

arasındaki ayırımın ölçüsüdür. Duyarlılık, özgüllük ve doğruluk, dengeli doğruluk gibi performans ölçütleri sırasıyla (17)-(20)'de hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (17)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (18)$$

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+YN+DN} \quad (19)$$

$$\text{Dengeli Doğruluk} = \frac{(\text{Duyarlılık}+\text{Özgüllük})}{2} \quad (20)$$

Ölçütlerde DP, melanom sınıfına dahil olup melanom olarak algılanan örnek sayısını; YP, nevüs ve seboreik keratoz sınıfına dahil olup melanom olarak algılanan örnek sayısını; DN, nevüs ve seboreik keratoz sınıfına dahil olup nevüs ve seboreik keratoz olarak algılanan örnek sayısını; YN ise melanom sınıfına dahil olup nevüs ve seboreik keratoz olarak algılanan örnek sayısını ifade etmektedir.

3.3. Sayısal Karşılaştırma

Bu çalışmada melanom ile nevüs ve seboreik keratoz lezyonları şekil, renk ve doku öznelikleri kullanılarak geleneksel makine öğrenmesi ve topluluk yaklaşımları ile sınıflandırılmıştır. Elde edilen test sınıflandırma sonuçları Tablo 2'de gösterilmiştir.

Tablo 2. Sınıflandırma Sonuçları

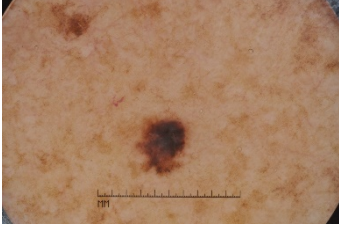
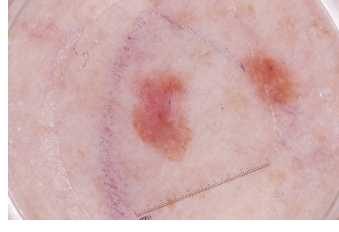

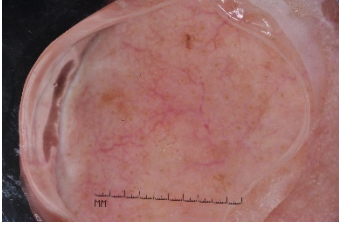
Sınıflandırma Yöntemi	Duyarlılık	Özgüllük	Doğruluk	Dengeli Doğruluk
<i>k</i> -NN	%25.64	%79.99	%69.33	%52.77
DVM	%51.28	%51.12	%51.15	%51.21
Kolay Topluluk	%76.06	%58.38	%61.83	%67.22
RUSBoost	%100	%99.17	%99.33	%99.58
Dengelenmiş Torbalama	%68.37	%67.08	%67.33	%67.72
Dengelenmiş Rastgele Orman	%65.10	%65.42	%64.16	%64.76

Geleneksel makine öğrenmesi yaklaşımlarından *k*-NN yöntemi ile %25.64 duyarlılık ve %79.99 özgüllük elde edilirken DVM yöntemiyle duyarlılığın %51.28'e yükseldiği ve özgüllüğün %51.12'ye düştüğü görülmektedir. Dengesiz veri kümelerinde sınıflandırıcı performansını incelemek için dengeli doğruluk metriği daha doğru ve kıyaslanabilir sonuçlar göstermektedir. Dengeli doğruluk değerine bakıldığında iki yöntemin de yaklaşık %52'lik bir başarıya sahip olduğu görülmektedir.

Dengesiz veri kümelerini farklı tekniklerle dengeleyen topluluk sınıflandırıcı sonuçları incelendiğinde %65.10 ile %100 duyarlılık, %58.38 ile %99.17 özgüllük, %61.83 ile %99.33

doğruluk ve %64.76 ile %99.58 dengeli doğruluk değeri hesaplanmıştır. Geleneksel makine öğrenmesi yaklaşımları ile kıyaslandığında elde edilen sonuçların genel olarak daha başarılı olduğu görülmektedir. Topluluk yöntemleri tabanlı sonuçlara göre %64.76 dengeli doğruluğu ile en düşük sınıflandırma doğruluğu Dengelenmiş Rastgele Orman yöntemi ile elde edilirken %99.58 dengeli doğruluğu ile en yüksek sınıflandırma doğruluğu RUSBoost yöntemi ile elde edilmiştir. Bazı örnek test görüntüleri için sınıflandırma sonucunda elde edilen sınıf etiketleri ile gerçek etiketlerin karşılaştırma sonuçları Tablo 3'te verilmiştir.

Tablo 3. Örnek Test Görüntülerinin Tahmin Edilen Sınıf Etiketleri ile Gerçek Etiketleri

Test Görüntüleri	Tahmin Edilen Sınıf Etiketleri	Gerçek Etiket
	<p>k-NN: nevüs veya seboreik keratoz DVM: nevüs veya seboreik keratoz Kolay Topluluk: nevüs veya seboreik keratoz RUSBoost: melanom Dengelenmiş Torbalama: nevüs veya seboreik keratoz Dengelenmiş Rastgele Orman: nevüs veya seboreik keratoz</p>	Melanom
	<p>k-NN: nevüs veya seboreik keratoz DVM: nevüs veya seboreik keratoz Kolay Topluluk: nevüs veya seboreik keratoz RUSBoost: melanom Dengelenmiş Torbalama: nevüs veya seboreik keratoz Dengelenmiş Rastgele Orman: nevüs veya seboreik keratoz</p>	Melanom
	<p>k-NN: nevüs veya seboreik keratoz DVM: nevüs veya seboreik keratoz Kolay Topluluk: nevüs veya seboreik keratoz RUSBoost: melanom Dengelenmiş Torbalama: nevüs veya seboreik keratoz Dengelenmiş Rastgele Orman: nevüs veya seboreik keratoz</p>	Melanom
	<p>k-NN: melanom DVM: melanom Kolay Topluluk: melanom RUSBoost: nevüs veya seboreik keratoz Dengelenmiş Torbalama: melanom Dengelenmiş Rastgele Orman: melanom</p>	Nevüs veya seboreik keratoz

4. Sonuçlar ve Öneriler

Bu çalışmada cilt lezyon görüntülerinden şekil, renk ve doku öznelikleri çıkartılarak görüntüler melanom ya da nevüs ve seboreik keratoz olarak sınıflandırılmıştır. Sınıflandırma

işlemleri k -en yakın komşuluk, destek vektör makineleri ve topluluk öğrenme yöntemlerinden kolay topluluk, RUSBoost, dengelenmiş torbalama ve dengelenmiş rastgele orman sınıflandırıcıları ile yapılmıştır. Elde edilen sonuçlara ve diğer sınıflandırıcılarla yapılan karşılaştırma sonuçlarına göre en yüksek %100 duyarlılık, %99.17 özgülük, %99.33 doğruluk ve %99.58 dengeli doğruluk RUSBoost sınıflandırıcısı ile hesaplanmıştır. Ayrıca önerilen yöntem ISIC 2017 dengesiz veri kümesi üzerinde uygulanıp test edildiğinden geleneksel makine öğrenmesi yaklaşımlarından olan k -NN ve DVM'nin performansının %25 ile %52 değerleri arasında kaldığı gözlemlenmiştir. Buna karşın, topluluk öğrenmesi tabanlı dengelenmiş yaklaşımların performansı %58-%100 arasında hesaplanmıştır. Bu sonuçlar geleneksel makine öğrenmesi yaklaşımlarıyla dengelenmiş topluluk öğrenmesi yaklaşımlarının sınıflandırma performansı arasında dikkat çekici bir fark olduğunu göstermektedir.

Sonuçların başarısını analiz etmek için farklı yöntemler ile elde edilen sınıflandırma doğrulukları yine ISIC 2017 veri kümesi kullanılarak yapılan çalışmalar ile karşılaştırılmıştır. Yapılan karşılaştırmalar Tablo 4'te verilmiştir. Tablo 4'te yer alan “-” simgesi çalışmalarda bildirilmemiş sonuçları göstermektedir. Çalışmaları kısaca özetlemek gerekirse:

Thao ve ark., ISIC 2017 veri kümesindeki 2000 eğitim görüntüsünü döndürme, yakınlaştırma gibi farklı veri arttırma yöntemleriyle 6000 görüntüye çıkarmışlardır. Oluşan yeni görüntüleri 5400 eğitim ve 600 doğrulama olarak ayırmışlardır. Verileri 18 katmandan oluşan basit ConvNet mimarisi ve transfer öğrenimi kullanan VGG16 ile sınıflandırmışlardır. Her bir model performans ölçütü için sınıflandırma sonuçlarının ortalaması alınarak nihai sonuçlar elde edilmiştir. Li ve ark., 2000 lezyon eğitim görüntülerini x veya y ekseninde döndürerek eğitim verilerini arttırmışlardır. Lezyonların segmentasyonunu ve sınıflandırması aynı anda gerçekleştirmek için lezyon indeksleme ağını önermişlerdir. Bu ağ FCRN-50 ağına eklenen artık modülde yeni bir artık modülü kullanan daha derin bir model olan FCRN-88'tir. Önerdikleri ağ modeli 3 farklı deri lezyonu görüntü işleme görevini yerine getirerek %49 oranında duyarlılık değeri elde etmiştir. Khoulood ve ark., eğitim veri kümesindeki görüntülere ilk olarak Gauss filtresi uygulamışlardır, daha sonra görüntülerin lezyon alanlarını kırpılmışlardır ve görüntüleri 180x180 olarak yeniden boyutlandırmışlardır. W-Net ağı ile segmente edilen görüntüler daha sonra Inception-ResNet ağı ile sınıflandırılmış ve %95.2 oranında bir duyarlılık değeri elde etmişlerdir. Yılmaz ve ark., hesaplama karmaşıklığını gidermek için ISIC 2017 veri kümesindeki görüntüleri 224x224 boyutuna yeniden boyutlandırmışlardır ve veri arttırma yöntemi uygulamışlardır. MobileNet, MobilNetV2 ve NasNetMobile mimarileri yığın boyutları 16, 32 ve 64 olacak şekilde kullanılıp eğitilmiş ve 9 model ortaya çıkarmışlardır. En yüksek doğruluğu NasNetMobile modeli ile %82.0 oranında elde etmişlerdir.

Tablo 4. Sınıflandırma Karşılaştırması

Sınıflandırma Yöntemi	Duyarlılık	Özgüllük	Doğruluk	Dengeli Doğruluk
(Thao ve ark., 2017)	%86.9	%44.2	%51.5	-
(Li ve ark., 2018)	%49.0	%96.1	%85.7	-
(Khouloud ve ark., 2021)	%95.2	%97.9	%96.9	-
(Yılmaz ve ark., 2021)	-	-	%82.0	-
RUSBoost	%100	%99.17	%99.33	%99.58

Önerilen dengesiz veri kümelerinde topluluk yöntemlerine dayalı sınıflandırma yaklaşımının literatürdeki çalışmalara kıyasla daha yüksek duyarlılık, özgüllük ve doğruluk değerlerine sahip olduğu gösterilmiştir. Sonuç olarak, önerilen yaklaşımın melanom ve nevüs ve seboreik keratoz sınıflandırmasında başarılı bir şekilde uygulanabileceği düşünülmektedir.

Teşekkür

Bu kısımda çalışmada yardımları ya da destekleri bulunan kişi veya kişilere ya da kurumlara teşekkür edilebilir.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Bangare, S. L., Dubal, A., Bangare, P. S. ve Patil, S. T. (2015). Reviewing Otsu's Method for Image Thresholding. *International Journal of Applied Engineering Research*, 10(9), 21777-21783.
- Binder, M., Schwarz, M., Winkler, A., Steiner, A., Kaider, A., Wolff, K. ve Pehamberger, H. (1995). Epiluminescence Microscopy: A Useful Tool for The Diagnosis of Pigmented Skin Lesions for Formally Trained Dermatologists. *Archives of Dermatology*, 131(3), 286-291.
- Breiman, L. (1996). Bagging Predictors. *Machine Learning*, 24(2), 123-140.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.
- Celebi, M. E., Kingravi, H. A., Uddin, B., Iyatomi, H., Aslandogan, Y. A., Stoecker, W. V. ve Moss, R. H. (2007). A Methodological Approach to The Classification of Dermoscopy Images. *Computerized Medical Imaging and Graphics*, 31(6), 362-373.

- Celebi, M. E., Iyatomi, H., Stoecker, W. V., Moss, R. H., Rabinovitz, H. S., Argenziano, G. ve Soyer, H. P. (2008). Automatic Detection of Blue-White Veil and Related Structures in Dermoscopy Images. *Computerized Medical Imaging and Graphics*, 32(8), 670-677.
- Celebi, M. E., Codella, N. ve Halpern, A. (2019). Dermoscopy Image Analysis: Overview and Future Directions. *IEEE Journal of Biomedical and Health Informatics*, 23(2), 474-478.
- Chang, W. Y., Huang, A., Yang, C. Y., Lee, C. H., Chen, Y. C., Wu, T. Y. ve Chen, G. S. (2013). Computer-Aided Diagnosis of Skin Lesions Using Conventional Digital Photography: A Reliability and Feasibility Study. *PloS one*, 8(11), e76212.
- Chen, C., Liaw, A. ve Breiman, L. (2004). Using Random Forest to Learn Imbalanced Data. *Technical Report, Berkeley*.
- Cortes, C. ve Vapnik, V. (1995). Support Vector Machines. *Machine Learning*, 20, 273-297.
- Ganster, H., Pinz, P., Rohrer, R., Wildling, E., Binder, M. ve Kittler, H. (2001). Automated Melanoma Recognition. *IEEE Transactions on Medical Imaging*, 20(3), 233-239.
- Goodson, A. G. ve Grossman, D. (2009). Strategies for Early Melanoma Detection: Approaches to The Patient with Nevi. *Journal of the American Academy of Dermatology*, 60(5), 719-735.
- Khoulood, S., Ahlem, M., Fadel, T., & Amel, S. (2022). W-net and inception residual network for skin lesion segmentation and classification. *Applied Intelligence*, 52(4), 3976-3994.
- Lee, T., Ng, V., Gallagher, R., Coldman, A. ve McLean, D. (1997). Dullrazor®: A Software Approach to Hair Removal from Images. *Computers in Biology and Medicine*, 27(6), 533-543.
- Li, Y. ve Shen, L. (2018). Skin Lesion Analysis Towards Melanoma Detection using Deep Learning Network. *Sensors*, 18(2), 556.
- Liu, X. Y., Wu, J. ve Zhou, Z. H. (2008). Exploratory Undersampling for Class-Imbalance Learning. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 39(2), 539-550.
- Messadi, M., Bessaid, A. ve Taleb-Ahmed, A. (2009). Extraction of Specific Parameters for Skin Tumour Classification. *Journal of Medical Engineering & Technology*, 33(4), 288-295.
- Okur, E. Ve Turkan, M. (2018). A Survey on Automated Melanoma Detection. *Engineering Applications of Artificial Intelligence*, 73, 50-67.
- Schapire, R. E. (1999, Temmuz). A Brief Introduction to Boosting. International Joint Conference on Artificial Intelligence (s. 1401-1406). Stockholm, İsveç.
- Seiffert, C., Khoshgoftaar, T. M., Van Hulse, J. ve Napolitano, A. (2009). RUSBoost: A Hybrid Approach to Alleviating Class Imbalance. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 40(1), 185-197.
- Sheha, M. A., Mabrouk, M. S. ve Sharawy, A. (2012). Automatic Detection of Melanoma Skin Cancer Using Texture Analysis. *International Journal of Computer Applications*, 42(20), 22-26.
- Silveira, M., Nascimento, J. C., Marques, J. S., Marçal, A. R., Mendonça, T., Yamauchi, S., Maeda, J. ve Rozeira, J. (2009). Comparison of Segmentation Methods for Melanoma Diagnosis in Dermoscopy Images. *IEEE Journal of Selected Topics in Signal Processing*, 3(1), 35-45.
- Thao, L.T., ve Quang, N.H. (2017). Automatic Skin Lesion Analysis Towards Melanoma Detection. 21st Asia Pacific Symposium on Intelligent and Evolutionary Systems (s.106-111). Hanoi, Vietnam.
- Tsao, H., Olazagasti, J. M., Cordero, K. M., Brewer, J. D., Taylor, S. C., Bordeaux, J. S., Chren, M. -M., Sober, A. J., Tegeler, C., Bhushan, R. ve Begolka, W. S. (2015). Early Detection of Melanoma: Reviewing The ABCDEs. *Journal of the American Academy of Dermatology*, 72(4), 717-723.
- Yılmaz, A., Kalebaşı, M., Samoylenko, Y., Güvenilir, M. E. ve Uvet, H. (2021). Benchmarking of Lightweight Deep Learning Architectures for Skin Cancer Classification using ISIC 2017 Dataset. arXiv preprint , vol.1, no.1, 1-2.

ISIC: <https://challenge.isicarchive.com/>, (Erişim Tarihi: 28 Nisan 2022).

ISIC2017: <https://challenge.isic-archive.com/landing/2017/44/>, (Erişim Tarihi: 28 Nisan 2022).

WHO: <https://www.who.int/news-room/fact-sheets/detail/cancer>, (Erişim Tarihi: 28 Nisan 2022).

SCF: <https://www.skincancer.org/>, (Erişim Tarihi: 28 Nisan 2022).

CDC: <https://www.cdc.gov/cancer/skin/>, (Erişim Tarihi: 28 Nisan 2022).