



# Dermoskopik Görüntülerdeki Melanomun Çoklu Makine Öğrenmesi Sınıflandırıcıları ile Tespiti Detection of Melanoma with Multiple Machine Learning Classifiers in Dermoscopy Images

Uğur Emre Yıldız ve Volkan Kılıç

Elektrik-Elektronik Mühendisliği, İzmir Katip Çelebi Üniversitesi, İzmir, Türkiye  
y180207002@ogr.ikc.edu.tr, volkan.kilic@ikc.edu.tr

**Özetçe** —Cilt kanseri vakaları, son yıllarda atmosferdeki ozon tabakasının incelmeye başlaması ve delinmesi sonucunda Ultraviyole ışınlarının etkisinin artmasıyla giderek yaygınlaşmıştır. Cilt kanseri türleri arasında en ölümcül olanlarından birisi olan melanomun erken teşhiste yüksek oranda tedavi edilebilmesi, bu alandaki çalışmalara olan ilgiyi arttırmıştır. Bu çalışmada dermoskopik görüntülerdeki melanomun teşhisinde kullanılacak makine öğrenmesi yaklaşımları üzerine odaklanılmıştır. İlk adımda dermoskopik görüntü veri tabanından erişilen fotoğraflara görüntü işleme teknikleri uygulanarak renk ve doku özellikleri çıkarılmıştır. İkinci adımda ise bu özellikler kullanılarak, farklı programlama ortamlarında makine öğrenmesi sınıflandırıcıları eğitilmiş ve test edilmiştir. Önerilen yöntemden elde edilen sonuçlar melanomun % 97 doğrulukla tespit edilebileceğini göstermiştir.

**Anahtar Kelimeler**—makine öğrenmesi; melanom; görüntü işleme.

**Abstract**—Skin cancer cases, in recent years, has become increasingly widespread because of increasing the effect of ultraviolet radiation as a result of thinning and perforation of the ozone layer in the atmosphere. The fact that melanoma, one of the most lethal types of skin cancer, can be treated at a high rate in early diagnosis has increased the interest in the studies in this field. In this study is focused on machine learning approaches that can be used in the diagnosis of melanoma in dermoscopic images. In the first step, color and texture features of images accessed from the dermoscopic image database were extracted with image processing techniques. In the second step, by using these features machine learning classifiers in different program environments have been trained and tested. Results from the proposed method indicated that melanoma can be detected with 97 % accuracy.

**Keywords**—machine learning; melanoma; image processing.

## I. GİRİŞ

Cilt hücrelerinin anormal büyümesi olarak özetlenebilen cilt kanseri, Amerikan Kanser Topluluğu'nun araştırmalarına göre tüm kanser türleri arasında en yaygın olanıdır [1]. Cilt kanserinin birçok türünden birisi olan melanom ise diğer türlere nazaran daha az görülmesine rağmen, Dünya Sağlık Örgütü'nün yaptığı araştırmaya göre cilt kanserine bağlı ölümlerin başlıca sebebidir [2]. Bu nedenle melanomu önlemeye yönelik çalışmalara olan ilgi giderek artmaktadır.

Yapay zekâ çalışmalarına katlanarak artan ilgi, biyomedikal alanındaki çalışmalarına da katkı sağlamaktadır [3]. Yapay zekânın bir kolu olan makine öğrenmesinin sınıflandırma dalına ait çalışmalar melanom üzerinde de yapılmakta [4], [5] ve çeşitli görüntü işleme yöntemleri ile sonuçlar alınmaktadır [6]–[12]. Sinir ağları ve makine öğrenmesinin kümeleme dalına ait yöntemler kullanılarak yapılan çalışmalar da bu hastalığın farklı açılardan tespitine olanak sunmaktadır [13], [14]. Büyük miktarda etiketlenmiş eğitim verilerinin kullanılması ve algılanması ile ilgili makine öğrenmesinin bir dalı olan “derin öğrenme” çalışmaları da medikal görüntü analizi için uygulanabilmektedir [15]. Derin öğrenme çalışmaları melanomun tespiti için de yapılmakta [16], hatta hangi cilt kanseri türünün hangi aşamada olduğuna kadar tespit edilebilmektedir [17]. Kliniklerde çıplak gözle melanom teşhisi konulurken yaşanabilen insan kaynaklı hatalar Literatürdeki çalışmalar sayesinde azalmış, hastalığa erken teşhis imkanı sağlanmıştır. Bu çalışmanın literatürdeki diğer çalışmalardan farkı ise renk özelliklerine ek olarak doku özelliklerinin seçilmesidir. Seçilen bu doku özelliklerinin ayırt ediciliği sayesinde sınıflandırıcıların performansı artırılmıştır.


Bildirinin sonraki bölümleri şu şekilde düzenlenmiştir. Bölüm II’de ön işleme adımları, öznelik çıkarımı ve sınıflandırıcılar tanıtılacaktır. Bölüm III’te ise elde edilen sonuçlar literatürdeki yöntemlerle karşılaştırılarak tartışılacaktır. Vargılar bölümünde ise yapılan çalışmalar özetlenip hedefler anlatılacaktır.

## II. ÖNERİLEN YÖNTEM

Bu bölümde kullanılan yöntemler, öznelik çıkarma işlemleri ve sınıflandırıcılar ile bu işlemlerin yapıldığı programlama ortamları tanıtılacaktır.

### A. Ön İşleme

Bu çalışmada, Portekiz Matosinhos’ta Pedro Hispano Hastanesi Dermatoloji servisinin açık erişime sunduğu  $PH^2$  veri tabanı kullanılmıştır [18]. Veri tabanı, 160’ı melanom olmayan, 40’ı melanomlu olmak üzere 8-bit RGB (kırmızı, yeşil, mavi) formatında, bmp (bitmap) uzantılı 768x560 boyutlarındaki 200 görüntüden oluşmaktadır. Ayrıca, her bir görüntünün melanomlu olup olmadığı ve ben rengi gibi bilgilerin bulunduğu tablo da veri tabanında mevcuttur. Algısal olarak homojen dağılıma sahip bir renk uzayının kullanılması tıbbi görün-



Şekil 1: (a)'da sağlıklı ben (b)'de melanom teşhisi konmuş ben görülmektedir.

telemeye doğru tahmine yönelik başarı oranını daha yüksek seviyeye çıkarmaktadır [6]. Bu nedenle RGB renk uzayı yerine insanın görme mekanizmasıyla daha benzer olan Renk Özütü (Hue), Doymunluk (Saturation) ve Parlaklık (Brightness) renk kanallarından oluşan HSV renk uzayı tercih edilmiştir [19]. Görüntüler RGB' den HSV formatına MATLAB ortamında dönüştürülmüştür. Veri setinden alınmış melanomlu olan ve olmayan iki örnek Şekil 1'de görülmektedir.

## B. Öznitelik Çıkarımı

Makine öğrenmesi sınıflandırıcılarında kullanılmak üzere HSV'ye dönüştürülmüş görüntülerden özniteliklerin çıkarılması gerekmektedir. Özniteliklerin ayırt ediciliği sınıflandırıcılarının başarısıyla doğru orantılıdır. Burada renk ve doku özniteliklerinin çıkarma işlemleri anlatılacaktır.

1) *Renk özniteliği çıkarımı*: Renk özniteliği çıkarma aşamasında, HSV formatındaki görüntülerin her bir kanalındaki ortalama, maksimum ve standart sapma değerlerinden oluşan renk varyasyonu kullanılmıştır. MATLAB ortamında, ortalama renk özütü, ortalama doymunluk, ortalama parlaklık, maksimum renk özütü, maksimum doymunluk, maksimum parlaklık, standart sapma renk özütü, standart sapma doymunluk, standart sapma parlaklık olmak üzere dokuz öznitelik elde edilmiştir.

2) *Doku özniteliği çıkarımı*: Renk öznitelikleri çıkarıldıktan sonra makine öğrenmesi sınıflandırıcılarının doğruluğunu yükseltmek için doku öznitelikleri çıkarılmıştır. Doku öznitelikleri, görüntünün yoğunluk ve renk geçişlerine bağlı olarak yorumlanmasını sağlayan istatistiksel özniteliklerdir [6]. Deri lezyonlarının yapısına ve biçimine göre yapılan doku analizi, sınıflandırıcılar için uygun bir öznitelik olarak kullanılabilir. Gri seviye eş oluşum matrisi (Gray Level Co-Occurrence Matrix) doku analizinden özniteliklerin hesaplanmasında en sık kullanılan yöntemlerden biridir. Doku analizi altında kontrast, enerji, homojenlik ve korelasyon olmak üzere dört farklı doku özniteliği çıkarımı yapılmaktadır. Ancak bu çıkarım işleminin gri renk formatında yapılması gerektiğinden görüntüler gri formata dönüştürülmüştür. Renk ve doku özniteliklerinin oluşturduğu toplam 13 öznitelige ayrıca her bir görüntünün melanom olup olmadığını belirten çıktı bilgisi de eklenmiştir. Veri tabanındaki 200 görüntünün her birine ait 14 öznitelik programlama ortamlarındaki sınıflandırıcılarda kullanılacaktır.

## C. Sınıflandırıcılar

Öznitelikler çıkarıldıktan sonra MATLAB, Python ve Weka programlarının kendilerine özgü makine öğrenmesi kütüphane ve araç kutuları kullanılarak sınıflandırma işlemi yapılmıştır. Kullanılan sınıflandırıcıların özellikleri ise şöyledir:

1) *Destek vektör makinesi sınıflandırıcısı*: Destek vektör makinesi (Support Vector Machine - SVM), farklı sınıflara ait verileri belirlemek için en uygun şekilde bir doğru kesiti (hyperplane) oluşturan eğitmenli (supervised) bir makine öğrenmesi modelidir [20]. Eğitmenli makine öğrenmesi modellerinde veri kümesindeki verilerin girdi niteliklerine göre hangi çıktıları vereceği belirlenmiştir. SVM'de doğru kesiti bir sınır olarak düşünülebilir ve bu sınırın çizileceği yer ise farklı sınıfın üyelerine en uzak olacak şekilde belirlenir [21]. Veri dağılımına göre sınır ya doğrusal (linear) ya da doğrusal olmayacak şekilde belirlenebilir.

$$f(x) = \text{sign}(w^t x_i + b) \quad (1)$$

Burada  $f(x)$  sınıflandırıcıya,  $w^t$  ağırlıklardan oluşan  $N$ -boyuttaki bir vektöre,  $b$  ise yanlılık terimine karşılık gelmekte [22] ve ikili sınıflandırma problemlerinde kullanılır.

Doğrusal olarak istenilen şekilde ayrılamayan veri setlerinde Kernel SVM (Çekirdek SVM) kullanılır. Çekirdek fonksiyonu olarak da polinomsal (derece temelli) ve Gaussian (varyans temelli) metotlar sıklıkla tercih edilir. Derece temelli çekirdek fonksiyonu kuadratik (2. dereceden), ya da kübik (3. dereceden) olabilir.

$$\psi(x, x_i) = e^{-\frac{\|x - x_i\|^2}{2\sigma^2}} \quad (2)$$

Burada  $\sigma^2$  bu fonksiyonun varyansını tanımlamakta,  $\psi(x, x_i)$  çekirdek fonksiyonu olup radyal taban fonksiyonu olarak kullanılmıştır.

2) *Torbalama sınıflandırıcısı (Bagging classifier-BC)*: Birden fazla sınıflandırıcıyı bir arada kullanıp sonuçlarını birleştiren sınıflandırma tipleri makine öğrenmesi yöntemleri olarak sıklıkla tercih edilmektedir [23]. Bu yöntemler genel olarak torbalanma (bagging) ve takviyeli sınıflandırma (boosting) olarak ayrılırlar. Torbalanma sınıflandırma yönteminde ardışık karar ağaçları (decision trees), birbirinden bağımsız olarak veri kümesindeki bir önyüklemeye (bootstrapping) örneği kullanılarak oluşturulur [24]. Projede kullanılan sınıflandırıcılardan da birisi olan Bagging Trees metodunun sonucunda ise salt çoğunluk kullanarak tahmin gerçekleştirir. Takviyeli sınıflandırma yönteminde ise karar ağaçları önceki tahmin edicilerle bağlıdır. Önceki tahminlere bağlı olarak yapılan yanlış tahminlere fazladan ağırlık verilir.

3)  $\kappa$  - en yakın komşu sınıflandırıcısı:  $\kappa$  en yakın komşu sınıflandırma algoritması ( $\kappa$  Nearest Neighbor -  $\kappa$ NN), eğitmenli bir sınıflandırma algoritmasıdır.  $\kappa$ NN yeni bir örnek geldiğinde var olan öğrenme verisinden faydalanarak, sınıflandırma yapılması esasına dayanan örnek tabanlı bir sınıflandırma algoritmasıdır [25]. Yeni örneğin sınıfı, en yakın sınıfı bilinen  $\kappa$  kadar komşusunun sınıfına göre belirlenir.  $\kappa$ NN sınıflandırma algoritmasında temel parametreler mesafe metriği (distance metric) ve  $\kappa$  değeridir.  $\kappa$  değeri bahsedildiği gibi sınıfına bakılacak komşu sayısıdır. Bir diğer parametre olan mesafe metriği olarak ise literatürde öklit mesafesi (euclidean distance) kullanılabilir [26]. Öklit uzaklığı  $d$ , kartezyen koordinat sisteminde  $m$ - boyutlu uzayda bulunan  $\mathbf{p} = (p_1, p_2, \dots, p_m)$  ve  $\mathbf{q} = (q_1, q_2, \dots, q_m)$  olan 2 nokta arasında  $d(\mathbf{p}, \mathbf{q})$  olarak gösterilir ve  $d(\mathbf{p}, \mathbf{q}) = d(\mathbf{q}, \mathbf{p}) = \sqrt{\sum_{i=1}^m (q_i - p_i)^2}$  eşitliğiyle hesaplanır.

4) *Lojistik regresyon*: Lojistik regresyon (Logistic Regression - LR), eğitilmiş makine öğrenmesi modelidir ve ikili sınıflama gereken algoritmalarda sıklıkla tercih edilir. Lojistik regresyonda sınıflandırma işlemi, örnek uzaydaki verileri bir doğru yardımıyla ikiye bölerek yapılır ve uzayın ayrılan kısımları iki ayrı sınıf olarak düşünülür. Bu çalışmada ikili sınıflandırma algoritması (melanomlu ya da değil) gerektiğinden lojistik regresyon sınıflandırıcı algoritması tercih edilmiştir.

#### D. Yazılım Araçları

Burada sınıflandırıcıların uygulandığı yazılım ortamlarından bahsedilecektir. Projede, Weka, MATLAB ve Python geliştirme ortamlarından faydalanılmıştır.

1) *Weka*: Kullanılan programlardan biri olan Weka Waikato Üniversitesi'nde geliştirilmiştir ve makine öğrenmesi alanında sıklıkla kullanılmaktadır [27]. Weka programının 3.8 versiyonu kullanılmış olup kütüphanesinde bulunan SVM, LR, BC ve  $\kappa$ NN sınıflandırıcıları ile sonuçlar alınmıştır.

2) *MATLAB*: Kullanılan bir diğer program olan MATLAB, MathWorks tarafından geliştirilmiş olup 2018b sürümü kullanılmıştır. Bu çalışmada, Classification Learner araç kutusunda yer alan SVM, LR, BC ve  $\kappa$ NN algoritmaları kullanılmış ve sonuçları karşılaştırılmıştır.

3) *Python*: Python makine öğrenmesi alanında son yıllarda içerdiği kütüphaneler ve sunduğu araçlar nedeniyle giderek popüler hale gelmiştir. Bu çalışmada Python programının 3.7 sürümü tercih edilmiş olup makine öğrenmesi komutlarını içeren "Scikit-Learn" kütüphanesi kullanılmıştır. Diğer iki programda olduğu gibi burada da SVM, LR, BC,  $\kappa$ NN algoritmaları kullanılmıştır.

### III. DENEYSEL SONUÇLAR

Melanom tespitini yapan sınıflandırıcıların performanslarını ölçmek için doğruluk yüzdesi (Accuracy - DY), hassaslık (Sensitivity - H), spesifiklik (Specificity - S), F1 değeri (F1 score), işlem karakteristik eğrisi (Receiver Operating Characteristic - İKE) altında kalan alan metrikleri kullanılmıştır.

$$DY = -\frac{DP + DN}{DP + DN + YP + YN} \times 100 \quad (3)$$

$$H = -\frac{DP}{DP + YN} \quad (4)$$

$$S = -\frac{DN}{DN + YP} \quad (5)$$

Burada DP, DN, YP, YN değerleri sırasıyla doğru pozitif (True Positive), doğru negatif (True Negative), yanlış pozitif (False Positive), yanlış negatif (False Negative) değerlerine karşılık gelmektedir. Hassaslık ve spesifiklik, özellikle sağlık alanında yapılan makine öğrenmesi çalışmalarında geçen kavramlardır. Hassaslık gerçek durumu pozitif (hasta) olan vakaların ne kadarının pozitif teşhis edildiğini gösterirken, spesifiklik gerçek durumu negatif (sağlıklı) olan vakaların ne kadarının doğru şekilde teşhis edildiğini gösterir. F1 değeri kesinlik (Precision) ve gerçeklik (Recall) değerlerinin harmonik ortalamasıyla hesaplanmaktadır ve 0 ile 1

arasında değer alır [28]. Kesinlik doğru pozitif örneklerin tüm doğru değerlere oranı ile ifade edilirken gerçeklik doğru pozitif değerlerin doğru pozitif ve yanlış negatif değerlere oranı olarak tanımlanır. İKE eğrisi ise x-ekseni spesifiklik, y-ekseni ise hassaslık değerlerinden oluşan bir eğridir. İKE eğrisinin altında kalan alan tanı koyma testlerinin üstünlüğü için bir karşılaştırma ölçeği olarak kullanılır ve değeri ne kadar büyükse, tahminde bulunan sınıflandırıcı o kadar doğru tanı koymaktadır [29]. Bu sınıflandırıcıların önemli bir parametresi olan k- katlamalı çapraz doğrulama (k-fold Cross Validation), makine öğrenmesi uygulamalarında eğitim ve test için ayrılan veri kümesini k parçaya ayırıp parçalardan birini test, diğerlerini eğitim için seçip sonuçların alınmasını sağlar. Bu işlem değişen k değerine göre her birinde farklı test parçası seçilmek suretiyle k kez tekrarlanır. Bu çalışmada 3 farklı program için k, 10 ve 3 değerlerine göre sonuçlar elde edilip karşılaştırılmıştır. İstenmeyen yüksek derecede yanlılık (bias) ve değişkenlik (variance) oranları k değeri 5 ya da 10 seçildiği takdirde gözlemlenmez [30]. Bu nedenle k değeri 3 ve 10 seçilerek iki şekilde yapılmış, sonuçlar literatürde önceden yapılan çalışmalarla [6] karşılaştırılmıştır. Sonuçlar üç farklı programda sınıflandırıcılar kullanılarak elde edilmiştir.

Tablo I'de dört farklı sınıflandırıcının üç farklı programda iki farklı katlamalı çapraz doğrulama değerinde alınan doğruluk yüzdesi değerleri gösterilmektedir. Tablo I'de görüldüğü

Tablo I: DOĞRULUK YÜZDESİ DEĞERLERİ

Sınıflandırıcılar	Programlar	MATLAB	WEKA	Python	Çapraz Doğrulama (k)
		(%)	(%)	(%)	
SVM		93	90.5	97.0	10
		93.5	91.0	97.0	3
LR		89	87.5	95.0	10
		89.5	89.5	93.0	3
BC		94.5	90.5	95.0	10
		93.5	90.0	94.0	3
$\kappa$ NN		92.5	90.0	95.0	10
		93.5	89.0	95.0	3

üzere doğruluk yüzdesi değerleri en yüksek Python'da alınmıştır. Sınıflandırıcı parametreleri varsayılan değerler kullanılmış olup parametrelerin iyileştirilmesine gidilmemiştir. Aynı yöntemlerin farklı programlarda farklı sonuç vermesi, kütüphanelerinde tanımlanan varsayılan değerlerin farklı olması ve eğitim aşamasında seçilen setlerin rastgele olmasıyla açıklanabilmektedir. Sınıflandırıcılara ait hassaslık, spesifiklik, F1 ve İKE sonuçları Tablo II 'de verilmiştir. Tablo I ve

Tablo II: İKE, HASSASLIK, SPESİFİKLİK, F1 DEĞERLERİ

	İKE	Hassaslık	Spesifiklik	F1	Çapraz Doğrulama (k)
	SVM	0.99	0.88	1.00	
LR	0.99	0.94	0.98	0.94	3
	0.99	0.88	0.97	0.88	10
BC	0.94	0.81	0.95	0.81	3
	0.91	0.81	0.98	0.87	10
$\kappa$ NN	0.96	0.81	0.97	0.84	3
	0.90	0.81	0.98	0.87	10
	0.92	0.88	0.97	0.88	3

Tablo II'deki değerler incelendiğinde SVM sınıflandırıcısının melanom tespitinde daha üstün bir performans sergilediği görülmüştür. Tablo I'de SVM % 97'lik bir doğruluk yüzdesi gösterirken diğer sınıflandırıcılar % 95'te kalmıştır. SVM sınıflandırıcısı İKE, hassaslık, spesifiklik ve F1 gibi metriklerin yer aldığı Tablo II'de tüm metriklerde diğer sınıflandırıcılara üstünlük sağlamıştır. Bu nedenle, melanom hastalığının makine öğrenmesi ile tespitinde SVM sınıflandırıcısı önerilmektedir. Önerdiğimiz bu yöntem daha sonra literatürdeki çalışmalarla karşılaştırılıp sonuçlar Tablo III'te verilmiştir. Melanom hastalığının tespitiyle ilgili aynı veri seti kullanılarak yapılan çalışmalarda alınan doğruluk değerleri % 79.10 ile % 96 arasında değişmekteyken önerdiğimiz yöntem % 97'lik doğruluk sonucuna ulaşmıştır.

Tablo III: YÖNTEMLERİN KARŞILAŞTIRILMASI

Yöntemler	[7]	[8]	[9]	[10]	[6]	Önerilen Yöntem
Doğruluk Yüzdesi (%)	79.10	84.30	92.00	93.83	96.00	<b>97.00</b>

#### IV. VARGILAR

Bu çalışmada, dermoskopik görüntülerden melanom hastalığının tespiti, makine öğrenmesi sınıflandırıcılarıyla yüksek oranda sağlanmıştır. Dört farklı makine öğrenmesi algoritması birbirleriyle ve üç farklı programdaki sonuçlarıyla karşılaştırılmıştır. Ayrıca, değişen katlamalı çapraz doğrulama değerlerinin performansa olan etkisi incelenmiştir. En yüksek doğruluk değeri % 97 ile Python programında SVM sınıflandırıcısıyla elde edilmiş, böylelikle Tablo III'te verilen literatür çalışmalarından daha yüksek doğruluk değerine ulaşılmıştır. Bu çalışmanın gelecekte kolorimetrik özellikteki diğer hastalıklara da uyarlanıp, mevcut sonuçların daha da ilerletilmesi hedeflenmektedir.

#### TEŞEKKÜR

Bu çalışma TÜBİTAK 116E934 projesi kapsamında desteklenmektedir.

#### KAYNAKÇA

- [1] R. A. Smith, K. S. Andrews, D. Brooks, S. A. Fedewa, D. Manassaram-Baptiste, D. Saslow, O. W. Brawley, and R. C. Wender, "Cancer screening in the united states: a review of current american cancer society guidelines and current issues in cancer screening," *CA: a cancer journal for clinicians*, vol. 68, no. 4, pp. 297–316, 2018.
- [2] W. H. Organization et al., *Artificial tanning devices: public health interventions to manage sunbeds*. World Health Organization, 2017.
- [3] Y. Shoham, R. Perrault, E. Brynjolfsson, J. Clark, J. Manyika, J. C. Niebles, T. Lyons, J. Etchemendy, and Z. Bauer, "The ai index annual report," 2018.
- [4] H. Ozkan, R. Gurleyen, E. Usta, and R. K. Kumrular, "Automatic skin lesion segmentation," in *EBBT*. IEEE, 2017, pp. 1–3.
- [5] H. Yalcin, "Çeşitli özniteliklerle kötü huylu melanom karakterizasyonu characterization of melanomas using a variety of features," 2015.
- [6] Z. Waheed, A. Waheed, M. Zafar, and F. Riaz, "An efficient machine learning approach for the detection of melanoma using dermoscopic images," in *C-CODE*. IEEE, 2017, pp. 316–319.
- [7] J. S. Marques, C. Barata, and T. Mendonça, "On the role of texture and color in the classification of dermoscopy images," in *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2012, pp. 4402–4405.
- [8] C. Barata, M. E. Celebi, and J. S. Marques, "Improving dermoscopy image classification using color constancy," *IEEE journal of biomedical and health informatics*, vol. 19, no. 3, pp. 1146–1152, 2014.
- [9] L. Bi, J. Kim, E. Ahn, D. Feng, and M. Fulham, "Automatic melanoma detection via multi-scale lesion-biased representation and joint reverse classification," in *ISBI*, 2016, pp. 1055–1058.
- [10] G. Schaefer, B. Krawczyk, M. E. Celebi, and H. Iyatomi, "Melanoma classification using dermoscopy imaging and ensemble learning," in *2nd Asian Conference on Pattern Recognition*. IEEE, 2013, pp. 386–390.
- [11] A. Bayram, N. Horzum, A. U. Metin, V. Kılıç, and M. E. Solmaz, "Colorimetric bisphenol-a detection with a portable smartphone-based spectrometer," *IEEE Sensors Journal*, vol. 18, no. 14, pp. 5948–5955, 2018.
- [12] V. Kılıç, G. Alankus, N. Horzum, A. Y. Mutlu, A. Bayram, and M. E. Solmaz, "Single-image-referenced colorimetric water quality detection using a smartphone," *ACS Omega*, vol. 3, no. 5, pp. 5531–5536, 2018.
- [13] H. Mhaske and D. Phalke, "Melanoma skin cancer detection and classification based on supervised and unsupervised learning," in *CCUBE*. IEEE, 2013, pp. 1–5.
- [14] V. Kılıç, N. Horzum, and M. E. Solmaz, "From sophisticated analysis to colorimetric determination: Smartphone spectrometers and colorimetry," in *Color Detection*. IntechOpen, 2018.
- [15] G. Litjens, T. Kooi, B. E. Bejnordi, A. A. A. Setio, F. Ciompi, M. Ghahfoorian, J. A. Van Der Laak, B. Van Ginneken, and C. I. Sánchez, "A survey on deep learning in medical image analysis," *Medical image analysis*, vol. 42, pp. 60–88, 2017.
- [16] N. C. Codella, Q.-B. Nguyen, S. Pankanti, D. Gutman, B. Helba, A. Halpern, and J. R. Smith, "Deep learning ensembles for melanoma recognition in dermoscopy images," *IBM Journal of Research and Development*, vol. 61, no. 4/5, pp. 5–1, 2017.
- [17] A. Esteva, B. Kuprel, R. A. Novoa, J. Ko, S. M. Swetter, H. M. Blau, and S. Thrun, "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, p. 115, 2017.
- [18] T. Mendonça, P. M. Ferreira, J. S. Marques, A. R. Marcal, and J. Rozeira, "Ph 2-a dermoscopic image database for research and benchmarking," in *EMBC*. IEEE, 2013, pp. 5437–5440.
- [19] M. E. Solmaz, A. Y. Mutlu, G. Alankus, V. Kılıç, A. Bayram, and N. Horzum, "Quantifying colorimetric tests using a smartphone app based on machine learning classifiers," *Sensors and Actuators B: Chemical*, vol. 255, pp. 1967–1973, 2018.
- [20] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*. John Wiley & Sons, 2012.
- [21] A. Y. Mutlu, V. Kilic, G. Kocakusak, A. Bayram, N. Horzum, and M. Solmaz, "Smartphone based colorimetric detection via machine learning," *Analyst*, pp. 2434–2441, 2017.
- [22] J. A. Suykens and J. Vandewalle, "Least squares support vector machine classifiers," *Neural processing letters*, vol. 9, no. 3, pp. 293–300, 1999.
- [23] A. Y. Mutlu and V. Kılıç, "Machine learning based smartphone spectrometer for harmful dyes detection in water," in *SIU*. IEEE, 2018, pp. 1–4.
- [24] L. Breiman, "Bagging predictors," *Machine learning*, vol. 24, no. 2, pp. 123–140, 1996.
- [25] J. M. Keller, M. R. Gray, and J. A. Givens, "A fuzzy k-nearest neighbor algorithm," *IEEE transactions on systems, man, and cybernetics*, no. 4, pp. 580–585, 1985.
- [26] S. A. Dudani, "The distance-weighted k-nearest-neighbor rule," *IEEE Trans. on Systems, Man, and Cybernetics*, no. 4, pp. 325–327, 1976.
- [27] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witten, "The weka data mining software: an update," *ACM SIGKDD explorations newsletter*, vol. 11, no. 1, pp. 10–18, 2009.
- [28] D. M. Powers, "Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation," *Journal of Machine Learning Technologies*, pp. 37–63, 2011.
- [29] L. Tomak and B. Yüksel, "İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması," *Journal of Experimental and Clinical Medicine*, vol. 27, no. 2, pp. 58–65, 2009.
- [30] G. James, D. Witten, T. Hastie, and R. Tibshirani, *An introduction to statistical learning*. Springer, 2013, vol. 112.