

Ön Eğitimli Evrişimsel Sinir Ağı Modellerinde Öznitelik Seçim Algoritmasını Kullanarak Cilt Lezyon Görüntülerinin Sınıflandırılması

Burak TAŞCI^{1*}

¹Fırat Üniversitesi Teknik Bilimler MYO. Elektrik ve Enerji Bölümü, Hibrid ve Elektrikli Taşıtlar Teknolojisi Programı, Elazığ, Türkiye

*btasci@firat.edu.tr

(Geliş/Received: 22/02/2022;

Kabul/Accepted: 30/05/2022)

Öz: Dünya Sağlık Örgütü tarafından belirtildiği gibi, cilt kanseri oluşumu son yıllarda artmaktadır. Her yıl dünya çapında 2 ila 3 milyon arasında melanom dışı cilt kanseri ve en az 132.000 kötü huylu cilt kanseri ortaya çıkmaktadır. Deri lezyonlarının uygun otomatik teşhisi ve melanom tanıma, melanomların erken tespitini büyük ölçüde iyileştirebilir. Cilt kanserinde erken teşhis hastaların doğru tanı ve tedaviye sahip olmasını sağlar. Bu çalışmada, cilt lezyonu görüntülerden deri kanserinin kötü huylu olup olmadığını teşhis etmek için kübik tip Destek Vektör Makinesi (DVM) sınıflandırıcısı ve ön eğitimli Evrişimsel Sinir Ağı (ESA) tabanlı AlexNet ve ResNET50 derin mimarileri kullanılarak derin öznitelikler çıkartıldı ve ardından birleştirildi. Daha sonra, ReliefF algoritması ile bu derin özniteliklerden etkili ve ayırt edici öznitelikler seçildi. Birleştirilen derin özniteliklerine farklı sınıflandırıcı algoritmaları uygulandı. Kübik tip DVM en iyi sonucu verdiği için kullanılmıştır. Önerilen yöntemde sınıflandırma doğruluğu Kaggle veri seti için %92.41, HAM10000 veri seti için %85.17'dir. Deneysel çalışmalarda, önerilen modelin doğruluk skoru diğer çalışmalardan daha başarılı olduğu gözlemlenmiştir.

Anahtar kelimeler: Öznitelik Seçimi, Sınıflandırma, Evrişimsel Sinir Ağları, Destek Vektör Makinesi.

Classification of Skin Lesion Images Using Feature Selection Algorithm in Pre-Trained Convolutional Neural Network Models

Abstract: As stated by the World Health Organization, the occurrence of skin cancer has been increasing in recent years. Between 2 and 3 million non-melanoma skin cancers and at least 132.000 malignant skin cancers occur worldwide each year. Appropriate automatic diagnosis of skin lesions and melanoma recognition can greatly improve the early detection of melanomas. Early diagnosis in skin cancer ensures that patients have the correct diagnosis and treatment. In this study, deep features were extracted from skin lesion images to diagnose whether skin cancer is malignant or not, using cubic-type Support Vector Machine (SVM) classifier and pre-trained Convolutional Neural Network (CNN) based AlexNet and ResNet50 deep architectures, and then combined. Then, effective and distinctive features were selected from these deep features with the ReliefF algorithm. Different classifier algorithms were applied to the combined deep features. Cubic type SVM is used as it gives the best results. In the proposed method, the classification accuracy is 92.41% for the Kaggle dataset and 85.17% for the HAM10000 dataset. In experimental studies, it has been observed that the accuracy score of the proposed model is more successful than other studies.

Key words: Feature Selection, Classification, Convolutional Neural Networks, Support Vector Machine,

1. Giriş

Cilt kanserinin oluşturacağı riskler konusunda tıbbi farkındalığın artmasına ve erken fark edilebilme yöntemlerinin artışına rağmen, dünya çapında cilt kanseri görülme oranı son yıllarda çok artmıştır[1]. Malign melanom ve melanom dışı deri kanserleri, beyaz ırkta görülen en sık malignitelerdir [2]. Türkiye Sağlık Bakanlığı kanser bölümünden alınan 2011 epidemiyoloji istatistiklerine göre Türkiye'de cilt kanseri insidansı 100.000 kişi başına 18,91'dir ve en sık teşhis edilen üçüncü kanser türüdür [3]. Dermatolojik kanser türlerini tespit etmek için kullanılan yöntemlerden biri dermoskopidir. Dermoskopi cilt bölgesinin büyütülmüş ve aydınlatılmış bir görüntüsünü elde etmek için kullanılan bir girişimsel olmayan cilt görüntüleme tekniğidir. Hem cildi büyüten hem de yüzey yansımalarını ortadan kaldıran yeni bir görsel inceleme tekniği olan dermoskopi [4, 5], tanı performansını iyileştirmenin ve melanom ölümlerini azaltmanın temel yollarından biridir [5]. Melanomun dermoskopi görüntülerinden otomatik olarak tanınması, çeşitli zorluklardan dolayı zor bir iştir. İlk olarak, cilt lezyonları ve normal cilt bölgesi arasındaki düşük kontrast, doğru lezyon alanlarını ayırmayı zorlaştırır. İkincisi, melanom ve melanom olmayan lezyonlar yüksek derecede görsel benzerliğe sahip olabilir, bu da melanom lezyonunu melanom

*Sorumlu yazar: btasci@firat.edu.tr ORCID: 0000-0002-4490-0946

olmayandan ayırt etmede zorlukla sonuçlanır. Üçüncüsü, hastalar arasında cilt rengi, doğal kıllar veya damarlar gibi cilt koşullarının varyasyonu, renk ve doku vb. açısından farklı melanom görünümü üretir. Bu zorluklardan dolayı teşhis doğruluğu, dermatologlar arasında büyük ölçüde değişebilir. Bu nedenle, melanomun sınıflandırılması, bilgisayar destekli tanı görevlerinden biridir. Cilt kanseri görüntülerinin sınıflandırılmasında ön eğitimli derin öğrenme modelleri sıklıkla kullanılmıştır. Yapay zeka yöntemlerinden olan derin öğrenme, insan gözünden daha hızlı ve doğru bir şekilde sonuç vermektedir. Evrişimli Sinir Ağları (ESA), sınıflandırma ve görüntü, sinyal işleme alanlarında kullanılmaktadır. ESA'larda, yüksek başarılı sonuçlar alındığından dolayı sıklıkla kullanılmaktadır. Ayrıca ESA modellerinin girişine öznitelik vektörü değil görüntü verilmektedir.

Literatürde cilt kanseri görüntüleri gibi biyomedikal görüntülerin sınıflandırılmasında derin öğrenme modellerinin sıkça kullanıldığı görülmektedir.

Benyahia ve arkadaşları [6], ISIC 2019 ve PH2 veri setlerinde cilt lezyonlarının sınıflandırılmasını değerlendirmek için özellik çıkarıcı olarak 17 önceden eğitilmiş evrişimli sinir ağları ve 24 makine öğrenimi sınıflandırıcısını kullanmışlar. PH2 veri setinde %99 doğruluk elde etmişler. Dhivya ve arkadaşları [7], cilt lezyonu sınıflandırması için karar ağaçları ve rastgele orman algoritmalarını kullanmışlar. Yaklaşımlarını HAM10000 ve ISIC 2017'de test etmişler. Mazouze ve arkadaşları[8], Evrişimli sinir ağlarına dayalı cilt kanseri sınıflandırmasını gerçekleştiren bir web sunucusu olan DUNEScan'ı geliştirmişler. Çalışmalarında Grad-CAM ve UMAP algoritmalarını kullanmışlar. DUNEScan web sunucusuna <https://www.dunescan.org> ile erişilebilmektedir. Akram ve arkadaşları [9], melanom lezyonlarını sınıflandırmak için bir yöntem önermiştir. Deri lezyonları örnekleri üzerinde ön işleme gerçekleştirildikten sonra, temsili öznitelik kümesini hesaplamak için ölçekte değişmeyen öznitelik dönüşümü ve yönlendirilmiş gradyanların histogramı uygulamışlar. Daha sonra k-en yakın komşu(K-EYK) ve Destek Vektör Makinesi (DVM) olmak üzere iki sınıflandırıcı, melanom görüntülerini sınıflandırmak için hesaplanan öznitelikler üzerinde eğitilmiştir. Çalışma PH2, ISIC MSK, ISIC UDA ve ISBI-2017 dört referans dermoskopik veri setinde doğrulanmıştır. Önerilen tasarım ile %98.8, %99.2, %97.1 ve %95 doğruluk değerleri elde edilmiştir. Yap ve arkadaşları [10], otomatik cilt lezyonu teşhisi performansını iyileştirmek için çoklu görüntüleme yöntemlerini birleştiren bir yöntem sunmuştur. Yöntemi diğer çalışmalarla karşılaştırmak için ikili sınıflandırmanın yanı sıra beş sınıflı veri seti üzerinde denenmiştir. İki sınıf için 0.729 beş sınıf için 0.598 başarımla elde edilmiştir. Volkan Göreke [11], ISIC 2017 veri setini kullanarak deri lezyonlarının tespiti yapmıştır. Çalışmada VGG16 ön eğitimli derin sinir ağını kullanmıştır. VGG16'dan el ettiği öznitelikler yardımıyla sınıflandırma yapmıştır. Çalışmada %96 sınıflandırma doğruluk ve %100 AUC başarımla elde edilmiştir. Ergün ve Kılıç [12], çalışmalarında HAM10000 veri setini kullanarak kötü huylu cilt kanserinin tespiti için bir çalışma yapmıştır. AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16 derin öğrenme mimarileri kullanılmıştır. Resnet-34 mimarisi en başarılı sonucu vermiştir. ResNet-34'de ortalama %87.5 doğruluk oranı, %94 AUC skoru, %84.5 F-skoru, %87.6 kesinlik değeri elde edilmiştir. Şahin ve Alpaslan [13], SegNet mimarisini kullanarak deride bulunan lezyonları bölütleyebileceği bir sistem geliştirmiştir. Çalışmada ISBI2016 veri kümesi kullanılmıştır. Önerdikleri yöntem sayesinde doğruluk, özgüllük ve hassasiyet değerleri sırasıyla %93.46, %93.22 ve %87.88 elde edilmiştir. Oktay Yıldız [14], cilt kanserinin tespiti için C4Net, AlexNet, GoogLeNet, ResNet ve VGGNet ön- eğitimli ağ modellerinden elde ettiği sonuçları karşılaştırmıştır. En yüksek doğruluğu %96.94 ile C4Net ağ modelinde elde etmiştir. Ayrıca hassasiyet, özgüllük ve kesinlik için sırasıyla 0.976, 0.963 ve 0.965 sonuçlarına ulaşmıştır. Kadiroğlu ve arkadaşları [15], AlexNet ve VGG16 gibi ön eğitimli derin konvolüsyonel sinir ağları yardımıyla cilt kanserini tespit etmeye yönelik bir çalışma yapmıştır. Yaptıkları çalışmada, AlexNet fc6, AlexNet fc7, VGG16 fc6 ve VGG16 fc7 için %92, %94, %94, %94 doğruluk değerleri elde edilmiştir. Yıldız ve Kılıç [16], kötü huylu cilt kanserini tespit etmek için görüntü işleme tekniklerini kullanarak renk ve doku gibi öznitelikleri çıkarmışlardır. Daha sonra çıkardıkları öznitelikleri farklı makine öğrenmesi sınıflandırıcıları yardımıyla eğitip test etmişlerdir. DVM sınıflandırıcısı ile %97 doğruluk elde edilmiştir. Yıldırım ve Çınar [17], cilt kanserinin iyi huylu veya kötü huylu olup olmadığını belirlemek için Densenet201, Alexnet, Googlenet ve Resnet50 için ayrı ayrı sonuçlar elde edilmiştir. En yüksek doğruluk oranı % 83.49 ile Resnet50 ile elde edilmiştir. Çalışmada önerilen hibrit modelde doğruluk oranı %84.11'dir.


Bu çalışmada ön eğitimli ResNet50 ve Alexnet ön eğitimli ağ modellerinin birlikte kullanılması önerilmektedir. ResNet50 ve Alexnet modelleri öznitelik çıkarma işlemi için kullanılmıştır. ReliefF algoritması ile öznitelik seçimi yapılmıştır. ReliefF algoritması yardımıyla elde edilen daha az sayıdaki öznitelikler yardımıyla

kübik tip DVM’de sınıflandırma işlemi yapılmıştır. DVM diğer sınıflandırıcılara göre daha yüksek performans gösterdiği için seçilmiştir.

Bu makale kısaca şöyle düzenlenmiştir: 2. bölümde, veri setleri hakkında bilgi verilmiştir. Bölüm 3’te çalışmada kullanılan ön-eğitilmiş ağlar, ReliefF öznelik seçim algoritması ve DVM sınıflandırıcı hakkında bilgi sunulmuştur. Bölüm 4’te önerilen yöntem verilmiştir. Deneysel çalışma ve sonuçlar bölüm 5’te sunulmuştur. Sonraki bölümde tartışmaya yer verilmiştir. En son bölümde ise sonuçlar verilmiştir.


2. Veri Seti

Bu çalışmada kaggle sitesinden alınan veri seti [18] ve HAM10000 [19] herhangi bir ön işlem uygulanmadan kullanılmıştır. Kaggle veri setinde toplam 3297 görüntü bulunmaktadır. Kaggle veri seti iki sınıftan oluşmaktadır. Görüntüler dermatologlar tarafından incelendikten sonra etiketlenmiştir. 1800 adet cilt lezyonu görüntüsü iyi huylu tümör olarak etiketlenmiştir. Geriye kalan 1497 adet cilt lezyonu görüntüsü kötü huylu tümör olarak etiketlenmiştir. JPG formatındaki görüntüler 224×224 yükseklik ve genişliktedir. Kaggle veri setindeki iyi huylu ve kötü huylu tümörlere ait örnek şekil 1’de verilmiştir.



Şekil 1. Kaggle veri setindeki iyi ve kötü huylu lezyon örnekleri

HAM10000 veri setinde 100015 görüntü bulunmaktadır. Veri seti yedi sınıftan oluşmaktadır. Güneş Keratozları ve Bowen hastalığı (akiec) sınıfında 327 görüntü, Bazal hücreli karsinom (bcc) sınıfında 514 görüntü, Kötü huylu keratoz bkl sınıfında 1099 görüntü, Dermatofibrom (df) sınıfında 115 görüntü, Melanom (mel) sınıfında 1113 görüntü, Melanositik nevüsler (nv) sınıfında 6705 görüntü ve vasküler deri lezyonları (vasc) sınıfında 142 görüntü bulunmaktadır. HAM10000 veri setindeki sınıflara ait örnekler şekil 2’de verilmiştir.



Şekil 2. HAM10000 veri setinin sınıflarındaki görüntülerin örnekleri

3. Yöntemler

3.1. AlexNet

AlexNet, Krizhevsky ve ark. tarafından 2010 yılında geliştirilmiştir[20]. Bu model 1,2 milyon adet yüksek-çözünürlüklü resim ve 1000 adet sınıfa sahip olan ImageNet [21] veri setinin eğitilmesi amacıyla oluşturulmuştur. Bu mimari 25 katmandan oluşmaktadır. AlexNet ağında, konvolüsyon, havuzlama, dropout, tam bağlı katman, RELU, normalizasyon, softmax, giriş ve sınıflandırma katmanlarından oluşmaktadır. Alexnet'in giriş katmanında verilecek görüntü $227 \times 227 \times 3$ boyutlarındadır. Son katmanda ise sınıflandırma sayısının değeri verilir.

3.2. ResNet50

ResNet50 mimarisi mikro mimari modülüne sahiptir. Bu özelliği ResNet50'yi diğer ağ mimarilerinden ayırmaktadır. Bazı katmanlar arasındaki değişim göz ardı edilerek alt katmana geçiş işlemi yapılması tercih edilebilir. Resnet mimarisinde bu duruma izin verilerek başarı oranı daha üst seviyelere çıkarılmıştır. Resnet50 mimarisinde 177 katmandan oluşan bir ağ yer almaktadır. Ağın derinliği 50'dir. Ayrıca giriş katmanı $224 \times 224 \times 3$ boyutundadır [22].

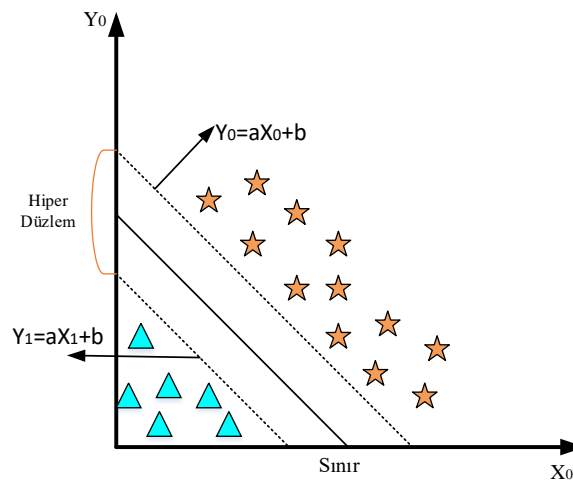
3.3. ReliefF

Öznitelik seçimi ile bir sınıfa ait olan derin öğrenme modellerinden elde edilen özniteliklerin alt kümesinin oluşturulmasıdır. Elde edilen alt küme sayesinde daha küçük boyutlu bir öznitelik vektörü oluşturmasına rağmen oluşturulan öznitelikler temel öznitelik vektörüne eşdeğer ve daha işlevseldir.

ReliefF, birçok öznitelik seçim uygulamasında başarılı sonuçlar veren en önemli öznitelik seçimi algoritmalarından biridir. ReliefF algoritmasında sıralama ve ağırlık matrisleri oluşur. Oluşan sıralama matrisinin ilk elemanı sınıflandırmada en fazla ağırlığa sahip öznitelik sütununun indisidir. Oluşan ağırlık matrisinde ise ilgili öznitelik sütununun ağırlık değeri bulunur. Bu değerlere bağlı olarak bir eşik değeri belirlenir. Eşik değerinin üzerinde bulunan değerler yeni matrise kaydedilir[23].

3.4. DVM Sınıflandırıcısı

DVM hem regresyon hem de sınıflandırma analizinde kullanılabilir. Ancak genellikle sınıflandırma çalışmalarında tercih edilmektedir. Veri setinden öznitelikler çıkarılır. Çıkarılan öznitelikler DVM yardımıyla koordinat düzlemine yerleştirilir [24]. DVM'nin kullanım amacı öznitelikler arasından geçen bir hiper düzlemi bulmaktır. Şekil 3'te bu hiper düzlem üzerinde bulunan doğrular gösterilmektedir. Y_0 ve Y_1 denklemleri için a ve b değerleri hesaplanır. Sınır olarak gösterilen lineer doğru sınıflar arasında ayırıcı görevi görmektedir.

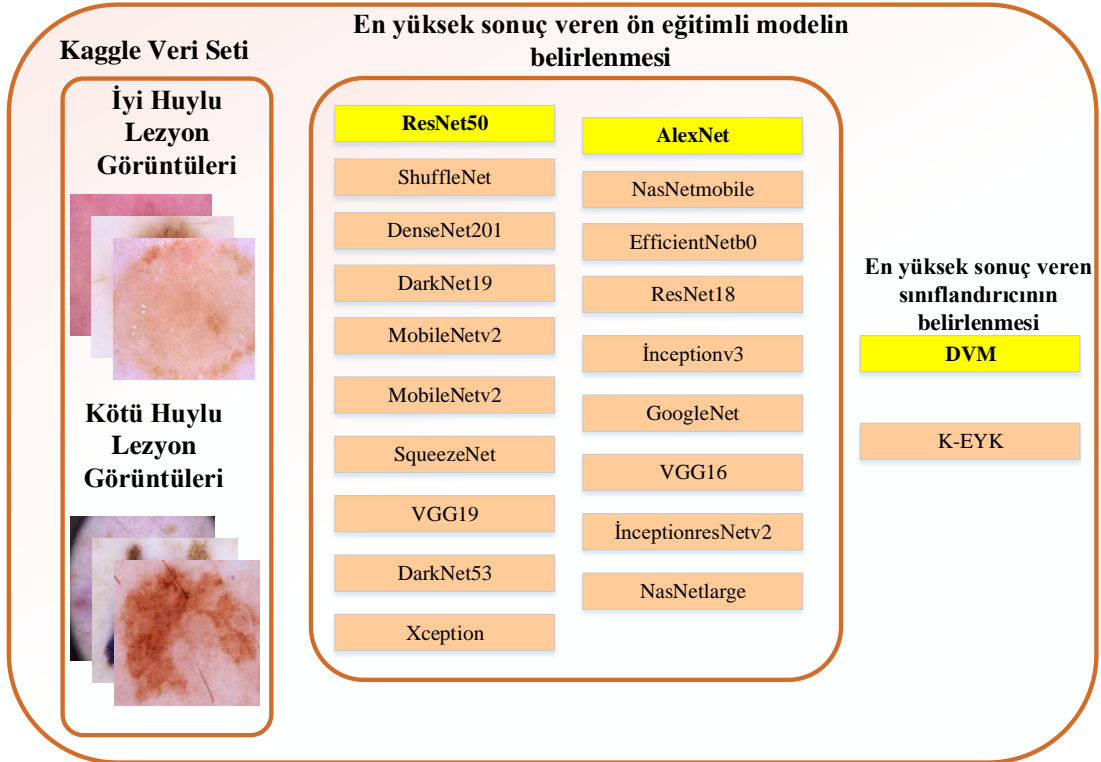


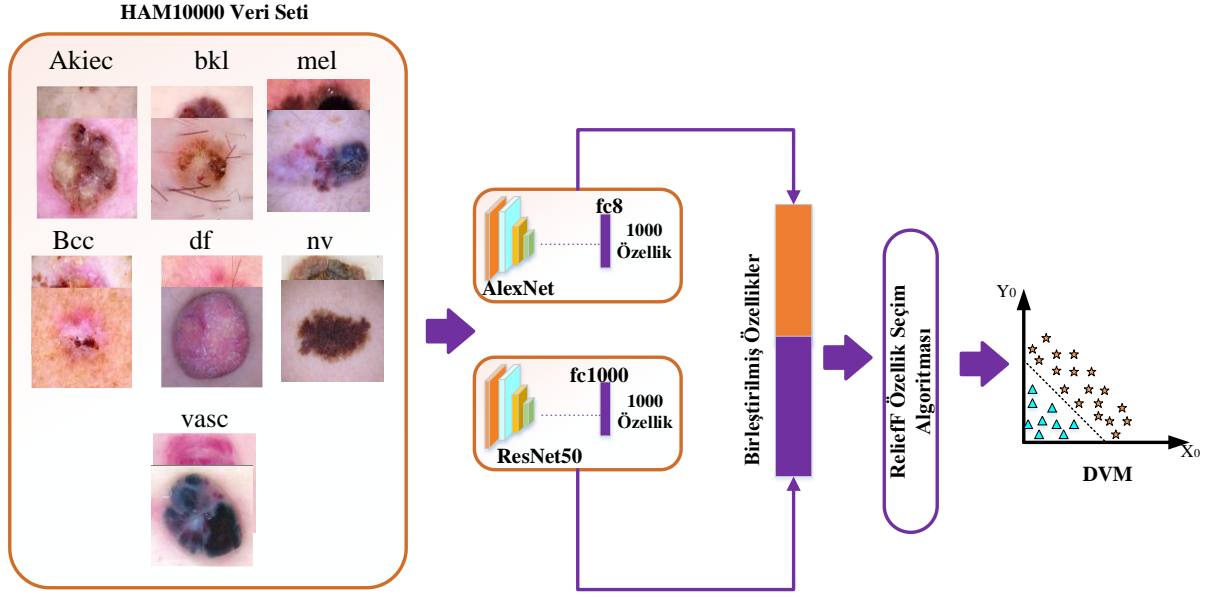
Şekil 3. Hiper düzlem ve destek vektörleri

4. Önerilen Yöntem

Bu çalışmada, cilt lezyonlarının sınıflandırılması için seçilmiş derin özniteliklere ve DVM sınıflandırıcısına dayalı bir sistem önerilmiştir. Önerilen sistem 8 aşamadan oluşmaktadır:

1. Aşama: Veri Setlerindeki görüntüler ağ yapılarının giriş boyutlarına göre ayarlanmıştır.
2. Aşama: Kaggle veri setindeki görüntüler 19 ön eğitilmiş modelin girişine ayrı ayrı uygulanarak öznitelikleri alınmıştır.
3. Aşama: Alınan öznitelikler rastgele %80 eğitim - %20 test ve %70 eğitim - %30 test için rastgele ayrılarak DVM ve K-EYK [25] sınıflandırıcılardan sonuçlar alınmıştır.
4. Aşama: DVM, 19 ön eğitilmiş modelde en yüksek sonucu verdiği için seçilmiştir.
5. Aşama: 19 ön eğitilmiş modelden AlexNet ve Resnet50 ESA mimarileri DVM sınıflandırıcıda en yüksek sonucu verdiği için öznitelik seçimi için kullanılmıştır.
6. Aşama AlexNet'in fc8 katmanından 1000 adet öznitelik, Resnet50'nin fc1000 katmanından 1000 adet öznitelik alınarak birleştirilmiştir.
7. Aşama: Birleştirilen özniteliklerden 200 tanesi ReliefF öznitelik seçim algoritması yardımıyla seçilmiştir.
8. Aşama: Elde edilen 200 öznitelik DVM algoritmasında sınıflandırılmıştır. Önerilen yaklaşımın tasarımı Şekil 4'te sunulmuştur.





5. Deneysel Çalışma ve Sonuçlar

5.1. Performans Ölçüm Metrikleri

Makine öğrenmesinde sınıflandırıcıların sınıflandırma başarısının ölçülmesi, sınıflandırıcının etiketlediği sınıf ile gerçek sınıf değeri arasındaki ilişkilerle gerçekleştirilir. Gerçek sınıf değeri pozitif olan bir veriyi pozitif olarak etiketlemeye DP (doğru pozitif), negatif olarak etiketlemeye yanlış negatif (YN), gerçek sınıf değeri negatif olan bir veriyi negatif olarak etiketlemeye doğru negatif DN), pozitif olarak etiketlemeye de YP (yanlış pozitif) denmektedir. Önerilen yaklaşım için karmaşıklık matrisindeki DP, DN, YP, YN sayıları kullanılarak performans ölçüm metrikleri hesaplanmıştır. Performans ölçütleri doğruluk, duyarlılık, özgüllük, kesinlik ve F-skor değerleri kullanılarak oluşturulmuştur. Performans ölçüm metrikleri aşağıdaki eşitlikler ile hesaplanmıştır.

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

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

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (3)$$

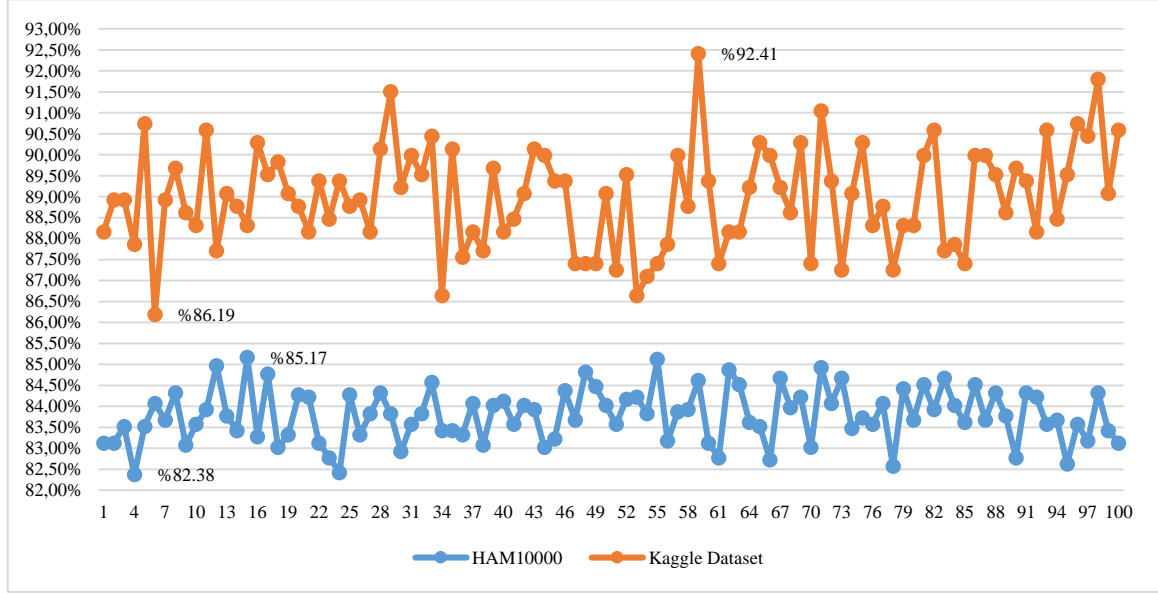
$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4)$$

$$F - \text{skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

5.2. Deneysel Çalışmalar

Bu çalışmadaki deneysel sonuçları elde etmek için Matlab ortamı kullanılmıştır. Deneysel sonuçlar, I7 işlemci, 8GB Ram ve 4GB NVIDIA ekran kartı bulunan bilgisayar kullanılarak elde edilmiştir. Çalışma iki temel aşamadan oluşmaktadır. İlk aşamada Kaggle veri seti kullanılarak tüm ön eğitimli modellerden öznitelikler çıkarılmıştır. Daha sonra hem %80 eğitim- %20 test için hemde %70 eğitim- %30 test için DVM ve K-EYK sınıflandırıcılarda sonuçlar alınmıştır. Alınan sonuçların tablo 1'de verilmiştir. En yüksek iki sonuç %80 eğitim- %20 test durumunda AlexNet ve ResNet50'de DVM sınıflandırıcıda alınmıştır. Son aşamada en yüksek sonuç veren AlexNet'in fc8 katmanından 1000 adet öznitelik, Resnet50'nin fc1000 katmanından 1000 adet özneliğin alınarak birleştirilmiştir. Çıkarılan öznitelikler birleştirildikten sonra ReliefF öznitelik seçimi uygulanmıştır.

Seçilmiş 200 öznitelik DVM sınıflandırıcıya verilmiştir. Sınıflandırma işlemi 100 defa yapılarak kontrol edilmiştir. Kaggle ve HAM10000 veri setlerinin 100 çalıştırılması sonucunda elde edilen grafik şekil 5'te verilmiştir. Kaggle veri setinin kullanılmasıyla en düşük %86.19, en yüksek %92.41 sonuçları elde edilmiştir. HAM10000 veri setinin kullanılmasıyla en düşük %82.38, en yüksek %85.17 sonuçları elde edilmiştir.

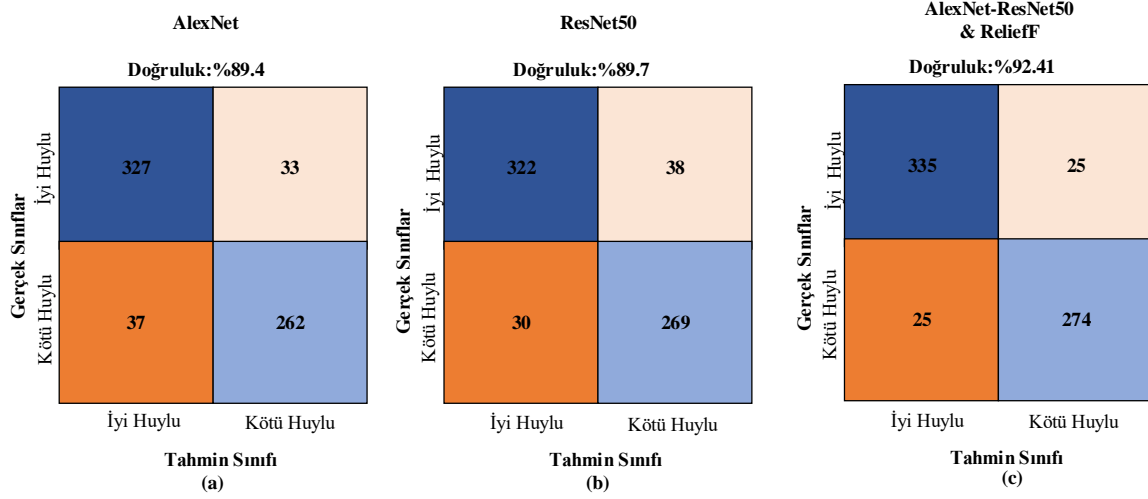


Şekil 5. Önerilen metotta Kaggle ve HAM10000 veri setlerinin kullanılmasıyla elde edilen 100 sonucun grafiği

Tablo 1. Ön eğitilmiş 19 ESA'nın kaggle veri setinin sınıflandırma doğrulukları

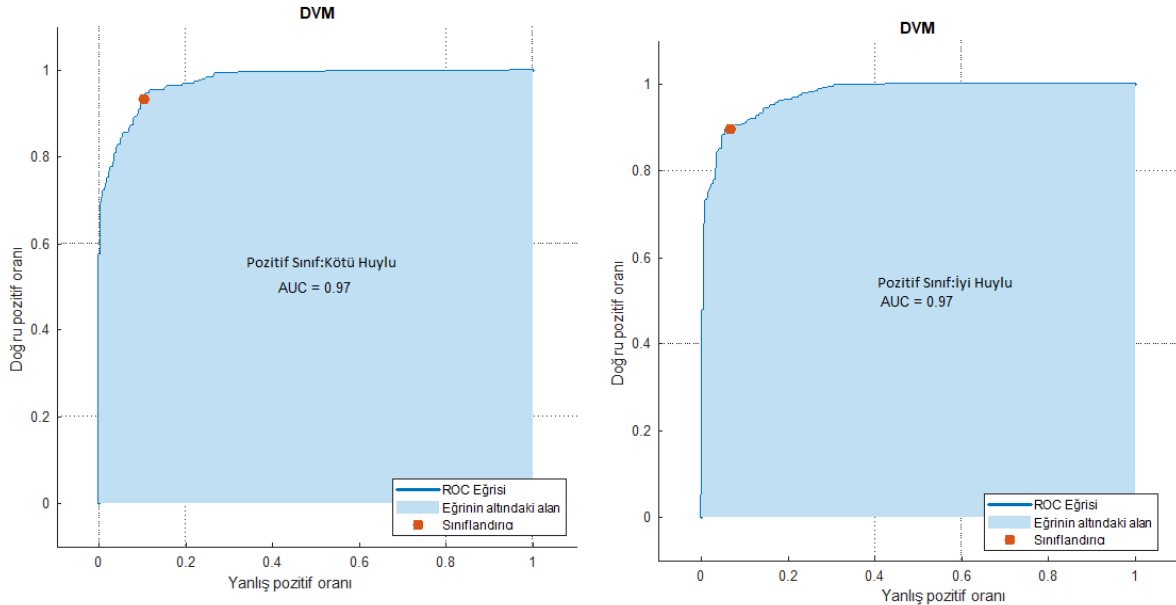
	%80-%20		%70-%30	
	SVM(%)	K-EYK (%)	SVM(%)	K-EYK (%)
ResNet50	89.70	86.90	88.80	81.70
AlexNet	89.40	84.93	87.10	79.20
ShuffleNet	89.40	85.82	84.90	77.10
DenseNet201	88.90	81.79	89.20	80.20
DarkNet19	88.60	80.63	86.20	76.80
MobileNetv2	88.60	80.54	87.90	82.60
ResNet101	88.30	79.47	88.70	84.20
SqueezeNet	88.30	78.68	86.70	83.20
VGG19	87.70	84.19	86.10	74.90
DarkNet53	87.40	79.53	87.40	76.90
Xception	86.90	79.95	86.00	79.10
NasNetmobile	86.60	78.81	84.30	81.70
EfficientNetb0	86.50	78.63	87.90	79.90
ResNet18	86.20	75.25	89.30	80.40
Inceptionv3	85.90	79.03	85.30	76.00
GoogleNet	85.60	74.47	85.10	81.70
VGG16	85.40	75.15	84.90	77.20
InceptionresNetv2	85.30	78.48	86.30	79.40
NasNetlarge	85.00	82.45	83.50	75.90

Sonuç olarak deri lezyon görüntü kümesinin sınıflandırılmasında önerilen yaklaşım ile kaggle veri setinde en yüksek %92.41, HAM10000 veri setinde 85.17 oranında bir genel başarı sağlanmıştır. Bu başarıların kaggle veri seti için karmaşıklık matrisleri Şekil 64’da gösterilmiştir. Şekil 6(a)’da cilt lezyon görüntüleri AlexNet modelinden elde edilen özniteliklerin DVM’de sınıflandırılması sonucu %89.4’lük doğruluğun elde edildiği karmaşıklık matrisi verilmiştir. Şekil 6(b)’de cilt lezyon görüntüleri ResNet50 modelinden elde edilen özniteliklerin DVM’de sınıflandırılması sonucu %89.7’lik doğruluğun elde edildiği karmaşıklık matrisi verilmiştir. Şekil 6(c)’de cilt lezyon görüntüleri AlexNet ve ResNet50 modellerinden elde edilen özniteliklerin ReliefF algoritmasında seçilmiş özniteliklerin DVM’de sınıflandırılması sonucu %92.41’lik doğruluğun elde edildiği karmaşıklık matrisi verilmiştir.



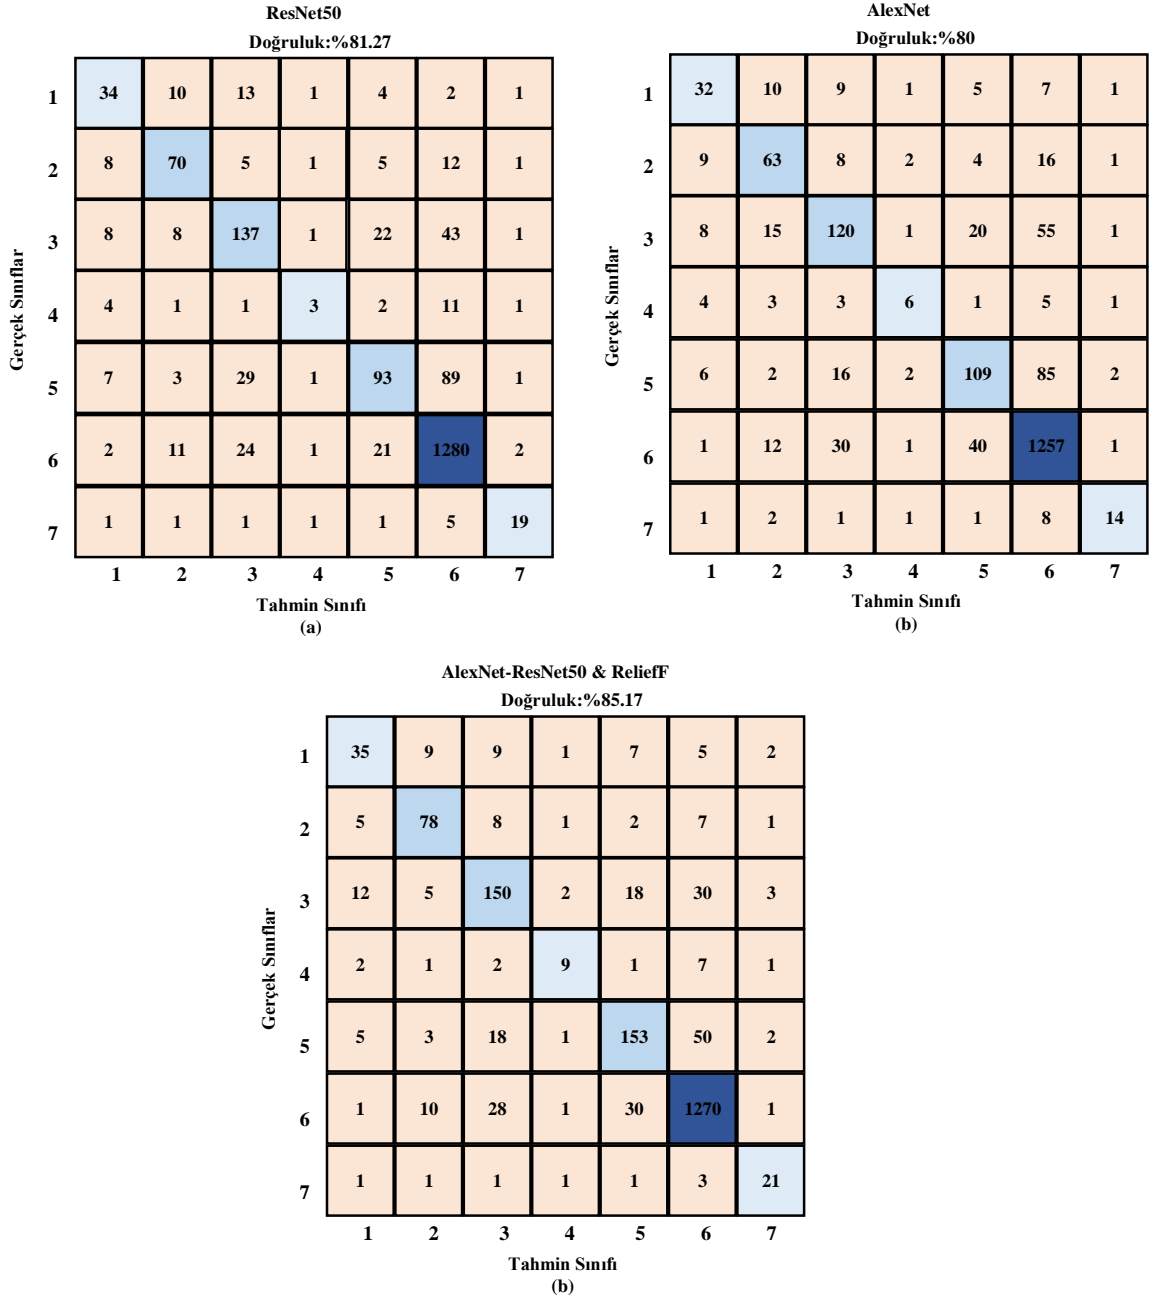
Şekil 6. Kaggle veri seti için karmaşıklık matrislerinin sonuçları

Şekil 7’de görüldüğü gibi önerilen yaklaşımın kaggle veri seti için AUC değeri 0.97 olarak elde edilmiştir.



Şekil 7. Kaggle veri seti için ROC eğrileri

HAM10000 veri seti için karmaşıklık matrisleri Şekil 8’de gösterilmiştir. Şekil 8(a)’da cilt lezyon görüntüleri AlexNet modelinden elde edilen özniteliklerin DVM’de sınıflandırılması sonucu %80’lik doğruluğun elde edildiği karmaşıklık matrisi verilmiştir. Şekil 8(b)’de cilt lezyon görüntüleri ResNet50 modelinden elde edilen özniteliklerin DVM’de sınıflandırılması sonucu %81.7’lik doğruluğun elde edildiği karmaşıklık matrisi verilmiştir. Şekil 8(c)’de cilt lezyon görüntüleri AlexNet ve ResNet50 modellerinden elde edilen özniteliklerin Relief algoritmasında seçilmiş özniteliklerin DVM’de sınıflandırılması sonucu %85.17’lik doğruluğun elde edildiği karmaşıklık matrisi verilmiştir.



Şekil 8. HAM10000 veri seti için karmaşıklık matrislerinin sonuçları(1. sınıf akiec, 2. sınıf bcc, 3. sınıf bkl, 4. sınıf df, 5. sınıf mel, 6. sınıf nv, 7. sınıf vasc)

Tablo 2’de duyarlılık, özgülük, kesinlik ve F-skor sonuçları verilmiştir.

Tablo 2. Performans Sonuçları

			Doğruluk(%)	Duyarlılık(%)	Özgüllük(%)	Kesinlik(%)	F-Skor(%)
Kaggle Veri Seti	AlexNet	1. Sınıf	89.4	90,83	87,63	89,84	90,33
		2. Sınıf		87,63	90,83	88,81	88,22
	ResNet50	1. Sınıf	89.7	89,44	89,97	91,48	90,45
		2. Sınıf		89,97	89,44	87,62	88,78
	AlexNet-ResNet50 & Relieff	1. Sınıf	92.41	93,06	91,64	93,06	93,06
		2. Sınıf		91,64	93,06	91,64	91,64
HAM1000	AlexNet	1. Sınıf	80.0	49,23	98,50	52,46	50,79
		2. Sınıf		61,17	97,68	58,88	60,00
		3. Sınıf		54,55	96,24	64,17	58,97
		4. Sınıf		26,09	99,60	42,86	32,43
		5. Sınıf		49,10	96,01	60,56	54,23
		6. Sınıf		93,67	73,37	87,72	90,59
		7. Sınıf		50,00	99,65	66,67	57,14
	ResNet50	1. Sınıf	81.27	52,31	98,45	53,13	52,71
		2. Sınıf		68,63	98,21	67,31	67,96
		3. Sınıf		62,27	95,91	65,24	63,72
		4. Sınıf		13,04	99,70	33,33	18,75
		5. Sınıf		41,70	96,91	62,84	50,13
		6. Sınıf		95,45	75,53	88,77	91,99
		7. Sınıf		65,52	99,65	73,08	69,09
	AlexNet-ResNet50 & Relieff	1. Sınıf	85.17	51,47	98,66	57,38	54,26
		2. Sınıf		76,47	98,48	72,90	74,64
		3. Sınıf		68,18	96,32	69,44	68,81
		4. Sınıf		39,13	99,65	56,25	46,15
		5. Sınıf		65,95	96,69	72,17	68,92
		6. Sınıf		94,71	84,87	92,57	93,62
		7. Sınıf		72,41	99,50	67,74	70,00

6. Tartışma

Bu makalede, önerilen Kübik tip DVM sınıflandırıcısı ve seçilen ESA tabanlı derin öznitelikler literatürdeki mevcut sistemlerle karşılaştırılmış ve sonuçlar Tablo 2'de sunulmuştur.

Tablo 3. Aynı veri kümesini kullanan çalışmaların sonuçları

Metot	Model	Eğitim-Test	Veri Seti	Doğruluk (%)
Farooq ve Arkadaşları [26]	Inception-V3 ve MobileNetV1	%25-%75	Kaggle	86
Fatih Demir [27]	MobileNetV2, L1Norm, RD ve DVM	%25-%75	Kaggle	88.35
Soylu ve Demir [28]	DarkNet-19, DarkNet-53, SqueezeNet, ShuffleNet	%30-%70	Kaggle	89.89
Khasanah ve Arkadaşları[29]	Random Forest	%25-%75	Kaggle	85
Fırıldak ve Arkadaşları[30]	AlexNET, Çekişmeli Üretici Ağ (ÇÜA)	%30-%70	HAM10000 HAM10000 +	76.55 93.14
Önerilen Metot	AlexNet, ResNet50, Relieff, DVM	%20-%80	Kaggle HAM10000	92.41 85.17

Farooq ve Arkadaşları[26], Pik Sinyal Gürültü Oranı (Peak Signal to Noise (PSNR)), Ortalama Karesel Hata (Mean Square Error (MSE)), Maksimum Mutlak Kare Sapma (Maximum Absolute Squared Deviation (MXERR)) ve Enerji Oranı/ Kare Normların Oranı (Energy Ratio/ Ratio of Squared Norms (L2RAT)) ön işlemlerini uygulanmadan önce ve uygulandıktan sonraki durumları karşılaştırmak için kullanmıştır. Çalışmanın ikinci kısmında Inception-V3 modelini ve MobileNetV1 modelini kullanmıştır. Inception-V3 %86'lık en yüksek doğruluk sonucuna ulaşmıştır. Fatih Demir [27], MobileNetV2 öğrenme modelini ve DVM algoritmasını içeren bir çalışma yapmıştır. Başarımı arttırmak için RD ve L1-Norm algoritmalarını kullanarak öznelik seçimi yapmıştır. MobileNetV2, L1Norm, RD ve DVM ile %88.35 başarımla elde etmiştir. Soylu ve Demir [28], darkNet-19, darkNet-53, squeezeNet, shuffleNet mimarileri karşılaştırılmıştır. En yüksek performansı %89,89 ile DarkNet-19 mimarisinde elde etmiştir. Fırıldak ve arkadaşları [30], HAM10000 çalışmasında veri setini kullanmıştır. Alexnet ağındaki parametrelerin kısmi ve tam transfer yoluyla aktararak %76.55 doğruluk elde etmiştir. Çekişmeli Üretici Ağ (ÇÜA) yardımıyla veri sayısını 59000'e çıkararak %93.14 doğruluk sonucunu elde etmiştir.

7. Sonuç

Bu çalışmada önerilen yöntemin belirlenmesinde 3297 cilt lezyon görüntüsünden oluşan Kaggle sitesinde yer alan veri seti kullanıldı. Kaggle veri seti 19 ön eğitilmiş modele uygulandı. En yüksek sonucu veren AlexNet ve ResNet'in öznelikleri birleştirildikten sonra özneliklerden ayırt edici ve daha etkili öznelikleri seçmek için Relief öznelik seçme algoritması uygulanmıştır. Son olarak, DVM sınıflandırıcı parametreleri için Küçük tip kullanılmış ve en iyi performansa sahip hiperparametreler seçilmiştir. Deneysel sonuçlara göre, cilt lezyonlarının sınıflandırılması için önerilen model kullanılarak en iyi doğruluk puanı Kaggle veri seti için %92.41, HAM10000 veri seti için %85.17 elde edilmiştir. Bu çalışmanın en büyük sınırlaması, kullanılan yöntemin daha büyük veri setlerine uygulaması durumunda daha güçlü bir donanım gerektirmesidir. Gelecekteki çalışmalarda, daha fazla görüntünün ve sınıfın bulunduğu farklı veri setlerini kullanarak yüksek başarımlı ağ mimarileri ile çalışmaların yapılması planlanmaktadır.

Kaynaklar

- [1] N. Sendur, Nonmelanoma skin cancer epidemiology and prevention, Turk. Klinikleri J. Int. Med. Sci, 1 (2005) 80-84.
- [2] T. Tarver, Cancer facts & figures 2012. American cancer society (ACS) Atlanta, GA: American Cancer Society, 2012. 66 p., pdf. Available from, Taylor & Francis, 2012.
- [3] E. Yurtseven, T. Ulus, S. Vehid, S. Köksal, M. Bosat, K. Akkoyun, Assessment of knowledge, behaviour and sun protection practices among health services vocational school students, International journal of environmental research and public health, 9 (2012) 2378-2385.
- [4] H. Kittler, H. Pehamberger, K. Wolff, M. Binder, Diagnostic accuracy of dermoscopy, The lancet oncology, 3 (2002) 159-165.
- [5] N. Codella, J. Cai, M. Abedini, R. Garnavi, A. Halpern, J.R. Smith, Deep learning, sparse coding, and SVM for melanoma recognition in dermoscopy images, International workshop on machine learning in medical imaging, Springer, 2015, pp. 118-126.
- [6] S. Benyahia, B. Meftah, O. Lézoray, Multi-features extraction based on deep learning for skin lesion classification, Tissue and Cell, 74 (2022) 101701.
- [7] C. Dhivyaa, K. Sangeetha, M. Balamurugan, S. Amaran, T. Vetrisevi, P. Johnpaul, Skin lesion classification using decision trees and random forest algorithms, Journal of Ambient Intelligence and Humanized Computing, (2020) 1-13.
- [8] B. Mazoure, A. Mazoure, J. Bédard, V. Makarenkov, DUNEScan: a web server for uncertainty estimation in skin cancer detection with deep neural networks, Scientific Reports, 12 (2022) 1-10.
- [9] T. Akram, H.M.J. Lodhi, S.R. Naqvi, S. Naeem, M. Alhaisoni, M. Ali, S.A. Haider, N.N. Qadri, A multilevel features selection framework for skin lesion classification, Human-centric Computing and Information Sciences, 10 (2020) 1-26.

- [10] J. Yap, W. Yolland, P. Tschandl, Multimodal skin lesion classification using deep learning, *Experimental dermatology*, 27 (2018) 1261-1267.
- [11] V. Göreke, Cilt Kanseri Lezyonlarının Sınıflandırılmasında Derin Öğrenme Sınıflandırıcıya Dayalı Bir Yöntem, *Türk Doğa ve Fen Dergisi*, 10 (2021) 30-36.
- [12] E. ERGÜN, K. KILIÇ, Derin Öğrenme ile Artırılmış Görüntü Seti üzerinden Cilt Kanseri Tespiti, *Black Sea Journal of Engineering and Science*, 192-200.
- [13] N. Şahin, N. Alpaslan, SegNet Mimarisi Kullanılarak Cilt Lezyon Bölütleme Performansının İyileştirilmesi, *Avrupa Bilim ve Teknoloji Dergisi*, (2020) 40-45.
- [14] O. YILDIZ, Derin öğrenme yöntemleriyle dermoskopi görüntülerinden melanom tespiti: Kapsamlı bir çalışma, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34 (2019) 2241-2260.
- [15] Z. Kadiroğlu, B.N. Akilotu, A. Şengür, M. Kayaoğlu, Derin Öznitelikler ve Renk Kullanılarak Dermoskopik Görüntülerin Sınıflandırılması *Classification of Dermoscopic Images Using Deep Features and Color*.
- [16] U.E. Yıldız, V. Kiliç, Detection of Melanoma with Multiple Machine Learning Classifiers in Dermoscopy Images, *2019 Medical Technologies Congress (TIPEKNO)*, IEEE, 2019, pp. 1-4.
- [17] M. YILDIRIM, A. ÇINAR, Classification of Skin Cancer Images with Convolutional Neural Network Architectures, *Turkish Journal of Science and Technology*, 16 (2021) 187-195.
- [18] Kaggle, "Skin Cancer: Malignant vs. Benign" <https://www.kaggle.com/fanconic/skin-cancer-malignant-vs-benign>, 2021.
- [19] P. Tschandl, C. Rosendahl, H. Kittler, The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions, *Scientific data*, 5 (2018) 1-9.
- [20] A. Krizhevsky, I. Sutskever, G.E. Hinton, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25 (2012).
- [21] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, L. Fei-Fei, Imagenet: A large-scale hierarchical image database, *2009 IEEE conference on computer vision and pattern recognition*, Ieee, 2009, pp. 248-255.
- [22] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [23] M. Robnik-Šikonja, I. Kononenko, Theoretical and empirical analysis of ReliefF and RReliefF, *Machine learning*, 53 (2003) 23-69.
- [24] W.S. Noble, What is a support vector machine?, *Nature biotechnology*, 24 (2006) 1565-1567.
- [25] L.E. Peterson, K-nearest neighbor, *Scholarpedia*, 4 (2009) 1883.
- [26] M.A. Farooq, A. Khatoon, V. Varkarakis, P. Corcoran, Advanced deep learning methodologies for skin cancer classification in prodromal stages, *arXiv preprint arXiv:2003.06356*, (2020).
- [27] F. Demir, Derin Öğrenme Tabanlı Yaklaşımla Kötü Huylu Deri Kanserinin Dermoskopik Görüntülerden Saptanması, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 33 (2021) 617-624.
- [28] E. Soylu, R. Demir, Development and Comparison of Skin Cancer Diagnosis Models, *Avrupa Bilim ve Teknoloji Dergisi*, (2021) 1217-1221.
- [29] N. Khasanah, R. Komarudin, N. Afni, Y.I. Maulana, A. Salim, Skin Cancer Classification Using Random Forest Algorithm, *SISFOTENIKA*, 11 (2021) 137-147.
- [30] K. Fırıldak, M.F. Talu, G. Çelik, Transfer Öğrenme ve Çekişmeli Üretici Ağ Yaklaşımlarını Kullanarak Cilt Lezyonu Sınıflandırma Doğruluğunu İyileştirilmesi, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32 (2020) 491-498.