

## Derin Öğrenme Tabanlı Yaklaşımla Kötü Huylu Deri Kanserinin Dermatoskopik Görüntülerden Saptanması

Fatih DEMİR<sup>1\*</sup>

<sup>1</sup> Elektronik ve Otomasyon Bölümü, Teknik Bilimler MYO, Fırat Üniversitesi, Elazığ, Türkiye  
\*<sup>1</sup> fatihdemir@firat.edu.tr

(Geliş/Received: 20/03/2021;

Kabul/Accepted: 22/04/2021)

**Öz:** Deri kanseri erken teşhis edilmezse ölümlü sonuçlanan vakalara yol açabilir. Dermatoskopik görüntüler, deri kanserini erken teşhis etmek için en önemli veridir. Yapay zeka modellerini içeren bilgisayar destekli uygulamalar, dermatoskopik görüntülerden deri kanserini teşhis etmek için uzmanlara yardım etmede faydalı bir araç olabilir. Özellikle, derin öğrenme tabanlı uygulamalar medikal görüntülerden hastalık tespit etmede popüler hale gelmiştir. Bu çalışmada, MobileNetV2 modelini içeren bir derin öğrenme tabanlı yaklaşım, dermatoskopik görüntülerden kötü huylu deri kanserini teşhis etmek için kullanılmıştır. Önceden eğitilmiş MobileNetV2 modelinin tam bağlı katmanındaki değerler kullanılarak öznelikler çıkarılmıştır. Bir sonraki aşamada sınıflandırma performansını artırmak için rasgele değişken (RD) ve L1-Norm DVM algoritmalarıyla özneliklerden yüksek seviyeli olanlar seçilmiştir. En son olarak diğer sınıflandırıcılara göre daha iyi performans sağladığı için Destek Vektör Makineleri (DVM) algoritması ile sınıflandırma işlemi yapılmıştır. Önerilen yöntemle %88.35 sınıflandırma doğruluğu elde edilmiştir. Ayrıca aynı veri setini kullanan bir diğer çalışmaya göre daha iyi bir başarımla sağlanmıştır. Bu çalışmada, eğitim sürecinde düşük hesaplama maliyeti elde edilmiştir. Gelecek çalışmalarda birden çok derin öğrenme modelinden elde edilen özneliklerle sınıflandırma performansı daha da artırılmaya çalışılacaktır.

**Anahtar kelimeler:** Kötü huylu deri kanseri, MobileNetV2 modeli, öznelik seçme, sınıflandırma.

### Detection of Malignant Skin Cancer from Dermatoscopic Images with Deep Learning Based Approach

**Abstract:** Skin cancer can lead to fatal cases if not diagnosed early. Dermatoscopic images are the most important data for early diagnosis of skin cancer. Computer-aided applications involving artificial intelligence models can be a useful tool in helping professionals to diagnose skin cancer from microscopic images. In particular, a deep learning-based applications have become popular for disease detection from medical images. In this study, a deep learning-based approach, including the MobileNetV2 model, was used to diagnose malignant skin cancer from dermatoscopic images. The features are extracted using values from the fully connected layer of the pre-trained MobileNetV2 model. In the next step, high-level features were selected by Random Forest (RF) and L1-Norm SVM algorithms to increase the classification performance. Finally, since it provides better performance compared to other classifiers, the classification process has been made with Support Vector Machines (SVM) algorithm. The classification accuracy of 88.35% was achieved with the proposed method. In addition, a better performance was achieved compared to another study using the same data set. In this study, low computational costs were obtained in the training process. In future studies, the classification performance will be tried to be further increased with features obtained from multiple deep learning models.

**Key words:** Malignant skin cancer, MobileNetV2 model, feature selection, classification.

#### 1. Giriş

Deri kanseri, beyaz tenli insanlarda en sık görülen kötücül hastalıktır. Bununla birlikte cilt kanserine yakalanma oranları küresel ölçekte artmaktadır [1]. Kötü huylu cilt kanseri (melanom), en ölümcül cilt kanseri türlerinden biridir ve dünya çapında yılda 55.000 kişi melanomdan ölmektedir; bu, tüm kanser ölümlerinin % 0.7'sine tekabül etmektedir. Ancak ölüm oranları ülkeden ülkeye büyük farklılıklar göstermektedir. 2008'den 2018'e kadar olan süreçte, melanom vakalarının yıllık sayısı, kısmen artan ultraviyole ışınlarına maruz kalmaya bağlı olarak %53 artmıştır [2]. Melanom, en ölümcül cilt kanseri türlerinden biri olmasına rağmen, erken teşhis, hayatta kalma şansını büyük bir oranda artırmaktadır.

Bir dermatolog tarafından kötü huylu bir lezyonun teşhisinin ilk adımı, şüpheli cilt bölgesinin görsel olarak incelenmesidir. Bazı lezyon tiplerinin benzerliğinden dolayı doğru tanı önemlidir; dahası, tanısal doğruluk, hekimin mesleki deneyimi ile ilişkilidir [3]. Ek teknik destek olmadan, dermatologlar melanom tanısında %65-

\* Sorumlu yazar: [fatihdemir@firat.edu.tr](mailto:fatihdemir@firat.edu.tr). Yazarların ORCID Numarası: <sup>1</sup> 0000-0003-3210-3664


%80'lik bir doğruluk oranına sahiptir [4]. Şüpheli durumlarda, görsel inceleme, özel bir yüksek çözünürlüklü ve büyüteçli kamera ile alınan dermatoskopik görüntülerle desteklenir. Kayıt sırasında aydınlatma kontrol edilir ve cilt üzerindeki yansımaları azaltmak için bir filtre kullanılır, böylece daha derin cilt katmanları görünür hale gelir. Bu teknik destek ile cilt lezyonu tanısının doğruluğu %49 daha artırılabilir [5]. Görsel inceleme ve dermatoskopik görüntülerin kombinasyonu sonucunda dermatologlar tarafından %75-%84 oranında mutlak melanom saptama doğruluğu elde edilebilir [6]. Bununla birlikte teşhis doğruluğu, farklı deneyimleri olan uzmanlar arasında büyük ölçüde değişebilir. Sonuç olarak, tarama programlarına ve ikinci bağımsız bir görüş olarak kullanılabilen yarı veya tam otomatik bilgisayar destekli tanı sistemlerinin geliştirilmesine büyük ilgi vardır [7]. Bu tür bilgisayar destekli tanı sistemlerinde en çok kullanılan yaklaşımlar yapay zeka modelleridir. Özellikle 2012 yılında Krizhevsky ve diğerlerinin [8] AlexNet isimli modelinin ImageNet 2012 yarışmasındaki başarısından sonra medikal görüntü sınıflandırma üzerine derin öğrenme yaklaşımlarının kullanımı artmıştır.

Cilt kanseri görüntülerinin sınıflandırılmasında derin öğrenme modelleri sıkça kullanılmıştır. Brinker ve diğerleri [9] cilt kanseri görüntülerini Nevus ve Melanoma olarak iki sınıfa ayırmıştır. Sınıflandırma için ResNet-50 modeli seçilmiştir. ResNet-50 modelinde, sabit bir öğrenme oranı yerine modelin her katmanı için farklı bir öğrenme oranı kullanılmıştır. Ayrıca, öğrenme hızlarını düşürmek için kosinüs işlevine dayalı yeni yöntemler kullanılmıştır. Bu metot ile % 82.3'lük bir duyarlılık oranı yakalanmıştır. Hosny ve diğerleri [10], veri setindeki her bir görüntüyü veri artırma tekniğini kullanarak veri setini büyüttüler ve transfer öğrenmesi yaklaşımı ile sınıflandırma problemi ele aldılar. Bu yaklaşım ile %95.91'lik sınıflandırma doğruluğuna ulaşılmıştır. Estava ve diğerleri [11], çalışmalarında kullandıkları veri setini iyi huylu ve kötü huylu olmak üzere iki sınıfa ayırmıştır. Ön işleme adımında, veri setindeki görüntüler Gauss filtreleme yöntemiyle işlenmiştir. AdNet isimli derin öğrenme modeli ile %87.81 doğruluğa ulaşılmıştır. Nugroho ve diğerleri [12] HAM10000 isimli cilt kanseri veri setini yedi sınıfa ayırmıştır. Sıfırdan tasarlanan ve eğitilen Evrişimsel Sinir Ağları (ESA) modeli %78 sınıflandırma doğruluğuna ulaşmıştır. Alqudah ve diğerleri [13], üç sınıf cilt kanseri görüntülerini tanımak için önceden eğitilmiş AlexNet ve GoogLeNet modellerini kullanmıştır. Kullanılan veri seti, bölütlemesiz veri seti ve bölütlemeli veri seti olmak üzere iki formata ayrılmıştır. Sınıflandırma doğruluğu bölütlemeli veri seti için % 92.2 ve bölütlemesiz veri seti için % 89.8 olmuştur.

Bu çalışmada önceden eğitilmiş MobileNetV2 modeline ve Destek Vektör Makinelerine (DVM) dayanan bir yaklaşım, dermatoskopik görüntülerden iyi huylu ve kötü huylu deri kanserini tespit etmek için önerilmiştir. MobileNetV2 modeli öznetelik çıkarma işlemi için kullanılmıştır. L1-Norm DVM ve Rasgele Değişken (RD) algoritmaları ile öznetelik seçimi yapılmıştır. Sınıflandırma aşamasında polinomal (kübik) çekirdek fonksiyonunu kullanan DVM algoritması yüksek bir performans sağladığı için seçilmiştir.

## 2. Materyal ve Metodoloji


Bu çalışmada iki sınıflı (iyi huylu ve kötü huylu) deri kanseri sınıflandırma problemi için derin öğrenme tabanlı bir yaklaşım önerilmiştir. Önerilen yöntem öznetelik çıkarma, öznetelik seçme ve sınıflandırma olmak üzere üç aşamadan oluşmaktadır. Öznetelik çıkarma aşamasında önceden eğitilmiş MobileNetV2 modelinin "Logits" isimli tam bağlı katmanı kullanılmıştır. Bu katmandan 1000 adet öznetelik elde edilmiştir. Öznetelik seçme aşamasında L1-Norm DVM algoritması ile 217 adet RD algoritması ile 223 adet öznetelik seçilmiştir. Sınıflandırma performansını artırmak için bu iki öznetelik seti birleştirilmiştir. Sınıflandırma aşamasında daha iyi sınıflandırma doğruluğu verdiği için DVM algoritması kullanılmıştır. Önerilen yöntemin temsili gösterimi Şekil 1'de verilmiştir.



Şekil 1. Önerilen yöntemin temsili gösterimi.

## 2.1. Veri seti

Bu çalışmada kullanılan veri seti toplam 3297 adet görüntüden oluşmaktadır. Bu görüntülerin her biri 224×224 yükseklik ve genişlikle JPG formatında kaydedilmiştir. Bu görüntülerin 1800 adedi iyi huylu tümör ve 1497 adedi kötü huylu tümör olarak etiketlenmiştir. Bu veri seti oluşturulurken uzman doktorlar hastalardan biyopsi örnekleri almıştır ve kanser hücrelerinin daha net görünmesi için dermatoskop cihazları kullanılmıştır. Veri setindeki her iki sınıf için birkaç örneğin gösterimi Şekil 2’de verilmiştir.




Şekil 2. Her iki sınıf için veri setinden örnekler.

## 2.2. MobileNetV2 Mimarisi

MobileNetV1 [14], Google ekibi tarafından 2017 yılında önerilen, mobil veya gömülü cihazlara odaklanan hafif bir ESA modelidir. MobileNetV1, standart evrişimin iki aşamasını, yani derinlemesine evrişim ile noktasal evrişimi derinlemesine ayrılabilen evrişimi kullanmaktadır. MobileNetV1 yapısında bit çarpımının hesaplanması kanallara göre yapılır ve kanal sayısı değişmez. Daha sonra, 1×1 evrişim çekirdeğinin kanal sayısı değiştirilebilir. MobileNetV1'in hiperparametreleri ayarlanarak verimlilik ve doğruluk arasındaki denge sağlanabilir.

MobileNetV2 [15], MobileNetV1 modeline tersine çevrilmiş artık yapılar ve doğrusal darboğazlar getirerek geliştirilmiştir. Derinlemesine evrişim, kanal sayısını değiştiremez ve bu da öznetellik çıkarımının giriş kanallarının sayısı ile sınırlı olmasına neden olur. Tersine çevrilmiş artık yapılar bu sorunu çözer. Artık yapı,  $1 \times 1$  boyutunda azalan evrişim filtresi,  $3 \times 3$  boyutunda evrişim filtresi ve  $1 \times 1$  boyutunda artan evrişim filtresi düzeninde olan yapı tersine çevrilmiş artık yapıda  $1 \times 1$  boyutunda artan evrişim filtresi,  $3 \times 3$  boyutunda derinlemesine evrişim filtresi ve  $1 \times 1$  boyutunda azalan evrişim filtresi düzenindedir. Tersine çevrilmiş artık yapıdaki aktivasyon fonksiyonu, öğrenmeyi hızlandırır, gradyan dağılımını bastırır ve modelin kararlılığını artırır. MobileNetV2 modelinin blok yapısı Şekil 3'te verilmiştir.



Şekil 3. MobileNetV2 modelinin blok şeması.

## 2.2. Rastgele Değişken (RD) Algoritması

RD, birbiriyle ilgisiz birden çok karar ağacı oluşturmak için rastgele yeniden örnekleme önyüklemesi tekniği ile düğüm stokastik sınıflandırma tekniğini kullanan ve oylama yoluyla nihai sınıflandırma sonuçlarını üreten entegre bir makine öğrenmesi yöntemidir [16]. RD, karmaşık etkileşimli özellikleri analiz edebilir (Şekil 2). RD yöntemi, gürültü ile eksik verilere karşı daha sağlamdır ve daha hızlı bir öğrenme hızına sahiptir. RD algoritması değişkenlerin önem ölçümünü yapabildiğinden, yüksek boyutlu veriler için bir öznetelik seçim aracı olarak kullanılabilir.

Eğitim verilerinin  $(X, Y)$   $n$  adet örnek içerdiği varsayılırsa, bir regresyon ağacı oluşturmak için  $b$  alt kümelerini rasgele çıkarılır.  $i$  ( $icb$ ) alt kümesi çıkarıldığında, diğer örnekler torba dışı veriler olarak kabul edilir. Ek olarak, sabit boyutlu  $m$  ( $m < M$ ) vektörü, girdi değişkeni olarak  $M$  boyutlu vektörden seçilir ve regresyon ağacının öznetelik uzayı oluşturulur. Bölme değişkeni, bölme büyüme süreci sırasında minimum varyans kriteri tarafından seçilir (Denklem 1).

$$I = \min_s \frac{\sum_{s=1}^n (X_s - X'_s)^2}{n} \quad (1)$$

burada  $I$ , optimal bölme değişkeni ve  $s$ , gömülü örnek boyutudur.  $X_s$  ve  $X'_s$  sırasıyla değişkenlerin değerini ve ortalama değerini temsil eder. Ağaç büyümesi tamamlandıktan sonra rastgele bir değişken oluşur ve daha sonra torba dışındaki verilerin model üzerindeki etkisi ortalama kare hata ( $OKH$ ) ile hesaplanır.

$$OKH = \frac{\sum_{i=1}^n (y_i - y'_i)^2}{n} \quad (2)$$

$n$ , çantanın dışındaki verilerin örnek boyutunu belirtir;  $y_i$ ,  $y'_i$  sırasıyla örnek setinin gerçek ve tahmin edilen değerlerini temsil eder. RD modeli, ortalama kare artıkları aracılığıyla gösterge girdi değişkenlerinin önemini azaltır,  $[OKH_1, OKH_2, \dots, OKH_k]$  'deki ortalama kare kalıntıların sırasını elde etmek için cep dışı verilerle  $K$  regresyon ağaçları oluşturur ve torbadan çıkarılan veri artık matrisini oluşturmak için çoklu örneklemeden sonra yeni regresyon ağacı  $K$ 'yi oluşturur.  $M$  girdi değişkeni için değişken önemi ( $D_{\delta}$ ) Denklem 3'teki gibi ölçülür.

$$D_{\delta} = \frac{\sum_{j=1}^k (OKH_j - OKH_{kj})}{k.S_H} \quad (3)$$

$D_{\delta}$  değişkenin önem puanı,  $k$  ( $j \in k$ ) karar ağaçlarının sayısı,  $S_H$ ,  $K$  karar ağaçlarının standart hatasıdır.

### 2.3. L1-Norm DVM

L1-Norm DVM algoritmasında öznitelik sayısı maliyet parametresi ( $M$ ) ile belirlenir.  $N$  örneğe sahip bir veri seti ( $X$ ) Denklem 4'teki gibi ifade edilmiştir.

$$X = \{(x_i, y_i) | x_i \in R^n, y_i \in \{-1, 1\}\}_{i=1}^k \quad (4)$$

Burada  $x_i$ , örneklerini ( $y_i$ ) sınıf etiketlerini temsil etmektedir. Binari sınıflandırma probleminde (Denklem 5) DVM algoritması ile, kenar payını maksimize edecek hiper düzlem öğrenilir.

$$y_i(wx_i - b) \geq 1, i = 1, \dots, k \quad (5)$$

Burada,  $w$  ağırlık vektörü ve  $b$  ise bias vektörüdür. Denklem 5'teki problemi baz alarak Denklem 6'da belirlenen optimizasyon probleminin çözümlenmesi gerekir.

$$\min \frac{1}{2} \|w\|^2 \quad (6)$$

Kenar payının yakınındaki mesafe hatalarından kaynaklanan çözümlenmeleri düzeltmek için Denklem 4, Denklem 6'daki gibi yeniden düzenlenir.

$$y_i(wx_i - b) \geq 1 - \delta, \delta_i \geq 0, i = 1, \dots, k \quad (7)$$

Ortaya çıkan seyrek çözümlerin bir sonucu olarak L1-Norm DVM tabanlı öznitelik seçimi için Denklem 5 kısıtlaması ile Denklem 6 kullanılır [17].

$$\min \|w\|^1 + M \sum_{i=1}^k \max(0, 1 - y_i(\alpha^T x_i + b))^2 \quad (8)$$

" $\alpha$ ", Lagrange çarpanları ile elde edilen katsayılardan oluşan vektörü temsil eder.  $M$  maliyet parametresi ile seçilen özniteliklerin sayısı belirlenir.

### 2.3. DVM sınıflandırıcısı

DVM sınıflandırıcısı iki sınıfı birbirinden ayırmak için bir hiper düzlem ( $w^T x_i + b = 0$ ) kullanır. Lagrange algoritması ile optimize edilen  $w$  ağırlıklarının Denklem 9'daki eşitliği sağlamaktadır.

$$w = \sum_i^n \alpha_i y_i x_i \quad (9)$$

$n$  destek vektörleri,  $y_i$  sınıfları,  $x_i$  girişleri ve  $\alpha_i$  Lagrange katsayılarını simgelemektedir. Lineer ayrılan ve lineer ayrılamayan örnekler için DVM algoritmasında kullanılan karar verme işlevleri sırasıyla Denklem 10 ve Denklem 11'de verilmiştir.

$$f(x) = \text{sgn}(\sum_i^n \alpha_i y_i x_i^T x + b) \quad (10)$$

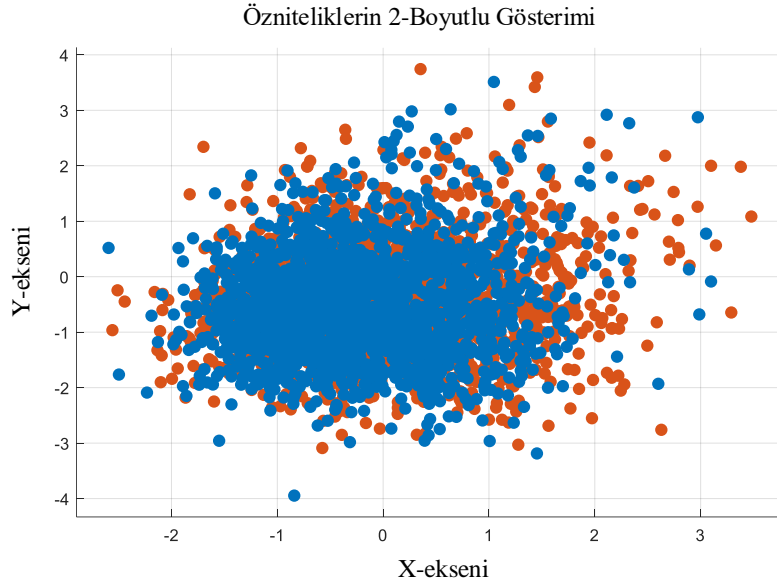
$$f(x) = \text{sgn}(\sum_i^n \alpha_i y_i K(x_i, x) + b) \quad (11)$$

Denklem 11'deki  $K$ , çekirdek işlevidir. Lineer olmayan örnekler  $K$  ile farklı bir uzaya taşındıktan sonra örnekler lineer olarak ayrılabilir.

## 3. Deneysel Çalışma ve Sonuçlar

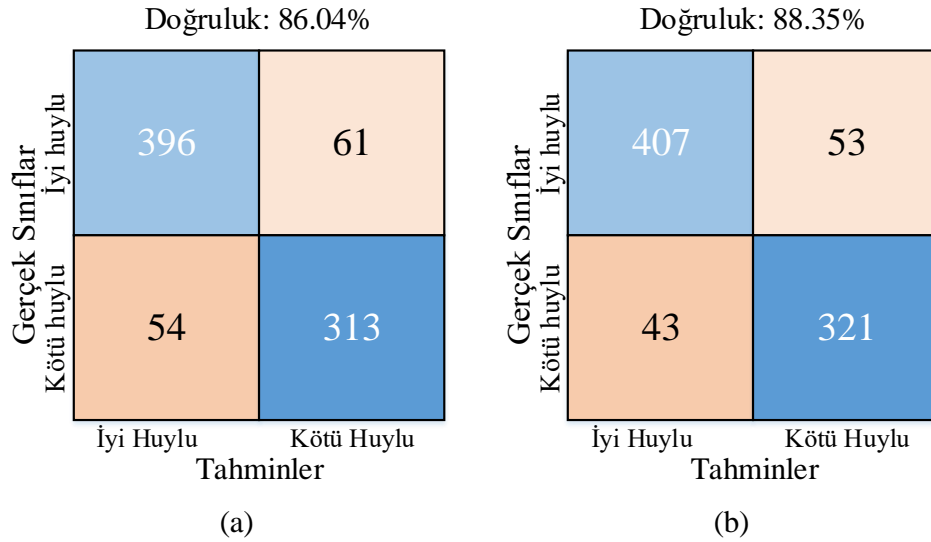
Bu çalışmadaki tüm kodlamalar Windows 10 işletim sistemi üzerine kurulu Matlab isimli simülasyon programıyla gerçekleştirilmiştir. Önerilen metodun performansını değerlendirmek için kullanılan veri setinin %75'i eğitim için, %25'i test için rasgele ayrılmıştır. Öznitelikleri çıkarmak için MobileNetV2 modelinin "Logits" isimli tam bağlı katmanı kullanılmıştır. Bu katmandan 1000 adet öznitelik çıkarılmıştır. Hem hesaplama maliyetini

azaltmak hem de sınıflandırma performansını artırmak için RD ve L1-Norm DVM öznelik seçme algoritmaları kullanılmıştır. RD algoritmasında ağaç sayısı 50 olarak ayarlanarak 223 adet öznelik seçilmiştir. L1-Norm DVM algoritmasında cezalandırma parametresi ( $M$ ) 0.02 seçilerek 217 öznelik çıkarılmıştır. Bu iki öznelik seti birleştirilerek (440 öznelik) DVM sınıflandırıcısına iletilmiştir. Birleştirilen öznelik setinin saçılım düzeni Şekil 4'te verilmiştir. Şekil 4'te görüldüğü gibi iki sınıfa ait veriler doğrusal olarak ayırlanamamaktadır. Bu nedenle DVM algoritmasında 3. dereceden polinomal (kübik) çekirdek işlevi kullanılmıştır. Ayrıca DVM sınıflandırıcısının çekirdek boyutu "19" olarak seçilerek kutu sınırlaması "1" olarak seçilmiştir.



Şekil 4. Birleştirilmiş özneliklerin saçılım düzeni.

Öznelik seçme algoritmalarının kullanılmadığı ve kullanıldığı her iki durum için karmaşıklık matrisi sonuçları Şekil 5'te verilmiştir. Öznelik seçme algoritmalarının kullanılmadığı durum için %86.04 sınıflandırma doğruluğu elde edilmiştir (Şekil 5(a)). Öznelik seçme algoritmalarının kullanıldığı durum için %88.35 sınıflandırma doğruluğuna ulaşılmıştır (Şekil 5(b)). Ayrıca her iki durum için duyarlılık, özgüllük, kesinlik ve F-skor sonuçları Tablo 1'de verilmiştir.



Şekil 5. Karmaşıklık matrisi sonuçları.

**Tablo 1.** Diğer performans metriklerinin sonuçları

Öznitelik sayısı	Sınıflar	Duyarlılık	Özgüllük	Kesinlik	F-skor
1000	İyi Huylu	0.87	0.85	0.88	0.87
	Kötü Huylu	0.85	0.86	0.84	0.84
440	İyi Huylu	0.88	0.88	0.90	0.89
	Kötü Huylu	0.88	0.88	0.86	0.87

Tablo 2’de RD ve L1-Norm DVM algoritması ile çıkartılan özniteliklerin diğer sınıflandırıcı algoritmalarındaki sınıflandırma doğrulukları verilmiştir.

**Tablo 2.** Sınıflandırıcılara göre doğruluk sonuçları

Sınıflandırıcılar	Doğruluk (%)
Lineer Ayırtaç	83.75
Karar Ağacı	76.50
K-en Yakın Komşu	80.55
Saf Bayes	72.30
DVM	88.35

Tablo 3’te aynı veri setini kullanan Farooq ve diğerleri [18] Inception-V3 modelini ve MobileNetV1 modelini sınıflandırma için kullanmıştır. Inception-V3 modeli MobileNetV1 modelinden daha iyi performans sağlayarak %86 sınıflandırma doğruluğuna ulaşmıştır.

**Tablo 3.** Aynı veri setini kullanan yöntem ile karşılaştırma

Metot	Model	Doğruluk (%)
Farooq ve diğerleri [18]	Inception-V3 ve MobileNetV1	86.00
Önerilen metot	MobileNetV2, L1Norm, RD ve DVM	88.35

#### 4. Sonuçlar

Bu çalışmada, dermatoskopik görüntülerden kötü huylu deri kanserini saptamak için MobileNetV2 derin öğrenme modelini ve DVM algoritmasını içeren bir yaklaşım kullanılmıştır. Ayrıca önerilen yöntemin başarımını artırmak için RD ve L1-Norm algoritmaları ile öznitelik seçimi yapılmıştır. Öznitelik seçimi kullanılmadan önerilen yöntemin sınıflandırma doğruluğu %86.04 olmuştur. Öznitelik seçme algoritmaları ile sınıflandırma doğruluğu %2.31 oranında iyileştirilmiştir. Ayrıca aynı veri setini kullanan diğer bir yöntemle göre sınıflandırma doğruluğu %2.35 oranında geliştirilmiştir. Bununla birlikte diğer derin öğrenme tabanlı yaklaşımlar kullanılarak sınıflandırma doğruluğu artırılacağı düşünülmektedir. Bu çalışmada, sıfırdan eğitilmiş bir derin öğrenme modeli kullanılmadığı için eğitim sürecinde düşük hesaplama maliyeti elde edilmiştir. Bu durum da öğrenilebilir parametrelerin optimizasyon süresini azaltmıştır. Ayrıca öznitelik seçme algoritmalarıyla öğrenilebilir parametre sayısı daha da azaltılmıştır. Dahası daha az parametre ile daha yüksek bir başarımla elde edilmiştir. Önerilen bu yöntemin uzmanlara karar vermede yardımcı bir araç olarak kullanılması düşünülmektedir.

#### Kaynaklar

- [1] Nami N, Giannini E, Burrioni M, Fimiani M, Rubegni P. Teledermatology: state-of-the-art and future perspectives. Expert Review of Dermatology 2012; 7(1): 1–3.
- [2] Fabbrocini G, Triassi M, Mauriello MC, Torre G, Annunziata MC, De Vita V, Pastore F, D'Arco V, ve diğerleri. Epidemiology of skin cancer: role of some environmental factors, Cancers 2010; 2(4), 1980–1989.
- [3] Haenssle HA, Fink C, Schneiderbauer R, Toberer F, Buhl T, Blum A, Kalloo A, Ben Hadj Hassen, ve diğerleri. Man against machine: diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. Annals of Oncology 2018; 29(8), 1836–1842.

- [4] Argenziano G, Soyer HP. Dermoscopy of pigmented skin lesions--a valuable tool for early. *The lancet oncology* 2001; 2(7), 443–449.
- [5] Kittler H, Pehamberger H, Wolff K, Binder M. Diagnostic accuracy of dermoscopy. *The lancet oncology* 2002; 3(3), 159–165.
- [6] Ali A-RA, Deserno TM. A systematic review of automated melanoma detection in dermatoscopic images and its ground truth data. In *Medical Imaging*; 12 February 2012; San Diego, California, USA.
- [7] Fabbrocini G, De Vita V, Pastore F, D'Arco V, Mazzella C, Annunziata MC, Cacciapuoti S, Mauriello MC, ve diğerleri. Teledermatology: from prevention to diagnosis of nonmelanoma and melanoma skin cancer. *International journal of telemedicine and applications* 2011; 2011(125762).1-5.
- [8] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks, *Communications of the ACM* 2017; 60(6), 84–90.
- [9] Brinker TJ, Hekler A, Enk AH, Berking C, Haferkamp S, Hauschild A, Roman C, Berking C. Deep neural networks are superior to dermatologists in melanoma image classification, *European Journal of Cancer* 2019; 119, 11–17.
- [10] Hosny KM, Kassem MA, Foad MM. Classification of skin lesions using transfer learning and augmentation with AlexNet, *PloS one* 2019; 14(5), 217-293.
- [11] Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, Thrun S. Dermatologist-level classification of skin cancer with deep neural networks, *nature* 2017; 542(7639), 115–118.
- [12] Nugroho AA, Slamet I, Sugiyanto. Skin cancer identification system of HAM10000 skin cancer dataset using convolutional neural network, In *AIP Conference Proceedings*; 27 December 2019; pp. 20039.
- [13] Alqudah AM, Alquraan H, and Qasmieh IA. Segmented and non-segmented skin lesions classification using transfer learning and adaptive moment learning rate technique using pretrained convolutional neural network, In *Journal of Biomimetics, Biomaterials and Biomedical Engineering* 2019; 42, 67–78.
- [14] Howard AG, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T. Mobilenets: Efficient convolutional neural networks for mobile vision applications 2019; arXiv preprint arXiv:1704.04861.
- [15] Sandler M, Howard A, Zhu M, Zhmoginov A, and Chen L-C. Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*; 18-22 June 2018; Salt Lake City, Utah, USA, pp. 4510–4520.
- [16] [Liu S, Li H, Zhang Y, Zou B, Zhao J. Random forest-based track initiation method. *The Journal of Engineering* 2019; 2019(19), 6175–6179.
- [17] Bradley PS, Mangasarian OL. Feature selection via concave minimization and support vector machines, In *ICML* 1998; 98, 82–90.
- [18] Farooq MA, Khatoon A, Varkarakis V, Corcoran P. Advanced Deep Learning Methodologies for Skin Cancer Classification in Prodromal Stages 2020; arXiv preprint arXiv:2003.06356.