




Deri lezyonlarının evrimsel yapay sinir ağları ile sınıflandırılması

Classification of skin lesions using convolutional neural networks

Onur BİLGİNER¹ , Burcu TUNGA^{1*} , Rüştü Murat DEMİRER² 

¹Matematik Mühendisliği Bölümü, Fen-Edebiyat Fakültesi, İstanbul Teknik Üniversitesi, İstanbul, Türkiye
bilginer16@itu.edu.tr, tungab@itu.edu.tr

²Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Işık Üniversitesi, İstanbul, Türkiye.
murat.demirer@isikun.edu.tr

Geliş Tarihi/Received: 15.10.2020
Kabul Tarihi/Accepted: 08.09.2021

Düzeltilme Tarihi/Revision: 24.08.2021

doi: 10.5505/pajes.2021.68700
Araştırma Makalesi/Research Article

Öz

Bu çalışmada Uluslararası Deri Görüntüleme Birliği tarafından 2019 yılında yayınlanan ve 25000'den fazla dermoskopik deri görüntüsü içeren ISIC 2019 veri seti kullanılarak 4 çeşit (Melanom, Melanositik Nevüs, Bazal Hücreli Karsinom, İyi Huylu Keratoz) deri pigmentasyonu Evrimsel Sinir Ağları yöntemi yardımıyla sınıflandırılmıştır. Sınıflandırma yapılırken InceptionV3 yapay sinir ağı mimarisi kullanılmıştır. Deri görüntülerine ön işlem olarak Hilbert Dönüşümü ve Yüksek Boyutlu Model Gösterilimi uygulanmıştır. Elde edilen sonuçlara göre test verisi üzerinde Hilbert Dönüşümü uygulanmış görüntülerde Bazal Hücreli Karsinom hastalığının sınıflandırılmasında %89 başarı oranı elde edilmiştir. Yüksek Boyutlu Model Gösterilimi ile Kontrast Artırımı uygulanan görsellerde ise Melanomun sınıflandırılmasında %78 başarı oranı elde edilmiştir.

Anahtar kelimeler: Deri pigmentasyonlarının sınıflandırılması, Hilbert dönüşümü, Yüksek boyutlu model gösterilimi.

Abstract

In this paper we classified 4 skin lesions (Melanoma, Melanocytic Nevus, Basal Cell Carcinoma, Benign keratosis) from ISIC 2019 dataset which was published by International Skin Imaging Collaboration in 2019. We used InceptionV3 convolutional neural network model for classification. We applied two preprocessing methods: High Dimensional Model Representation (HDMR) and Hilbert Transform. In conclusion we obtained 89% accuracy on classification of Basal Cell Carcinoma using Hilbert Transform. Moreover, we obtained 78% accuracy on classification of Melanoma using Contrast Enhancement High Dimensional Model Representation (HDMR).

Keywords: Classifications of skin lesions, Hilbert transform, High dimensional model representation.

1 Giriş

Dünya genelinde yaygın görülen deri kanserlerinden olan Melanom ve Bazal Hücreli Karsinomun (BHK) erken teşhisi hastanın hayatta kalma şansını ciddi ölçüde artırmaktadır. Bu nedenle birçok Avrupa Birliği kuruluşu deri kanserinde erken teşhis programlarını desteklemektedir. Önceleri Melanom ve BHK başarıyla tespit edilmesi dermatologların teşhis yeteneğine bağlıyken, 2017 yılında ilk kez Evrimsel Sinir Ağları (ESA) kullanılarak sınıflandırma yapılmıştır [1]. Girdi olarak görüntüler alan ve bu görüntüleri birbirinden ayırıp kategorize eden bir derin öğrenme algoritması olan ESA ile yapılan çalışmalar [2]-[4], sinir ağları kullanarak Nevüs ve Melanom ayırt etmenin dermatologların tespitine göre daha hassas olduğunu göstermiştir[1]. Bununla birlikte, yalnızca ikili sınıflandırma diğer tür lezyonları yok saydığından Nevüs ve Melanom dışındaki diğer tür hastalıkların teşhisinde sıkıntı yaratmaktaydı. Bunun için araştırmacılar çoklu sınıflandırma yapabilecek modeller üzerinde çalışmaya başlamışlardır. Ancak bugüne kadar dermatologlardan daha iyi bir hassasiyetle çoklu tahmin yapan bir model ortaya koyulamamıştır [5].

Bu çalışmada, 2019 yılında Uluslararası Deri Görüntüleme Birliği tarafından yayınlanan ISIC 2019 veri seti kullanılmıştır. Bu veri setini kullanan başka çalışmalar da vardır: Bunlardan ilki, 5 çeşit deri lezyonu kullanılarak 13 dermatolog tarafından yapılan sınıflandırmayı ve aynı zamanda ESA kullanılarak hem ikili (iyi huylu, kötü huylu) hem de çoklu sınıflandırmayı içeren çalışmadır. Bu çalışmada elde edilen sonuçlara göre ESA modeli

ile yapılan hem ikili hem de çoklu sınıflandırmanın, dermatologların yaptığından daha duyarlı ve özgün olduğu görülmüştür [6]. ISIC veri tabanını kullanan diğer bir çalışmada ise yine ESA kullanılarak cilt lezyonlarının yeni bir yöntemle sınıflandırması yapılmaya çalışılmıştır. Bu çalışmada sekiz farklı deri lezyonuna ait görüntü ile çalışılmış, renk sabitliği algoritması, veri artırma ve ağırlıklandırma tekniklerinden yararlanılarak sınıflandırma yapılmış ve Melanomun tespitinde %61, BHK'nın tespitinde ise %86 başarı sağlanmıştır [7]. Aynı veri tabanını kullanan bir başka çalışmada ise transfer öğrenmesi ve GoogleNet ile önceden eğitilmiş model kullanılmaktadır. Model parametreleri başlangıç değerleri olarak kullanılır ve sonra bunlar eğitim yoluyla değiştirilmektedir. Bu yöntemle sekiz farklı cilt grubunun sınıflandırılması yapılmış ve Melanomun tespitinde %71, BHK'nın tespitinde ise %80 başarı sağlanmıştır [8]. 2020 yılında yine aynı veri seti üzerinde EfficientNet ESA mimarisi kullanan bir başka çalışmada ise 8'li sınıflandırma yapılmış Bazal Hücreli Karsinoma tespitinde %72 başarı sağlanırken, Melanomun tespitinde %59 başarı sağlanmıştır [9].

Burada önerilen ESA tabanlı deri lezyonu sınıflandırılması yöntemi içerisinde öncelikle Yüksek Boyutlu Model Gösterilimi (YBMG) ve Hilbert dönüşümü kullanılarak görüntüler iki farklı ön işlemden geçirilmiş, yeniden ölçeklendirilmiş ve elde edilen yeni görüntüler ayrı ayrı basit bir Evrimsel sinir ağı (ESA) modeli ve yine bir ESA modeli olan InceptionV3 mimarisi kullanılarak sınıflandırmaya tabi tutulmuştur. Elde edilen sonuçlar iki farklı ön işlem ve ön işlemsiz durum için

*Yazışılan yazar/Corresponding author

karşılaştırmalı olarak değerlendirilerek tablolar halinde verilmektedir.

2 Veri seti

2019 yılında yayınlanan ISIC veri tabanında Melanom, Melanositik Nevüs, Bazal Hücreli Karsinom, Aktinik Keratoz, İyi Huylu Keratoz, Dermatofibrom, Vasküler Lezyonlar, Skumaöz Hücreli Karsinom ve hiçbir kategoriye ait 25331 deri görüntüsü bulunmaktadır. Bu çalışmada bu farklı deri hastalıklarına ait görüntülerden yalnızca dördü sınıflandırma amaçlı olarak seçilmiştir toplamda farklı deri bozukluklarına ait 23344 dermoskopik görüntüsü kullanılmıştır[10]. Bu bozukluklar veri setindeki kısaltmaları ile birlikte aşağıdaki gibidir:

- Melanom (MEL),
- Melanositik Nevüs (NV),
- Bazal Hücreli Karsinom (BCC),
- İyi Huylu Keratoz (BKL).


Bu deri lezyonlarından Melanom Bazal Hücreli Karsinom kötü huylu Melanositik Nevüs ve İyi Huylu Keratoz iyi huylu olarak bilinmektedir. Çalışmada kullanılan görsellerin veri setindeki dağılımı Tablo 1'de verilmektedir.

Tablo 1. Kullanılan veri sayıları.

Table 1. Number of data.

MEL	NV	BCC	BKL
4552	12456	3323	2624

Bu hastalıklara ait örnek deri görselleri ise Şekil 1'de gösterilmiştir. Bu görseller soldan sağa doğru sırasıyla Melanom, Melanositik Nevüs, Bazal Hücreli Karsinom ve İyi Huylu Keratoz lezyonlarına aittir.



Şekil 1. Dermoskopik görseller.

Figure 1. Dermoscopic images.

3 Önerilen yöntem

Önerilen ESA tabanlı deri lezyonu sınıflandırılması yöntemi sırasıyla kaskad bağlanan iki ana yapıdan geçmektedir: Önişleme süreci ve ESA tabanlı sınıflandırma süreci

3.1 Önişleme süreci

ISIC 2019 veri setinde yer alan ve yukarıda açıklanan şekilde 4 kategoriye ait görüntülere iki farklı önişlem uygulanmıştır. Bunlardan ilkinde, görüntülere YBMG yöntemi kullanılarak görüntünün kontrastlığı artırılmış; ikincisinde ise Hilbert dönüşümü kullanılarak yeni görüntüler elde edilmiştir. Bir sonraki alt bölümde bilimsel yazında yer alan bu iki yöntem ile ilgili kısa anlatım yapılacaktır.

3.1.1 YBMG kullanılarak kontrast artırma

Son 30 senedir bilimsel yazında yer alan ve bir çok araştırma alanında kullanılan Yüksek Boyutlu Model Gösterilimi (YBMG) yöntemi, çok değişkenli fonksiyonlar ve çok değişkenli veri setlerinde ayrıştırım ve boyut indirgeme amacıyla kullanılan bir yöntemdir[11]-[13]. YBMG, çok değişkenli bir fonksiyonu

daha az değişkenli fonksiyonların sonlu toplamı şeklinde; eğer ayrık veriler üzerinde çalışılıyorsa çok değişkenli bir veri setini daha az değişkenli veri setlerinin toplamı olarak yazılmasına olanak sağlar[14],[15].

YBMG açılımına ait temel formül aşağıda verilmektedir.

$$f(x_1, \dots, x_N) = f_0 + \sum_{i=1}^N f_i(x_i) + \sum_{\substack{i,j=1 \\ i < j}}^N f_{ij}(x_i, x_j) + \dots + f_{12\dots N}(x_1, \dots, x_N) \quad (1)$$

Açılımın sağ taraf terimleri birbirine diktir ve aşağıdaki yok olma koşulları sağ taraf terimlerini belirlemede kullanılır.

$$\int_{a_1}^{b_1} dx_1 \dots \int_{a_N}^{b_N} dx_N W_1(x_1) \dots W_N(x_N) f_i(x_i) = 0 \quad (2)$$

Yok olma koşullarının içerisinde yer alan ağırlık fonksiyonu çarpımsaldır ve aşağıda verilen normalizasyon koşulunu sağlar.

$$W(x_1, \dots, x_N) \equiv \prod_{j=1}^N W_j(x_j), \quad x_j \in [a_j, b_j] \quad (3)$$

$$\int_{a_j}^{b_j} dx_j W_j(x_j) = 1$$

YBMG algoritmasının başlıca işi sağ taraf terimlerinin belirlenmesidir. Sabit terimin belirlenmesi amacıyla

$$I_0[F(x_1, \dots, x_N)] = \int_{a_1}^{b_1} dx_1 W_1(x_1) \dots \int_{a_N}^{b_N} dx_N W_N(x_N) F(x_1, \dots, x_N) \quad (4)$$

operatörü tanımlanır. Bu operatör Denklem (1) ile verilen YBMG'nin temel açılımının her iki tarafına, yok olma ve normalizasyon koşulları altında etki ettirildiğinde açılımın sağ tarafına ait ilk terim olan f_0 bulunacaktır. Daha üst basamaktan terimler de benzer operatörler tanımlanarak bulunabilir[11],[14],[16]. YBMG açılımı daha önce belirttiği gibi

$$d_j \equiv (\xi_1^{(j)}, \dots, \xi_N^{(j)}, \phi_j), \quad (5)$$

$$\phi_j \equiv f(\xi_1^{(j)}, \dots, \xi_N^{(j)}), \quad 1 < j \leq m$$


şeklindeki ayrık noktalarda verilen çok değişkenli veri setleri için de kullanılmaktadır. Bu veri setleri için YBMG yöntemi içinde yer alan ağırlık fonksiyonları Dirac delta fonksiyonları olarak seçilmelidir.

$$W(x_1, x_2, \dots, x_N) = \sum_{j=1}^m \alpha_j \delta(x_1 - \xi_1^{(j)}) \dots \delta(x_N - \xi_N^{(j)}) \quad (6)$$

Burada, α parametresi veri seti içerisindeki her bir noktaya farklı önem verilmesi amacıyla kullanılır.

RGB formatındaki bir görsel her bir pikseldeki renk bilgisini saklayan kırmızı (R), yeşil (G) ve mavi (M) olmak üzere 3 ayrı kanaldan oluşur. Diğer bir deyişle, birer 3 değişkenli veri seti olarak düşünülebilir ve $I(x,y,z)$ şeklinde gösterilebilir. Burada x ve y , piksellerin konumlarına karşılık gelirken z ise RGB kanallarını ifade etmektedir.

Renkli bir görsel YBMG açılımı kullanılarak sabit, tek değişkenli, iki değişkenli ve üç değişkenli bileşenlerin toplamı olarak ifade edilebilir [16],[17]. Burada sabit bileşen ve birli bileşenler düşük frekanslı bileşenlerdir. Sabit bileşen gri tonlu bir görsel bilgisine sahipken, tek değişkenli bileşenler yatay ve dikey çizgiler şeklinde renk bilgisi tutmaktadır. İki değişkenli bileşenler görselin ana hatlarının bilgisini tutarken, üç değişkenli bileşenler ise bu hatların etrafındaki yüksek frekanslı bileşenlerin bilgisini saklamaktadır. Bu sayede bir renkli görseldeki kontrastı artırmak için iki ve üç değişkenli bileşenler orijinal görselin üzerine eklenir [16],[17]. YBMG bileşenleri kullanılarak kontrastı artırılmış bir deri görseli ve orijinal hali Şekil 2’de verilmektedir.



Şekil 2. Orijinal ve kontrastı artırılmış görseller.

Figure 2. Original and contrast enhanced images.

3.1.2 Hilbert dönüşümü

David Hilbert tarafından ortaya atılan Hilbert Dönüşümü, girdi olarak bir fonksiyon alan ve çıktı olarak başka bir fonksiyon veren bir doğrusal operatördür. Hilbert Dönüşümü, Cauchy integral formülü kullanılarak aşağıdaki gibi tanımlanmıştır [18].

$$v(t) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{u(\eta)}{t - \eta} d\eta \quad (7)$$

Bir fonksiyonun (veya sinyalin) $u(t)$ Hilbert dönüşümü, bu integralin bir temel değer olarak mevcut olması koşuluyla verilir. Has olmayan integral dönüşümü aşağıdaki şekilde tanımsız bölgeye çok yaklaşılarak ama dışında kalarak iki kere integrali alınır.

$$v(t) = \lim_{\epsilon \rightarrow 0} \frac{-1}{\pi} \int_{-A}^{\epsilon} \frac{u(\eta)}{\eta - t} d\eta + \int_{\epsilon}^A \frac{u(\eta)}{\eta - t} d\eta \quad (8)$$

u fonksiyonu (satur vektörü) her deri lezyonu görüntüsünde bir satur vektörüne karşılık gelen pikselleri gösterir. Hilbert Dönüşümünün her satıra uygulanmasıyla her satur vektörü u nun harmonik eşleniği olan v vektörü elde edilir. Bu şekilde o satur boyunca her piksele karşılık gelen kompleks $I(t) = u(t) + iv(t)$ fonksiyonu elde edilir. Bu fonksiyon görüntülerin her saturının piksel parlaklığı ve fazının her satur boyunca nasıl değiştiğini gösterir.

Çalışmamızda pikselin parlaklığı ve fazı, Hilbert dönüşümünden elde edilen aşağıdaki denklemler bulunmaktadır. Her satırdaki piksel parlaklığı,

$$I(t) = \sqrt{u^2(t) + v^2(t)} \quad (9)$$


ve pikselin yönlülüğü yani fazı (argümanı)

$$\theta(t) = \tan^{-1}\left(\frac{v(t)}{u(t)}\right) \quad (10)$$

bağıntısı ile belirlenir.

Bu sayede CNN ile yapılan sınıflandırmada başarının artırılması amaçlanmıştır. Hilbert Dönüşümü uygulanan bir görselin,

uygulanmadan önceki haliyle karşılaştırılması Şekil 3’te verilmiştir.



Şekil 3. Orijinal ve Hilbert dönüşümü uygulanmış görseller.

Figure 3. Original and Hilbert Transform applied images.

3.2 Sınıflandırma süreci

Önişlemeden geçirilmiş görsellerin sınıflandırılması için ilk olarak basit bir ESA mimarisi kullanılarak sınıflandırma yapılmıştır. 12 katmandan oluşan bu mimaride 6 milyon parametre hesaplanmaktadır. Bu mimarinin katmanları Şekil 4’te verilmiştir.

Katmanlar
Evrişim
Evrişim
Maksimum Havuzlama
Seyreltme
Evrişim
Evrişim
Maksimum Havuzlama
Seyreltme
Düzleştirme
Tam Bağlı Katman
Seyreltme
Tam Bağlı Katman

Şekil 4. Basit ESA mimarisinin katmanları.

Figure 4. Layers of simple CNN architecture.

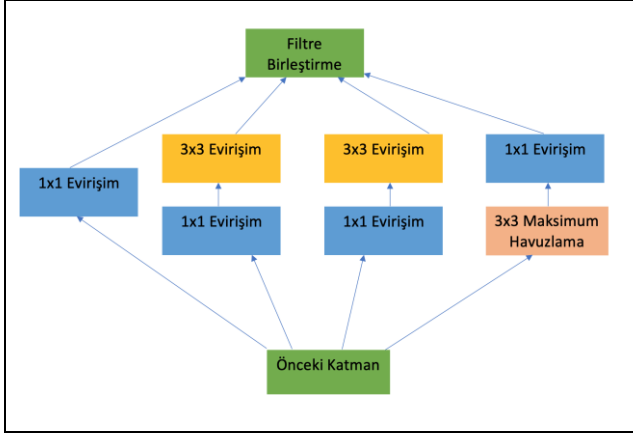
Daha sonra, daha gelişmiş bir ESA mimarisi olan InceptionV3 mimarisi kullanılmıştır. Bu mimari, Google tarafından 2014 yılında geliştirilmiştir. 48 katmandan oluşan model yaklaşık 21 milyon parametre hesaplanmaktadır [19]. Şekil 5’te katmanları görülebilen InceptionV3 mimarisi bu anlamda basit ESA mimarisine oranla çok daha fazla katmandan oluşan, daha derin bir mimariye sahip bir yapay sinir ağı modelidir. Inception mimarisi, diğer modellerden farklı olarak Inception Katmanı adı verilen bir katmana sahiptir.

Katmanlar
Evrişim
Maksimum Havuzlama
Inception mimarisi (3a)
Inception mimarisi (3b)
Maksimum Havuzlama
Inception mimarisi (4a)
Inception mimarisi (3b)
Inception mimarisi (3c)
Inception mimarisi (4d)
Inception mimarisi (4c)
Maksimum Havuzlama
Inception mimarisi (5a)
Inception mimarisi (5b)
Ortalama Havuzlama
Seyreltme (%40)
Lineer Regresyon
Normalize edilmiş Üstel Fonksiyon

Şekil 5. InceptionV3 mimarisinin katmanları.

Figure 5. Layers of InceptionV3 architecture.

Bu katman, bir önceki katmandan aldığı girdiyi farklı filtre boylarına sahip evrişim ve birleştirme işlemlerinden geçirdikten sonra tekrar birleştirerek tek bir vektör haline getirir. Bu işlem sayesinde iç katmanlar, görseldeki şeklin boyutuna uygun boyuttaki filtreyi kullanarak, cisimlerdeki boyut farklılıklarına rağmen şekli tanır [19]. Inception katmanının basit bir gösterimi Şekil 6'da görülebilir.



Şekil 6. Inception katmanı.

Figure 6. Inception layer.

Çalışmada yapılan sınıflandırmada sinir ağının son katmanında sınıflandırıcı aktivasyon fonksiyonu olarak Normalize Edilmiş Üstel Fonksiyon kullanılmıştır. Normalize Edilmiş Üstel fonksiyonu, girdinin hangi sınıfa ait olduğunu olasılıksal olarak, 0 ve 1 arasında bir sayı üreterek, tahminler [20].

4 Bulgular

Bu çalışmada önerilen yöntemin başarımını gösterebilmek amacıyla önışlemeden geçirilmiş ve geçirilmemiş görüntülere ikili ve dördütlü sınıflandırmalar yapılmıştır. İkili sınıflandırma için sadece InceptionV3 mimarisi kullanılırken dördütlü sınıflandırma için karşılaştırma yapabilmek amacıyla basit bir ESA mimarisi de kullanılarak önışlemler ve önışlemsiz sınıflamalar için de verimlilik araştırması yapılmıştır.


İkili sınıflandırma için melanom ve nevüs lezyonları seçilmiştir. Bu iki lezyonun seçilmesinin nedeni melanom ve nevüs lezyonlarının birbirine çok benzeyen ve sıkça karıştırılan iki farklı tür olmasıdır. Melanomun kötü huylu ve nevüsün iyi huylu olması nedeniyle bu iki hastalığın birbirinden ayırt edilmesi büyük önem teşkil etmektedir. Bu amaçla önışlemeden geçirilmiş ve geçirilmemiş görüntüler ile çalışılmıştır.

Önışlemeden geçirilmemiş durum için sistem 12875 adet nevüs ve 4522 adet melanom lezyonlarına ait görüntü kullanılarak eğitilmiş, sonrasında 100 nevüs ve 100 melanom lezyonuna ait test görüntüsü ile sınama yapılmıştır. Toplam 200 görüntünün kullanıldığı sınıflandırma için doğruluk oranı %80 olarak bulunmuştur.

Önışlemeden geçirilmeden yapılan sınıflandırmaya ait karışıklık matrisi Şekil 7'de görülmektedir. Bu sınıflamaya göre nevüsün belirlenmesinde %77 başarı sağlanırken, melanomun belirlenmesinde %83 başarı elde edilmiştir.

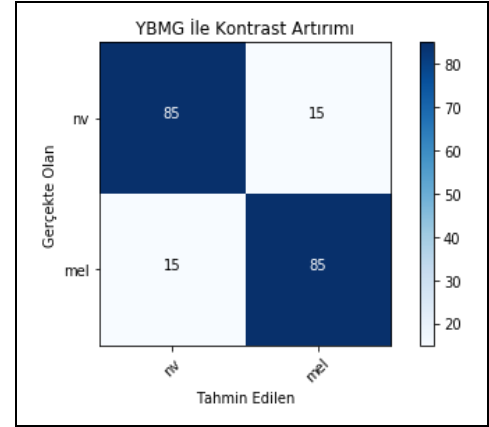
İkili sınıflandırma için YBMG ile kontrastı artırılmış Melanom ve Nevüs görsellerinin sınıflandırılmasında sistem aynı sayıda görüntü ile eğitilmiş ve 100 nevüs ile 100 melanom lezyonuna ait test görüntüsü ile sınıflandırıldığında elde edilen doğruluk %85 olarak bulunurken nevüsün belirlenmesinde %85, melanomun

belirlenmesinde %85 başarı sağlanmıştır. Bu sınıflandırmaya ait karışıklık matrisi Şekil 8'de görülmektedir.



Şekil 7. Önışlem uygulanmadan Melanoma ve Nevüs görsellerinin ikili sınıflandırılmasıyla oluşan karışıklık matrisi.

Figure 7. Confusion matrix formed by dual classification of Melanoma and Nevus images without preprocessing.

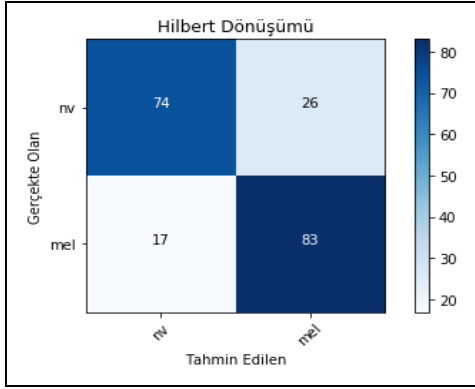


Şekil 8. YBMG ile kontrastı artırılmış Melanoma ve Nevüs görsellerinin ikili sınıflandırılmasıyla oluşan karışıklık matrisi.

Figure 8. Confusion matrix formed by dual classification of contrast enhanced Melanoma and Nevus images with HDMR.

Burada önışlem olarak görüntülere YBMG uygulanarak kontrastlığın artırılmasının başarıyı arttırdığı rahatça gözlenmektedir. Son olarak ikili sınıflandırmada önışlem olarak Hilbert dönüşümünün uygulandığı durum incelenmiş ve bu durum için de sistem aynı sayıda görüntü ile eğitilerek yine 100 nevüs 100 melanom olmak üzere toplam 200 test görüntüsü ile sınanmış ve %79 oranında doğruluk elde edilmiştir. Nevüsün belirlenmesinde başarı oranı %74 iken melanomun belirlenmesinde başarı oranı %83 olmuştur. Şekil 9 bu sınıflandırmaya ait karışıklık matrisini göstermektedir. Bu açıklamalar ışığında ikili sınıflama için Hilbert dönüşümü önışlemi kullanılarak yapılan sınıflama ile önışlemsiz yapılan sınıflama arasında büyük bir fark olmadığı görülmektedir.

Çalışmanın temel amacı olan dördütlü sınıflandırma için ise ikili sınıflandırma ile aynı yol izlenerek önışlemsiz, YBMG yöntemi kullanılarak yapılan önışlemler ve Hilbert dönüşümü ile yapılan önışlemler durumlar incelenmiştir. Dördütlü sınıflandırma için Tablo 1'de verilmiş olan miktarlarda Melanom, Bazal Hücreli Karsinom, Melanositik Nevüs, Keratoz lezyonlarına ait görseller kullanılarak model eğitilmiş, sonrasında her bir hastalıktan 100 tane olmak üzere toplam 400 tane test verisi kullanılarak değerlendirme yapılmıştır.



Şekil 9. Hilbert Dönüşümü uygulanmış Melanoma ve Nevüs görsellerinin ikili sınıflandırılmasıyla oluşan karışıklık matrisi.

Figure 9. Confusion matrix formed by dual classification of contrast enhanced Melanoma and Nevus images with Hilbert Transform.

İlk olarak basit ESA mimarisine bir sınıflandırma yapılmıştır. Bu sınıflandırmada elde edilen sonuçlar Tablo 2’de verilmiştir.

Tablo 2. Dört lezyon için basit mimari ile sınıflandırma başarı yüzdeleri.

Table 2. Success percentages for four lesion classification with simple architecture.

Lezyon Türü	Önişlemsiz	Hilbert Dönüşümü Önişlemli	YBMG Önişlemli
BCC	%86	%62	%58
MEL	%73	%63	%74
NV	%78	%76	%79
BKL	%51	%47	%58

Elde edilen sonuçlar incelendiğinde, önişlemler ile anlamlı bir gelişme sağlayamadığı görülmektedir. Daha sonra InceptionV3 mimarisine kullanılarak aynı işlemler tekrar edilmiştir. Yapılan sınıflandırmada elde edilen sonuçlar Tablo 3’te verilmiştir.

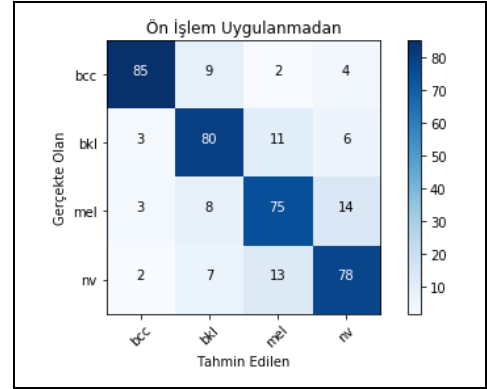
Tablo 3. Dört lezyon için InceptionV3 sınıflandırma başarı yüzdeleri.

Table 3. InceptionV3 success percentages for four lesion classification.

Lezyon Türü	Önişlemsiz	Hilbert Dönüşümü Önişlemli	YBMG Önişlemli
BCC	%85	%89	%76
MEL	%75	%69	%78
NV	%78	%76	%79
BKL	%80	%64	%75

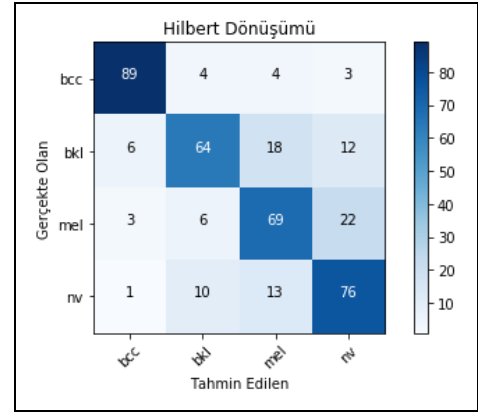
Tablo 3 incelendiğinde önişlem olarak Hilbert dönüşümünün kullanıldığı durumda Karsinom lezyonunun tespitinde oldukça iyi bir başarı sağlandığı görülmektedir. Melanom için ise farklı önişlemli ve önişlemsiz sınıflandırmada elde edilen yüzdeler bakıldığında YBMG yönteminin önişlem olarak kullanıldığı durumda melanom tespitinde %78 başarının yakalandığı görülmektedir. Ayrıca tablo incelendiğinde, Nevüs için önişlem uygulanmasının yalnızca %1 oranında başarı artımı sağlarken Keratoz’un belirlenmesinde önişlemlere hiç gerek kalmadan yalnızca ESA’nın kullanımıyla %80 gibi oldukça iyi bir sonuç elde edildiği rahatça görülebilmektedir.

Dörtlü sınıflandırma için 400 test verisi üzerinden çalışılmış önişlem uygulanmayan Hilbert Dönüşümü uygulanan ve son olarak YBMG uygulanan görüntülerin sınıflandırılmasına ait karışıklık matrisleri sırasıyla Şekil 10, Şekil 11 ve Şekil 12’de verilmektedir.



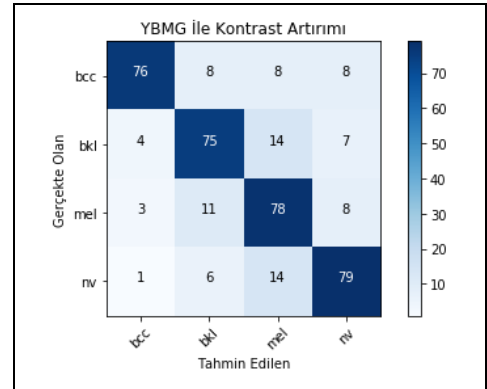
Şekil 10. Önişlem uygulanmamış görseller ile yapılan sınıflandırma için test verisinin karışıklık matrisi.

Figure 10. Confusion matrix of test data for classification without preprocessing.



Şekil 11. Hilbert dönüşümü uygulanmış görseller ile yapılan sınıflandırma için test verisinin karışıklık matrisi.

Figure 11. Confusion matrix of test data for classification with Hilbert Transform applied images.



Şekil 12. YBMG ile kontrast artırımı uygulanmış görseller ile yapılan sınıflandırma için test verisinin karışıklık matrisi.

Figure 12. Confusion matrix of test data for classification with contrast enhanced images with HDMR.

5 Sonuç

Bu çalışmada çeşitli deri lezyonlarının ikili ve dörtlü sınıflandırılması üzerinde çalışılmıştır. İkili sınıflandırma için birbirine çok benzeyen melanom ve nevüs lezyonları kullanılmıştır. Bu iki lezyonun birbirinden ayırt edilmesi, birinin iyi huylu birinin kötü huylu olması ve sıkça

karıştırılması nedeniyle çok önem teşkil etmektedir. Dörtlü sınıflandırma için ise sıkça karşılaşılan bazal hücreli karsinom (bcc), iyi huylu keratoz (bkl), melanoma (mel), melanositik nevüs (nv) lezyonları seçilmiştir.

Çalışmada kullanılan farklı lezyonlara ait görüntüler, Uluslararası Deri Görüntüleme Birliği (ISIC) tarafından yayınlanan ve çeşitli deri pigmentasyonlarının dermatoskopik görsellerini içeren ISIC 2019 veri seti içerisinde alınmıştır. Görüntüler üzerinde sınıflandırma yapabilmek için basit bir Evrişimsel sinir ağı (ESA) modeli ve yine bir ESA modeli olan InceptionV3 mimarisi kullanılmıştır. Yapılan sınıflandırmanın doğruluğunu artırma düşüncesiyle iki farklı önışlem yöntemi üretilmiştir. Bu önışlemler ham görüntülere Hilbert Dönüşümü uygulanması ve yine ham görüntülere Yüksek Boyutlu Model Gösterilimi ile Kontrast Artırımı yapılması durumlarıdır. Görüntülerin sınıflandırılması hem önışlemsiz hem de iki farklı önışlemli durumlar için karşılaştırmalı olarak değerlendirilmiştir. İkili sınıflama da önışlem için üretilen yöntemlerin hem genel başarıyı hem de nevüs ve melanoma lezyonlarının tespit oranını önemli ölçüde yükselttikleri gözlemlenmiştir. Dörtlü sınıflama için ise inceptionV3 mimarisi kullanıldığında melanoma ve karsinomun tespitinde önışlemden geçirilmiş olan görüntülerle yapılan sınıflamanın sonuca oldukça katkı verdikleri hatta kötü huylu iki kanser çeşidi olan melanom ve karsinom tespitine ait başarı oranlarını sırasıyla %78 ve %89 a çıkardıkları gözlemlenmiştir.

Sonuç olarak, günümüzde çok sık rastlanan deri lezyonlarının bilgisayar ile tespitine ait yeni bir ESA tabanlı çalışma önerilmiş ve çalışmanın farklı önışleme teknikleri altındaki başarımı karşılaştırmalı olarak incelenmiştir.

6 Conclusion

In this study, double and quadruple classifications of various skin lesions was studied. Very similar melanoma and Nevus lesions were used for dual classification. It is very important to differentiate these two lesions from each other because one is benign and the other one is malignant and they are often confused. Common basal cell carcinoma (bcc), benign keratosis (bkl), melanoma (mel), and melanocytic nevus (nv) lesions were selected for quadruple classification.

The images of the different lesions used in the study were taken from the ISIC 2019 data set published by the International Skin Imaging Collaboration (ISIC), which contains dermatoscopic images of various skin pigmentations. A simple Convolutional neural network (ESA) model and InceptionV3 architecture, which is also an ESA model, were used to classify images. With the idea of increasing the accuracy of the classifications, two different pre-treatment methods were produced. These preprocesses are applying Hilbert Transform to raw images and applying Contrast Enhancement with High Dimensional Model Representation to the raw images. The classification of the images was evaluated comparatively for both non-preprocessed and two different preprocessed situations. In the dual classification, it has been observed that the methods produced for pretreatment significantly increase both the overall success and the detection rate of nevus and melanoma lesions. When the inceptionV3 architecture is used, for the quadruple classification, it was observed that the classification made with images that were pre-processed in the detection of melanoma and carcinoma contributed greatly to the result and even increased the success rates of the detection of two malignant types of cancer, melanoma and carcinoma, to 78% and 89%, respectively.

As a result, a new ESA-based study of computerized detection of skin lesions, which are very common today, has been proposed and the performance of the study under different preprocessing techniques was examined comparatively.

7 Yazar katkı beyanı

Gerçekleştirilen çalışmada Onur BİLGİNER fikrin oluşması, tasarımın yapılması bilimsel yazın taraması sonuçların değerlendirilmesi başlıklarında; Burcu TUNGA elde edilen sonuçların değerlendirilmesi, sonuçların incelenmesi yazım denetimi ve içerik açısından makalenin kontrol edilmesi başlıklarında; Rüştü Murat DEMİRER elde edilen sonuçların değerlendirilmesi, sonuçların incelenmesi yazım denetimi ve içerik açısından makalenin kontrol edilmesi başlıklarında katkı sunmuşlardır.

8 Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur.

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

9 Kaynaklar

- [1] Binder M, Steiner A, Schwarz M, Knollmayer S, Wolff K, Pehamberger H. "Application of an artificial neural network in epiluminescence microscopy pattern analysis of pigmented skin lesions: a pilot study". *British Journal of Dermatology* 130, 460-465, 1994.
- [2] Gürkan H, Hanilçı A. "Evrişimsel sinir ağı ve QRS imgeleri kullanarak EKG tabanlı biyometrik tanıma yöntemi". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 26(2), 318-327, 2020.
- [3] Özkan K, Seke E, Isik S. "Wheat kernels classification using visible-near infrared camera based on deep learning". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 27(5), 618-626, 2021.
- [4] Cevik F, Kilimci ZH. "Derin öğrenme yöntemleri ve kelime yerleştirme modelleri kullanılarak Parkinson hastalığının duygu analiziyle değerlendirilmesi". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 27(2), 151-161, 2020.
- [5] 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*, 542(7639), 115-118, 2017.
- [6] Maron RC, "Systematic outperformance of 112 dermatologists in multiclass skin cancer image classification by convolutional networks". *European Journal of Cancer*, 119, 57-65, 2019.
- [7] Eddine GA, Skin Lesion Classification Using Deep Neural Network. MSc Thesis, Mohamed El Bachir El Ibrahimi University, El Anceur, Algeria, 2019.
- [8] Kassem MA, Hosny KM, Fouad MM. "Skin lesions classification into eight classes for ISIC 2019 using deep convolutional neural network and transfer learning". *IEEE Access*, 8, 114822-114832, 2020.
- [9] Gessert N, Nielsen M, Shaikh M, Werner R, Schlaefer A. "Skin lesion classification using ensembles of multi-resolution EfficientNets with meta data". *MethodsX*, 7, 1-8, 2020.
- [10] Combalia M, Codella NC, Rotemberg V, Helba B, Vilaplana V, Reiter O, Halpern AC, Puig S, Malvey J "Bcn20000: Dermoscopic lesions in the wild". *arXiv*, 2019. <https://arxiv.org/pdf/1908.02288.pdf>.

- [11] Demiralp M. "High Dimensional Model Representation and its application varieties". *Mathematical Research*, 9, 146-159, 2003.
- [12] Dere N, Tunga B. "License Plate Recognition System by Using High Dimensional Model Representation". *2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT 2018)*, Ankara, Turkey, 19-21 October 2018.
- [13] Karcılı A, Tunga B. "High dimensional model representation (HDMR) with clustering for image retrieval". *ICNPAA 2016 World Congress: International Conference in Nonlinear Problems in Aviation and Aerospace*, La Rochelle, France, 5-8 July 2016.
- [14] Tunga MA, Demiralp M. "A Novel Method for Multivariate Data Modelling: Piecewise Generalized EMPR". *Journal of Mathematical Chemistry*, 51(10), 2654-2667, 2013.
- [15] Tunga MA, Demiralp M. "A new approach for data partitioning through high dimensional model representation". *International Journal of Computer Mathematics*, 85(12), 1779-1792, 2008.
- [16] Tunga B, Koçanaoğulları A. "Digital image decomposition and contrast enhancement using high-dimensional model representation". *Signal Image and Video Processing*, 12(1), 299-306, 2018.
- [17] Altın EM, Tunga B. "High dimensional model representation in image processing". *International Conference on Computational and Mathematical Methods in Science and Engineering*, Cadiz, Spain, 3-7 July 2014.
- [18] Neri U. *Singular Integrals*. 1st ed. New York, USA, Springer-Verlag Heidelberg, 1971.
- [19] Faizan S. "Understanding Inception Network from Scratch". www.analyticsvidhya.com/blog/2018/10/understanding-inception-network-from-scratch/ (06.05.2019).
- [20] Mahmood H. "Softmax Function, Simplified". <https://towardsdatascience.com/softmax-function-simplified-714068bf8156> (05.07.2019).