



Türk Doğa ve Fen Dergisi

Turkish Journal of Nature and Science

www.dergipark.gov.tr/tdfd



Cilt Lezyonlarının Sınıflandırılmasında Derin Öğrenme Tabanlı Bir Yöntem

Volkan GÖREKE^{1*}

¹ Sivas Cumhuriyet Üniversitesi, Sivas Teknik Bilimler MYO, Bilgisayar Teknolojileri Bölümü, Sivas, Türkiye
Volkan GÖREKE ORCID No: 0000-0002-2418-8373

*Sorumlu yazar: vgoreke@cumhuriyet.edu.tr

(Alınış: 21.09.2020, Kabul: 05.01.2021, Online Yayınlanma: 25.06.2021)

Anahtar Kelimeler

Cilt kanseri,
Derin sinir ağları,
Veri artırma,
Öznitelik çıkarma

Öz: Cilt kanseri kötü huylu tümörlerin kontrolsüz çoğalması nedeni ile başlar. Dünya çapında sık karşılaşılan bir kanser türüdür. Uzman hekimler tarafından çıplak gözle incelemesi ve teşhis konulması güçtür. Bu yüzden bilgisayar destekli teşhis sistemleri hekimlere tanı koymada yardımcı olabilir. Bu sistemler günümüzde yapay zekânın bir türü olan derin sinir ağlarını yaygın olarak kullanır. Pek çok derin sinir ağı içeren çalışmada derin sinir ağının girişinde veri girişi olarak doğrudan medikal görüntüler kullanılır. Bu çalışmada ise görüntü verisinden ön eğitilmiş derin sinir ağı ile elde edilmiş nümerik veri, ön işlemden geçirilerek sınıflandırıcı girişine uygulanmıştır. Ağ mimarisine bağlı olarak bu sistemler öznitelikleri kendi katmanlarında çıkarırlar. Bu çalışmada VGG16 ön eğitilmiş derin sinir ağı kullanılarak ilk önce ağ katmanlarından görüntülere ilişkin öznitelikler elde edilmiştir. Daha sonra yüksek miktarda veri içeren bu özniteliklerin boyutu azaltılmıştır. Böylece sınıflandırmada en iyi başarıyı sağlayacak öznitelikler elde edilmiştir. Veri artırma algoritması kullanılarak elde edilen nümerik veri artırılmış ve CNN tür derin sinir ağında %96 sınıflandırma doğruluğu ve %100 AUC başarımları elde edilmiştir.

30

A Method Based On Deep Learning For Classification Skin Lesions

Keywords

Skin cancer,
Deep neural networks,
Data augmentation,
Feature extraction

Abstract: Skin cancer which is a common type of cancer worldwide, occurs due to the uncontrolled proliferation of malignant tumors. Skin cancer is difficult to examine and diagnose by specialist physicians through the naked eye. Therefore, computer-aided diagnostic systems can assist physicians in diagnosing. These systems commonly use deep neural networks, a type of artificial intelligence nowadays. In studies involving many deep neural networks, medical images are used directly as data input at the entrance of the deep neural network. In this study, the numerical data obtained from image data by using a pre-trained deep neural network were applied to classifier input after pre-processing. Depending on the network architecture, these systems extract features in their own layers. In this study, using the VGG16 pre-trained deep neural network, firstly, the features related to the images were obtained from the network layers. Then, the size of these features containing large amounts of data was reduced. Thus, the features that will provide the best performance in classification were obtained. The numerical data obtained by using the data augmentation algorithm was increased and 96% classification accuracy and 100% AUC performance were obtained in CNN type deep neural network.

1. GİRİŞ

Cilt kanseri, dünya çapında en sık teşhis edilen kanserlerden biridir. Melanoma olarak da bilinen kötü huylu bir cilt tümörü, genellikle melanosit hücreleri kontrolden çıkmaya başladığında başlar. Çeşitli deri tümörleri arasında, malign melanoma, yakındaki dokulara üstün gelme duyarlılığı ve yüksek ölüm oranı nedeniyle en saldırgan öldürücü türdür [1]. Cilt kanserlerinin sağlık kontrolü sırasında çıplak gözle

görsel incelemesi, cilt lezyonları ve normal dokular arasında farklılıkları yeterince ortaya koyamadığı için yanlış bir tanıya neden olabilir. Bu nedenle, cilt kanseri tanıma için otomatik ve güvenilir bir bilgisayar destekli tanı (Computer Aided Diagnosis, CAD) sistemi, dermatologlara kararlarını desteklemek ve yardımcı olmak için ikinci bir görüş sağlayan önemli bir değerlendirme aracıdır [2]. Bu çalışmada kullanılan görüntü veri seti ile ilgili literatürde yapılan lezyon tespit çalışmaları aşağıda özetlendiği gibidir.

Codella ve arkadaşlarının yaptığı çalışmada destek vektör makinesi sınıflandırıcı olarak kullanılmış %88,8 doğruluk elde edilmiştir [3]. Matsunaga ve arkadaşları yaptıkları çalışmada 1444 ek görüntü verisi kullanmışlardır. Sınıflandırıcı olarak derin evrişimli sinir ağı (convolutional neural network-CNN) yapısı ile melanoma sınıflandırmasında %82,8 doğruluk ve %95,8 ortalama eğri altında kalan alan (area under curve-AUC) değeri elde etmişlerdir [4]. Guo ve Yang tarafından yapılan çalışmada çoklu kanal ResNet derin sinir ağı mimarisi kullanılmıştır. Çalışmalarında %82,4 doğruluk, %91,7 AUC başarımları elde etmişlerdir [5]. Chen ve arkadaşları sınıflandırma işlemi için çok görevli bir yapı tasarlamışlardır. Tasarladıkları yapı bölütleme ağı ve sınıflandırma ağı olmak üzere iki bölümden oluşturulmuştur. Bu yapı ile gerçekleştirilen sınıflandırmada %80,1 doğruluk başarımları elde etmişlerdir [6]. Menegola ve arkadaşları ön eğitilmiş VGG yapısında derin sinir ağı kullanarak 7544 ek görüntü verisi ile ISIC 2017 veri seti üzerinde melanoma ve seboreik keratoz sınıflandırmasında %87,4 melanoma doğruluğu %89,5 seboreik keratoz doğruluğu ve ortalama %90,8 AUC başarımları elde etmişlerdir [7]. Yang ve arkadaşları derin CNN yapıda bir sınıflandırıcı kullanarak %88,6 doğruluk ve %91,1 AUC başarımlarına sahip sınıflandırma gerçekleştirmişlerdir [8]. Devries ve Ramchandram ön eğitilmiş Inception-v3 model derin sinir ağını 1341 ek görüntü verisi ile sınıflandırma için kullanmışlar ve %84,5 melanoma doğruluğu, %91,3 seboreik keratoz doğruluğu, ortalama %88,6 AUC başarımları elde etmişlerdir [9]. Diaz ve arkadaşları cilt lezyonlarının özelliklerini modelleyen özel alt sistemleri içeren ve teşhisinin yorumlanabilirliğini iyileştirmeyi amaçlayan CNN tabanlı bir CAD sistemi olan DermaKNet'i sunmuşlar, %91 AUC başarımları elde etmişlerdir [10]. Tang ve arkadaşları, deri lezyonu sınıflandırmasını gerçekleştirmek için yeni bir Global-Part CNN önermiş, geliştirdikleri algoritma, sıralı olarak eğitilmiş iki alt modelden oluşmuştur. İlk model (Global-CNN), ince ayarlanmış bir Xception ağı kullanılarak yeniden boyutlandırılan cilt lezyon görüntüleri üzerinde eğitilmiştir. ISIC 2017 veri seti üzerinde %92,6 AUC başarımları elde etmişlerdir [11]. Zhang ve arkadaşlarının yapmış oldukları güncel bir çalışmada, melanoma ve seboreik keratoz sınıflandırması için SDL (synergic deep learning) olarak adlandırılan bir modeli önermişlerdir. Çalışmalarında görüntü verisini derin sinir ağının girişine olarak kullanmış ve melanoma sınıflandırmasında %88,8, seboreik keratoz sınıflandırmasında %92,5 doğruluk ve ortalama %91,3 AUC değeri elde etmişlerdir [12].

Bu çalışmada ise literatürdeki diğer çalışmalardan farklı olarak medikal görüntüler doğrudan derin sinir ağına uygulanmamıştır. İlk önce ön eğitilmiş derin sinir ağından otomatik olarak nümerik öznitelikler çıkarılmıştır. Bu nümerik veri seti üzerinde veri artırma algoritması ile ön işleme uygulanarak eğitim veri seti artırılmıştır. Daha sonra ön işlemde geçen nümerik veri seti kullanılarak derin sinir ağı yapısı ile daha başarılı sınıflandırma gerçekleştirilmiştir.

Bu çalışma aşağıdaki şekilde organize edilmiştir. Bölüm 2'de çalışmada kullanılan veri seti ve yazılım geliştirme ortamı tanıtılmıştır. Kullanılan ön eğitilmiş derin sinir ağı mimarisi açıklanmıştır. Bu mimariye ait derin sinir ağı ile nümerik öznitelikler çıkarılarak, tek değişkenli veri artırma algoritması ile nümerik veri artırılmıştır. Uygulanan yöntemin başarımları ölçümü sınıflandırmada kullanılan farklı veri giriş stratejileri uygulanarak gerçekleştirilmiştir. Bunlar artırılmış görüntü veri seti, artırılmamış nümerik veri seti ve bu çalışmada önerilen artırılmış nümerik veri seti olarak gerçekleştirilmiştir. Literatürdeki çalışma sonuçları ile önerilen sistemin elde ettiği başarımlar karşılaştırılarak, önerilen sistemin üstünlüğü ortaya konmuştur. Bölüm 3'de konu ile ilgili çalışma yapacak araştırmacılar için seçilecek sınıflandırıcı mimarisi ve kullanılacak yöntemlerin başarımları yorumlanarak önerilerde bulunulmuştur.

2. MATERYAL VE YÖNTEM

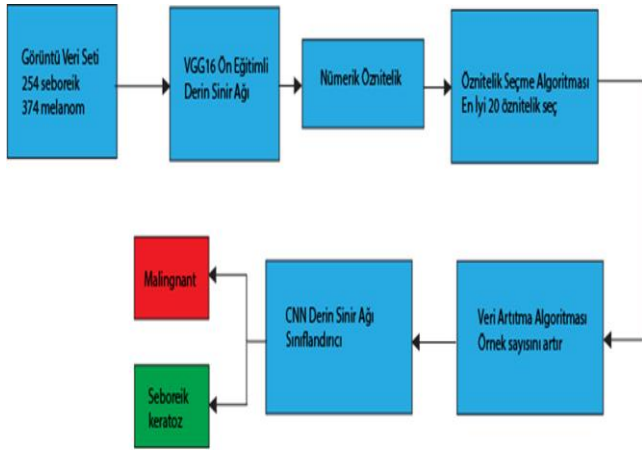
2.1. Veri Seti ve Araçlar

Bu çalışmada ISIC 2017 veri seti [3] kullanılmıştır. Bu veri seti cilt lezyonlarındaki melanoma teşhisini iyileştirmek için uluslararası bir girişim olan ISIC tarafından sunulmuştur. Melanoma, nevrus ve seboreik keratoz olmak üzere üç sınıf içerir. Veri seti iki grup şeklinde ikili alt sınıflandırma yapısında sunulmuştur. Melanoma sınıflandırması (örneğin Melanoma ve diğerleri) ve seboreik keratoz sınıflandırması (seboreik keratoz ve diğerleri) içerir. Veri seti içinde her bir grup 1 ve 0 etiket sayısal değerine göre farklı sınıfları işaret eder. Literatürde kapsamı seboreik keratoz ve melanoma sınıflandırmasına dayalı çalışmalar mevcuttur [13] [4][10].

Yukarıda ifade edilen kapsamda gerçekleştirilen bu çalışmada 254 adet seboreik keratoz ve 374 adet melanoma lezyona ait görüntüler kullanılmıştır. Çalışmadaki tüm işlemler Microsoft Visual Studio Community IDE üzerinde Python Anaconda 5.2.0 ortamında geliştirilen yazılım ile gerçekleştirilmiştir.

2.2. Önerilen Yöntem

Literatürde medikal görüntülerin sınıflandırması için oldukça yaygın olarak derin öğrenmeye dayalı sinir ağı kullanılır. Bu sistemlerin tamamına yakınında ise sınıflandırma işlemi için derin sinir ağının girişine medikal görüntüler verilmektedir [14] [15]. Bu çalışmada ise medikal içeriği olan görüntüler sınıflandırıcıya direkt olarak verilmeyip, bu görüntülerden ön eğitilmiş VGG16 ile elde edilen nümerik öznitelik grubu veri artırma algoritması ile artırılarak sınıflandırıcı girişine uygulanmıştır. Geliştirilen bu yönteme ilişkin işlem adımları aşağıdaki Şekil 1 ile verilmiştir.



Şekil 1. Geliştirilen yönteme ilişkin işlem adımları


2.2.1. Ön eğitilmiş VGG16 modeli kullanılarak özellik elde edilmesi

Evrişimli sinir ağı (CNN), pek çok türdeki hastalıkların bilgisayar destekli tespiti ve teşhisi alanında başarılı sonuçlar göstermiştir. CNN, sıfırdan eğitim için büyük miktarda veriye ihtiyaç duyar. Tıbbi görüntüler söz konusu olduğunda, çok sayıda etiketli görüntü elde etmek zordur. Bu gibi durumlarda, ImageNet gibi çok sayıda doğal görüntü üzerinde önceden eğitilmiş CNN'ler kullanılabilir [16] Simonyan ve Zisserman tarafından tanıtılan [17] ve bir evrişimli sinir ağı türü olan VGG16'nın homojen mimarisi, beş evrişimli blok tarafından oluşturulur, böylece her bloğun girişi bir öncekinin çıktısıdır. VGG16, geri yayılma mekanizması aracılığıyla her katmandaki filtreleri (kernel) optimize ederek sınıflandırıcının giriş görüntüsünü temsil eden özellikleri bu görüntülerden çıkarabilir. Ön eğitilmiş derin sinir ağı içinde birden fazla model bulunmaktadır. Bu çalışmada, ön eğitilmiş derin sinir ağı modeli seçilirken izlenen strateji başarıyı en düşük olanı tercih etme doğrultusunda olmuştur [18]. Çünkü bu şekilde çalışmada önerilen metodun başarıyı daha nesnel şekilde ortaya konmuş olmaktadır. Diğer türlü ön eğitilmiş modelin başarıyı sistem başarımına etki edecek ve önerilen metodun üstünlüğü objektif bir şekilde ortaya konamamış olabilecektir.

VGG16 mimarisi ve özellik çıkarma işlemine ait blok diyagramlar Şekil 2 ile verilmiştir [17].

Derin öğrenme özneliği çıkarımı gerçekleştirirken, önceden eğitilmiş ağı, giriş görüntüsünün ileriye doğru yayılmasına, önceden belirlenmiş katmanda durmasına ve o katmanın çıktılarını özellikler olarak almasına izin veren rastgele bir özellik çıkarıcı olarak ele alınır. N görüntüden oluşan bir veri kümesi verildiğinde, veri kümesindeki tüm görüntüler için özellik çıkarma işlemi tekrarlanabilir ve toplamda $N \times 21.055$ adet özellik vektörü elde edilebilir [19].

Bu çalışmada her iki sınıf için toplam 628×21.055 adet özellik VGG16 modeli kullanılarak elde edilmiştir.

Şekil 2. VGG16 mimarisi ve özellik çıkarma blok şeması
Conv: convolution, FC: Full Connected

2.2.2. Özellik seçme

Yüksek boyutlu veriler, yüksek hesaplama maliyeti ve bellek kullanımı nedeniyle birçok sınıflandırma algoritması için de ciddi bir sorundur. Ayrıca özellik uzayındaki bir azalmanın daha anlaşılır bir modele yol açtığını ve sınıflandırma başarıyı üzerinde olumlu katkı yapabileceğinden söz edilebilir [20]. Bu nedenle bir önceki aşamada her bir görüntü için VGG16 modelinden elde edilen 21.055 adet özellikten Tek Değişkenli Özellik Seçim Algoritması kullanılarak 20 adedi seçilmiştir [21]. Belirtilen algoritma farklı istatistiksel puanlama işlevlerine dayalı sıralı bir özellik listesi döndüren bir özellik seçme yöntemidir. Bu yöntem sınırlı örnekler ve çok sayıda özellik içeren çalışmalarda en iyi sonucu verdiği için seçilmiştir [22]. Bu işlem Anaconda ortamında "sklearn.feature_selection" python modülü kullanılarak gerçekleştirilmiştir.

2.2.3. Veri artırma

Veri artırma, mevcut örnekleri yeni veriler oluşturmak için dönüştürerek sınırlı miktarda veriyi çoğaltan bir tekniktir. Bu teknik, bilgisayar görmesi, ses tanıma ve zaman serileri sınıflandırma uygulamalarında sentetik eğitim verileri oluşturmak için uygulanmıştır [23]. Veri artırma derin öğrenme için önemli performans kazanımları sağlamaktadır. Bu kazanımlar artan sınıflandırma doğruluğu, kararlılık ve azaltılmış ezberleme (overfitting) olarak ifade edilir [24]. Bu çalışmada nümerik veriler üzerinde işlem gören veri artırma algoritması [25] düzenlenerek uygulanmıştır. 628 adet nümerik veriden 1256 artırılmış nümerik veri elde edilmiştir. Algoritmaya ait sözde kod aşağıda belirtilmiştir. Burada Veri_matrisi 628 satır, 20 sütundan oluşan bir nümerik matristir.

```

For i=1 to Veri_sayısı
  Artırma_oran=0,5
  Artırılacak_öznitelik_sayısı=yuvarla(Artırma_oran*boyut(veri_matrisi))[1]
  Artırılacak_öznitelik_index=rastgele_seç(boyut(veri_matrisi)[1], Artırılacak_öznitelik_sayısı)
  Sırala(Artırılacak_öznitelik_index)
  Öznitelik_index= Artırılacak_öznitelik_index olmayan özellikler için indeksleri bul.
  Artırılmış_veri(i, Öznitelik_index)=Veri_matrisi(i, Öznitelik_index)
  Rastgele_satır_index= Her özellik için rastgele örneklenmiş değerler için rastgele satır indeksi bul.
  For n,j in (Artırılacak_öznitelik_index)

```

```

Artırılmış_veri(i,j)=Veri_matrisi(Rastgele_satr
_index[n],j)
End for
End for

```

2.3. Deneysel Sonuçlar

Sınıflandırma işlemi orijinal nümerik veri, uygulanan yöntem ile artırılmış nümerik veri ve sınıflandırma girişine görüntüler doğrudan uygulanarak gerçekleştirilmiştir. Görüntü veri seti Python ImageDataGenerator modülü kullanılarak artırılmış, 628 adet görüntüden 2512 artırılmış görüntü elde edilmiştir. Görüntü verisinin artırılması derin sinir ağlarında eğitim başarımını artırır [26]. Görüntü verisinin artırılarak çalışmada kullanılmasının amacı önerilen yöntemin başarımını daha objektif olarak ölçmektir.

Çalışmada iki temel mimaride derin sinir ağı sınıflandırıcı olarak kullanılmıştır. Tablo 1 ile her bir mimari hiper parametre değerleri ile birlikte verilmiştir. Yapay zeka uygulamalarında göreceli olarak küçük veri seti kullanıldığında daha çok çapraz doğrulama (cross-validation) yöntemi tercih edilmektedir. Fakat klinik uygulamalarda bu yaklaşım daha az net sonuç vermektedir [27]. Elde edilecek sonuçların daha net olması açısından bu çalışmada testler eğitim-test ayırma (train-test split) yaklaşımı kullanılarak gerçekleştirilmiştir.

CNN, görüntüler ve videolar gibi görsel veri işleme için geliştirilmiş bir derin öğrenme algoritmasıdır. CNN, farklı görevleri yerine getiren farklı katman türlerine sahiptir. Bunlar “convolution layer”, “activation function layer”, “pooling layer”, “fully connected layer” ve “dropout layer” olarak isimlendirilir [28]. Tekrarlayan sinir ağı (Recurrent Neural Networks, RNN) yapılarında sonuç, sadece o andaki giriş değil, diğer girişlere de bağlı olarak çıkarılır. Bu ağlarda girişler şimdiki ve önceki bilgilerin birleştirilmesi ile çıkış üretirler [28].

Tablo 1. Kullanılan derin sinir ağı mimarileri

Parametre	CNN	RNN
Units	512,256	-
Layers	1,2	1
Activation function	ReLU	ReLU
Learning rate	1e-3	1e-3
Loss function	Binary cross entropy	Binary cross entropy
Epocs	250	250
Optimizer	SGD	SGD
Decay	1e-5	1e-5
Momentum	0,3	0,3
Fully connected units	2048,1024	2048,1024
Fully connected layer	1,2	1,2
RNN units	-	512
Dropout	-	0,25

Uygulanan yönteme göre derin sinir ağı sınıflandırıcıların başarımı doğruluk ölçütü ve alıcı çalışma karakteristik eğrisi (receiver operating characteristic curve, ROC) ile ölçülmüştür. ROC eğrisinin elde edilmesinde “recall” ölçütü kullanılır. Bu

ölçütlerin matematiksel ifadeleri Eşitlik 1 ve Eşitlik 2 ile verilmiştir.

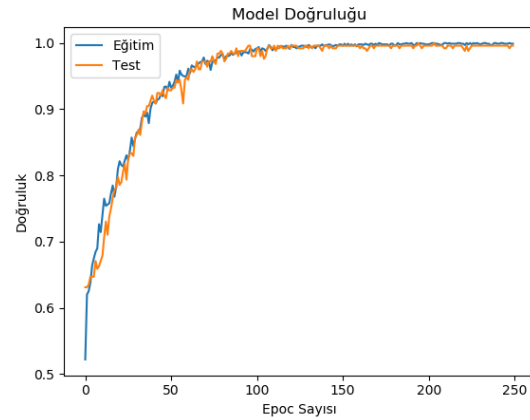
$$Doğruluk = (TP+TN)/(TP+FN+FP+TN) \quad (1)$$

$$Recall = TP/(TP+FN) \quad (2)$$

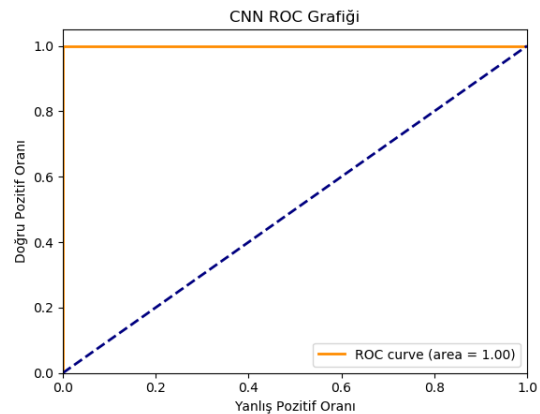
Burada TP (true positive), doğru tespit edilen hasta sayısı, TN (true negative), doğru tespit edilen sağlıklı sayısı, FP (false positive), yanlış tespit edilen hasta sayısı (sağlıklı iken hasta olarak sınıflandırılmış), FN (false negative), yanlış tespit edilen sağlıklı sayısını (hasta iken sağlıklı olarak sınıflandırılmış) ifade etmektedir [29].

Bunlara ek olarak ROC eğrisi (curve) recall ile FP/(TN+FP) oranı arasındaki değişimi verir [30] ve AUC (area under the curve) değerinin hesaplanmasında kullanılır. AUC, hastalığı olan rastgele bir kişinin sağlıklı olan rastgele bir kişiden daha yüksek bir test ölçümüne sahip olma olasılığı olarak yorumlanır [31]. Modelin doğruluğu (accuracy) ölçülerek güvenilirliği ve geçerliliği kanıtlanmış olur [32].


Artırılmış nümerik veri için CNN ve RNN modellerin doğruluk ve ROC grafikleri sırasıyla Şekil 3, Şekil 4, Şekil 5 ve Şekil 6 ile verilmiştir.




Şekil 3. CNN model doğruluk grafiği




Şekil 4. CNN ROC grafiği




Şekil 5. RNN model doğruluk grafiği



Şekil 8. CNN ROC grafiği




Şekil 6. RNN ROC grafiği

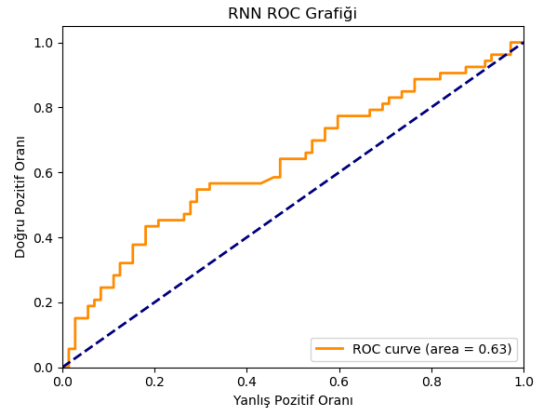


Şekil 9. RNN model doğruluk grafiği

Artırılmamış nümerik veri için CNN ve RNN modellerin doğruluk ve ROC grafikleri sırasıyla Şekil 7, Şekil 8, Şekil 9 ve Şekil 10 ile verilmiştir.




Şekil 7. CNN model doğruluk grafiği




Şekil 10. RNN ROC grafiği

Artırılmış görüntü ile ilgili başarımların grafikleri Şekil 11 ve Şekil 12 ile verilmiştir.



Şekil 11. CNN model doğruluğu



Şekil 12. CNN ROC grafiği

Tablo 2. Derin Sinir Ağ modelleri için başarımların karşılaştırması

Giriş Verisi	Doğruluk	AUC
Orijinal Nümerik Veri (CNN)	0,65	0,63
Artırılmış Nümerik Veri (CNN)	0,96	1
Orijinal Nümerik Veri (RNN)	0,63	0,63
Artırılmış Nümerik Veri (RNN)	0,93	0,99
Artırılmış Görüntü Verisi (CNN)	0,87	0,94

Literatürde ISIC 2017 veri setine ait cilt lezyonlarının melanoma ve seboreik keratoz olarak sınıflandırmasının yapıldığı farklı çalışmalar ile önerilen yöntemin başarımları karşılaştırılarak sonuçlar Tablo 3 ile verilmiştir.

Tablo 3. Önerilen yöntemin başarımın literatür ile karşılaştırması

Kaynakça	Sınıflandırıcı	Veri Girişi	Doğruluk %	AUC %
[4]	CNN	Görüntü	82,8	95,8
[7]	VGG	Görüntü	88,4	90,8
[8]	CNN	Görüntü	88,6	91,1
[9]	INCEPTION-V3	Görüntü	87,9	88,6
[10]	DERMAKNET	Görüntü	87,5	91,0
[12]	SDL	Görüntü	92,5	91,3
Önerilen Yöntem	CNN	Nümerik	96,0	1

Bu çalışmada önerilen yöntem ile melanoma ve seboreik keratoz tür lezyon içeren görüntülerden elde edilen nümerik veriler kullanılarak derin CNN tür sınıflandırıcı ile melanoma ve seboreik keratoz sınıflandırmasında %96 doğruluğa ve %100 AUC başarımına ulaşılmıştır.

3. TARTIŞMA VE SONUÇLAR

Yapay zeka kullanılan sınıflandırma çalışmalarında öznelik seçme yöntemi sınıflandırma başarımını artırmaktadır [33] [34]. Bu çalışmada derin sinir ağının girişine sınıflandırma işlemi için medikal görüntüler doğrudan verilmemiş, derin sinir ağının katmanlarından elde edilen öznelikler en iyi performansı sağlayacak şekilde seçilerek sınıflandırıcı katmanına aktarılmıştır. Bu yöntem ile sınıflandırıcı başarımı artırılmıştır.

Ayrıca derin sinir ağı ile yapılan çalışmalarda veri boyutunun sentetik olarak artırılması görüntü verisi içeren çalışmalarda yaygın olarak kullanılmaktadır. Bu çalışmada ise sınıflandırma başarımının artırılması için veri artırma görüntü verisi üzerinde ve elde edilen nümerik veri üzerinde ayrı ayrı uygulanarak sınıflandırma başarımları araştırılmıştır. Yapılan araştırma sonucuna göre seçilen nümerik veri üzerinde veri artırma yöntemi daha üstün bir sınıflandırma başarımı sağlamıştır.

Bu çalışmada ayrıca iki temel derin sinir ağı sınıflandırma işlemi için ayrı ayrı test edilmiştir. Test sonucunda CNN tür derin sinir ağı RNN tür derin sinir ağına göre daha başarılı bir sınıflandırma yapmıştır.

Bu çalışmada önerilen yöntem ile melanoma ve seboreik keratoz sınıflandırması daha başarılı şekilde yapılmıştır. İki farklı derin sinir ağı mimarisinin de test edildiği bu çalışmada önerilen yöntemi kullanan CNN modeli cilt lezyonlarının tespitinde daha üstün başarımlar sağlamak için kullanılabilir. Bu alanda çalışacak araştırmacılar derin sinir ağı için CNN mimaride bir yapıyı tercih edebilirler.

KAYNAKLAR

- [1] Siegel RL, Miller KD, Jemal A. Cancer statistics, 2019. CA Cancer Journal for Clinicians. 2019;69(1):7-34.
- [2] Jones OT, Jurascheck LC, Van Melle MA, Hickman S, Burrows NP, Hall PN, et al. Dermoscopy for melanoma detection and triage in primary care: A systematic review. BMJ Open. 2019;9.
- [3] Codella NCF, Gutman D, Celebi ME, Helba B, Marchetti MA, Dusza SW, et al. Skin lesion analysis toward melanoma detection: A challenge at the 2017 International symposium on biomedical imaging [ISBI], hosted by the international skin imaging collaboration [ISIC]. In: International Symposium Biomedical Imaging. Washington, D.C 2018-April:p.168-172.
- [4] Matsunaga K, Hamada A, Minagawa A, Koga H. Image Classification of Melanoma, Nevus and Seborrheic Keratosis by Deep Neural Network Ensemble. 2017;2-5. <http://arxiv.org/abs/1703.03108>
- [5] Guo S, Yang Z. Multi-Channel-ResNet: An integration framework towards skin lesion analysis. Informatics in Medicine Unlocked. 2018;12:67-74.

- [6] Chen S, Wang Z, Shi J, Liu B, Yu N. A multi-task framework with feature passing module for skin lesion classification and segmentation. In: 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI). Washington, D.C. April 4-7, 2018.p.1126-1129.
- [7] Menegola A, Tavares J, Fornaciali M, Li LT, Avila S, Valle E. RECOD Titans at ISIC Challenge 2017. 2017;1-5. Available from: <http://arxiv.org/abs/1703.04819>
- [8] Yang X, Li H, Wang L, Yeo SY, Su Y, Zeng Z. Skin Lesion Analysis by Multi-Target Deep Neural Networks. In: 2018 40 th Annual International Conference IEEE Eng Med Biol Soc EMBS. Honolulu, HI, USA 2018 July;p.1263-1266.
- [9] DeVries T, Ramachandram D. Skin Lesion Classification Using Deep Multi-scale Convolutional Neural Networks. 2017; <http://arxiv.org/abs/1703.01402>
- [10] González-Díaz I. DermaKNet: Incorporating the Knowledge of Dermatologists to Convolutional Neural Networks for Skin Lesion Diagnosis. IEEE J Biomed Heal Informatics. 2019;23[2]:547-59.
- [11] Tang P, Liang Q, Yan X, Xiang S, Zhang D. GP-CNN-DTEL: Global-Part CNN Model with Data-Transformed Ensemble Learning for Skin Lesion Classification. IEEE J Biomed Heal Informatics. 2020;1-1.
- [12] Zhang J, Xie Y, Wu Q, Xia Y. Medical image classification using synergic deep learning. Medical Image Analysis. 2019; 54:10-19
- [13] Yang X, Zeng Z, Yeo SY, Tan C, Tey HL, Su Y. A Novel Multi-task Deep Learning Model for Skin Lesion Segmentation and Classification. <https://arxiv.org/abs/1703.01025> 2017;1-4.
- [14] Yadav SS, Jadhav SM. Deep convolutional neural network based medical image classification for disease diagnosis. Journal of Big Data. 2019;6(113).
- [15] Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. Medical Image Analysis journal. 2017;42 :60-88.
- [16] Abraham B, Nair MS. ScienceDirect Computer-aided detection of COVID-19 from X-ray images using multi-CNN and Bayesnet classifier. Biocybernetics and Biomedical Engineering. 2020;1-10.
- [17] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. 3rd International Conference Learn Represent ICLR 2015 - San Diego, CA, 2015;1-14.
- [18] Tian H, Pouyanfar S, Chen J, Chen S C, Iyengar S C. Automatic Convolutional Neural Network Selection for Image Classification Using Genetic Algorithms. IEEE 19th International Conference on Information Reuse and Integration for Data Science. Utah, USA, 2018.
- [19] Chollet F. Deep Learning with Phyton. Manning. 2018.
- [20] Janeczek A, Gansterer WNW, Demel M, Ecker G. On the Relationship Between Feature Selection and Classification Accuracy. Fsdm. 2008;90-105.
- [21] Guda V, Golla M, Datta A. Performance Analysis of Learning Models on Medical Documents. IJIRT 2018;4(12):822-828.
- [22] Subho RH, Chowdhury R, Chaki D, Islam S, Rahman D. A Univariate Feature Selection Approach for Finding Key Factors of Restaurant Business. In: 2019 IEEE Region 10 Symposium (TENSYP). India, Kolkata: 2019;p.605-610.
- [23] Rashid KM, Louis J. Times-series data augmentation and deep learning for construction equipment activity recognition. Advanced Engineering Informatics. 2019;42:100944.
- [24] Lashgari E, Liang D, Maoz U. Data augmentation for deep-learning-based electroencephalography. Journal of Neuroscience Methods journal. 2020;346:108885.
- [25] Basic Data Augmentation & Feature Reduction [Internet]. Available from: <https://www.kaggle.com/bigironsphere/basic-data-augmentation-feature-reduction>
- [26] Wong SC, Gatt A, Stamatescu V, McDonnell MD. Understanding Data Augmentation for Classification: When to Warp? 2016 2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA). Gold Coast, QLD, Australia;2016
- [27] Alakus TB, Turkoglu I. Comparison of deep learning approaches to predict COVID-19 infection. Chaos, Solitons and Fractals. 2020;140:110120.
- [28] Jauro F, Chiroma H, Gital AY, Almutairi M, Abdulhamid SM, Abawayj JH. Deep learning architectures in emerging cloud computing architectures: Recent development, challenges and next research trend. Applied Soft Computing Journal. 2020;96:106582.
- [29] Mumtaz W, Qayyum A. A deep learning framework for automatic diagnosis of unipolar depression. International Journal of Medical Informatics. 2019;132(103983).
- [30] Hajian-Tilaki K. Receiver operating characteristic (ROC) curve analysis for medical diagnostic test evaluation. Caspian Journal of Internal Medicine 2013;4(2):627-35.
- [31] Safari S, Baratloo A, Elfil M, Negida A. Evidence Based Emergency Medicine; Part 5 Receiver Operating Curve and Area under the Curve. Emergency 2016;4(2):111-3.
- [32] Roger P. Evaluating Information: Validity, Reliability, Accuracy, Triangulation. In: Research Methods in Politics; SAGE Press; 2011;p.79-99
- [33] Dougherty E, Hua J, Sima C. Performance of Feature Selection Methods. Curr Genomics. 2009;10(6):365-74.
- [34] Dan Lo CT, Ordóñez P, Cepeda C. Feature selection and improving classification performance for malware detection. In: 2016 IEEE International Conference Big Data. Atlanta, GA, USA 2016;p.560-566.