



MobileNetV2 ve MobileNetV3 Tabanlı Derin Öğrenme Yaklaşımları ile Cilt Kanserlerinin Sınıflandırılması

Halit Çetiner

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

July 10, 2022

MobileNetV2 ve MobileNetV3 Tabanlı Derin Öğrenme Yaklaşımları ile Cilt Kanserlerinin Sınıflandırılması

Halit Çetiner^{1*}

¹Teknik Bilimler MYO, Isparta Uygulamalı Bilimler Üniversitesi, Türkiye

*(halitcetiner@isparta.edu.tr)

Özet – İnsanların yaşadığı çevresel ortamların farklı sebeplerden dolayı zarar görmesi sonucunda ozon tabakası delinmiştir. Bu delinme neticesinde ise güneş ışınlarına ait faydalı ve zararlı ışınlar maruz kalma miktarında artma meydana gelmiştir. İnsanların güneş ışınları altında kalma süresinin artması sonucunda vücudun çeşitli bölgelerinde cilt renklerinde değişimler yaşanmaktadır. Tıp dünyası ise genel anlamda cilt üzerinde meydana gelen değişimleri cilt kanseri olarak tanımlamaktadır. Halk arasında ise sıklıkla karşılaşılan cilt kanser türleri ise melanoma (mel), dermafibroma (df), vascular (vasc), benign keratosis (bkl), melanocytic nevi (nv), basal cell carcinoma (bcc), actinic keratosis (akiec) türleri olarak bilinmektedir. Cilt üzerindeki tüm değişimler kanser olmayabilmektedir. Bu durumda olası bir cilt değişiminin her ne kadar cilt üzerindeki tüm değişimleri cilt kanseri olarak nitelemek mümkün olmasa da cilt değişimlerinden elde edilen görüntüler kullanarak, hangi görüntünün hangi kansere ait olduğu belirlemek mümkündür. Bu çalışmada cilt sağlık uzmanların yetersizliği ve iş yoğunluğu düşünülerek transfer öğrenme tabanlı derin öğrenme modellerinin sınıflandırma başarısı karşılaştırılmıştır. MobileNet mimarisine ait yeni bir aktivasyon fonksiyonu ile sunulan MobileNet V3 Large ve ReLU aktivasyon fonksiyonlu MobileNet V2 etkili bir şekilde karşılaştırılmıştır. KFold 2 seçeneğine göre eğitim ve test verileri ikiye ayrılarak yapılan deneysel çalışmalarda ağırlıklı değerleri ile kullanılan her iki model de birbirine yakın eğitim ve test doğruluk değerlerine ulaşmıştır.

Anahtar Kelimeler – MobileNet V3, MobileNet V2, Cilt Kanseri, Derin Öğrenme, Transfer Öğrenme

I. GİRİŞ

Yeryüzünde yaşayan insan sayısı her geçen gün artış göstermektedir. Önümüzdeki yıllar içerisinde yeryüzünde yaşayan toplam insan sayısının on milyara yaklaşması beklenmektedir [1]. Buna paralel bir şekilde Dünya Sağlık Örgütü (WHO) başta olmak üzere çeşitli kurum ve kuruluşlar geçen on yıl içerisinde insan sağlığını bozan hastalıkların artış gösterdiğini ifade etmektedir [2]. İnsan sağlığını bozan etmenler arasında görülen su, hava ve toprak kirliliği insan hastalığını artıran etmenler arasında görülmektedir. Pimentel et al. [2] belirttiği gibi günümüzde dünyada meydana gelen ölümlerin ana sebebi olarak çevresel bozulmalar görülmektedir. Hava, su ve toprak kirliliği ile birlikte yetersiz beslenme ve insanların çevreye

verdiği zararlar neticesinde büyük ölümler yaşanmaktadır. Bunun da ötesinde insan sağlığına zarar veren bir diğer etmen ise tütüne bağlı dumanlar ve kapalı mekanlardaki yemek pişirme durumu olarak görülmektedir [3]. Belirtilen etki ve çevresel faktörler ile bağlantılı olarak kanser vaka sayılarında artış görülmektedir [2].

Çeşitli organ ve dokularda kanser vakaları görülmesine rağmen cilt kanserlerinde son zamanlarda bir artış bulunmaktadır [4]. Bu artışın ana sebebi olarak gösterilen hava, su ve toprak kirlilikleri olduğu belirtilmektedir. Bu kirlilikler ile birlikte oluşan ozon tabakası incelmesi zararlı güneş ışınlarının insanlara doğrudan zarar vermesine neden olmaktadır. Bunun neticesinde ise cilt kanser görülme sayısında artış gözlenmektedir

[5]–[7]. Cilt, insana ait yüzeysel alanı en büyük organ olarak tanımlanmaktadır [8]. Cilt, insanın organlarına gelebilecek olası saldırılarda dış ortamdan iç ortamı koruma görevi görmektedir. Cilt bunlara ek olarak insan vücut ısısını normal koşullarda tutmasına yardımcı olmaktadır. Olası bir zararlı güneş ışığından vücudu koruyacak hastalıklara karşı ilk önlemin alınmasını sağlamaktadır. Yararlı güneş ışınlarının emilimini sağlayarak D vitamini oluşumuna izin vermektedir [8]. Ancak, aşırı güneş ışığına maruz kalma durumunda cilt yüzeylerinde tahribat oluşarak anormal çoğalmalar yaşanabilmektedir. Bu durumda cilt yüzeyinden başlayan hastalık ilerleyebilmektedir.

Değişken şekilde ve yapılarda cilt yüzeyinde meydana gelen anormallikleri tespit ederek analizlerin yapılması gerekmektedir. Farklı teknikler kullanılarak cilt yüzeylerindeki görüntüler üzerinden tıbbi analizler gerçekleştirilebilmektedir. Bu makale kapsamında yaygın olarak görülen keratosis (akiec), basal cell carcinoma (bcc), bening keratosis (bkl), dermafibroma (df), melanoma (mel), melanocytic nevi (nv), ve vascular (vasc) cilt kanser türleri analiz edilmiştir. Mel türü olmak üzere diğer türlerin yaygınlaşmadan önce ilk aşamalarında tedavisinin yapılması önem arz etmektedir. Ancak cilt lezyonlarının ilerleyişi geç tespit edilirse hastanın hayatta kalma şansı %10'lara doğru düşüş yaşamaktadır [9].

Belirtilen problemi yapay zeka algoritmaları ile çözebilmek için araştırma yapılmıştır. Araştırmalar neticesinde klasik makine öğrenme tabanlı geleneksel yapay sinir ağı algoritmalarının bu problemleri çözmede zorluklar yaşadığı belirlenmiştir [10]. Bu sebepten dolayı yine makine öğrenmenin alt alanı olan derin öğrenme ile yüzeysel cilt görüntülerinin analizi gerçekleştirilmiştir. Derin öğrenme doğal dil işleme, duygu analizi, bilgisayarlı görü analizi, metin analizi, ses tanıma, biyomedikal görüntü analizi gibi pek çok farklı disiplinde özgün çalışmalar yapmaya izin vermektedir [11]–[13]. Günümüze kadar donanımların çok fazla güçlü olmaması gibi sebeplerden dolayı yaygınlık göstermeyen derin öğrenme uygulamaları yaygınlaşmıştır. Bu yaygınlaşmanın tek sebebi donanım kabiliyetlerinin artış göstermesi değil aynı zaman da farklı disiplinlere ait veri setlerinin artış göstermesidir. Cilt kanser tipleri sınıflandırmak için derin öğrenmenin alt alanı olan Konvolüsyon

Sinir Ağları (CNN) algoritmalarını temel alan iki farklı mimariden model oluşturulmuştur. Oluşturulan modeller MobileNet V3 Large ve MobileNet V2 modelleridir. Her iki modelde 1.2 milyon görüntüye sahip ImageNet veri setinin önceden eğitilmesi ile oluşturulmuştur. Her iki modelinde farklı bir katman yapısı ve şekli bulunmaktadır.

Literatürde önceden eğitilmiş sinir ağlarını temel alan mimari modeller olduğu gibi önceden eğitilmiş mimari ağlarını temel almayan mimari modeller ile de cilt kanserlerini sınıflandırma problemi çözüme kavuştuğu görülmektedir. Bu çalışmada literatürde çok fazla yayına sahip olmayan MobileNet V3 mimarisini temel alan bir model ile derin öğrenme tabanlı bir model geliştirilmiştir. MobileNet mimarilerinin çıkış amacı olarak mobil cihazlar gibi taşınabilir cihazlarda da kullanılmasının istenmesidir. Modellerin hafif olması sebebiyle küçük, taşınabilir cihazlarda kullanılabilir. Belirtilen motivasyon ve gerekçelerden dolayı MobileNet mimarisinin son yayınlanan iki versiyonu olan MobileNet V2 ile MobileNet V3 Large mimarilerinin ağırlıklarının tamamını transfer öğrenme amaçlı kullanarak cilt kanseri türleri sınıflandırılmıştır.

Bu amaç doğrultusunda gerçekleştirilen makalenin literatüre sağladığı ana katkılar aşağıda verilmiştir.

- MobileNet V2, ReLU aktivasyon fonksiyonu kullanmasına rağmen MobileNet V3 modelinden daha hızlı bir şekilde model eğitimini tamamlamıştır.
- MobileNet V2 mimarisine ait tüm ağırlık değerleri kullanılarak KFold 2 ile %98.74 doğruluk başarı oranına ulaşılmıştır.
- MobileNet V3 Large mimarisine ait tüm ağırlık değerleri kullanılarak KFold 2 ile %98.45 doğruluk başarı oranına ulaşılmıştır.

Makalenin bundan sonraki kısımları üç farklı bölümden meydana gelmektedir. Birinci bölümde makalede deneysel çalışmalarda kullanılan materyal ve yöntemler sunulmuştur. İkinci bölümde ise karşılaştırma yapılan her iki modelin performans metrikleri verilmiştir. Son bölümde ise makale hakkında sonuçlandırıcı bilgiler verilmiştir.

II. MATERYAL VE YÖNTEM

A. Materyal

Makale çalışmalarında derin öğrenme modelinin güvenilirliği ve geçerliliği veri setine bağlıdır. Bu sebepten dolayı verisi uzmanlar tarafından hazırlanmış bir veri seti tercih edilmiştir. Tercih edilip makalede kullanılan veri seti Avusturya ülkesinin Dermatoloji bölümünde hazırlanmıştır. 2 farklı Dermatoloji bölümü cilt uzmanları tarafından hazırlanan veri setinde 10015 adet görüntü bulunmaktadır [14]. Bu veri setinde bulunan actinic keratosis (akiec), basal cell carcinoma (bcc), bening keratosis (bkl), dermafibroma (df), melanoma (mel), melanocytic nevi (nv), ve vascular (vasc) adlı 7 adet farklı hedefe sahip sınıflar bulunmaktadır. Bu veri setinde bulunan hedef sınıf etiketlerinden akiec, bcc, bkl, df, mel, nv, vasc hedef etiketleri sırasıyla 327, 514, 1099, 115, 1113, 6705, 142 adetten oluşmaktadır.

B. MobileNet V3 Large

Son zamanlarda taşınabilir cihaz ve aygıtların artış göstermesi ile birlikte transfer öğrenme tabanlı algoritmalar gelişim göstermiştir. Bunlardan bir tanesi de MobileNet tabanlı mimarilerdir. MobileNet mimarisinin üç farklı versiyonu bulunmaktadır. Bunlardan bir tanesi MobileNet V1 mimarisidir [15]. MobileNet V1 mimarisinde bottlenecek yapısı gibi bazı değişiklikler ile MobileNet V2 mimarisi önerilmiştir [16]. MobileNet mimarileri temel

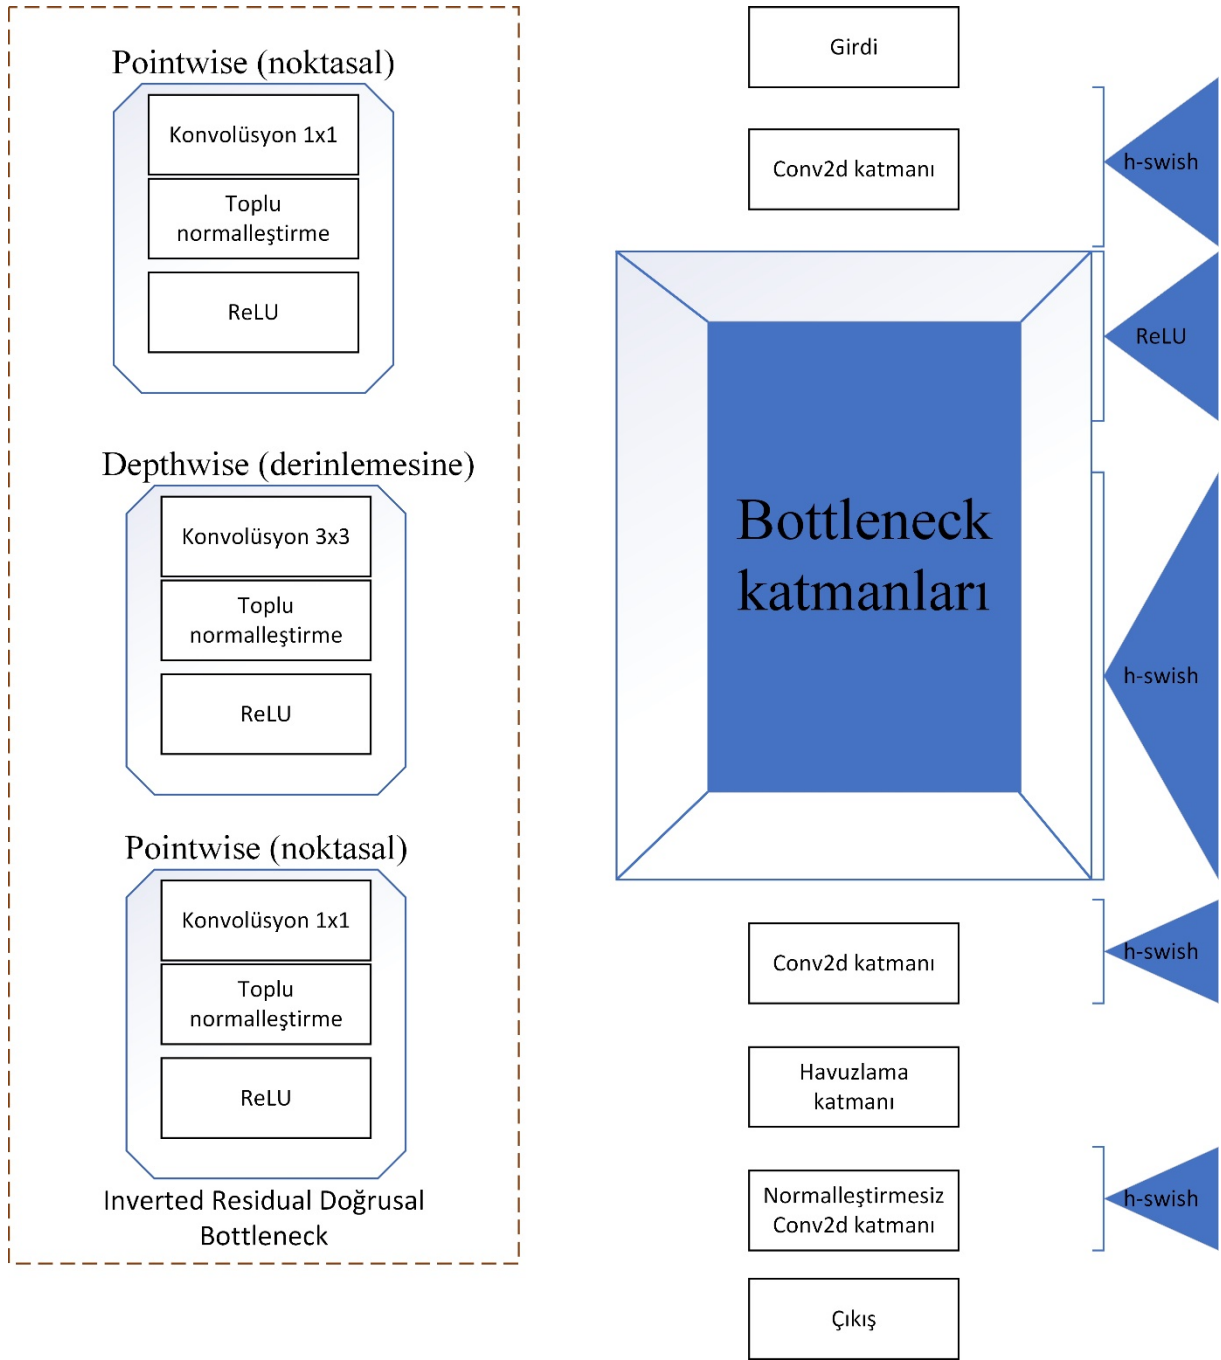
alınarak son zamanlarda geliştirilen bir diğer mimari ise MobilNet V3 mimarisidir. MobileNet V3 mimarisinin de iki farklı versiyonu bulunmaktadır. Bunlardan birincisi MobileNet V3 Small, diğeri ise MobileNet V3 Large mimarisidir. Bu makalede MobileNet V3 Large mimarisi temel alınmıştır. MobileNet V3 mimarisi, NAS ve NetAdapt ağlarına ait olan arama optimizasyon algoritmalarından yardım almaktadır. Aynı zamanda MobileNet V2 mimarisinde ağırlıklı olarak kullanılan ReLU aktivasyon fonksiyonu yerine h-swish aktivasyon fonksiyonunu kullanmaktadır [17]. Swish fonksiyonu ise ReLU gibi bir aktivasyon fonksiyonudur. Swish aktivasyon fonksiyonu Denklem 1'de gösterilmiştir.

$$swish(x) = x\phi\sigma(x) \quad (1)$$

Denklem 1'de tanımlanan fonksiyonda sigmoid aktivasyon fonksiyonu kullanılmaktadır. Sigmoid aktivasyonu hesaplama maliyeti yüksek olmasından dolayı hard swish fonksiyonu adı verilen bir fonksiyona dönüştürülmüştür. Bu fonksiyonda Denklem 2'de verilmiştir.

$$h - swish[x] = x \frac{ReLU6(x + 3)}{6} \quad (2)$$

Denklem 2'de belirtilen fonksiyonda yüksek işlem yüküne sahip sigmoid aktivasyon fonksiyonu yerine ReLU6 fonksiyonu kullanılmıştır.



Şekil 1. MobileNet V3 modeli [17]

Şekil 1’de hem MobileNet V3 Small ve hem de MobileNet V3 Large mimarilerine ait detaylı çizimler görülmektedir. MobileNet V2 mimarisi doğrusal bottlenecek ve inverted residual özelliğine sahiptir. Doğrusal bottleneck özelliği çok fazla bilgi kaybı olmaksızın yüksek boyut uzayından öznelikleri çıkartmak için kullanılmaktadır. MobileNet V2 girdi boyutunu azaltmak için doğrusal bottlenecek yapısını kullanmaktadır. Doğrusal bottleneck, bir bottleneck katmanıdır. Bu katman doğrusal aktivasyon fonksiyonu ile 1x1 boyutundaki konvolüsyon filtresini birleştirmektedir. MobileNet V2 konvolüsyon bloklarını doğrusal bottlenecek katmanlarına

eklemektedir [17]. Şekil 1’de gösterilen MobileNet V2 yapısına özgü olan inverted residual yapısı ise ReLU katmanları yerine giriş bilgilerinden anlamlı tüm bilgileri çıkartmak için en güvenilir ve etkili bir yoldur. MobileNet V2 mimarisinde bottleneck bloğunun başında bir genişleme katmanı bulunmaktadır. Aynı zamanda MobileNet V2 mimarisi gradyan kaybı ve gradyan patlamasını önlemek için bottleneck yapıları arasında kısayollar kullanılmaktadır. Inverted residual blok yapısı ise bellek maliyetlerini oldukça azaltmaktadır. MobileNet V3 ise bu özellikleri Nas ve NetAdapt ağ araştırma yardımıyla ileriye götürmüştür. 2019 yılının ortalarından günümüze

ReLU yerine h-swish doğrusal olmayan aktivasyon fonksiyonu ile etkinliğini artırmıştır.

C. MobileNet V2

Diğer transfer öğrenme modellerinden hafif olması, mobil cihazlarda kullanılabilir olmasından dolayı yoğun olarak kullanılmaktadır [15]. Mobil telefonlardaki görüntü işleme uygulamalarının çalışabilmesi için geliştirilmiş bir mimardır. MobileNet V2, derinlemesine ayrılabilir konvolüsyon (DWC) yapısı kullanılmaktadır. DWC yönteminde derinlemesine konvolüsyon

(DC) yapısı haricinde 1x1 boyutlarında bir filtreleme uygulanmaktadır. MobileNet V2, MobileNet V1 versiyonuna göre ağırlık sayısı azaltılmış bir mimardır. Aynı zamanda 1x1 boyutlarındaki filtreleme ile noktasal konvolüsyon yapmaya izin verilir hale getirilmiştir. Yapılan bu yenilikler ile performansı artırılmıştır. Şekil 2’de gösterilen yapıya göre MobileNet V2 mimarisini tanımlayan t, c, n ve s parametreleri genişleme değeri, çıkış kanal sayısı, atlama değerlerini göstermektedir.

Giriş	Operatör	t	c	n	s
224 x 224 x 3	Konvolüsyon 2D	-	32	1	2
112 x 112 x 32	bottleneck	1	16	1	1
112 x 112 x 16	bottleneck	6	24	2	2
56 x 56 x 24	bottleneck	6	32	3	2
28 x 28 x 32	bottleneck	6	64	4	2
14 x 14 x 64	bottleneck	6	96	3	1
14 x 14 x 96	bottleneck	6	160	3	2
7 x 7 x 160	bottleneck	6	320	1	1
7 x 7 x 320	Konvolüsyon 1 2D 1 x 1	-	1280	1	1
7 x 7 x 1280	Havuzlama (Ortalama) 7 x 7	-	-	1	-
1 x 1 x 1280	Konvolüsyon 2D 1 x 1	-	k	-	-

Şekil 2. MobileNetV2 modeli [16]

III. BULGULAR

Bu makale kapsamında detaylı karşılaştırması yapılan MobileNet V3 ve MobileNet V2 modellerine ait performans tabloları Tablo 1 ve Tablo 2’de verilmiştir.


Tablo 1. KFold değerlerine göre MobileNet V3 performans sonuçları

KFold	Optimizasyon metodu	Doğruluk	Kayıp
1	Adam	96.9	0.14
2	Adam	99.9	0.03
Ortalama		98.4	0.07

Temel MobileNet V3 modelinin performans tablosu gösterilmiştir. 3 farklı KFold değerine göre elde edilen sonuçlar ayrı ayrı verilmiştir. Bu sonuçlara göre kayıp ve doğruluk sonuçları verilmiştir.

Tablo 2. KFold değerlerine göre performans sonuçları


KFold	Optimizasyon metodu	Doğruluk	Kayıp
1	Adam	97.52	0.112
2	Adam	99.96	0.001
Ortalama		98.74	0.05



Şekil 3. Eğitim doğruluk grafiği


Şekil 3'te MobileNet V2 ve MobileNet V3 Large derin öğrenme mimari modellerinin başarı oranları verilmiştir. Sunulan mimari modellerinin başarı oranlarına bakıldığında MobileNet V3 Large modelinde çok az daha fazla başarı sunmuştur. 20. adımdan sonra her iki modelde birbirine yakın sonuç vermiştir. Eğitim sırasında her iki model de Adam optimizasyon yöntemi ile eğitilmiştir. KFold 2 seçeneğine göre eğitim ve test verileri ayrılmıştır.

Elde edilen sonuçların alınmasında her iki MobileNet mimarisinin ağırlık değerleri kullanılmıştır. Şekil 4 içerisinde ise her iki modelin kayıp grafik değerleri gösterilmiştir. Eğitim grafiğinde doğruluk değeri yükseldikçe kayıp değeri azalmaktadır. Bu azalma neticesinde oluşan grafik Şekil 4'te gösterilmiştir. Bu grafiğe göre MobileNet V3 Large modelinin kayıp değerleri diğer modele göre daha azdır.




Şekil 4. Eğitim kayıp grafiği

Şekil 5’te ise MobileNet V3 Large ve MobileNet V2 kullanıldığında yüksek doğruluk oranlarında sınıflandırma gerçekleştirebilmektedir. Her iki modelde temel varsayılan ağırlık değerleri



Şekil 5. Test doğruluk grafiği

Şekil 6’da gösterilen test kayıp grafiklerinde ise ölçüm sonuçlarına göre MobileNet V3 Large her iki modelin kayıp ölçümleri verilmiştir. Bu modelinin oldukça daha az bir kaybı vardır.



Şekil 6. Test kayıp grafiği

Eğitim ve test doğruluk değerleri incelendiğinde MobileNetV2 ve MobileNet V3 Large modellerinin performans grafikleri birbirine yakındır. Her iki modelde sınıflandırma problemlerinde etkin bir şekilde kullanılabilir.

IV. SONUÇLAR

Çevresel kirliliğin artışına bağlı olarak meydana gelen ozon tabası zedelenmesi bilim adamlarının araştırma yaptığı bir konudur. Çünkü ozon tabakası zedelenmesi sonucunda farklı dalga boylarında ışınım yapan zararlı güneş ışınlarına maruz kalma miktarı artış göstermektedir. Bu gibi sebeplerden dolayı farklı yaş aralıklarında görülebilen cilt kanserleri otomatik sınıflandıran bir sistem bu makalede önerilmiştir. Önerilen yapıda genel olarak MobileNet mimarisini temel alan iki farklı versiyonu etkin bir şekilde karşılaştırılmıştır. Yapılan deneysel çalışmalar neticesinde MobileNet V2 ve MobileNet V3 mimarisinin performans sonuçlarının birbirine yakın çıktığı görülmektedir. Bu sonuçları elde edebilmek için eğitim ve test verileri KFold 2 seçeneğine göre ayrılmıştır. Her bir KFold değerinden elde edilen sonuçlar sunularak etkin bir karşılaştırma yapılmıştır. Ağırlıklı olarak kullanılan her iki model ve bu modelleri temel alan transfer öğrenme tabanlı yöntemler geliştirilebilir. Geliştirilen bu yapılar cilt kanseri sınıflandırmada kullanılabilir.

KAYNAKLAR

- [1] R. Perroy, "World population prospects," *United Nations*, vol. 1, no. 6042, pp. 587–592, 2015.
- [2] D. Pimentel *et al.*, "Ecology of Increasing Diseases: Population Growth and Environmental Degradation," *Hum. Ecol. Interdiscip. J.*, vol. 35, no. 6, pp. 653–668, 2007, doi: 10.1007/s10745-007-9128-3.
- [3] N. Bruce, R. Perez-Padilla, and R. Albalak, "The health effects of indoor air pollution exposure in developing countries," *Geneva World Heal. Organ.*, vol. 11, 2002.
- [4] U.-O. Dorj, K.-K. Lee, J.-Y. Choi, and M. Lee, "The skin cancer classification using deep convolutional neural network," *Multimed. Tools Appl.*, vol. 77, no. 8, pp. 9909–9924, 2018, doi: 10.1007/s11042-018-5714-1.
- [5] A. J. McMichael and T. McMichael, *Planetary overload: global environmental change and the health of the human species*. Cambridge University Press, 1993.
- [6] P. Martens and A. J. McMichael, *Environmental change, climate and health: issues and research methods*. Cambridge University Press, 2009.
- [7] R. L. McKenzie, L. O. Björn, A. Bais, and M. Ilyas, "Changes in biologically active ultraviolet radiation reaching the Earth's surface," *Photochem. Photobiol. Sci.*, vol. 2, no. 1, pp. 5–15, 2003.
- [8] F. W. Alsaade, T. H. H. Aldhyani, and M. H. Al-Adhaileh, "Developing a Recognition System for Diagnosing Melanoma Skin Lesions Using Artificial Intelligence Algorithms," *Comput. Math. Methods Med.*, vol. 2021, p. 9998379, 2021, doi: 10.1155/2021/9998379.
- [9] D. B. Mendes and N. C. da Silva, "Skin lesions classification using convolutional neural networks in clinical images," *arXiv Prepr. arXiv1812.02316*, 2018.
- [10] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [11] M. Choudhary, S. S. Chouhan, E. S. Pilli, and S. K. Vipparthi, "BerConvoNet: A deep learning framework for fake news classification," *Appl. Soft Comput.*, vol. 110, p. 107614, 2021, doi: https://doi.org/10.1016/j.asoc.2021.107614.
- [12] T. Chen, R. Xu, Y. He, and X. Wang, "Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN," *Expert Syst. Appl.*, vol. 72, pp. 221–230, 2017, doi: https://doi.org/10.1016/j.eswa.2016.10.065.
- [13] X. Xu, L. Zhang, J. Li, Y. Guan, and L. Zhang, "A Hybrid Global-Local Representation CNN Model for Automatic Cataract Grading," *IEEE J. Biomed. Heal. Informatics*, vol. 24, no. 2, pp. 556–567, Feb. 2020, doi: 10.1109/JBHI.2019.2914690.
- [14] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions," *Sci. data*, vol. 5, no. 1, pp. 1–9, 2018.
- [15] A. G. Howard *et al.*, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv Prepr. arXiv1704.04861*, 2017.
- [16] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510–4520.
- [17] S. Qian, C. Ning, and Y. Hu, "MobileNetV3 for Image Classification," in *2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*, 2021, pp. 490–497. doi: 10.1109/ICBAIE52039.2021.9389905.