

Cilt Kanseri Görüntüleri Kullanılarak Eğitilen EfficientNet-B3 Mimarisinde Hiperparametre Seçiminin Sınıflandırma Performansına Etkisinin İncelenmesi

Ahmet Bahadır KARLI^{1*}, Buket KAYA²

¹ Stratejik Bilgi Yönetim Sistemleri, Tıp Fakültesi, Dicle Üniversitesi, Diyarbakır, Türkiye

² Elektronik ve Otomasyon Bölümü, EOSB Meslek Yüksek Okulu, Fırat Üniversitesi, Elazığ, Türkiye

*¹ abkarli@gmail.com, ² bkaya@firat.edu.tr

(Geliş/Received: 26/01/2024;

Kabul/Accepted: 27/03/2024)

Öz: Bu çalışmada cilt kanserini tespit etmek için derin öğrenme tekniklerini kullanan EfficientNetB3 gibi mimarilerin performanslarını görmek için cilt lezyonlarını içeren HAM10000 veri seti ile çalışma yapılmıştır. Bu çalışmada derin öğrenmede, öğrenme oranının görüntü sınıflandırmada kullanılan evrişimli sinir ağlarını kullanan mimariler üzerindeki etkisini görmek için uygulamalar yapılmıştır. Bu uygulamalar öğrenme oranının, veri setinin büyüklüğü ve çeşitliliği ve eğitimde kullanılan görüntü sayıları ile birlikte artırılmış görüntü sayılarının hem sınıflandırmadaki başarıya hem de eğitim için geçen süreye etkisini görmek amacıyla yapılmıştır. Mimari olarak EfficientNetB3 ve veri seti olarak ta Kaggle platformunda açık erişimi olan HAM10000 veri seti kullanılmıştır. Çalışmanın sonunda, mümkün olduğu kadar artırılmış görüntü kullanmadan ve her bir hastalık sınıfına ait 600 görüntü olacak şekilde, 0,002 öğrenme oranı ve 10 yerine epoch 15 alınarak beşinci uygulamada en yüksek 0.8234 doğruluk performansı elde edilmiştir.

Anahtar kelimeler Evrişimli sinir ağı, öğrenme oranı, derin öğrenme, HAM10000, cilt kanseri

Investigation of the Effect of Hyperparameter Selection on Classification Performance in EfficientNet-B3 Architecture Trained Using Skin Cancer Images

Abstract: In this study, a study was conducted with the HAM10000 dataset containing skin lesions to see the performance of architectures such as EfficientNetB3, which uses deep learning techniques to detect skin cancer. In this study, applications were made in deep learning to see the effect of the learning rate or learning rate on architectures using convolutional neural networks used in image classification. These applications were made to see the effect of the learning rate, the size and diversity of the data set, and the number of images used in training, as well as the increased number of images, on both the success in classification and the time taken for training. EfficientNetB3 was used as the architecture and HAM1000 dataset, which is open access on the Kaggle platform, was used as the dataset. At the end of the study, without using as many augmented images as possible and with 600 images of each disease class, a learning rate of 0.002 and epoch 15 instead of 10, the highest accuracy performance of 0.8234 was achieved in the fifth application.

Key words: Convolutional neural network (CNN), learning rate, deep learning, HAM10000, skin cancer

1. Giriş

Genellikle melanom ve nonmelanom olarak iki kategoriye ayrılan ve vücudun diğer bölgelerine yayılım eğilimi gösteren cilt kanseri tehlikeli kanser türlerinden biridir. Cilt kanserinin teşhisi için şüpheli bir cilt lezyonundan alınması suretiyle genellikle biyopsi yönetimi kullanılır. Bu yöntem yavaş ve zaman alıcıdır [1]. Melanom türü cilt kanseri, erken teşhis edildiğinde tedavi edilebilir bir kanser türüdür. Bundan dolayı cilt kanserini erken tespit etmek için yeni teknikler geliştirilmektedir [2]. Melanom nadir görülen bir kanser türü olsa da ölüm oranı yüksek bir kanser türüdür [3]. Melanom türü kanserlerde erken teşhis kritik bir faktördür. Erken teşhis edilmediğinde, vücudun diğer bölgelerine yayılarak hastanın ölümüne yol açar [4]. Erken teşhisin önemli olduğu Melanom türü cilt kanserinin tespitinde cilt lezyonlarını sınıflandırmak için derin öğrenme teknikleri kullanılarak çok hızlı teşhis konulabilir. Derin öğrenme teknikleri kullanılarak cilt lezyonlarını sınıflandırmak için, genel olarak görüntünün bölümlere ayrılması, özelliklerin çıkarılması ve sınıflandırılması aşamaları gerçekleştirilir. Görüntü sınıflandırmada kullanılan derin öğrenme tekniklerinden biri Evrişimli Sinir Ağlarıdır.


Derin öğrenme (çok katmanlı yapay sinir ağı), katmanlı mimarisiyle büyük veri setlerinden öğrenme gerçekleştiren makine öğreniminin bir alt dalıdır. Derin öğrenmede hatayı minimuma düşürmek için kullanılan gradyan iniş tabanlı optimizasyon algoritmaları (Stochastic gradient descent, momentum, adam, adagrad, rmsprop ve adadelta) bu başarının bir parçası olmaktadır [5]. Derin öğrenme, son yıllarda hem denetimli hem de denimsiz öğrenme zorluklarında yaygın olarak kullanılmaktadır [6]. Evrişimli Sinir Ağları, görüntü sınıflamada iyi

* Sorumlu yazar: abkarli@gmail.com. Yazarların ORCID Numarası: ¹ 0009-0005-5997-2546, ² 0000-0001-9505-181X

performans gösteren modellerden biridir. Evrişimli Sinir Ağları, tıbbi görüntülerin analizi, görüntü tanıma ve diğer alanlarda yaygın olarak kullanılmaktadır [7].

Derin ağ modelleri tasarlanırken, katman sayısı, nöron sayısı, öğrenme oranı gibi ne olması gerektiği modeli tasarlayan kişiye bırakılmış, probleme, veri setine göre değişiklik gösteren parametreler hiper parametre (hyperparameters) olarak adlandırılmaktadır [8]. Sinir ağlarını ayarlamak için öğrenme oranı, kayıp gradyan düşüşüne göre ağırlıklarındaki ayarlamayı tanımlayan, ağırmızdaki ağırlıkları güncelleyen, optimum ağırlıklara doğru ne kadar hızlı veya yavaş ilerleyeceğimizi belirleyen böyle önemli bir hiperparametredir [9]. Başka bir deyişle bir hiper parametre, en doğru tahminleri elde etmek amacıyla uygulayıcı tarafından uygulanan modelin dışında bir yapılandırma değişkenidir [10]. Hiper parametreler, model parametrelerini tahmin etme sürecinin önemli bir parçasıdır ve genellikle uygulayıcı tarafından tanımlanır.

Derin öğrenme sinir ağları, stokastik gradyan iniş optimizasyonu kullanılarak eğitilir [11]. Evrişimli sinir ağları ileri beslemeli ve geri yayımlı olarak çalışan sinir ağlarıdır. Stokastik gradyan iniş, modelin mevcut durumu için hata gradyanını tahmin eden ve ardından geri yayılım olarak adlandırılan hataların geri yayılımı algoritmasını kullanarak modelin ağırlıklarını güncelleyen bir optimizasyon algoritmasıdır [12]. Bilinen en popüler optimizasyon algoritması uyarlamalı öğrenme oranı yöntemini kullanan Adam algoritmasıdır. Eğitim sırasında, hatanın geri yayılımı, ağırdaki bir düğümün ağırlıklarının sorumlu olduğu hata miktarını tahmin eder ve ağırlığı öğrenme oranına göre ölçeklendirerek güncelleme yapar. Bu durumda öğrenme oranı parametresinin, eğitimde kullanılacak veri seti boyutu da dikkate alarak nasıl belirleneceği önerilen çalışma ile ele alınmıştır. Eğitimdeki istikrarsızlığı veya eğitimdeki performans dalgalanmalarını önlemek için başlangıçtaki öğrenme oranını büyük mü yoksa küçük mü seçmek gerektiği üzerine araştırma yürütülmüştür. Büyük seçildiğinde eğitim süresi önemli ölçüde kısalmış ama kullanılan modelin performansının dalgalanmasına sebep olur. Çok küçük seçilirse eğitim süresi önemli ölçüde uzayabilir hatta yetersiz bir çözümde takılıp kalabilir. Dolayısıyla öğrenme oranı parametresi modelin performansını belirleyen, sinir ağlarını ayarlamak için kullanılan en önemli parametrelerden biri olduğundan dolayı hem eğitim süresini kısaltacak hem de yüksek doğrulukla sınıflama yapacak şekilde orantılı bir öğrenme oranı belirlemek gerekiyor. Şekil 1'de öğrenme oranı seçiminin eğitimdeki kayıp üzerine etkisi gösterilmektedir.



Şekil 1. Öğrenme oranı seçiminin eğitimdeki kayıp üzerindeki etkisi [13]


Cilt kanserindeki lezyonları sınıflandırmak için Evrişimsel Sinir Ağları kullanılabilir. Amit Sanjay Shete ve arkadaşları [6] cilt kanserlerini tespit etmek için Evrişimsel sinir ağlarını ve dermastokopik görüntülerden oluşan HAM10000 veri setini kullanmışlardır. Veri setindeki görüntü kirliliğinin giderildiği ve transfer öğrenme yaklaşımının ve ImageNet ağırlıklarının kullanıldığı çalışmada 0.77 F1-skoru elde edilmiştir. Karar Ali ve arkadaşları [14], Önceden eğitilmiş ImageNet ağırlıkları üzerinde transfer öğrenimi gerçekleştirerek ve Evrişimsel Sinir Ağlarında ince ayar yaparak, EfficientNets B0-B7 mimarilerini HAM10000 veri seti üzerinde eğittiler. Bu mimariler içinde %87,91 ile en yüksek doğruluk oranını EfficientNet B4 mimarisi vermiştir. Oktay Yıldız tarafından yapılan çalışmada cilt kanseri melanomu tespit etmek için Evrişimsel Sinir Ağlarını kullanan C4Net mimarisi önerilmiştir. Sunulan çalışmada önerilen mimari, derin öğrenme algoritmalarını kullanan AlexNet, GoogleNet, ResNet, VGGNet gibi mimariler ile birlikte yapay sinir ağları, k-En yakın komşu algoritması ve Destek vektör makinesi gibi geleneksel makine öğrenme algoritmalarıyla da karşılaştırılmıştır. Veri seti olarak ISIC tarafından derlenen 3920 dermoskopi görüntünün kullanıldığı çalışmada önerilen C4Net mimarisi ile %96,94 ile diğer yöntemlere göre daha fazla sınıflandırma doğruluğu elde edilmiştir [15]. Erhan Ergün ve arkadaşları tarafından melanom tespiti için HAM10000 veri seti kullanılarak yapılan çalışmada derin öğrenme mimarileri

karşılaştırılmıştır. Cilt lezyonlarını sınıflandırmak için popüler olan AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16 mimarilerinin kullanıldığı çalışmada ResNet-34 mimarisi, %84,5 F-skoru ile diğer mimarileri geride bırakmıştır [16]. Tri Cong Pham ve arkadaşları melanom tespiti için HAM10000 veri setini kullanmışlardır. Çalışmada melanomun renk, doku ve şekil özellikleri hakkında karşılaştırmalar yapılmıştır. Çalışmada HSV (Ton-Doygunluk-Değer), LBP (Yerel İkili Model) gibi 7 özellik çıkarma yöntemi ile birlikte veri ön işleme adımı olarak Gauss Bulanıklığı, Normalleştirme ve Gauss Bulanıklığı ile Normalleştirmenin birleşimi yöntemleri kullanılarak karşılaştırmalar yapılmıştır. Sınıflandırıcı olarak SVM (Destek Vektör Makinesi), LR (Lojistik Regresyon), RF (Rastgele Orman), BRF (Dengeli Rastgele Orman) gibi algoritmaların kullanıldığı çalışmada özellik çıkarma yöntemi olarak HSV ve sınıflandırıcı olarak Dengeli Rastgele Ormandan oluşan yöntemde %74,75 doğruluk değeri elde edilmiştir [17].

2. Materyal ve Metot

2.1. Veri Seti ve Uygulama Detayları

Bu çalışmada Pigmente lezyonları (renkli yara) için tüm önemli teşhis kategori vakalarını temsil eden (vasc, bkl, akiec, bcc, df, mel, nv) 10015 dermatoskopik görüntülerden oluşan HAM10000 veri seti kullanılmıştır. EfficientNetB3 mimarisi kullanılarak oluşturulan modelde derin öğrenme ağı eğitilmiş, eğitim ve test verilerine ilişkin sonuçlar farklı öğrenme oranları kullanılarak elde edilmiştir. Çalışmanın amacı derin mimaride kullanılan hiper parametrelerden öğrenme oranının mimari üzerindeki sınıflandırma başarısı ve eğitim için geçen süreye etkisini görmektir. Bununla birlikte eğitimde kullanılacak olan veri setinin çeşitliliği ve görüntü sayılarının ve artırılmış görüntülerin de modelin üzerindeki etkisini görmek amacıyla çalışmada farklı sayılarda eğitim veri seti oluşturularak çalışma yapılmıştır. Çalışmada kullanılan 10015 görüntüden oluşan veri setindeki her bir hastalık sınıfına ait görüntüler aynı sayıda değildir. Derin Öğrenme mimarisinin eğitim sürecinde kullanılacak olan her bir hastalık sınıfına ait görüntü sayılarında mümkün olduğu kadar homojen dağılımını sağlamak amacıyla, görüntüler, artırılmış görüntü ile görüntü sayıları eşitlenerek kullanılmıştır. Bundan dolayı başlangıçta eğitim aşamasında her sınıftan 300 görüntü olacak şekilde homojen bir dağılım sağlanmaya çalışılmıştır. Şekil 2'de HAM10000 veri setine ait örnek görüntüler verilmiştir.



Şekil 2. HAM10000 Veri Seti Örnek Görüntüleri

2.2. Metot

Bu çalışmada EfficientNetB3 mimarisi ve HAM1000 veri seti kullanılarak uygulamalar yapılmıştır. Veri setinde cilt kanserleri teşhis vakalarını temsil eden 7 sınıfa ait 10015 JPEG formatında görüntü mevcuttur. Veri setindeki görüntüler ortalama 450X600 piksel boyutunda ve 7 hastalık sınıfını temsil eden görüntülerden oluşmaktadır. Hastalık sınıflarının dağılımı aşağıdaki Tablo 1’de gösterilmiştir.

Tablo 1 . HAM10000 veri seti hastalık sınıflarının dağılımı

Sınıf No	Adı	Veri Seti frekansı
1	akiec	327
2	bcc	514
3	bkl	1099
4	df	115
5	mel	1113
6	nv	6705
7	vasc	142


Tablo 1’de görüldüğü gibi veri setindeki hastalık sınıflarına ait görüntü sayıları eşit değildir. Çalışma, Kaggle platformunda GPU T4 X 2 grafik kartı desteği alınarak gerçekleştirilmiştir. Veri seti 0,8 oranında eğitime, 0,1 oranında doğrulama ve 0.1 oranında test için ayrılmıştır.

Çalışmada kullanılan HAM10000 veri setindeki her hastalık sınıfına ait görüntüler Tablo 1’de görüldüğü gibi birbirine yakın sayıda değildir. Örneğin nv hastalık sınıfına ait görüntü sayısı 6705 iken vasc hastalık sınıfına ait görüntü sayısı 142 adettir. Dengeli olmayan bu veri setindeki görüntüler, eğitim amaçlı rastgele seçilirken görüntü sayısı çok olan bir hastalık sınıfına ait görüntülerin belirleyici olmaması için homojen bir dağılım sağlanması gerekiyordu. Bu durum göz önünde bulundurularak ilk çalışmada eğitim için rastgele seçilen görüntü sayılarında homojen bir dağılım sağlanması amacıyla her bir sınıftan en fazla 200 en az 92 görüntü olacak şekilde veri seti bölünmüştür. İlk çalışmada toplamda her bir sınıftan 300 görüntü olacak şekilde artırılmış görüntülerle denge sağlanmıştır. Eğitim için her sınıftan 300, toplamda 2100 görüntü kullanılmıştır. Momentumu (kontrollü inme) değiştirmeden ilk değer olarak ImageNet ağırlıkları kullanılarak ***öğrenme oranı 0,001***, epoch 10 ve eğitim için batch size 30 olarak alınmıştır. Tablo 2’de ilk uygulamada eğitim için seçilen görüntülerin sayısı verilmiştir.

Tablo 2 . Birinci uygulama, eğitim için seçilen görüntülerin sayısı

n=300 # number of samples in each class for train dataframe	
Initial length of train dataframe is 1206	
Found 200 validated image filenames. for class nv	creating 100 augmented images
Found 200 validated image filenames. for class bkl	creating 100 augmented images
Found 200 validated image filenames. for class mel	creating 100 augmented images
Found 200 validated image filenames. for class bcc	creating 100 augmented images
Found 200 validated image filenames. for class akiec	creating 100 augmented images
Found 92 validated image filenames. for class df	creating 208 augmented images
Found 114 validated image filenames. for class vasc	creating 186 augmented images
Total Augmented images created= 894 Length of augmented dataframe is now 2100	
Found 2100 validated image filenames belonging to 7 classes. for train generator Found 1001 validated image filenames belonging to 7 classes. for valid generator Found 1002 validated image filenames belonging to 7 classes. for test generator	

Bu parametreler ile model eğitilmiştir. Eğitim süresi 0 saat 11 dakika 58,36 saniye sürmüştür ve model 0,7585 doğruluk performansı göstermiştir. Uygulamada elde edilen eğitimdeki kayıplar ve doğrulama doğruluğuna ilişkin ölçüm grafikleri ve yapılan tahminlere ilişkin test sonuçlarını gösteren karmaşıklık matrisi Şekil 3 ve Şekil 4'te gösterilmiştir. Eğitim ve test sonuçlarına ilişkin değerlendirmeler tartışma kısmında yapılmıştır.




Şekil 3. Birinci uygulama kapsamındaki eğitim kaybı ve doğrulama doğruluğu grafikleri

		Confusion Matrix						
		akiec	bcc	bkl	df	mel	nv	vasc
Actual	akiec	26	3	0	2	1	0	0
	bcc	8	37	0	1	1	4	1
	bkl	19	10	64	1	8	8	0
	df	1	0	0	10	0	0	0
	mel	11	2	13	2	61	22	1
	nv	12	13	31	4	55	548	8
	vasc	0	0	0	0	0	0	14
			akiec	bcc	bkl	df	mel	nv
		Predicted						


Şekil 4. Birinci uygulama kapsamındaki karmaşıklık matrisi

İkinci uygulamada model üzerindeki etkilerini görmek için öğrenme oranını ve eğitimde kullanılan görüntü sayıları artırılarak uygulama yapılmıştır. Bu aşamada eğitim için her hastalık sınıfından 700 görüntü olacak şekilde kullanılan görüntü sayısı toplam 4.900 olarak belirlendi. Momentumu değiştirmeden ilk değer olarak ImageNet ağırlıkları kullanılarak ***öğrenme oranı 0,002***, epoch 10 ve eğitim için batch değeri 30 seçilmiştir. Eğitim süresi 0 saat 23 dakika 51,68 saniye sürmüştür ve model 0,8104 doğruluk performansı göstermiştir. Uygulamada elde edilen eğitimdeki kayıplar ve doğrulama doğruluğuna ilişkin ölçüm grafikleri ve yapılan tahminlere ilişkin test sonuçlarını gösteren karmaşıklık matrisi Şekil 5 ve Şekil 6'da gösterilmiştir.



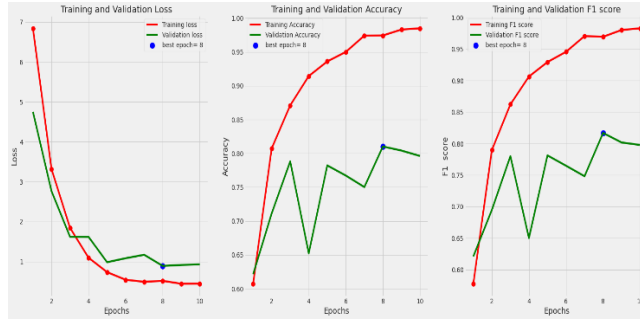
Şekil 5. İkinci uygulama kapsamındaki eğitim kaybı ve doğrulama doğruluğu grafikleri

Cilt Kanseri Görüntüleri Kullanılarak Eğitilen EfficientNet-B3 Mimarisinde Hiperparametre Seçiminin Sınıflandırma Performansına Etkisinin İncelenmesi




Şekil 6. İkinci uygulama kapsamındaki karmaşıklık matrisi

Üçüncü aşamada da eğitim için her hastalık sınıfından 700 görüntü olacak şekilde kullanılan görüntü sayısı toplam 4.900 olarak belirlendi. Momentumu değiştirmeden ilk değer olarak ImageNet ağırlıkları kullanılarak **öğrenme oranı 0,0022**, epoch 10 ve eğitim için batch değeri 30 seçilmiştir. Eğitim süresi 0 saat 23 dakika 54,32 saniye sürmüştür ve model 0,8074 doğruluk performansı göstermiştir. Uygulamada elde edilen eğitimdeki kayıplar ve doğrulama doğruluğuna ilişkin ölçüm grafikleri ve yapılan tahminlere ilişkin test sonuçlarını gösteren karmaşıklık matrisi Şekil 7 ve Şekil 8’de gösterilmiştir.




Şekil 7. Üçüncü uygulama kapsamındaki eğitim kaybı ve doğrulama doğruluğu grafikleri



Şekil 8. Üçüncü uygulama kapsamındaki karmaşıklık matrisi

Dördüncü adımda eğitim için her hastalık sınıfından 700 görüntü olacak şekilde kullanılan görüntü sayısı toplam 4.900 olarak belirlendi. Momentumu değiştirmeden ilk değer olarak ImageNet ağırlıkları kullanılarak

öğrenme oranı 0,0025, epoch 10 ve eğitim için batch değeri 30 seçilmiştir. Eğitim süresi 0 saat 23 dakika 44,92 saniye sürmüş ve model 0,8004 doğruluk performansı göstermiştir. Uygulamada elde edilen eğitimdeki kayıplar ve doğrulama doğruluğuna ilişkin ölçüm grafikleri ve yapılan tahminlere ilişkin test sonuçlarını gösteren karmaşıklık matrisi Şekil 9 ve Şekil 10'da gösterilmiştir.



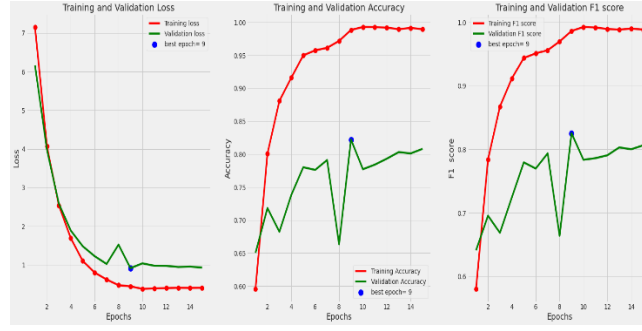
Şekil 9. Dördüncü uygulama kapsamındaki eğitim kaybı ve doğrulama doğruluğu grafikleri

		Confusion Matrix						
		akiec	bcc	bkl	df	mel	nv	vasc
Actual	akiec	27	3	1	1	0	0	0
	bcc	5	44	0	0	2	1	0
	bkl	6	6	81	0	11	6	0
	df	0	1	2	8	0	0	0
	mel	3	0	11	0	83	15	0
	nv	2	13	26	0	78	545	7
	vasc	0	0	0	0	0	0	14
			akiec	bcc	bkl	df	mel	nv
		Predicted						

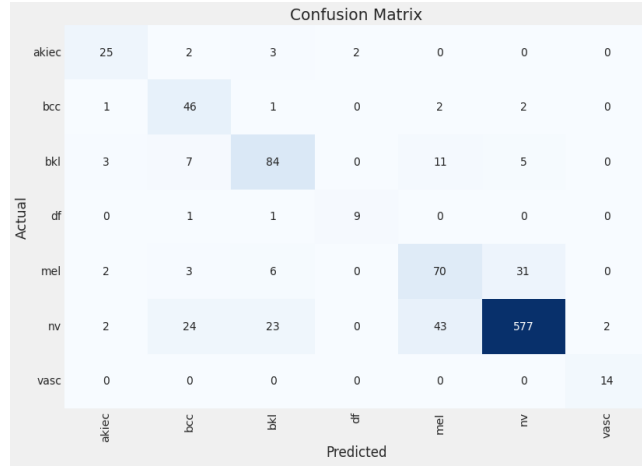
Şekil 10. Dördüncü uygulama kapsamındaki karmaşıklık matrisi

Beşinci ve son aşamada eğitimde kullanılan görüntü sayılarında azalmaya gidildi. Amaç eğitimde kullanılan görüntü sayılarının da öğrenme oranının etkisi ile birlikte modelin aşırı öğrenme eğilimine girmeden optimal sayının etkileri gösterilmek istenmiştir. Bununla birlikte bu uygulamada aynı zamanda mümkün olduğu kadar artırılmış görüntü kullanılmadan her bir hastalık sınıfından 600 görüntü olacak şekilde eğitimde kullanılan toplam görüntü sayısı 4.200 olarak belirlenmiştir. Momentumu değiştirmeden ilk değer olarak ImageNet ağırlıkları kullanılarak **öğrenme oranı 0,002**, epoch 10 yerine epoch 15 ve eğitim için batch değeri 30 seçilmiştir. Eğitim süresi 0 saat 31 dakika 32,29 saniye sürmüş ve model 0,8234 doğruluk performansı göstermiştir. Uygulamada elde edilen eğitimdeki kayıplar ve doğrulama doğruluğuna ilişkin ölçüm grafikleri ve yapılan tahminlere ilişkin test sonuçlarını gösteren karmaşıklık matrisi Şekil 11 ve Şekil 12'de gösterilmiştir.

Cilt Kanseri Görüntüleri Kullanılarak Eğitilen EfficientNet-B3 Mimarisinde Hiperparametre Seçiminin Sınıflandırma Performansına Etkisinin İncelenmesi



Şekil 11. Beşinci uygulama kapsamındaki eğitim kaybı ve doğrulama doğruluğu grafikleri



Şekil 12. Beşinci uygulama kapsamındaki karmaşıklık matrisi

4. Sonuç ve Tartışma

Bu çalışmada, evrimsel sinir ağlarının eğitiminde kullanılan ve kullanıcı tarafından belirlenen hiperparametrelerden, öğrenme oranının ve eğitimde kullanılacak veri setinin büyüklüğü ve çeşitliliğinin, artırılmış görüntü sayılarının eğitim üzerindeki etkisi gösterilmeye çalışılmıştır. Çalışmada elde edilen sonuçlar aşağıda maddeler halinde verilmiştir.

- Veri setinin büyüklüğüne bağlı olarak eğitim başlangıcında seçilecek olan öğrenme oranının ne çok küçük ne de çok büyük seçilmemesi, veri setine bağlı olarak optimal öğrenme oranı seçilmesi halinde doğruluk oranının arttığı görülmüştür.
- Her ne kadar eğitimde kullanılacak olan veri setinin büyüklüğü ve çeşitliliği önemli olsa da, veri setinin çok büyük olmasından dolayı doğruluk oranının sürekli artan bir grafikte artmadığı, başarının aynı oranda yükselmediği bir noktadan sonra başarıya etkisinin azaldığı görülmüştür.
- Veri setindeki görüntü sayıları eşitlenirken kullanılan artırılmış görüntü sayılarının da başarıya etkisi olduğu görülmüştür. Bunun sebebi, eğitim için rastgele seçilen görüntülerdeki gürültüler, olumsuzluklar eğitimdeki başarıya etki etmektedir. Veri setindeki çeşitlilik önemli olduğu kadar, her bir sınıftaki görüntü sayılarının da birbirine yakın olması önemlidir. Bir sınıftaki görüntülerden kaydırma, yatay çevirme, yakınlaştırma vb. gibi yöntemler kullanılarak artırılmış görüntüler elde edildiği zaman, görüntüdeki gürültüler ve olumsuzlukların sayısı da artacağından eğitimdeki başarıya olumsuz etkileri olacaktır.

Gelecek çalışmalarda evrimsel sinir ağları eğitilirken, eğitimde kullanılacak veri setindeki görüntüler, filtremeden geçirilerek mümkün olduğu kadar gürültüler ve olumsuzluklar azaltılırsa aynı oranda başarının da artacağı kanaatini taşımaktayız.

Kaynaklar

- [1] Elgamal, M. Automatic skin cancer images classification, International Journal of Advanced Computer Science and Applications, 2013, vol. 4, no. 3 pp:287-294.
- [2] Dildar M, Akram S, İrfan M, Khan HU, Ramzan M, Mahmood AR, Alsaiari SA, Saeed AHM, Alraddadi MO, Mahnashi MH. Cilt Kanseri Tespiti: Derin Öğrenme Tekniklerini Kullanan Bir İnceleme. *Uluslararası Çevre Araştırmaları ve Halk Sağlığı Dergisi* . 2021; 18(10):5479. <https://doi.org/10.3390/ijerph18105479>
- [3] Key Statistics for Melanoma Skin Cancer. Am. Cancer Soc. Available online: <https://www.cancer.org/content/dam/CRC/PDF/Public/8823.00.pdf> (Erişim Tarihi: 15 November 2023)
- [4] Khan MQ et al., Classification of Melanoma and Nevus in Digital Images for Diagnosis of Skin Cancer, in IEEE Access, 2019, vol. 7, pp. 90132-90144, doi: 10.1109
- [5] Seyyarer, E., Ayata, F., Uçkan, T., Karci, A., Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması, Anatolian Journal of Computer Sciences, 2020, Volume 5 No 2 pp:90-98
- [6] Shete, A. S., Rane, A. S., Gaikwad, P. S., & Patil, M. H, Detection of skin cancer using cnn algorithm. International Journal,2021, 6(5), pp:215-218.
- [7] Kasinathan G, Jayakumar S, Gandomi AH, Ramachandran M, Fong SJ, and Patan R. Automated 3-D lung tumor detection and classification by an active contour model and CNN classifier. Expert Systems with Applications,Nov. 2019, vol. 134. Elsevier BV, pp. 112–119, doi: 10.1016/j.eswa.2019.05.041.
- [8] Çarkacı, N. Derin öğrenme Uygulamalarında en Sık Kullanılan Hiper-Parametreler, Medium. Available at: <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> (Erişim Tarihi: 24 November 2023).
- [9] Rakhecha, A. Understanding learning rate, Medium. Available at: <https://towardsdatascience.com/https-medium-com-dashingaditya-rakhecha-understanding-learning-rate-dd5da26bb6de> (Erişim Tarihi: 22 November 2023).
- [10] Çarkacı N. Derin öğrenme Uygulamalarında Hiper parametre seçim yöntemleri, Medium, <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-model-dogrulama-ve-hiper-parametre-secim-yontemleri-823812d95f3> (Erişim Tarihi : 15 November 2023).
- [11] Deledalle, C, MLIP - chapter 3 - introduction to deep learning PPT. Available at: <https://www.slideshare.net/CharlesDeledalle/mlip-chapter-3-introduction-to-deep-learning> (Erişim Tarihi: 28 November 2023).
- [12] Brownlee, J. Understand the impact of learning rate on neural network performance, MachineLearningMastery.com. Available at: <https://machinelearningmastery.com/understand-the-dynamics-of-learning-rate-on-deep-learning-neural-networks/> (Erişim Tarihi: 05 November 2023).
- [13] Kızrak, A. Keras ile Derin Öğrenmeye Giriş. GitHub. Available at: https://github.com/ayyucekizrak/Keras-ile-Derin-Ogrenmeye-Giris/blob/master/B%C3%B6lüm4/Optimizasyon_Y%C3%B6ntemlerinin_Kar%C5%9F%C4%B1la%C5%9F%C4%B1rmas%C4%B1.ipynb (Erişim Tarihi: 20 November 2023).
- [14] Karar A, Shaikh ZA, Khan AA, Laghari AA. Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer, Neuroscience Informatics, Dec. 2022,vol. 2, no. 4. Elsevier BV, p. 100034, doi: 10.1016/j.neuri.2021.100034.
- [15] Yıldız, O. Derin öğrenme yöntemleriyle dermoskopi görüntülerinden melanom tespiti: Kapsamlı bir çalışma. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 2019, 34.4: 2241-2260.
- [16] Ergün, E. Kılıç, K. Derin öğrenme ile artırılmış görüntü seti üzerinden cilt kanseri tespiti. Black Sea Journal of Engineering and Science, 2021, 4(4). pp 192-200.
- [17] Pham TC, Tran GS, Nghiem TP, Doucet A, Luong CM, Hoang VD. Cilt Kanserinin Sınıflandırılmasına Yönelik Karşılaştırmalı Bir Çalışma, 2019 Uluslararası Sistem Bilimi ve Mühendisliği Konferansı (ICSSE) , 2019,Dong Hoi, Vietnam, s. 267-272, doi: 10.1109/ICSSE.2019.8823124.