



Evrişimsel Sinir Ağları ile Görüntülerde Gürültü Türünü Saptama

Noise Type Detection in Images with Convolutional Neural Networks

Aybüke GÜNEŞ

Tokat Gaziosmanpaşa Üniversitesi
Bilgisayar Mühendisliği
Tokat, Türkiye
aybuke.gunes95@gmail.com
ORCID: 0000-0003-1027-4905

Yasemin ÇETİN KAYA

Tokat Gaziosmanpaşa Üniversitesi
Bilgisayar Mühendisliği
Tokat, Türkiye
yasemin.kaya@gop.edu.tr
ORCID: 0000-0002-6745-77

Öz

Gürültü, görüntü elde etme sırasında görüntüye eklenen istenmeyen sinyallerdir. Bir görüntüden gürültünün arındırılmasında kullanılan filtre yöntemlerinin başarılı olabilmesi için gürültü türünün doğru şekilde analiz edilmesi gerekmektedir. Bu çalışma ile görüntülerdeki gürültü türünün ve gürültüsüz görüntülerin doğru ve pratik şekilde saptanması hedeflenmiştir. Ayrıca, Evrişimli Sinir Ağları (ESA) ile gürültü tahmininde hangi eniyileme algoritmasının tercih edilebileceğine ışık tutulmaya çalışılmıştır. Görüntülerde tuz-biber, gauss ve benek gürültü türlerinin saptanması için VGG-16 mimarisi temel alınarak bir ESA modeli önerilmiştir. Önerilen model transfer öğrenme yöntemi ve ince ayar yaklaşımı kullanılarak eğitilmiş ve beş eniyileme algoritmasının model başarımı üzerindeki etkisi incelenmiştir. Gürültü türünün saptanması için en iyi doğruluk %98,75 ile RMSProp eniyileme algoritması kullanılarak elde edilmiştir. Başarım performansları, gürültü türünün saptanmasında önerilen ESA mimarisinin başarı ile kullanılabileceği gösterilmiştir.

Anahtar sözcükler: Gürültü Türünü Saptama, Transfer Öğrenme, Eniyileme Algoritmaları, Evrişimli Sinir Ağları

Abstract

Noise is unwanted signals added to the image during image acquisition. In order for the filter methods used to remove noise from an image to be successful, the type of noise must be analyzed correctly. This study aims to identify the type of noise in images and noise-free images accurately and practically. In addition, it is tried to highlight on which

optimization algorithm can be preferred in noise estimation with Convolutional Neural Networks (CNN). A CNN model based on the VGG-16 architecture was proposed for the detection of salt and pepper, Gaussian and speckle noise types in images. The proposed model was trained using the transfer learning method and fine-tuning approach, and the effect of five optimization algorithms on the model performance was investigated. The best accuracy of 98.75% for noise type detection was obtained using the RMSProp optimization algorithm. The performance results show that the proposed CNN architecture can be successfully used for noise type detection.

Keywords: Noise Type Detection, Transfer Learning, Optimization Algorithms, Convolutional Neural Networks

1. Giriş

Görüntü elde etme esnasında çeşitli nedenlerden dolayı görüntüye eklenen istenmeyen sinyaller gürültü olarak adlandırılmaktadır [1]. Görüntü hayatımızın birçok alanının ayrılmaz bir parçası haline gelmiştir [2]. Tıpta hastalık teşhisinde, askeri alanda uydu görüntülerinde, özel anların unutulmaz kılınması istendiğinde, kimlik doğrulama işlemlerinde ve benzeri birçok durumda görüntüden ve görüntünün kusursuzluğunun istenmesinden bahsetmek mümkündür. Görüntüler elde edilirken veya bir yerden bir yere aktarılırken toz, ışık, ses, sıcaklık gibi çevresel etkenler görüntülerde gürültüye sebep olmaktadır [3]. Savunma sanayiden sağlık sektörüne, çevrimiçi bireysel başvurulardan güvenlik sistemlerine pek çok alanda yer alan görüntünün, gürültülü olması yanlış teşhis, hatalı tanılama, güvenlik açığı gibi önemli sorunlara sebep olabilmektedir.

Görüntülerde çeşitli etkenlerden kaynaklanan gürültüler, görüntünün kullanıldığı yere göre farklı sorunlara neden olur.

Bu sorunları ortadan kaldırmak için görüntünün gürültüden arındırılması gerekir. Görüntülerdeki gürültüyü gidermek için Gauss ve adaptif medyan filtreleri gibi filtreleme yöntemleri kullanılmaktadır [4]. Ancak bu filtrelerin başarı oranları gürültü türüne göre farklılık göstermektedir. Bilinmeyen bir gürültü türüne uygulanacak filtreler istenen başarıyı her zaman göstermeyebilir. Dolayısıyla gürültü türünün doğru bir şekilde tahmin edilmesi, uygun filtre kullanımı sağlamak ve başarı oranını artırmak için önemlidir [5]. Gürültü arındırma işleminin görüntüler üzerine gerçekleştirilen çalışmalar için son derece önemli olması, doğru ve etkin bir şekilde gürültü türünün tahmin edilmesini gerektirmektedir.

Kaynaklarda, anlık ve keskin sinyal değişimleri sonucu ortaya çıkan görüntüde siyah ve beyaz noktaların oluşmasına neden olan tuz-biber gürültüsü, sıcaklığın yüksek olması, az miktarda aydınlatma olması ve transferden kaynaklı görüntüye eklenen gauss gürültüsü, benek değerlerinin rastgele çarpılması sonucu oluşan benek gürültüsü gibi gürültü türlerine sıklıkla rastlanmaktadır [6]. Bu gürültü türlerinin, görüntülerden arındırılmasındaki en önemli unsur gürültü türünün doğru saptanmasıdır.

Farklı sorunların çözümüne olanak sağlayan derin öğrenmenin görüntü üzerine yapılan çalışmalardaki başarısı, 2012 yılında ImageNet yarışmasında birinci olan AlexNet mimarisi ile başlamış ve yüksek başarı gösteren VGG16, LeNet, GoogleNet ve ResNet mimarileri ile devam etmiştir [7]. ImageNet yarışmasında birçok görüntü tanıma algoritması ortaya atılmış ve bu algoritmalar başarı sağladıkça derin öğrenme mimarileri de ön plana çıkmıştır. Günümüzde birçok sorunun çözümü için derin öğrenme mimarilerinin kullanımı yaygınlaşmıştır. Görüntü tanıma ve sınıflandırmada sağlık[8], finans [9], savunma[10], tarım [11] ve çevre[12] gibi farklı alanlarda derin öğrenme mimarilerinin kullanımı tercih edilir olmuştur. Son yıllarda büyük ilerleme kaydeden derin öğrenme algoritmalarından ESA, bilgisayarla görü, konuşma işleme gibi çeşitli alanlarda farklı görüntü tanıma görevlerinde kullanılmaktadır [13]. Resmin özelliklerini algılamaktan sorumlu evrişim, ağırlık hesaplama yükünü azaltan ortaklama, olasılıksal sınıflandırma yapan tam bağlı katman ve ağırlık ezber yapmasını engellemeye çalışan dropout katmanı ESA'da kullanılan genel katmanlardır.

Derin öğrenme mimarilerinde kullanılan eniyileme algoritmaları da derin öğrenme için önemli parametrelerden biridir. Eniyileme algoritmasının performansı, modelin eğitim verimliliğini doğrudan etkilemektedir. Çalışmamızda derin öğrenme için etkili ve pratik kabul edilen, RMSProp [14], Adagrad [15], Adam [16], Adadelta [17] ve SGD [18] olmak üzere beş farklı eniyileme algoritması kullanılmıştır. Gürültü türünü saptamak için geliştirilecek ESA mimarilerinde daha pratik ve daha doğru sonuçlar elde edebilmek için ileride yapılacak çalışmalarda hangi eniyileme algoritmalarının tercih edilebileceğine ışık tutulmaya çalışılmıştır

Derin öğrenme model performansı iyileştirmek için kullanılabilecek önemli etkenlerden biri de transfer öğrenme yöntemidir. Sınırlı eğitim verisine sahip derin öğrenme alanındaki çalışmalarda, önceden eğitilmiş ve iyi sonuçlar veren transfer öğrenme modeli kullanılarak yapılacak olan

tahmin işlevinin öğrenme başarısını iyileştirmesi beklenmektedir [19]. Bu çalışmada görüntülerdeki gürültü türünü saptamak için VGG16 mimarisini temel alan bir model önerilmiştir. Önerilen model, transfer öğrenme yöntemi ve ince ayar yaklaşımı ile eğitilmiş ve eniyileme algoritmalarının model başarımı üzerindeki etkisi incelenmiştir.

Çalışmanın bundan sonraki bölümleri şu şekilde düzenlenmiştir: Bölüm-2'de kaynaklarda görüntülerde gürültü tahmini ile ilgili yapılan çalışmalar özetlenmiştir. Bölüm-3'te çalışmada kullanılan veri kümesi, yöntem, deneysel tasarım ve başarımlar ölçütleri sunulmuştur. Bölüm-4'te çalışmada elde edilen bulgular sunulmuş ve tartışılmıştır. Son bölüm çalışmanın sonucunu ve ileriki çalışmalar için önerileri içermektedir.

2. İlgili Çalışmalar

Görüntü sağlıktan astronomiye, coğrafi bilimlerden askeri uygulamalara, günlük yaşamdan uydu görüntülerine kadar hayatımızın ayrılmaz bir parçası haline gelmiştir. Görüntünün hayatımızdaki yerinin ve işlevinin artması ile birlikte ışık, ses gibi farklı etkenlerden dolayı görüntülerde oluşan gürültüler de kaynaklardaki çalışma alanlarından biri haline gelmiştir. Gürültüsüz görüntülerin önemi artmış, bu da beraberinde görüntülerindeki gürültülerin doğru şekilde tahmin edilmesi ve ortadan kaldırılması için farklı çalışmaların uygulanmasına neden olmuştur.

Tai ve Yang görüntü gürültüsü tahmini için basit ve hızlı bir algoritma önermiştir [20]. Giriş görüntüsünün Gauss gürültüsü tarafından bozulduğu varsayılır. Yapıları veya ayrıntıları gürültü varyans tahminine dahil etmemek için, ilk olarak birinci dereceden gradyanları kullanan basit bir kenar algılama algoritması uygulanır. Daha sonra bir Laplacian operatörü ve ardından tüm görüntünün ortalamasının alınması sağlanır. Bu yöntem ile çok doğru gürültü varyansı tahmini sağlanması hedeflenmektedir. Yöntem yüksek seviyeli gürültüler için iyi başarımlar gösterirken, gürültü seviyesi düşük olduğunda iyileştirmelere gidilmesinin uygun olacağı değerlendirilmektedir.

Zoran ve Weiss doğal görüntülerin ölççek boyunca sabit bir basıklık değerine sahip olması gerektiğini belirtmektedir [21]. Doğal görüntülerdeki sapmaların görüntünün doğasında bulunan gürültülerden kaynaklandığını ve görüntüdeki gürültülerin saptanması ile doğal görüntülerdeki ölççek boyunca görülebilecek basıklık sorununun önüne geçilebileceğini varsaymaktadır. Varsayımdan yola çıkarak yeni model önerilmiş ve bozulmuş doğal görüntülerdeki gürültü standart sapmasını tahmin etmek için kullanılmıştır. Sonuçlar, bozulmuş varsayılan doğal görüntülerin aslında gürültülü olduğunu ve temizlenebilir olduğunu göstermektedir.

Kaynaklarda görüntülerdeki gürültülerin giderilmesi için farklı yöntemler önerilmiştir. Bu çalışmalar çoğunlukla tek bir gürültü türünün: gauss gürültüsü [21, 23], benek gürültüsü [5], tuz-biber gürültüsü [4, 24, 25] giderilmesine yönelik olmaktadır.

Pimpalkhute ve ark. sayısal görüntülerdeki gauss gürültüsünün Ayrık Dalgalı Dönüşüm (DWT) yöntemi ile

ortadan kaldırılması ile oluşturulan gürültü tahmin modeli önermiştir [23]. Burger ve ark. görüntüleri gürültüden arındırmak için çok katmanlı algılayıcı (Multi Layer Perceptron - MLP) kullanmayı önermektedir [21]. MLP birçok açıdan değerlendirilmeye çalışılarak incelenmiş ve BM3D'den daha iyi olduğu görülmüştür.

Magud ve ark. ultrason görüntülerde yaygın olan gürültü tiplerinden benek gürültüsünün, noktaların bir benekten daha büyük olduğu durumlar da dahil olmak üzere, giderilmesi için geliştirilmiş bir medyan filtresi önermektedir [5]. Sonuçlar önerilen yöntemin, ultrason görüntülerinden benek gürültüsünü başarılı bir şekilde gidermek için kullanılabileceğini göstermektedir.

Güraksın görüntülerde sıklıkla karşılaşılan tuz-biber gürültüsünün giderilmesi için k-ortalama algoritması kullanılarak tasarlanan bir filtre önermektedir [24]. Önerilen filtrenin başarımlarını karşılaştırmak için standart gürültü giderme filtrelerinden olan ortalama ve ortanca filtreleri ile uyarlamalı ortanca filtre kullanılmıştır. Sonuçlarda yalnızca görüntülerdeki gürültü oranı 0,1 iken önerilen yöntemin performansı ortanca filtre ile uyarlamalı ortanca filtreden düşüktür. Bunun yanında gürültü seviyesindeki artışın k-ortalama algoritması ile tasarlanan filtreleme yönteminin diğer üç filtreleme yöntemine kıyasla başarıyı artırdığı gözlemlenmiştir. Değirmenci ve ark. görüntülerde saptanan tuz-biber gürültüsünün giderilmesi için uyarlamalı medyan filtresi ve görüntülerde tuz-biber gürültüsü olmayan yerler içinde anahtarlamalı Gauss filtresi uygulamayı önermektedir [4]. Amaç değişik gürültü türlerine değişik filtreler uygulayarak görüntünün kenarlarının bulanıklaşmasının önüne geçmek ve görüntüyü gürültüden arındırmaktır. Deneysel sonuçlar, kullanılan yöntem ile kenar beneklerinin bulanıklaşma miktarının azaltılabileceğini ve görüntülerdeki gürültülerin azaltılması için geleneksel yöntemlere oranla daha iyi sonuçlar verdiğini göstermektedir.

Görüntüleri gürültüden arındırmak için uygulanan yöntemler gürültünün türüne göre değişiklik göstermektedir. Bu nedenle görüntülerdeki gürültülerin saptanması amacıyla çalışmalar gerçekleştirilmektedir. Çizelge-1'de gürültü türünü saptama çalışmalarına ait bilgiler sunulmuştur.

Sil ve ark. evrimsel sinir ağlarının, görüntüden gürültü gidermek için kullanılan diğer algoritmalara göre nasıl başarımlar gösterdiğini kıyaslamak için VGG16 ve Inception-v3 algoritmalarını kullanmıştır [26]. BSDS300 görüntü veri kümesinden rastgele alınmış 14000 görüntü ile gürültü sınıflandırma için iki yöntemin değerlendirmesi yapılmış ve 30 tur sonrasında Inceptionv3 mimarisi, VGG16 mimarisinden daha iyi eğitim doğruluğu vermiştir. Sınamada %68.35 doğruluk ile Inceptionv3 mimarisi, %67,99 doğruluk oranlı VGG16'dan daha fazla başarımlar sağlamıştır.

Liu ve ark. gürültü türü saptamak için sekiz evrişim katmanı, dört ortaklama katmanı ve üç tam bağlı katman olmak üzere toplam 15 katmanlı bir CNN modeli önermiştir [27]. BSDS500 veri kümesi kullanılarak, önerilen model %90,1 gürültü tipi sınıflandırma doğruluğu elde etmiştir.

Lemarchand gürültü türü saptamak için MobileNetV2 modelini kullanarak bir çalışma gerçekleştirmiştir [28]. ImageNet veri kümesinin değerlendirme kümesinden alınan 10000 görüntünün 9600'ü eğitim,200'ü doğrulama ve 200'ü ise sınama için kullanılmıştır. Model 200 tur boyunca 5.10^{-5} öğrenme oranı ile eğitilmiştir. Sınama sonucunda gürültü sınıflandırmada %93 doğruluğa ulaşılmıştır.

Literatürde ayrıca medikal görüntüler gibi özel bir alandaki görüntülerde gürültüyü saptamak için gerçekleştiren çalışmalarda bulunmaktadır. Li ve ark. uzaktan algılama görüntülerindeki gürültü türlerini saptamaya yönelik bir çalışma gerçekleştirmiştir [29]. Önerilen model dört evrişim ve dört ortaklama katmanı içermektedir. NWPU-RESISC45 veri kümesinin %70'i eğitim %30'u ise sınama için kullanılmıştır. Gerçekleştirilen sınama sonucunda önerilen modelle %99,2 doğruluk elde edilmiştir. Tripathy ve ark. göğüs röntgeni görüntülerinde gürültüyü saptamak için farklı ESA modelleri kullanmıştır [30]. Ayrıca, veri artırımının başarımlar üzerindeki etkisi incelenmiştir. Veri artırımı uygulandığında gürültü türü sınıflandırma performansında artış gözlemlenmiştir. Rahman ve ark. taramalı elektron mikroskobu görüntülerindeki gürültü türlerini saptama için makine öğrenmesi yöntemlerini kullanmıştır [31]. Çalışmada 13 farklı makine öğrenmesi algoritmasının performansı sınanmıştır. En iyi doğruluk performansı(%93) ADA, HisGB, GB, XGB ve Stacking algoritmaları ile elde edilmiştir.

Görüntüden gürültü arındırma işlemi yani filtre uygulaması gürültünün türüne göre gerçekleştirilmektedir. Gürültü türlerinin saptanması doğru ve pratik şekilde gerçekleştirilebilir ise görüntüden gürültü arındırma çalışmalarında kullanılan filtrelerin başarımlar oranlarını artılabileceği düşünülmektedir. Bu nedenle çalışmamızda görüntü çalışmalarında başarılı bir şekilde kullanılan ESA ile oluşturulan bir model aracılığıyla gürültü türü saptamalarının doğru ve pratik bir şekilde hangi eniyileme algoritmaları kullanılarak yapılacağı belirlenmesi amaçlanmıştır.

Çizelge-1 Gürültü türü saptama çalışmaları

Çalışma	Veri kümesi	Görüntü Türü	En Başarılı Model/ler	Doğruluk %
Sil ve ark. [26]	BSDS300	Günlük hayattan çeşitli görüntüler	Inception-V3	68,35
Liu ve ark. [27]	BSDS500	Günlük hayattan çeşitli görüntüler	Özel CNN modeli	90,1
Lemarchand ve ark. [28]	ImageNet (sınama kümesi)	Günlük hayattan geniş kapsamlı görüntüler	MobileNet V2	93
Li ve ark. [29]	NWPU-RESISC45	Uzaktan algılama görüntüsü	Özel CNN modeli	99,2
Tripathy ve ark. [30]	Montgomery and Shenzhen	Göğüs röntgeni görüntüleri	VGG16, DenseNet	99,42
Rahman ve ark. [31]	Electron Microscopy Images	Taramalı elektron mikroskobu görüntüleri	ADA, GB, HisGB, XGB, Stacking	93

3. Araçlar ve Yöntem

3.1 Veri kümesi

Çalışma için tuz-biber, gauss ve benek gürültü türlerini içeren bir veri kümesi hazırlanmıştır. Tuz-biber gürültüsü, veri iletimi sırasında yaşanan hatalardan kaynaklı oluşan bir gürültü türüdür. Ani ve keskin sinyal değişimleri sonucu ortaya çıkmaktadır [6]. Görüntüde tuz ve biber serpiştirilmiş gibi duran siyah ve beyaz renkli noktaların oluşmasına neden olmaktadır. Gauss gürültüsü genellikle görüntü elde edilirken oluşan sinyal hatalarından kaynaklanmaktadır. Sıcaklığın yüksek olması, az miktarda aydınlatma olması ve transferden kaynaklı görüntüye eklenen bir gürültü türüdür. Gürültülü görüntü, gauss gürültüsünde gerçek benek değerlerinin rastgele gauss gürültü değerleri ile toplanması sonucunda ortaya çıkmaktadır [25]. Benek gürültüsü ise gauss ve tuz-biber gürültülerinden farklı şekilde benek değerleri ile rastgele değerlerin çarpılması sonucu oluşmaktadır [6].

Veri kümesinin oluşturulması kısmında orijinal görüntülere (günlük hayattan çeşitli nesne, yapı ve doğa görüntüleri) Matlab programlama dili aracılığıyla beş farklı düzeyde (0,05-0,01-0,1-0,2-0,3) tuz-biber, gauss ve benek gürültüsü eklenerek bir veri kümesi elde edilmiştir. Her bir görüntü aynı forma indirgenmiş, siyah-beyaz, 256x256 benek boyutunda ve jpg formu haline getirilmiştir. Şekil-1’de veri kümesinde yer alan orijinal bir görüntü sunulmuştur. Bu görüntüye üç farklı gürültü türü beş farklı düzeyde uygulandıktan sonra elde edilen görüntüler Şekil-2’de gösterilmektedir.



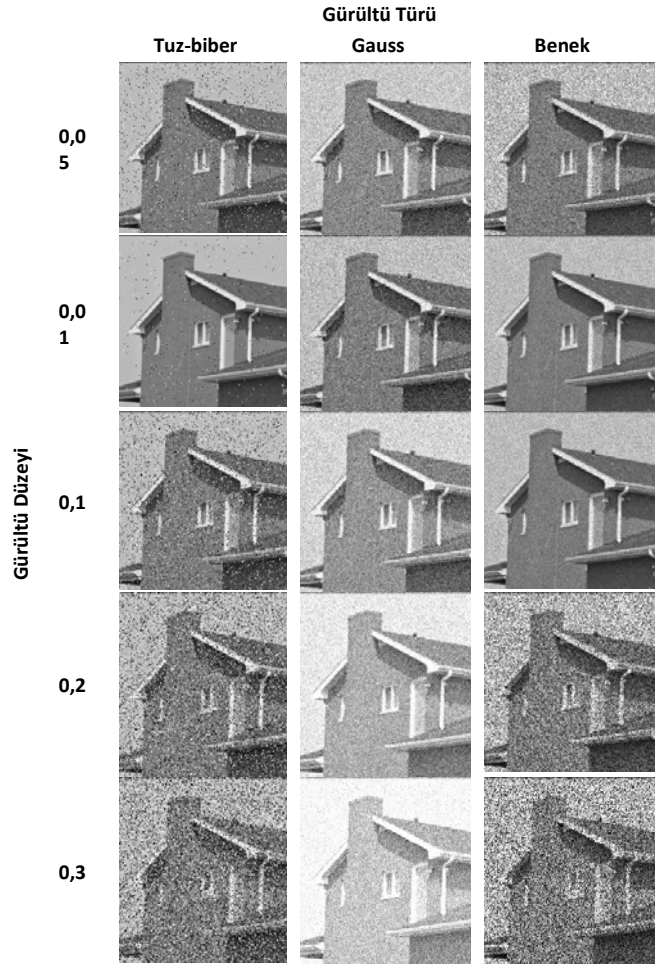
Şekil-1: Veri kümesi orijinal görüntü örneği

Veri kümesi 240 orijinal görüntü ve beş farklı düzey gürültü içeren 1200 gauss, 1200 tuz-biber, 1200 benek görüntü olmak üzere toplam 3840 görüntüden oluşmaktadır. Bu görüntülerden %70’lik kısım eğitim verisi iken geriye kalan % 30’luk kısım ise sınama verisidir. Eğitim verisi için ayrılmış %70’lik kısmın içinden %25’lik kısım ile ön mini sınama amaçlı kullanılan doğrulama veri kümesi oluşturulmuştur. Bu veri kümesinin kullanım amacı ince ayar denilen uygulama için gerekli ayarların sınama aşamasına geçmeden daha doğru saptama edilmesidir.

3.2 VGG16

VGGNet mimarisi Simonyan ve Zisserman tarafından 2014 yılında geliştirilen ve ImageNet yarışmasında iyi bir başarı sergilemiş (% 7,3 hata oranı) bir derin öğrenme modelidir [32]. Çalışmada kullanımı tercih edilen VGG16 mimarisinde her bir evrişim katmanının veya tam bağlı katmanın bir blok oluşturduğu modüler bir yapı mevcuttur. Modüllerdeki ortaklama katmanı özellik haritasının boyutunu küçültürken aynı zamanda en önemli bilgiyi korumak için kullanılmaktadır [33]. Mimarinin asıl amacı, ağ karmaşıklığını artırmadan

uygun katman derinliği ayarlarını dikkate alan bir model tasarlamaktır. Şekil-3’te VGG16’ya ait mimari yapı gösterilmektedir



Şekil-2: Veri kümesi gürültü türü ve düzeyi örnekleri

3.3 Transfer Öğrenme

Transfer öğrenme kavramı, elde edilen bilgilerin yeni şeylerin öğrenilmesine aktarılabilmesi yönüyle insan öğrenme davranışına benzemektedir [34]. Bireyler bir problemle karşılaştıklarında o problemin çözümüne en hızlı ve uygun şekilde ulaşmayı hedeflerler. Bireylerin problemlere ürettikleri çözüm onların tecrübe kazanmasını ve benzer bir problemle karşılaştıklarında bu tecrübeyi kullanmalarını sağlar. Aynı mantıkla düşünüldüğünde transfer öğrenme geçmişte birbirine benzer problemlerin çözümü için hazırlanmış kalıpların yeni karşılaşılmış sorunlar için iyi başarımlar ve hızlı sonuca ulaşmak amacıyla kullanıldığı bir yöntem olarak tanımlanabilir [35]. Transfer öğrenmenin yapılacak olan tahmin işlevinin öğrenme performansını iyileştirmesi amaçlanmaktadır [19]. Transfer öğrenme yönteminde, önceden eğitilmiş bir model, büyük ve karmaşık verileri eğitmek için belli katmanları dondurularak yeniden kullanılmaktadır [36].

Mevcut sınırlı veriler ile başarılı bir ESA modeli kurmak kolay değildir. Bunun yerine, büyük bir veri kümesi üzerinde iyi sonuçlar veren bir model eğitmek ve daha sonra bu eğitilen modeli sınırlı veriye sahip modelde uygulamak gerekir.


Günümüzde birçok çalışmada kullanılan transfer öğrenme yöntemleri, sınırlı eğitim verisine sahip derin öğrenme alanındaki çalışmalarda önemli ilerlemeler kaydetmiştir. Transfer öğrenme yöntemi kullanılarak oluşturulan model, yeni bir kategoriye öğrenirken, daha önce öğrenilen kategorilere ait özelliklerini birleştirmekte ve yeni kategoriye ait az sayıda örneği kullanarak yeni grubun eğitim sürecini doğru bir şekilde tanımlayabilmektedir [37].

3.4 Önerilen Model Mimarisi

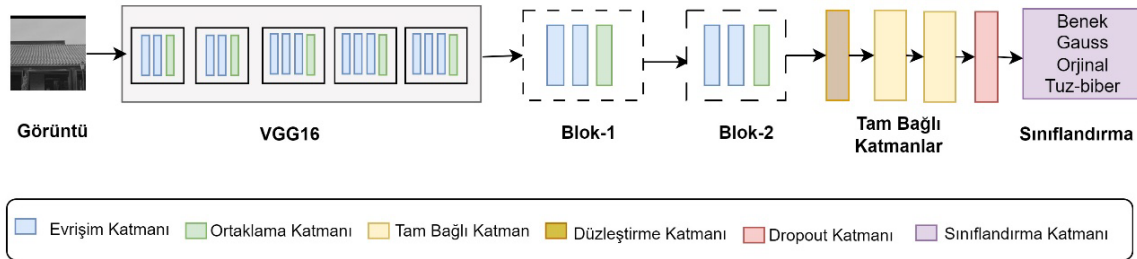
ESA mimarisinin tasarımında VGG16 temel alınmış olup katman sayısında değişiklikler yapılarak uygulanmak istenen çalışma için en iyi sonucu vermesi hedeflenmiştir. Şekil-4'te model mimarisine yer verilmiştir. VGG16 mimarisinin son bloğunda yer alan dört katmanı hariç diğer katmanları alınmış ve dondurulmuştur. Dondurulan katmanlardan sonra iki blok eklenmiş, her blokta iki evrişim katmanı ve her evrişim işleminden sonra bir ortaklama katmanı eklenmiştir. Birinci bloktaki evrişim katmanları 512 adet 3*3'lük filtre

kullanılırken, ikinci blokta ki evrişim katmanlarında 1024 adet 3*3'lük filtre kullanılmıştır. Ortaklama katmanında maksimum ortaklama yapılmıştır. Sonrasında bir adet düzleştirme ve iki adet tam bağlı katman eklenmiştir. Tam bağlı katmanlarda belirli bir değerin altında kalan düğümlerde seyreltilmeye gidilmesinin başarımı artırması sebebiyle ve aşırı öğrenmeyi önlemek için tam bağlı katmandan sonra 0,3 oranında dropout kullanılmıştır. Bunlara ilave Softmax sınıflandırıcısının kullanıldığı çıkış katmanının da eklenmesi ile yeni model kurulmuştur.

Çalışmada kullanılacak görüntü boyutları 224x224 olarak belirlenmiştir. Modelde kullanılan aktivasyon fonksiyonu Relu'dur. Modelde transfer öğrenme yöntemi ince ayar yaklaşımı ile gerçekleştirilmiştir. Önerilen modelde VGG16'nın ImageNet yarışmasında elde edilmiş ağırlıkları kullanarak transfer öğrenme gerçekleştirilmiştir. Oluşturulan yeni ESA mimarisinin büyük eğitim veri kümesine ihtiyaç duymadan ve daha az hesaplama maliyeti ile daha hızlı, daha etkin sonuçlar elde etmek için kullanılması hedeflenmiştir.



Şekil-3: VGG16 mimarisi



Şekil-4: Önerilen model mimarisi

3.5 Eniyileme Algoritmaları

Eniyileme algoritmaları derin öğrenme mimarilerinde kullanılan önemli parametrelerden biridir. Eniyileme algoritmasının performansı, modelin eğitim verimliliğini doğrudan etkilemektedir. Literatürde sıklıkla karşılaşılan eniyileme algoritmaları RMSProp, Adam, Adagrad, Adadelta ve SGD eniyileme algoritmalarıdır [38].

3.5.1 SGD

ESA'da varsayılan algoritmadır. Bir eğitim veri kümesinde tahmine dayalı modelin kayıp fonksiyonunu en aza indirmeyi hedeflemektedir. Diğer eniyileme algoritmalarına kıyasla daha yavaş çalışmaktadır [18]. Eniyileme sürecini iyileştirmek için tasarlanmıştır. RMSProp, AdaGrad, Adam ve AdaDelta'nın SGD'nin bir uzantısı olduğu söylenebilir [39].

3.5.2 RMSProp

Sabit bir şekilde artan öğrenme oranının etkisinden kurtulmak için geliştirilmiştir [14]. Her parametre için öğrenme hızının hesaplanmasında kısmi türevlerin azalan ortalamasını kullanmaktadır. Öğrenme hızı hesaplama açısından bakıldığında Adagrad'ın bir uzantısı olarak düşünülebilir. Derin öğrenme ağları için hem etkili hem de pratik kabul edilen bir eniyileme algoritmasıdır.

3.5.3 AdaGrad

Sabit öğrenme oranı sorununu çözmek için geliştirilmiştir. Her bir adım için farklı bir öğrenme hızı kullanmaktadır [15]. Öğrenme oranı giderek azalmakta ve belirli bir süre sonra öğrenme durmaktadır. Bu bir dezavantajdır. Çünkü uygun sonucun bulunmasından çok önce durma gerçekleşmiş olabilir. Arama sırasında önce o ana kadar görülen parametrenin kısmi türevlerini toplayarak, ardından ilk öğrenme oranı hiperparametresini, karesi alınan kısmi

türevlerin toplamının kareköküne bölerek her parametre için adım boyutunu hesaplamaktadır [40].

3.5.4 AdaDelta

Adagrad ve RMSProp 'dan farklı olarak öğrenme oranı belirlemek zorunlu değildir. Manuel olarak belirlenmiş bir başlangıç öğrenme oranına ihtiyacı ortadan kaldırmak için tasarlanmıştır [40]. RMSProp eniyileme algoritmasının yakınsamasını iyileştirmek için geliştirilmiştir.

3.5.5 Adam

Uygulamalarda tercih edilmesinin temel sebepleri arasında; uygulanmasının kolay olması, bellek gereksiniminin küçük olması, sezgisel olması ile çok az ayarlama gerektirmesi, gürültülü veya seyrek eğilimli problemler için uygun olması yer almaktadır [16]. Adagrad ve RMSProp eniyileme algoritmalarının en iyi özellikleri birleştirilmeye çalışılmıştır. Her bir giriş parametresi için adım boyutu hesaplanmaktadır. Her bir adım boyutu, her bir değişken için karşılaşılan kısmi türevlere dayalı olarak arama süresi boyunca otomatik uyarlanmaktadır [40]. Çizelge-2'de çalışmada kullanılan eniyileme algoritmalarına ait formüller sunulmuştur.

Çizelge-2 Eniyileme algoritmaları formülleri

Eniyileme Algoritması	Formül
Adagrad	$g_{t,i} = \nabla_{\theta_i} J(\theta_{t,i})$ (1)
	$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} g_{t,i}$ (2)
Adadelta	$E[g^2]_t = \rho E[g^2]_{t-1} + (1 - \rho)g^2_t$ (3)
	$RMS[g]_t = \sqrt{E[g^2]_t + \epsilon}$ (4)
	$\nabla x_t = \frac{\eta}{RMS[g]_t} g_t$ (5)
Adam	$m_t = \beta_1 m_{t-1} + (1 - \beta_1)g_t$ (6)
	$v_t = \beta_2 v_{t-1} + (1 - \beta_2)g_t^2$ (7)
	$m'_t = \frac{m_t}{1 - \beta_1^t}, v'_t = \frac{v_t}{1 - \beta_2^t}$ (8)
	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v'_t + \epsilon}} m'_t$ (9)
RMSProp	$E[g^2]_t = 0.9E[g^2]_{t-1} + 0.1g^2_t$ (10)
	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t$ (11)
	$g_t = \nabla_{\theta} J(\theta_t)$ (12)
SGD	$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)})$ (13)

$\theta \in R^d$: Model parametreleri; η : öğrenme katsayısı; $\nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)})$: hedef fonksiyon eğimi; $G_{t,ii}$: t. iterasyona hesaplanmış eğim değerlerinin kareleri toplamı; ϵ : öğrenme katsayısının 0'a bölünmemesini sağlayan sabit değer, varsayılan 10^{-8} ; v_t : geçmiş eğimlerin karelerinin ağırlıklandırılmış ortalaması; m_t : Momentum değişiklikleri; β_1 : varsayılan 0.9; β_2 : varsayılan 0.999; ρ : bozunma sabiti; Δx_t : parametre güncellemesi; $RMS[g]_t$: değerlerin aritmetik ortalamasının karelerinin karekökü

4. Deneyleler

4.1 Deneysel Tasarım

Uygulama ortamı olarak, ücretsiz GPU kullanım imkânı sunan Google Colaboratory [41] platformu kullanılmıştır. Platform, derin öğrenme kütüphanelerinin hazır olarak sunulduğu ücretsiz bir ortamdır. Uygulama Python'da geliştirilmiş ve evrişimsel sinir ağlarının bilgisayarlı görme uygulamalarında

sıklıkla tercih edilen, kolay ve hızlı tasarlanabilen Keras kütüphanesi kullanılmıştır [42,43].

Derin öğrenme uygulamalarında hatayı minimize edebilmek için eniyileme algoritmaları kullanılmaktadır. Bu algoritmaların yardımı ile ağırlık ürettiği çıkış değeri ve gerçek değer arasındaki fark küçük tutulmaya çalışılmaktadır. Çalışmada gürültü türü saptaması için önerilen model, eğitim veri kümesi kullanılarak Adadelta, Adagrad, Adam, RMSProp ve SGD eniyileme algoritmaları ile 70 tur boyunca eğitilmiştir. Eniyileme algoritmalarının tümünde öğrenme oranı olarak 0,0001 kullanılmış, diğer parametreler varsayılan değerleri ile kullanılmıştır. Eğitilen model daha sonra eğitim aşamasında karşılaşılmadığı yeni görüntüler içeren sına veri kümesi ile sınılanmıştır. Modelin farklı eniyileme algoritmaları ile elde ettiği sonuçlar karşılaştırılmıştır.

Çalışmanın ikinci aşamasında gürültü türü saptamasında farklı derin öğrenme mimarilerinin performanslarının gözlenmesi için DenseNet121[44], InceptionV3[45], ResNet50[46], Xception[47] ve MobileNetV2[48] olmak üzere beş farklı derin öğrenme mimarisi ile gürültü türü saptaması gerçekleştirilmiştir. Mimarilerin son katmanları çıkarılarak sırasıyla iki yeni tam bağlı katman, bir dropout katmanı ve son olarak dört nöronlu bir sınıflandırma katmanı eklenmiştir. Mimariler ince ayar yaklaşımı ile 70 tur boyunca eğitilmiş ve daha sonra sına veri kümesi kullanılarak sınılanmıştır. Bu işlem çalışmada kullanılan beş eniyileme algoritması ile gerçekleştirilmiştir. Tüm eniyileme algoritmalarında öğrenme oranı olarak 0,0001 kullanılmış, diğer parametreler ise varsayılan değerleri ile kullanılmıştır.

4.2 Başarım Ölçütleri

Model başarımının ölçülmesi için karışıklık matrisi, doğruluk, kesinlik, duyarlılık ve F1 skor değerleri ile farklı eniyileme algoritmaları kullanılarak eğitilen modelin başarım düzeyleri karşılaştırılmıştır [49-50]. Karışıklık matrisinde;

- Doğru Pozitifler(DP), sınıflandırıcı tarafından pozitif olarak sınıflandırılmış ve gerçek değerleri de pozitif olan değerleri,
- Yanlış Pozitifler(YP), sınıflandırıcı tarafından pozitif olarak sınıflandırılmamış ancak gerçek değerleri negatif olan değerleri,
- Doğru Negatifler(DN), sınıflandırıcı tarafından negatif olarak sınıflandırılmış ve gerçek değerleri de negatif olan değerleri,
- Yanlış Negatifler(YN), sınıflandırıcı tarafından negatif olarak sınıflandırılmış ancak gerçek değerleri pozitif olan değerleri ifade etmektedir. DP ve DN tahminin doğru yapıldığını, YP ve YN ise tahminin yanlış yapıldığını belirtmektedir.

Doğruluk tüm sınıflar için hesaplanan başarım ölçüsüdür. Doğru tahmin edilen sınıfların toplam örnek sayısına oranı şeklinde hesaplanmaktadır [50].

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (14)$$

Kesinlik pozitif tahmin değeri olarak da bilinmektedir. Pozitif sınıflandırmaların ne kadarının gerçekten doğru olduğunu

tahmin etmeye yarayan, gerçek pozitiflerin pozitif olarak sınıflandırılanlara bölünmesi ile elde edilen ölçüttür [50].

$$\text{Tutturma} = \frac{DP}{(DP+YN)} \quad (15)$$

Duyarlılık gerçek pozitiflerin ne kadarının doğru tahmin edildiğini bulmamıza yarar. Yani pozitif tahmin edilmesi gerekenlerin ne kadarının pozitif tahmin edildiğini gösteren, tüm pozitifler arasındaki gerçek pozitiflerin oranı veren ölçüttür [50].

$$\text{Bulma} = \frac{DP}{(DP+YP)} \quad (16)$$

Kesinlik ve duyarlılık değerlerinin harmonik ortalaması F1 skoru vermektedir [50]. Sınıflar arasında eşit dağılım olmayan veri kümelerinde daha doğru değerlendirmeler yapabilmek için doğruluk değerinin yerine kullanımı tavsiye edilmektedir [49]. Hem yanlış negatifleri hem de yanlış pozitifleri hesaba katan, 0 ile 1 arasında değişen bir ölçüttür [49].

$$\text{F1skor} = 2x (\text{Kesinlik} \times \text{Duyarlılık}) / (\text{Kesinlik} + \text{Duyarlılık}) \quad (17)$$

5. Sonuçlar ve Tartışma

5.1 Önerilen Model Sonuçları

Önerilen model Adadelta, Adagrad, Adam, RMSProp ve SGD eniyileme algoritmaları için 70 tur boyunca eğitilmiştir. Eğitim ve doğrulama aşamasına ait doğruluk ve kayıp grafikleri Şekil-5’de sunulmuştur. Adadelta, Adagrad, Adam ve RMSProp grafikleri incelendiğinde eğitim ve doğrulama görüntüleri için doğruluk değerlerinin birbirine çok yakın olduğu ve kayıp değerlerinin ise birkaç yerdeki farklılıklar dışında birbirine yakın düzeylerde seyrettiği gözlenmiştir. Doğrulamadaki kayıp değerleri ise bazı turlarda artmış olmasına rağmen genel olarak incelendiğinde hem doğruluk hem de kayıp değerleri eğitim ve doğrulama veri kümesi için birbirine eşdeğer olarak hareket etmiştir. SGD algoritmasında ise doğruluk

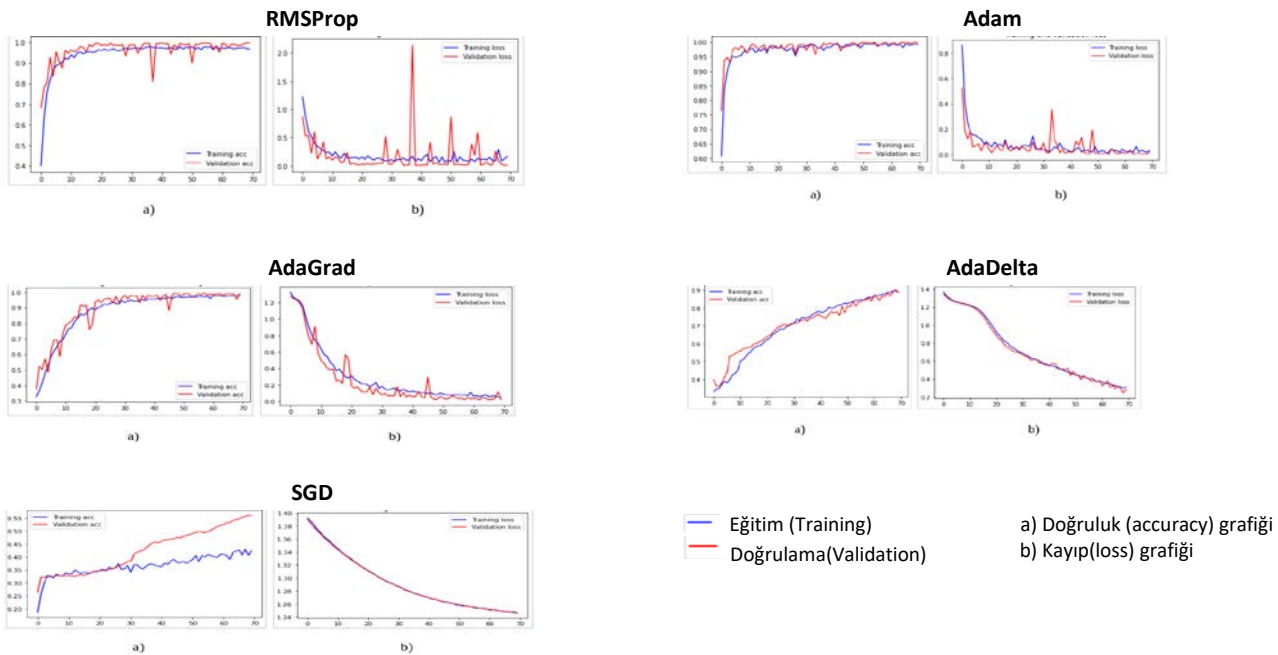
değerlerinin birbirinden farklı ilerlediği, doğrulama veri kümesi için doğruluk değerinin daha yüksek olduğu görülmektedir. Ancak kayıp değerlerinin birbirleri ile neredeyse aynı değerlerde seyrettiği görülmektedir. Şekil-5’teki grafiklerden de görülebileceği gibi önerdiğimiz model farklı eniyileme algoritmalarının kullanılması durumunda aşırı öğrenme durumuna düşmemiştir. Aşırı öğrenme durumunda eğitim aşamasında doğruluk grafiği artan bir eğilimle iyileşme gösterirken, doğrulama doğruluk grafiği eğitim doğruluğu ile birçok noktada çakışarak paralel seyrederken, belli bir tur değerinden sonra düşme eğilimine geçerse aşırı öğrenme durumuna düşmüş diyebiliriz.

Önerilen modelin başarımını saptama etmek için sına veri kümesi üzerindeki doğruluk, kesinlik, duyarlılık oranları ve F1 skorları hesaplanmış ve eniyileme algoritmalarının performansları karşılaştırılmıştır.

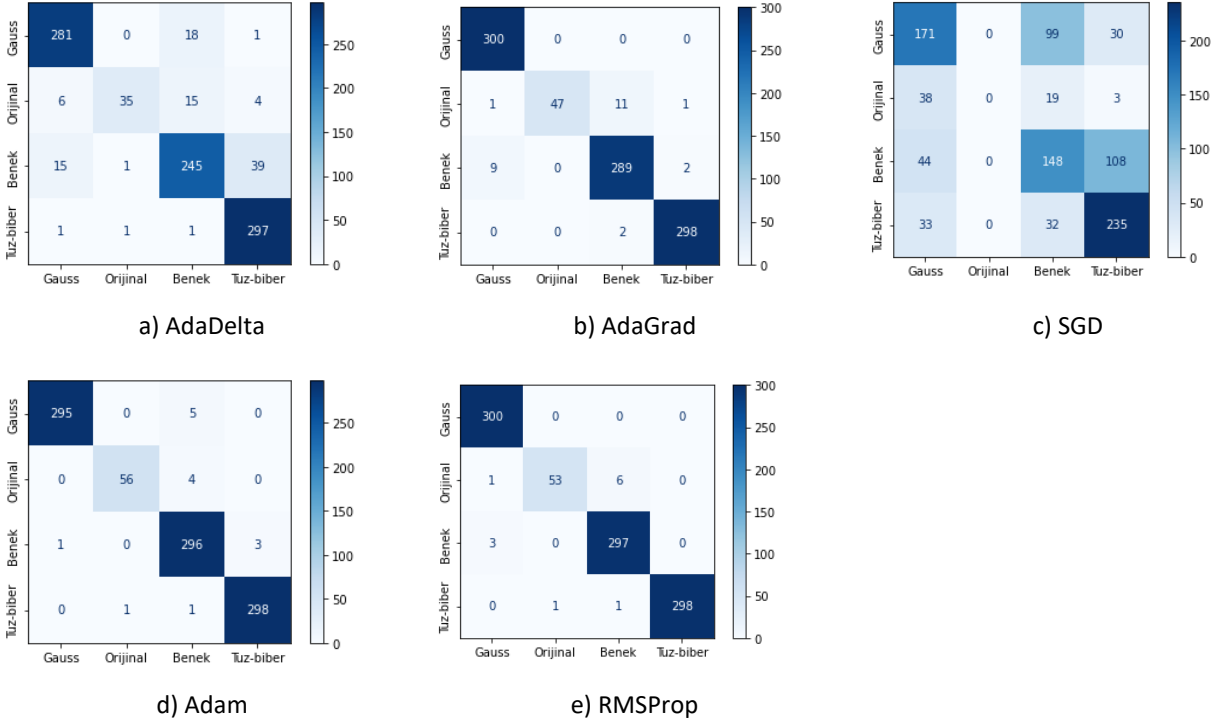
Çizelge-3’te Adadelta, Adagrad, Adam, RMSProp ve SGD eniyileme algoritmaları kullanılarak eğitilen modelin sına aşamasına ait doğruluk değerlerine yer verilmektedir. Çizelge-3 incelendiğinde RMSProp eniyileme algoritması kullanılarak oluşturulan modelin %98,75 doğruluk oranı ile en iyi doğruluk oranına sahip olduğu görülmektedir. İkinci sırada %98,44 doğruluk ile Adam eniyileme algoritması yer alırken, SGD eniyileme algoritması için %57,71 ile en düşük başarıyı göstermiştir.

Çizelge-3: Eniyileme algoritmalarına göre sına doğruluk değerleri

Eniyileme Algoritması	Doğruluk Değeri (%)
Adadelta	89,38
Adagrad	97,29
Adam	98,44
RMSProp	98,75
SGD	57,71



Şekil-5: Eniyileme algoritmaları doğruluk ve kayıp grafikleri



Şekil-6: Eniyileme algoritmalarına göre karışıklık matrisleri

Şekil-6'da eniyileme algoritmalarının her biri için karışıklık matrisleri verilmiştir. Karışıklık matrisi, gerçek etiket değerleri ile tahmin edilen etiketlerin dağılımlarını daha iyi analiz etmemizi sağlamaktadır. Şekil-6 incelendiğinde RMSProp eniyileme algoritması ile Adam eniyileme algoritmalarının toplam hata sayılarının birbirlerine yakın olduğu, Adagrad eniyileme algoritmasının hata sayısının ise RMSProp ve Adam eniyileme algoritmalarına göre daha fazla olmasına rağmen Adadelta ve SGD eniyileme algoritmalarının hata sayısından çok daha iyi olduğu görülmektedir. Ancak Adadelta ve SGD eniyileme algoritmalarının hata sayıları fazla olup görüntüler üzerindeki hata oranı dağılımları da farklılık göstermektedir. Her bir eniyileme algoritmasında orijinal görüntülerin benek gürültüsü olan görüntüler ile karıştırıldığı örneklere rastlanmaktadır. RMSProp, Adam ve Adagrad eniyileme algoritmaları için hatalı olarak etiketlenen bu orijinal görüntüler incelendiğinde, hatanın çoğunlukla aynı görseller üzerinde yapıldığı görülmüştür. Bu durumun sebebinin veri kümesinde yer alan orijinal görüntülerin içerdikleri parlak ve koyu noktalar sebebiyle benek gürültüsü olarak algılanması olduğu düşünülmektedir. En kötü sonuçlara sahip olan Adadelta ve SGD eniyileme algoritmaları için hata dağılımları daha farklıdır. İki eniyileme algoritması da diğerlerine göre daha çok hata sayısına sahip olup SGD eniyileme algoritmasının orijinal görüntülerin hiçbirini doğru saptama edemediği görülmüştür.

RMSProp, Adam ve Adagrad eniyileme algoritmaları için hata oranı dağılımları incelendiğinde gauss gürültüsü eklenmiş görüntüler ve tuz-biber gürültüsü eklenmiş görüntülerin çoğunlukla doğru saptama edildiği görülmektedir. Benek gürültüsü eklenmiş görüntüler ve orijinal görüntüler, gauss ve tuz-biber gürültüsü eklenmiş görüntülere göre daha çok hatalı saptama edilmiştir. Hatalı tahmin edilen benek gürültüsü eklenmiş görüntülerin çoğunun gauss gürültüsü eklenmiş

görüntüler ile karıştırıldığı görülmüştür. Gauss gürültüsü, görüntü elde etme sırasında yüksek sıcaklık, aydınlatmanın az olması veya transferlerden kaynaklı olarak görüntüde oluşan bozulmalardır, benek gürültüsü ise görüntüde parlak ve koyu noktalar olarak görülen yapıcı ve yıkıcı girişim modellerinden kaynaklanan bozulmalardır. Benek gürültüsü eklenmiş görüntülerin gauss gürültüsü olarak belirlenmiş olmasının nedeni belirli oranlarda (0,05-0,01 -0,1- 0,2- 0,3-0,4) gürültü eklenerek oluşturulan gürültülü görüntülerde bazı oranların benek gürültülü görüntüleri, gauss gürültüsündeki gibi algılanmasına sebep olmaktan kaynaklandığı düşünülmektedir.

Çizelge-4'te modele ait başarımlar ölçütleri görülmektedir. RMSProp algoritması tüm başarımlar ölçütlerinde en iyi sonucu elde etmiştir. Adam algoritması ise F1-Skor ve duyarlılık ölçütlerinde RMSProp ile aynı başarıyı göstermekte olup kesinlik ve doğrulukta ise bir miktar düşük değerler elde etmiştir. SGD ise diğer algoritmalara oranla görüntülerde gürültü saptamasında oldukça düşük başarımlar göstermiştir.

Çizelge-4: Modelin başarımlar ölçütleri

Eniyileme Algoritmaları	Doğruluk %	Kesinlik	Duyarlılık	F1-Skor
RMSProp	98,75	0,99	0,97	0,98
Adam	98,44	0,98	0,97	0,98
Adagrad	97,29	0,98	0,94	0,95
Adadelta	89,38	0,91	0,83	0,86
SGD	57,71	0,43	0,46	0,44

5.2 Diğer Modeller ile Karşılaştırma

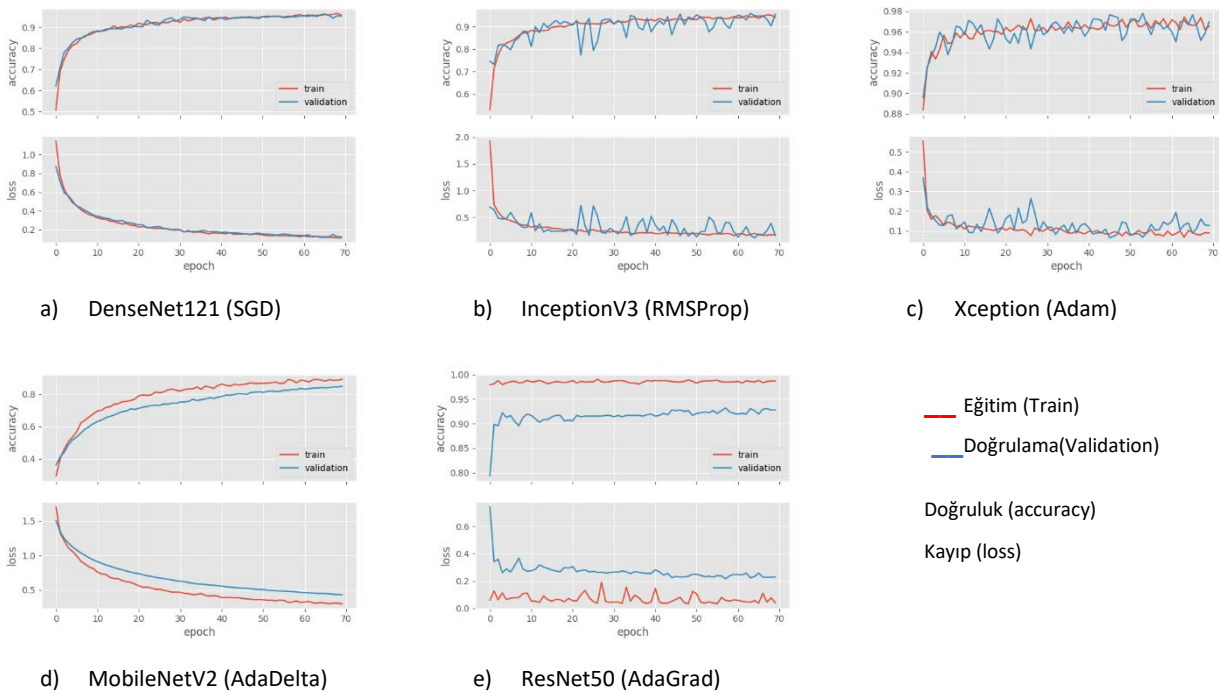
Çalışmanın ikinci aşamasında beş farklı derin öğrenme mimarisi beş farklı eniyileme algoritması ile 70 tur boyunca eğitilmiştir. Şekil-7'de her model ve eniyileme algoritmasını

içercek biçimde doğruluk ve kayıp grafiklerinden birer örnek sunulmuştur.

Şekil-7(a)'da DenseNet121 modeline ait doğruluk grafiği incelendiğinde eğitim ve doğrulama eğrilerinin paralel bir şekilde ilerlediği gözlenmektedir. Şekil-7(b) ve Şekil-7(c)'deki doğruluk grafiklerinde doğrulama eğrisinde dalgalanma gözlenmekle birlikte eğitim eğrisi ile kesiştiği noktalar bulunmaktadır. Modellerde dropout kullanılmasının bu duruma etkisi olduğu düşünülmektedir. Dropout uygulandığında tam bağlı katmanda her turda(epoch) farklı nöronlar aktif hale gelmekte ve bu bilgiler ile sınıflandırma kararı verilmektedir. Şekil-7(a), 7(b) ve 7(c)'de aşırı uyum gözlenmemektedir. Grafiklerde belli sayıda tur sonrasında

düzleşme görülmekte bu da modellerin maksimum öğrenme kapasitesine ulaştığını göstermektedir.

Şekil-7(d)'deki doğruluk grafiğinde ise doğrulama eğrisi eğitim eğrisini bir miktar aşağıdan takip etmekte, düşük seviyede aşırı öğrenme gözlenmektedir. Fakat turlar boyunca doğrulama eğrisi ile eğitim eğrisi paralel bir şekilde seyretmektedir. Şekil-7(e)'de ResNet50 modelinin AdaDelta eniyileme algoritması ile eğitim ve doğrulama aşamalarına ait doğruluk grafiğinde, doğrulama ve eğitim eğrileri birbirine paralel ilerlemesine rağmen aradaki fark 70 turun sonunda kapanmamıştır. ResNet50 modeli AdaDelta eniyileme algoritması ile eğitilirken aşırı öğrenme problemi yaşamıştır. Modelin ezberleme sorunu nedeniyle genelleme yeteneği zayıf kalmıştır.



Şekil-7: Modellerin doğruluk ve kayıp grafiklerinden örnekler

Modellerin sınama aşamasında gösterdiği performansın değerlendirilmesi amacıyla karışıklık matrisleri incelenmiştir. Şekil 8, 9, 10, 11 ve 12'de sırasıyla DenseNet121, InceptionV3, MobileNetV2, ResNet50 ve Xception modelleri için karışıklık matrisleri verilmiştir. Bu matrislerde x eksenini tahmin y eksenini ise gerçek sınıfları göstermektedir.

Karışıklık matrisleri DP ve YN değerleri açısından incelenmiştir. DP değeri model tarafından tahmin edilen sınıf ile gerçek sınıfların aynı olduğu görüntülerin toplam sayısını göstermektedir. Örneğin, Şekil-8(a)'daki matriste benek sınıfı için DP değeri 287'dir. Model sınama veri kümesindeki gerçekte benek sınıfında yer alan 290 görüntünün ait olduğu sınıfı benek olarak doğru tahmin etmiştir.

YN değeri ise model tarafından gerçekte ait olduğu sınıf yerine farklı bir sınıf olarak tahmin edilen görüntülerin toplam sayısını ifade etmektedir. Örneğin, Şekil-8(a)'daki matriste

benek sınıfı için YN değeri 13'tür. Gerçekte benek sınıfında yer alan 1 görüntü orijinal sınıfı, 12 görüntü ise Gauss sınıfı olarak hatalı tahmin edilmiştir. Böylece benek sınıfı için YN değeri 13(12+1) olmaktadır.

DenseNet121 modelinde, en çok hatalı sınıflandırılan gürültü türü benek gürültüsüdür. Benek gürültüsünün çoğunlukla Gauss gürültüsü olarak az sayıda ise orijinal olarak hatalı tahmin edildiği görülmektedir. SGD algoritması hariç diğer algoritmalar ile en doğru tahmin edilen gürültü tuz-biber gürültüsüdür.

Inceptionv3 modeline ait karışıklık matrisi incelendiğinde en çok hatanın (YP) Gauss gürültüsünü belirlerken yapıldığı saptama edilmiştir. Gauss gürültüsü en az hata ile RMSProp algoritması ile saptama edilmiştir. DP açısından incelendiğinde en başarılı saptama edilen gürültü türü ise tuz-biber gürültüsü olduğu görülmektedir.

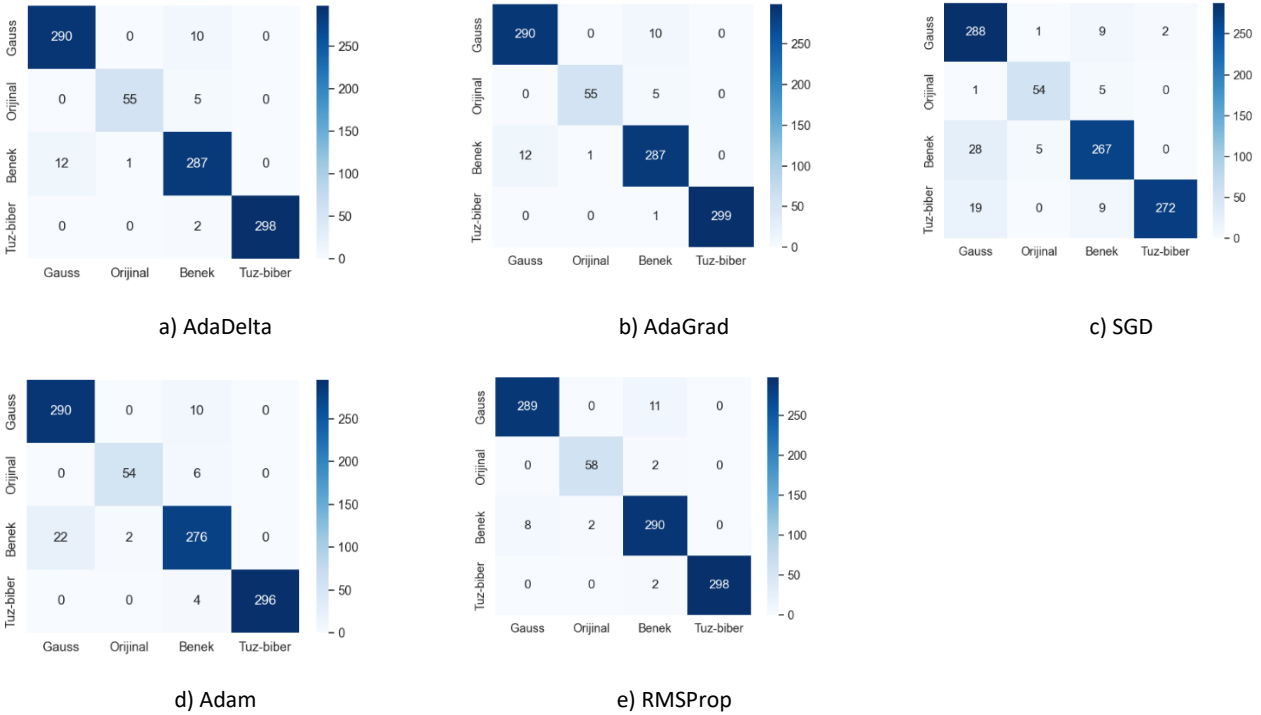
Şekil-10'daki karmaşıklık matrisleri incelendiğinde MobileNetV2 modelinin en başarılı etiketlemeyi tuz-biber gürültüsü için yaptığı görülmektedir. Benek ve Gauss gürültü türlerinde ise hatalı sınıflandırma sayıları fazladır. Model bu iki gürültü türünü ayırt etmekte zorlanmıştır. Gauss gürültüsü saptaması en iyi RMSProp(DP=288) ile yapılırken, benek gürültüsü saptaması ise Adam algoritması(DP=269) ile gerçekleştirilmiştir.

ResNet50 modeli AdaDelta algoritması (YN=5) haricinde diğer algoritmalar ile tuz-biber gürültülerini hatasız saptama edebilmektedir (Şekil-11). En çok hata ise Gauss gürültü türünü saptama ederken yapılmıştır. Gauss gürültüsü, çoğunlukla tuz-biber ve benek gürültüsü ile karıştırılmıştır.


Xception modeli ile en çok hata benek gürültü türünü saptama ederken yapılmıştır. Benek gürültü türünü en başarılı saptaması RMSProp(DP=252) algoritması ile olmuştur. Tuz-biber gürültüsü(YN değerleri 10-18 arasında) en az hata yapılan gürültü türü olmasına karşın az sayıda da olsa tüm gürültü türleri ile karıştırılmıştır.

Bu beş modelin genel karşılaştırması yapıldığında en başarılı şekilde saptama edilen gürültü türü tuz-biber gürültüsü olmuştur. En çok hatalı saptama yapılan gürültü türleri ise benek ve Gauss gürültüleri olmuştur. Benek gürültü türü en doğru şekilde ResNet50(DP değerleri 280-290 arasında) modeli ile saptama edilmiştir. Gauss gürültü türünü en az hata ile saptama eden model DenseNet121 modeli olup tüm algoritmaların DP değeri (289-290) hemen hemen eşittir. Tuz-biber gürültü türünü en iyi tahmin eden model ise ResNet50(DP değerleri 295-300 arası) modelidir.


Bu çalışmada önerdiğimiz model, RMSProp(DP=300) ve AdaGrad(DP=300) algoritmalarını kullanarak Gauss gürültüsündeki sına veri kümesindeki tüm görüntüleri hatasız olarak sınıflandırmıştır. (Şekil-6). Bu bağlamda, önceki beş modelden (en yüksek DP=290) daha iyi başarımlar göstermiştir. Benek(YN=3) gürültüsünde üç hata ve tuz-biber(YN=2) gürültüsünde iki hata ile başarılı etiketleme yapılmıştır. Önerilen model üç gürültü türünü de başarılı bir şekilde saptama edebilmiştir.



Şekil-8: DenseNet121 modeli karmaşıklık matrisleri




a) AdaDelta




b) AdaGrad



c) SGD




d) Adam




e) RMSProp


Şekil-9: InceptionV3 modeli karışıklık matrisleri




a) AdaDelta




b) AdaGrad



c) SGD




d) Adam




e) RMSProp


Şekil-10: MobileNetV2 modeli karışıklık matrisleri




a) AdaDelta




b) AdaGrad



c) SGD




d) Adam




e) RMSProp


Şekil-11: ResNet50 modeli karışıklık matrisleri




a) AdaDelta




b) AdaGrad



c) SGD



d) Adam



e) RMSProp

Şekil-12: Xception modeli karışıklık matrisleri

Çizelge-5: Modellerin doğruluk ve F1-Skor değerleri

	AdaDelta		AdaGrad		Adam		RMSProp		SGD	
	Doğruluk %	F1-Skor	Doğruluk %	F1-Skor	Doğruluk %	F1-Skor	Doğruluk %	F1-Skor	Doğruluk %	F1-Skor
DenseNet121	96,88	0.9647	96,98	0.9655	95,42	0.9496	97,40	0.9725	91,77	0.9146
InceptionV3	85,00	0.8018	85,69	0.7986	84,38	0.7994	87,92	0.8443	85,73	0.8193
ResNet50	93,65	0.9153	92,81	0.9290	95,31	0,9539	95,94	0.9453	81,88	0.8303
Xception	87,71	0.8523	87,60	0.8514	87,19	0.8479	87,50	0.8627	86,77	0.8596
MobileNetV2	83,02	0.8031	93,23	0.9280	93,23	0.9195	92,08	0.9096	92,40	0.9142
Önerilen Model	89,38	0,86	97,29	0,95	98,44	0,98	98,75	0,98	57,71	0,44

Çizelge-5’de çalışmada yer alan tüm modeller ile gürültü türü saptama için elde edilen doğruluk ve F1-Skor ölçütleri verilmiştir. Model bazında elde edilen en iyi değerler koyu renkle gösterilmiştir. Önerilen model RMSProp algoritması ile %98,75 doğruluk ve 0,98 F1-skor değerleri ile en iyi performansı göstermiştir. İkinci ve üçüncü en iyi başarımları sırasıyla DenseNet121(%97,40 doğruluk ve 0,97 F1-Skor) ve ResNet50(%95,94 doğruluk ve 0,95 F1-Skor) modelleri ile RMSProp eniyileme algoritması kullanılarak elde edilmiştir.

Modeller kullanılan eniyileme algoritması açısından incelendiğinde en iyi performansı gösteren algoritma RMSProp algoritması olmuştur. RMSProp DenseNet121, InceptionV3, ResNet50 ve Önerilen model olmak üzere dört modelde en iyi başarımları gösterirken, AdaGrad ve Adam algoritmaları MobileNetV2 modelinde en iyi başarımları göstermiştir. Xception modelinde ise AdaDelta algoritması ile en iyi doğruluk değeri elde edilirken, RMSProp ile en iyi F1-skor elde edilmiştir.

5.3 Önerilen Modelin Literatürdeki Çalışmalar ile Karşılaştırılması

Bu bölümde önerilen modelin performansı literatürde gerçekleştirilen çalışmalar ile karşılaştırılmıştır. Bu aşamada önerdiğimiz modelin genelleme performansı da sinanacaktır. Önerilen modelin çalışmada kullanılan veri kümesinden başka veri kümelerinde elde ettiği başarımları gözlemlenebilecektir.

Çalışmamızda genel olarak görüntülerdeki gürültü türü saptama edilmekte, özel bir alandaki görüntülere (örneğin medikal görüntüler, elektron mikroskobu görüntüleri) odaklanılmamıştır. Çizelge-1 incelendiğinde [26], [27] ve [28] çalışmalarında kullanılan veri kümelerinin bu açıdan uygun olduğu saptanmıştır. Bu üç veri kümesi kullanılarak önerilen modelin başarımları sinanmıştır. Önerdiğimiz modelin genelleme kapasitesini gözlemleyebilmek için model, bu veri kümeleri için tekrardan eğitilmemiş, daha önce eğitilmiş modelimiz sinama aşamasında kullanılmıştır. Bu aşamada en iyi başarımları gösteren RMSProp eniyileme algoritması kullanılarak eğitilen modelimiz kullanılmıştır. Sinama sonucunda elde edilen başarımları ölçütleri Çizelge-6’da verilmiştir.

Çizelge-6: BDS300, BDS500 ve ImageNet veri kümeleri ile elde edilen performanslar

Veri kümesi	Doğruluk %	Kesinlik	Duyarlılık	F1-Skor
BDS300	91,25	91,13	91,41	90,87
BDS500	93,91	93,91	93,94	93,77
ImageNet (sinama kümesi)	93,44	93,44	93,52	93,26

Sil ve ark. [26], Liu ve ark. [27] ve Lemarchand ve ark.[28] tarafından yapılan çalışmalar ile karşılaştırma gerçekleştirilmiştir. Sil ve ark.[26] görüntülerdeki gürültü türünü saptama etmek için InceptionV3 modelini transfer öğrenme yöntemi kullanarak eğitmiştir. BDS300 veri kümesini kullanarak InceptionV3 modeli ile %68,35 doğruluk elde etmiştir. Çalışmamızda önerilen model BDS300 veri

kümesi ile sinandığında %91,13 doğruluk ve 90,87 F1-Skor elde edilmiştir. Önerdiğimiz model ile BDS300 veri kümesinde gürültü türü saptamasında Sil ve ark. [26]’ya göre başarılı bir sonuç elde edilmiştir.

Liu ve ark. [27] gürültü türü saptaması için sekiz evrişim katmanı, dört ortaklama ve iki tam bağlı katmandan oluşan bir model önermiştir. BDS500 veri kümesini kullanarak eğitilen model sinama aşamasında siyah-beyaz görüntülerde gürültü türü saptamasında %90,1 doğruluğa sahiptir. Önerdiğimiz model ise BDS500 veri kümesi kullanılarak sinandığında %93,90 doğruluk ve 93,77 F1-Skor değerine ulaşmıştır. Önerdiğimiz model Liu ve ark. [27]’nin modelinden daha başarılı bir şekilde gürültü türü saptaması yapmaktadır.

Lemarchand ve ark. [28] MobileNetV2 modelini kullanarak ImageNet sinama veri kümesi üzerinde gürültü türü saptaması gerçekleştirmiştir. Çalışmada siyah-beyaz görüntüler ile %93 doğruluk elde edilmiştir. Önerdiğimiz model de %93,44 doğruluk ve 93,26 F1-skor ile bu veri kümesinde aynı başarımları göstermiştir.

BDS300, BDS500 ve ImageNet (sinama kümesi) veri kümeleri üzerinde gerçekleştirdiğimiz bu çalışmada, bu veri kümelerine özel bir eğitim gerçekleştirilmemesine rağmen gürültü türü saptaması başarıyla gerçekleştirilmiştir. Farklı veri kümeleri ile elde edilen bu sonuçlar modelimizin genelleme kabiliyetinin bir göstergesidir.

6. Sonuç

Görüntüleri gürültülerden arındırmak için kullanılacak olan filtrelerin, gürültü türüne göre oluşturulması gerekmektedir. Bunun yanında gürültü türünün doğru şekilde saptama edilememesi görüntünün gürültüden arındırılması için kullanılan yöntemlerin de başarısını olumsuz etkilemektedir. Eğer gürültü türünün tahmini doğru bir şekilde gerçekleştirilebilir ise görüntüye uygulanacak arındırma yöntemi gürültünün türüne göre belirleneceği için başarımları oranını da artıracaktır. Bu sebeple gürültü türünün doğru bir şekilde tahmin edilmesi, uygun filtre kullanımı sağlamak ve başarımları oranını artırmak için önem arz etmektedir. Artık sıklıkla görüntü işleme çalışmaları için kullanılan ESA mimarilerinin gürültü saptaması alanında kullanılabileceği düşünülmektedir. Çalışmada görüntülerde tuz-biber, gauss ve benek gürültü türlerinin saptanması için VGG-16 mimarisi temel alınarak bir ESA modeli önerilmiştir. Önerilen model transfer öğrenme yöntemi ve ince ayar yaklaşımı kullanılarak eğitilmiş ve beş eniyileme algoritmasının model başarımları üzerindeki etkisi incelenmiştir.

Yapılan sinama sonuçlarına göre beş farklı eniyileme algoritması kullanılarak elde edilen doğruluk değerleri, sırasıyla RMSProp eniyileme algoritması için %98,75, Adam eniyileme algoritması için %98,44, Adagrad eniyileme algoritması için %97,29, Adadelta eniyileme algoritması için %89,38 ve SGD eniyileme algoritması için %57,71’dir. RMSProp eniyileme algoritması önerilen model ile gürültü türü saptamasında %98,75 doğruluk oranı ile en iyi başarımları sahip olmuştur.

Literatürde yer alan DenseNet121, InceptionV3, ResNet50, Xception ve MobileNetV2 mimarileri ile gerçekleştirilen

karşılaştırma çalışması sonucunda önerilen modelin gürültü türü saptamasında en iyi başarıyı gösterdiği saptama edilmiştir. Bu çalışmada en başarılı gürültü türü saptamasının RMSProp eniyileme algoritmasının kullanıldığında elde edildiği gözlenmiştir. Ayrıca, üç farklı veri kümesi ile modelin genelleme performansı sınanmıştır. Bu veri kümelerinde önerilen model gürültü türünü başarı ile saptama edebilmiştir.

Bu çalışma ile gürültü türü saptamasında ESA mimarisinin başarı ile kullanılabilmesi gösterilmiştir. Eniyileme algoritmalarının başarı oranına ilişkin yapılmış bir çalışmanın ilerideki çalışmalar için uygun eniyileme algoritmasının tercih edilebilmesinde yardımcı olacağı düşünülmektedir. Hangi eniyileme algoritması ile daha verimli sonuçlar verebileceğine örnek teşkil eden bu çalışma, yeni bir görüntü tanıma çalışması yapılacağı durumlarda eniyileme algoritması seçimine ilişkin yön gösterici olacaktır.

Gelecekte aynı çalışma renkli görüntüler üzerinde de denenebilir ve aynı başarı oranlarının elde edilip edilemeyeceği değerlendirilebilir. Bunun yanında gürültü tahminine ek olarak görüntülerdeki gürültü oranlarının önemi de anlaşılmış olup görüntülerdeki gürültü seviyesi tahminlerinin doğru ve pratik yapılması gerektiği düşünülmüştür. Bu işlemler ile görüntülerin gürültülerden arındırılması işlemlerine ek bir katkı sağlanabilir.

Çalışmamızda gürültü türü saptamasında eniyileme algoritması seçimine ışık tutmak amacıyla beş farklı eniyileme algoritmasının modeller üzerindeki etkisi araştırılmıştır. Eniyileme algoritmaları öğrenme oranı, moment, epsilon ve ağırlık azalması (weight decay) gibi parametrelere sahiptir. Bu parametrelerin alacağı farklı değerler bir modelin yerel ya da global minimuma yakınsaması açısından farklı sonuçlara yol açabilmektedir. İleriki çalışmalarda gürültü türü saptamasında kullanılacak eniyileme algoritmalarının parametrelerinin incelenerek ve en iyi performansı gösteren parametrelerin araştırılmasıyla bir katkı daha sağlanabilir.

7. Kaynakça

- [1] Akar, E., Kara S., Akdemir H., ve Kırış A. *A MATLAB tool for an easy application and comparison of image denoising methods*. In 2015 Medical Technologies National Conference (TIPEKNO), pp. 1-4. IEEE, 2015.
- [2] Hoomod, H. K., ve Dawood S. H. *Fast image denoising based on modify CNN and noise estimation*. 2017 Annual Conference on New Trends in Information & Communications Technology Applications (NTICT). IEEE, 2017.
- [3] Verma, R., ve Ali J. *A comparative study of various types of image noise and efficient noise removal techniques*. International Journal of advanced research in computer science and software engineering 3.10 (2013).
- [4] Değirmenci, Ali, Çankaya İ., ve Demirci R. *Gradyan Anahtarlmalı Gauss Görüntü Filtresi*. Düzce Üniversitesi Bilim ve Teknoloji Dergisi 6.1 (2018): 196-215.
- [5] Magud, O., Tuba E., ve Bacanin N.. *An algorithm for medical ultrasound image enhancement by speckle noise reduction*. International Journal of Signal Processing 1 (2016): 146-151.
- [6] Kaur, S. *Noise types and various removal techniques*. International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE) 4.2 (2015): 226-230.
- [7] Dong, Shi, Wang P., ve Abbas K. *A survey on deep learning and its applications*. Computer Science Review 40 (2021): 100379.
- [8] Kaya, M. *Feature fusion-based ensemble CNN learning optimization for automated detection of pediatric pneumonia*. Biomedical Signal Processing and Control 87 (2024): 105472.
- [9] Akşehir, Z. D., ve Kılıç E. *Hisse Senedi Tahmininde Karşılaşılan Veri Dengesizliği Problemi için Yeni Bir Kural Tabanlı Yaklaşım ve 2D-CNN Modeli*. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi 15.1 (2022): 6-13.
- [10] Karn, A.L., Sengan, S., Kotecha, K., Pustokhina, I.V., Pustokhin, D.A., Subramaniyaswamy, V., ve Buddhi, D. *ICACIA: An Intelligent Context-Aware framework for COBOT in defense industry using ontological and deep learning models*. Robotics and Autonomous Systems 157 (2022): 104234.
- [11] Koklu, M., Unlarsen F. M., Ozkan İ. A., Aslan M. F., ve Sabancı K. *A CNN-SVM study based on selected deep features for grapevine leaves classification*. Measurement 188 (2022): 110425.
- [12] Kaya, M., Ulutürk Samet, Çetin Kaya Y., Altıntaş O., ve Turan B. *Optimization of Several Deep CNN Models for Waste Classification*. Sakarya University Journal of Computer and Information Sciences 6, no. 2 (2023): 91-104.
- [13] Alzubaidi, L., Zhang, J., Humaidi, A.J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M.A., Al-Amidie, M., ve Farhan, L.,. *Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions*. Journal of big Data 8 (2021): 1-74.
- [14] Reddy, S. V. G., Reddy K. T., ve ValliKumari V.. *Optimization of deep learning using various optimizers, loss functions and dropout*. Int. J. Recent Technol. Eng 7 (2018): 448-455.
- [15] Ward, R., Wu X., ve Bottou L. *Adagrad stepsizes: Sharp convergence over nonconvex landscapes*. The Journal of Machine Learning Research 21.1 (2020): 9047-9076.
- [16] Kingma, D. P., ve Adam J. B. *A method for stochastic optimization*. arXiv preprint arXiv:1412.6980 (2014).
- [17] Zeiler, M. D. *Adadelta: an adaptive learning rate method*. arXiv preprint arXiv:1212.5701 (2012).
- [18] Darken, C., Chang, J., ve Moody J. *Learning rate schedules for faster stochastic gradient search*. Neural networks for signal processing. Vol. 2. Helsinoger, Denmark: Citeseer, 1992.
- [19] Phan, T. V., Sultana, S., Nguyen, T. G., ve Bauschert, T. *Q-TRANSFER: A Novel Framework for Efficient Deep Transfer Learning in Networking*. In 2020 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC), pp. 146-151. IEEE, 2020.
- [20] Tai, S-C, ve Yang S-M. *A fast method for image noise estimation using laplacian operator and adaptive edge detection*. 2008 3rd International Symposium on Communications, Control and Signal Processing. IEEE, 2008.
- [21] Zoran, D., ve Weiss, Y. *Scale invariance and noise in natural images*. 2009 IEEE 12th International Conference on Computer Vision. IEEE, 2009.
- [22] Burger, H. C., Schuler, C. J., ve Harmeling. S. *Image denoising: Can plain neural networks compete with BM3D?*. 2012 IEEE conference on computer vision and pattern recognition. IEEE, 2012.
- [23] Pimpalkhute, V. A., Page R., Kothari A., Bhurchandi, K. M., ve Kamble, V. M. *Digital image noise estimation using DWT*

- coefficients. IEEE transactions on image processing 30 (2021): 1962-1972.
- [24] Güraksın, G. E. *Tuz Biber Gürültülerinin Giderilmesi için k-Ortalama Algoritması Tabanlı Filtre Tasarımı*. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2018, 22 (2), 972-978.
- [25] Küpeli, C., ve Bulut, F. *Görüntüdeki Tuz Biber ve Gauss Gürültülerine Karşı Filtrelerin Başarım Analizleri*. Haliç Üniversitesi Fen Bilimleri Dergisi 3.2 (2020): 211-239.
- [26] Sil, D., Dutta, A., ve Chandra, A. *Convolutional neural networks for noise classification and denoising of images*. In TENCON 2019-2019 IEEE Region 10 Conference (TENCON), pp. 447-451. IEEE, 2019.
- [27] Liu, F., Song, Q., ve Jin, G. *The classification and denoising of image noise based on deep neural networks*. Applied Intelligence 50 (2020): 2194-2207.
- [28] Lemarchand, F., Findeli, T., Nogues, E., ve Pelcat, M. *Noisebreaker: Gradual image denoising guided by noise analysis*. In 2020 IEEE 22nd International Workshop on Multimedia Signal Processing (MMSp), pp. 1-6. IEEE, 2020.
- [29] Li, Y., Yu X., Pei, J., Huo, W., Zhang, Y., Huang, Y., ve Yang, J.. *A Learning-Based Multi-Type Noise Suppressing Method for Remote Sensing Images*. In IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium, pp. 3299-3302. IEEE, 2022.
- [30] Tripathy, A., Das, A., Patel, M., Singhai, E., ve Tripathy, S. *Transfer Learning based Noise Classification in Chest X-Ray Images*. In 2021 Smart Technologies, Communication and Robotics (STCR), pp. 1-7. IEEE, 2021.
- [31] Rahman, S. S. M. M., Salomon, M., ve Dembélé, S. *Machine learning aided classification of noise distribution in scanning electron microscopy images*. In 2023 3rd International Conference on Computer, Control and Robotics (ICCCR), pp. 111-115. IEEE, 2023.
- [32] Simonyan, K., ve Zisserman, A. *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556 (2014).
- [33] Tao, J., Gu, Y., Sun, J.Z., Bie, Y., ve Wang, H. *Research on vgg16 convolutional neural network feature classification algorithm based on Transfer Learning*. In 2021 2nd China international SAR symposium (CISS), pp. 1-3. IEEE, 2021.
- [34] Fan, J., Lee J. H., ve Lee YK. *Application of transfer learning for image classification on dataset with not mutually exclusive classes*. 2021 36th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC). IEEE, 2021.
- [35] Fırıldak, K., ve Talu, M. F. *Evrşimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi*. Computer Science 4.2 (2019): 88-95.
- [36] Rajeswari, S. S., ve Nair, M. *A Transfer Learning Approach for Predicting Alzheimer's Disease*. 2021 4th Biennial International Conference on Nascent Technologies in Engineering (ICNTE). IEEE, 2021.
- [37] Li, G., Zhen, H., Jiao, F., Hao, T., Wang, D., ve Ni, K. *Research on tobacco leaf grading algorithm based on transfer learning*. In 2021 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA), pp. 32-35. IEEE, 2021.
- [38] Seyyarer, E., Ayata, F., Uçkan, T., ve Karci, A. *Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması*. Computer Science 5, no. 2 (2020): 90-98.
- [39] Quinn, J., McEachen, J., Fullan, M., Gardner, M., ve Drummy, M. *Dive into deep learning: Tools for engagement*. Corwin Press, 2019.
- [40] Goodfellow, I., Bengio, Y., ve Courville, A. *Deep learning*. MIT press, 2016.
- [41] Bisong, E. *Building machine learning and deep learning models on Google cloud platform*. Berkeley, CA: Apress, 2019.
- [42] Géron, A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc.", 2022.
- [43] Madhavan, S., Ahmed, S., Rao, V., ve John, A., 2021. *Compare deep learning frameworks*. <https://developer.ibm.com/articles/compare-deep-learning-frameworks/> (Erişim Tarihi: 15.09.2023).
- [44] Huang, G., Liu, Z., van der Maaten, L., ve Weinberger, K.Q. *Densely connected convolutional networks*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 21–26 July 2017; pp. 4700–4708.
- [45] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z. *Rethinking the inception architecture for computer vision*. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 2818-2826. 2016.
- [46] He, K., Zhang, X., Ren, S., ve Sun, J. *Deep residual learning for image recognition*. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770-778. 2016.
- [47] Chollet, F. *Xception: Deep learning with depthwise separable convolutions*. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1251-1258. 2017.
- [48] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., ve Chen, L-C. *Mobilenetv2: Inverted residuals and linear bottlenecks*. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 4510-4520. 2018.
- [49] Powers, D. *Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation*. Journal of Machine Learning Technologies 2.1 (2011): 37-63.
- [50] Powers, D. M. W. *Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation*. arXiv preprint arXiv:2010.16061 (2020)