

Transfer Derin Öğrenme Teknikleri ile Görüntü Sınıflandırmada Aktivasyon Fonksiyonlarının Performans Üzerindeki Etkisi

*Makale Bilgisi / Article Info

Alındı/Received: 28.07.2023

Kabul/Accepted: 07.03.2024

Yayımlandı/Published: 29.04.2024

The Effect of Activation Functions on Performance in Image Classification with Transfer Deep Learning Techniques

Gül Cihan HABEK^{1*}, Şakir TAŞDEMİR², Fatih BAŞÇİFTÇİ³, Ahmet YILMAZ¹

¹Karamanoğlu Mehmetbey Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Karaman, Türkiye

²Sinop Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Sinop, Türkiye

³Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, Türkiye

© Afyon Kocatepe Üniversitesi

Öz

İleri beslemeli yapay sinir ağı modeli olan konvolüsyonel sinir ağları (CNN) görüntülerin sınıflandırılması problemlerinde sıklıkla kullanılmaktadır. Genel olarak konvolüsyon katmanı, havuzlama katmanı ve tam bağlı katmandan oluşan CNN modeli üzerinde performansı iyileştirmek amacı ile birtakım eklemeler ve değişiklikler yapılarak yeni mimariler geliştirilmiştir. Bu çalışmada geliştirilen CNN tabanlı VGG16 ve ResNet50 mimarilerine sigmoid, tanh ve ReLu aktivasyon fonksiyonlu farklı sayıda gizli katman eklenerek derin transfer öğrenme tekniği ile görüntüler sınıflandırılmış ve performansları karşılaştırılmıştır. Sınıflandırma için kullanılan veri seti meyveler ile ilgili çoklu sınıflı bir veri seti olup kurulan modellerin son katmanında 10 nöronlu softmax sınıflandırıcı kullanılmıştır. Devir sayısı 10 girilerek sınıflandırma doğruluğu (accuracy), duyarlılık (precision), geri çağırma (recall) ve f1-ölçütü olmak üzere dört farklı metrik için sonuçlar alınmıştır. Alınan sonuçlar kıyaslandığında modeller arasında ResNet50 mimarisine sigmoid aktivasyon fonksiyonlu, 256 ve 128 nöronlu iki gizli katman ve 10 nöronlu bir softmax sınıflandırıcı katmanı olmak üzere toplam üç katman eklenerek oluşturulan modelin %97.5 sınıflandırma doğruluğu değeri ile en iyi sonucu verdiği gözlemlenmiştir. Son olarak dört metrik için alınan sonuçlar Friedman ve Nemenyi post-hoc testlerine tabi tutularak istatistiksel bir analiz yapılmış, modeller arasındaki ilişki test edilmiştir. Test sonucunda oluşturulan modellerin birbirleri ile ilişkili olduğu sonucuna varılmıştır.

Anahtar Kelimeler: Görüntü Sınıflandırma; Derin Öğrenme; ResNet50 Mimarisi; Transfer Derin Öğrenme; VGG16 Mimarisi.

Abstract

Convolutional neural networks (CNN), a feedforward neural network model, are frequently used in image classification problems. New architectures have been developed by making some additions and changes in order to improve the performance on the CNN model, which generally consists of convolution layer, pooling layer and fully connected layer. By adding different numbers of hidden layers with sigmoid, tanh and ReLu activation functions to the CNN-based VGG16 and ResNet50 architectures developed in this study, images were classified by deep transfer learning technique and the performances were compared. The dataset used for classification is a multi-class dataset related to fruits, and a 10-neuron softmax classifier was used in the last layer of the established models. Entering the epoch as 10, results were obtained for four different metrics: accuracy, precision, recall, and f1-score. When the results are compared, it has been observed that the model created by adding a total of three layers, including two hidden layers with 256 and 128 neurons, and a softmax classifier layer with 10 neurons, to the ResNet50 architecture with sigmoid activation function, gives the best result with a classification accuracy value of %97.5. Finally, the results obtained for the four metrics were subjected to the Friedman and Nemenyi post-hoc tests, a statistical analysis was made and the relationship between the models was tested. It was concluded that the models created as a result of the test were related to each other.

Keywords: Image Classification; Deep Learning; ResNet50 Architecture; Transfer Deep Learning; VGG16 Architecture.

1. Giriş

Bilgisayarların yazılan algoritmalar sayesinde insan zekâsını taklit ederek belirli birtakım görevleri yerine getirebilmesi yapay zekâ olarak adlandırılmaktadır. 1956 yılında İngiltere’de düzenlenen Dartmouth Konferansı’nda ilk defa adı geçen yapay zekâ kavramı gerçek anlamda 1997 yılında IBM (International Business Machines) tarafından üretilen Deep Blue adlı bilgisayarın

dünyada satranç oyununda en iyi olduğu bilinen Garry Kasparov’a galip gelmesi ile hayatımıza girmiştir (Buchanan 2005).

Kullanılan algoritmaların geliştirilmesi, büyük veri setlerinin sayısının artması, bilim ve teknolojik ilerlemeler sayesinde gittikçe daha popüler hale gelmeye, üzerinde daha fazla çalışmalar yapılmaya başlanmış; bu ilerlemelerle birlikte makine öğrenmesi ve derin öğrenme

kavramları ortaya çıkmıştır. Makinenin verilen geçmiş bilgilerden yola çıkarak henüz hiç görmediği yeni bilgiler üzerinde matematiksel modeller kullanıp karar alabilmesi yeteneğine makine öğrenmesi denmektedir. Derin öğrenme ise tek katmanlı ve çok katmanlı yapay sinir ağlarından sonra geliştirilen, yapay sinir ağları ile oluşturulmuş bir makine öğrenmesi alt türüdür (Habek 2022). Derin kelimesi artan katman sayısını ve dolayısıyla ağ yapısının derinleşmesini ifade eder; klasik yapay sinir ağlarından farklı olarak derin sinir ağları yüzlerce katmandan oluşabilir (Özçelik 2021). Kullanım amacı ise insan müdahalesini minimum seviyede tutarak eğitimi otomatik modeller geliştirebilmektir (Mascarenhas ve Agarwal 2021).

Görüntü sınıflandırma ele alınan görüntünün görsel içeriğine göre önceden tanımlanmış kategorilere sınıflandırılması sürecini ifade eder. Görselleri girdi olarak probleme uygun sınıflandırma işlemini gerçekleştirmek için ileri beslemeli yapay sinir ağı modeli olan konvolüsyonel sinir ağları (Convolutional Neural Networks, CNN) kullanılmaktadır. CNN, klasik yapay sinir ağından farklı olarak ağ ve nöronları dağıtmak yerine görüntünün özelliklerini çıkarmayı hedefler ve bu sebeple filtreler kullanır (Simonyan ve Zisserman 2014). Temel olarak CNN mimarisi girdi, konvolüsyon, havuzlama katmanları ile tam bağlı katman ve çıktı katmanından oluşmaktadır (Doğan ve Türkoğlu 2019). Performansın artırılması amacıyla CNN mimarisi üzerinde değişiklikler ve eklemeler yapılarak CNN tabanlı farklı mimariler geliştirilmiştir. Literatürde yaygın bir şekilde kullanılan CNN tabanlı mimariler LeNet, AlexNet, VGGNet, GoogleNet ve ResNet mimarileridir.

Çalışılan konu ile ilgili literatür çalışmaları meyve ve sebzelerin sınıflandırılması çalışmaları ve farklı disiplinlerdeki derin öğrenme transfer tabanlı mimariler ile yapılan sınıflandırma çalışmaları olmak üzere iki kısımda ele alınmıştır. Çalışmada kullanılan veri setine benzer disiplinlerdeki sınıflandırma çalışmalarına bakıldığında ilk çalışmada Gulzar (2023) farklı meyve çeşitlerinin sınıflandırılması için MobileNetV2 mimarisine dayalı TL-MobileNetV2 adlı yeni bir derin öğrenme yaklaşımı önermiştir. Önerilen yaklaşımda MobileNetV2 mimarisinin yaklaşık bin düğümden oluşan sınıflandırma katmanı çalışmada kullanılan veri setine göre özelleştirilmiş ve temel modele ortalama havuzlama katmanı, düzleştirme katmanı, yoğun katman, dropout ve softmax olmak üzere beş katmandan oluşan yeni bir başlık eklenmiştir. Kaggle platformunda paylaşılan Fruits 360 adlı kırk çeşit meyve içeren 26149 görüntülü bir veri seti kullanılarak AlexNet, VGG16, InceptionV3, ResNet ve

önerilen yöntem ile modeller kurulup duyarlılık, geri çağırma ve F1 ölçütü metrikleri için alınan sonuçlar kıyaslandığında ise TL-MobileNetV2 %99 duyarlılık, %99 geri çağırma ve %99 F1 ölçütü puanları ile en yüksek performansı göstermiştir.

Fruits 360 veri seti kullanılarak gerçekleştirilen başka bir çalışmada Hemalatha vd. (2022) makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak meyveleri çeşitlerine göre sınıflandırmak istemişlerdir. Çalışmada kullanılan veri seti Kaggle platformu üzerinden paylaşılan 131 meyve çeşidi ve toplam 90483 meyve görüntüsünden oluşmaktadır. Makine öğrenmesi yaklaşımlarından KNN, SVM ve DT (Decision Tree) algoritmaları ile derin öğrenme tabanlı MLP (Multilayer Perceptron) ve CNN mimarileri kullanılarak modeller oluşturulmuş olup elde edilen sonuçlar sınıflandırma doğruluğu ve ROC eğrisi metrikleri açısından değerlendirilmiştir. Tüm modeller arasında en iyi sonuç MLP ile kurulan model ile alınmış olup %97.36 sınıflandırma doğruluğu başarıları elde edilmiştir.

Behera vd. (2021) makine öğrenmesi ve transfer öğrenmeye dayalı yaklaşımları kullanarak papaya meyvesini olgunlaşmamış, kısmen olgun ve olgun olmak üzere üç kategoride sınıflandırmayı hedeflemişlerdir. Çalışmada kullanılmak amacıyla her sınıfta 100'er veri olacak şekilde toplam 300 papaya görüntüsü toplanarak bir veri seti oluşturulmuştur. Makine öğrenimi yaklaşımında LBP (Local Binary Pattern), HOG (Histogram of Oriented Gradients), GLCM (Gray-Level Co-Occurrence Matrix) olmak üzere 3 farklı özellik çıkarıcı ve KNN (K-Nearest Neighbours), SVM (Support Vector Machine), Naive Bayes olmak üzere 3 farklı sınıflandırıcı kullanılarak elde edilen performanslar doğruluk, eğri altındaki alan (AUC) ve gerekli eğitim süresi sonuçlarına göre karşılaştırılmıştır. Transfer öğrenme yaklaşımında ise CNN tabanlı ResNet101, ResNet50, ResNet18, VGG19, VGG16, GoogleNet ve AlexNet transfer öğrenme teknikleri kullanılmış olup alınan sonuçlar doğruluk, maksimum doğrulama doğruluğuna ulaşmak için iterasyon sayısı ve gerekli eğitim süresi açısından değerlendirilmiştir. HOG özellik çıkarıcı ve KNN sınıflandırıcı kullanıldığında %100 sınıflandırma doğruluğu ve 0,0995 s eğitim süresi ile makine öğrenmesi yöntemleri arasındaki en başarılı sonuç elde edilmiştir. Transfer tabanlı derin öğrenme yaklaşımları arasında ise VGG19 kullanıldığında %100 doğruluk ve 1dk 52 sn. eğitim süresi ile en iyi performans yakalanmıştır.

Bir sonraki çalışmada ise Rojas-Aranda vd. (2020) perakende mağazalarda kullanılması için bir meyve çeşidi sınıflandırma çalışması yapmayı amaçlamışlardır. Bu amaç doğrultusunda çalışmalarına özgü elma, portakal ve muz

olmak üzere 3 çeşit meyvenin şeffaf poşet içerisinde ve poşetsiz toplam 1067 görüntüsü alınarak bir veri seti oluşturulmuş; meyve sınıflandırması için MobileNetV2 tabanlı geliştirilmiş bir CNN mimarisi önerilmiştir. Doğruluğu arttırmak adına meyvelerin rengi ile ilgili tek bir RGB rengi, RGB histogramı ve K-means kümelemesinden elde edilen RGB merkezini kullanan farklı giriş özellikleri eklenerek yapılan deneylerden elde edilen sonuçlar karşılaştırıldığında beklenildiği gibi poşetsiz görüntülerin daha iyi bir performans gösterdiği gözlemlenmiş olup poşetsiz meyveler için %95 ve poşet içerisindeki meyveler için %93 sınıflandırma doğruluğu elde edilmiştir.

Meyve ve sebzelerin sınıflandırılması ile ilgili incelenen son çalışmada Ponce vd. (2019) zeytin meyvesi türlerini sınıflandırmak için altı farklı CNN tabanlı transfer derin öğrenme mimarisi kullanmışlardır. Sınıflandırma çalışması için Arbequina, Arbosana, Picual, Ocal, Changlot Real, Verdial de Huévar ve Lechín de Sevilla olmak üzere 7 farklı zeytin türü için 400'er zeytin meyvesi toplanıp 50'şer gruplar halinde görüntüleri alınarak her sınıf için 8'er görüntüden oluşan bir veri seti elde edilmiştir. Transfer öğrenme yöntemlerinden olan AlexNet, InceptionV1, InceptionV3, ResNet50, ResNet101 ve Inception-ResNetV2 mimarileri ile kurulan modellerden genel olarak %90 üzeri sınıflandırma doğruluğu başarıyla elde edilmiş olup modeller arasında en yüksek performans değeri Inception-ResNetV2 ile kurulan model kullanıldığında %95.91 olarak yakalanmıştır.

Derin öğrenme transfer tabanlı mimariler ile yapılan sınıflandırma çalışmalarına bakıldığında ise çalışmalardan birinde Al-Saedi ve Savaş (2022) derin transfer öğrenme tekniklerini kullanarak cilt kanseri sınıflandırması yapmayı amaçlamışlardır. Çalışmada Uluslararası Cilt Görüntüleme İşbirliği (ISIC, 2022) tarafından paylaşılan iyi huylu ve kötü huylu olmak üzere 64000 tümör görüntüsünden oluşan veri seti kullanılmıştır. DenseNet, Xception, InceptionResNetV2, EfficientNet, ResNet50 ve MobileNet olmak üzere altı derin öğrenme transfer modeli kullanılmış olup önceden eğitilmiş modeller orijinal modelin çıktı katmanını eklenerek ayrı ayrı uygulanmıştır. Her modelin sonuna iki gizli katman ve bir sınıflandırıcı katmanı olmak üzere toplam üç katman eklenmiştir. Gizli katmanlarda kullanılan aktivasyon fonksiyonu ReLu'dur; gizli katmanların nöron sayıları birbirine eşit ve 128'dir. Sınıflandırıcı katmanı ise veri setindeki sınıf sayısı kadar yani 2 nörondan oluşturulmuştur. Doğruluk, duyarlılık, f1 ölçütü, geri çağırma ve özgünlük metrikleri için sonuç alınarak mimarilerin performansları karşılaştırıldığında en iyi performans DenseNet kullanılarak oluşturulan model ile

alınmıştır. Bir diğer çalışmada Chen vd. (2022) akciğere enfekte covid-19 görüntülerini tespit etmek amacıyla ResNet tabanlı üç sınıflandırmalı inception-ResNet modelini önermişlerdir. Model için kullanılan veri seti Wuhan'da bulunan Jinyintan isimli hastanede çekilen sağlıklı bireylerin ve pnömoni hastalarının akciğer görüntülerinden oluşmaktadır. Çalışma kapsamında oluşturulan veri seti sağlıklı, erken hasta ve ağır hasta olmak üzere üç sınıftan oluşmakta ve toplam 2960 görüntü içermektedir. Oluşturulan model ImageNet veri seti kullanılarak eğitilmiş olup inception-ResNet'in sınıflandırma performansını arttırmak için çıktı öznitelik haritasının her bir kanalı sıkıştırılmış, genel ortalama havuzlama işlemi gerçekleştirilmiş ve öznitelik vektörü elde edilerek bir öz dikkat mekanizması sunulmuştur. CNN, ResNet ve inception-ResNet için doğruluk, duyarlılık ve özgünlük metrikleri ile sonuçlar alındığında en yüksek performans değerleri inception-ResNet kullanıldığında alınmıştır.

Mascarenhas ve Agarwal (2021) görüntü sınıflandırma çalışması yaparak VGG16, VGG19 ve ResNet50 mimarilerinin performanslarını karşılaştırmak istemişlerdir. Kullanılan veri seti bölgesel bir satıcıdan toplanılan ayakkabı, bakım, mücevher, saat ve çanta olmak üzere beş sınıftan oluşan toplam 6000 ürünün görüntüsünü ve fiyatını içermektedir. Çalışmadaki amaç ürünleri doğru sınıflara ayırarak fiyat karşılaştırması yapabilmektir. Ele alınan veri seti iki adımda sınıflandırılmıştır. İlk adımda VGG16, VGG19 ve ResNet50 kullanılarak görüntünün özellik çıkarımı yapılmış, sonraki adımda ise keşifsel veri analizi yardımı ile görüntüler sınıflandırılmıştır. Veri seti 1, 3, 5, 10, 15, 20 ve 100 devir çalıştırılarak kullanılan mimarilerin performansları karşılaştırıldığında en iyi performans ResNet50 ile yakalanmış olup ardından VGG19, sonrasında da VGG16 gelmektedir. Ayrıca devir değeri 15 ile 20 arasındayken kullanılan üç CNN mimarisi de en iyi ve mutlak performansı göstermiş; devir sayısı 15'ten küçük olduğunda yetersiz uydurma gösterdiği ve 20'yi geçince fazla uydurma gösterdiği gözlemlenmiştir.

Ammatmanee ve Gan (2021) turizm sektörüne katkı sağlamak amacı ile derin öğrenme yönteminin transfer öğrenme tekniğini kullanarak pansiyon alanlarının sınıflandırmasını yapmaya çalışmıştır. 7350 pansiyon resminden oluşan 7 sınıflı yeni bir veri seti oluşturularak literatürdeki çalışmalardan farklı, özgün bir çalışma yapılması hedeflenmiştir. SqueezeNet modelleri (SqueezeNet1_0 ve SqueezeNet1_1), ResNet modelleri (ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152) ve DenseNet modelleri (DenseNet121, DenseNet161, DenseNet169 ve DenseNet201) olmak

üzere toplam 11 CNN tabanlı transfer öğrenme tekniği kullanarak elde edilen doğruluk ve eğitim süreleri karşılaştırıldığında DenseNet121 ve DenseNet201 modellerinin diğer CNN modellerine göre daha iyi performans gösterdiği görülmüştür.

Talo (2019) yapmış olduğu çalışmada transfer öğrenme tekniğini kullanarak görüntü sınıflandırması için CNN tabanlı modeller önermiştir. Çalışmada erişimi halka açık Kimia Path24 isimli 23916 histopatolojik görüntüden oluşan 24 sınıflı veri seti kullanılmıştır. Kimia Path24 veri seti ile yapılmış olan gri tonlamalı görüntü çalışmalarından farklı olarak hem renkli hem de gri tonlamalı görüntüler kullanılmış, böylece renk ve doku özelliklerinden faydalanılarak görüntülerin sınıflandırılması yapılmıştır. Görüntüleri sınıflandırmak için ResNet-50 ve DenseNet-161 CNN tabanlı mimariler kullanılarak alınan sonuçlara bakıldığında gri tonlamalı görüntüler kullanıldığında DenseNet-161 ile %97.89, renkli görüntüler kullanıldığında ResNet-50 ile %98.87 performans değerleri elde edilmiştir.

Bu çalışmada VGG16 ve ResNet50 olmak üzere iki çeşit derin transfer öğrenme yöntemi kullanılarak bir sınıflandırma çalışması yapılmıştır. Çalışmanın amacı kullanılan transfer öğrenme yöntemlerine eklenen farklı aktivasyon fonksiyonlarına sahip çeşitli sayılarda gizli katmanların sınıflandırma performansını nasıl etkilediğini ölçmektir. Sınıflandırma için kullanılan veri seti beş farklı meyve çeşidi için taze ve çürük olmak üzere toplam 10 sınıftan oluşmaktadır. Eklenen gizli katmanlarda literatürdeki çalışmalarda sıklıkla tercih edilen sigmoid, tanh ve ReLu (Rectified Linear Unit-ReLu) aktivasyon fonksiyonları kullanılarak performans karşılaştırması yapmak hedeflenmiştir. Bu doğrultuda her mimariden on iki farklı model oluşturulup devir sayısı 10 olarak girilmiş; sınıflandırma doğruluğu (accuracy), duyarlılık (precision), geri çağırma (recall) ve f1-ölçütü olmak üzere dört farklı metrik için sonuçlar alınmıştır. Alınan sonuçlar kıyaslandığında modeller arasında ResNet50 mimarisine sigmoid aktivasyon fonksiyonlu, 256 ve 128 nöronlu iki gizli katman ve 10 nöronlu bir softmax sınıflandırıcı katmanı olmak üzere toplam üç katman eklenerek oluşturulan modelin %97.5 sınıflandırma doğruluğu değeri ile en iyi sonucu verdiği gözlemlenmiştir. Bu sonuç ikili sınıflandırmalarda yüksek performans gösteren sigmoid aktivasyon fonksiyonunun softmax sınıflandırıcı ile kullanıldığında ikiden fazla sınıftan oluşan veri setlerinde de yüksek performans elde edilebileceğini göstermiştir. Son olarak dört metrik için alınan sonuçlar Friedman ve Nemenyi post-hoc testlerine tabi tutularak istatistiksel bir analiz yapılmış, modeller arasındaki ilişki test edilmiştir. Test sonucunda oluşturulan modellerin birbirleri ile ilişkili olduğu sonucu elde edilmiştir.

2. Materyal ve Metot

Bu çalışmada literatürdeki sınıflandırma çalışmalarında sıklıkla kullanılan ve yüksek başarı gösteren VGG16 ve ResNet50 transfer derin öğrenme mimarileri kullanılarak bir sınıflandırma çalışması yapılmıştır. Çalışmada aktivasyon fonksiyonlarının ve gizli katman sayısının sınıflandırma performansı üzerindeki etkilerini ölçebilmek adına transfer derin öğrenme mimarilerine sigmoid, tanh ve ReLu aktivasyon fonksiyonlu çeşitli sayılarda gizli katmanlar eklenerek oluşturulan modeller, ele alınan veri seti üzerinden değerlendirilmiş; modellerin performansları karşılaştırılmıştır.

2.1 Veri seti

Çalışmada makine öğrenimi ve veri bilimi ile ilgili çalışmalar yapan araştırmacılar için çevrimiçi bir platform olan Kaggle üzerinden paylaşılan popüler "fruits and vegetables" veri seti kullanılmıştır. Veri setinde beşer çeşit meyve ve sebze ile ilgili taze ve çürük görüntüler yer almaktadır. Veri setinde bulunan meyve görüntüleri ile çalışılmak istendiğinden Çizelge 1'de görüldüğü gibi taze muz, taze elma, taze portakal, taze mango, taze çilek ile çürük muz, çürük elma, çürük portakal, çürük mango, çürük çilek olmak üzere toplam 10 sınıf ve 5997 görüntüden oluşan meyve veri seti ile çalışmaya devam edilmiştir. Her sınıfta bulunan görüntülerin sayısı eşite yakın bir sayıda olduğu için veri setinin dengeli dağıldığı söylenebilir. Son olarak veri seti oluşturulurken Google ve Bing görselleri ile Fruit360, Kaggle ve Sriram RK gibi farklı platformlardan yararlanılmıştır (Mukhiddinov vd. 2022).

Çizelge 1. Sınıflardaki veri dağılımları.

Sınıf	Veri sayısı
Elma	Taze: 612
	Çürük: 588
Muz	Taze: 624
	Çürük: 576
Mango	Taze: 605
	Çürük: 593
Portakal	Taze: 609
	Çürük: 591
Çilek	Taze: 603
	Çürük: 596
Toplam	Taze: 3053
	Çürük: 2944

2.2 Transfer öğrenme


Belirli bir konuda ele alınan problemi çözerken öğrenilen bilgiden ortak yanları bulunan başka bir problemi çözerken yararlanması durumuna transfer öğrenme denilmektedir. Makine öğrenmesi problemlerinde önceden eğitilmiş bir ağ, ikinci bir görevin modeli eğitilirken başlangıç noktası olarak tekrar kullanıldığında

modelin hızlı bir şekilde eğitilmesini ve performansının önemli ölçüde artmasını sağlar. Transfer edilecek modelin genel bir problemin çözümü için olması ve ikinci problemin birinci problem ile benzer yanlarının olması transfer öğrenimini gerçekleştirmenin ilk koşuludur. Görüntülerin girdi olarak alındığı görüntü işleme ve analiz problemlerinde transfer öğrenimi gerçekleştirmek oldukça yaygın bir çalışma biçimidir. Önceden eğitilmiş modelden elde edilen özellik, parametre veya ağırlık gibi önemli bilgiler yeni görev için kullanıldığında büyük veri seti eğitilirken gereken zamandan tasarruf edilmekte, küçük veri seti ile de oldukça iyi sonuçlar alınabilmektedir.

2.3 CNN mimarileri

CNN temel olarak konvolüsyon, havuzlama ve tam bağlı katmanlardan oluşan bir mimaridir (Bozkurt 2022). Mimaride bulunan sıralı katmanlar aracılığıyla çeşitli özellikler çıkartılır, son katman olan sınıflandırıcı katmanı ile de sınıflandırma işlemi gerçekleştirilir. Çıkartılan özellikler kullanılarak belirlenen sınıflar ve gerçek sınıfl arasındaki fark yani hata bulunur (Bozkurt 2021/2). Geri yayılım algoritması kullanılarak her defasında ağırlık değerleri güncellenir ve böylece en az hata ile özellik çıkarma süreci iyileştirilmiş olur. Genellikle görüntülerin sınıflandırılmasında kullanılan CNN mimarisi üzerinde performansın artırılması amacıyla değişiklikler ve

eklemeler yapılarak CNN tabanlı farklı mimariler geliştirilmiştir. Bu çalışmada CNN tabanlı derin öğrenme mimarilerinden VGG16 ve ResNet50 mimarileri kullanılarak görüntülerin sınıflandırılması çalışması yapılmıştır. VGG16, Oxford üniversitesindeki Simonyan ve Zisserman (2014) tarafından yayınlanan 'Very Deep Convolutional Networks for Large-Scale Image Recognition' adlı makale ile tanıtılmış olan bir CNN modelidir. Model, belirli bir görev veya konuda öğrenme sürecine tabi tutulmadan önce geniş bir veri kümesi üzerinde genel bir eğitim sürecinden geçmiş ve belirli görevler için ince ayar yapılabilen bir modeldir (Bozkurt 2021/1). 14 milyondan fazla görüntüden oluşan 1000 sınıflı ImageNet veri seti ile %92.7 sınıflandırma doğruluğuna ulaşmıştır. Şekil 1'de verilen mimaride görüldüğü gibi 224x224x3 boyutlarındaki RGB görüntü verileri girdi olarak alınıp sırasıyla 2 evrişim katmanı, 1 maksimum havuzlama katmanı, tekrar 2 evrişim katmanı ve 1 maksimum havuzlama katmanına gelir. Devamında 3 evrişim katmanı, 1 maksimum havuzlama katmanı, 3 evrişim katmanı ve 1 maksimum havuzlama katmanı, tekrar 3 evrişim katmanı ve 1 maksimum havuzlama katmanı eklenmiştir. Mimari tam bağlantılı katman ve ReLU katmanı ile devam eder. Son katmanda ise ImageNet veri setinin sınıf sayısı kadar yani 1000 çıktılı softmax sınıflandırıcı kullanılmıştır.



Şekil 1. VGG16 mimarisi (Mascarenhas ve Agarwal 2021)


Artık değerli nöral ağlar (residual neural network) kısaltılmış ismi ile ResNet, He vd. (2015) tarafından yayınlanan 'Deep Residual Learning for Image Recognition' adlı makale ile tanıtılmıştır. Makalede ağ derinliği arttıkça doğru orantılı olarak doğruluk değerinin de doygunluğa ulaştığı fakat daha sonra hızlı bir şekilde düşme eğilimine girdiği belirtilmiş olup katmanlar arasına kısayollar ekleyerek performans düşmesine çözüm

getirmeyi hedeflemişlerdir. Artık değerli nöral ağlar VGG ağlarından daha derin olmasına rağmen daha düşük karmaşıklığa sahiptir ve ImageNet veri seti üzerinde %96.43 başarı oranını yakalamıştır. Orijinal ResNet ağı ResNet-34'tür. Çalışmada ise ResNet50 ağı tercih edilmiştir. Resnet50 mimarisi Şekil 2'de görüldüğü gibi 48 evrişim katmanı, bir maksimum havuzlama katmanı ve bir ortalama havuzlama katmanından oluşur. VGG16'dan

farklı olarak ek bir kimlik eşleme'ye sahip olan ResNet50, bu özelliği sayesinde ağın eğitim sürecini iyileştirir, öğrenmeyi kolaylaştırır ve ağın daha derin olmasına izin verir (Bozkurt 2021/1).

İlk katman 7x7 çekirdek boyutundaki 64 farklı çekirdeğe sahip bir evrişim katmanıdır ve maksimum havuzlama katmanı ile devam eder. Bir sonraki evrişim katmanı 1x1 boyutunda 64 çekirdekli, 3x3 boyutunda 64 çekirdekli ve 1x1 boyutunda 256 çekirdekli katman olmak üzere 3 katmandan oluşur ve bu üç katman üç kez tekrarlanarak

toplam 9 katman oluşturur. Ardından 1x1 boyutlu 128 çekirdekli, 3x3 boyutlu 128 çekirdekli ve 1x1 boyutlu 512 çekirdekli katmanlar 4 kez tekrarlanarak 12 katman oluşturur. Sonrasında 1x1 boyutunda 256'lık çekirdek, 3x3 boyutunda 256 çekirdek ve 1x1 boyutunda 1024 çekirdek 6 kez tekrarlanarak 18 katman oluşturur. 1x1 boyutlu 512'lik çekirdek, 3x3 boyutlu 512'lik çekirdek, 1x1 boyutlu 2048'lik çekirdek 3 kez tekrarlanarak 9 katman daha oluşturur. Son olarak bir ortalama havuzlama yapılır, 1000 nöronlu tam bağlı katman ve softmax sınıflandırıcı ile 50. katman oluşturulmuş olur.



Şekil 2. ResNet50 mimarisini (Rojas-Aranda vd. 2020)

2.4 Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, sinir ağlarında, girişlerin ve bias'ların ağırlıklı toplamını hesaplamak için kullanılan matematiksel işlemlerdir (Nwankpa ve ark. 2018). Bu fonksiyonlar, bir nöronun çıkışını belirlemekte ve iletmekte önemli bir rol oynarlar. Nöronun çıkışı genellikle belirli bir eşik aşarsa (ateşleme eşik), nöron aktive olur ve bilgi iletim sürecine dahil olur. Yani aktivasyon fonksiyonları, sinir ağlarının öğrenme ve karar verme yeteneklerini kontrol etmek için kullanılır. Bu çalışmada transfer derin öğrenme modellerine farklı sayıda gizli katmanlar eklenerek oluşturulan modellerde sigmoid, tanh ve ReLu aktivasyon fonksiyonları kullanılarak aktivasyon fonksiyonlarının performansları karşılaştırılmak istenmiştir.

Adını sahip olduğu "S" harfine benzeyen eğriden (sigma) alan sigmoid özellikle ikili sınıflandırma problemlerinde yaygın bir şekilde kullanılmaktadır. Fonksiyonun dezavantajı, gradyanın çok küçük olduğu durumlarda ortaya çıkan doyumluk sorunundan etkilenmesidir. Ağırlıklar gradyan büyüklüğü ile orantılı bir şekilde güncellendiğinden öğrenme süreci yavaşlar ve ağın eğitimi zorlaşır (Alkhouly ve ark. 2021).

Çalışmada kullanılan bir diğer aktivasyon fonksiyonu olan tanh, sigmoid fonksiyonundan daha güçlü gradyanlara sahiptir ve türevleri 1.0'a kadar çıkabilir (Nwankpa ve ark.

2018). Bu sayede ağırlıklar ve bias güncellemeleri daha büyük adımlarla gerçekleşir. Ancak bu fonksiyon kaybolan gradyanlar sorununa yol açabilir ve eğitim sürecini yavaşlatabilir.

ReLU (Rectified Linear Units, Doğrultulan Doğrusal Üniteler), 2011 yılında "Deep Sparse Rectifier Neural Networks" adlı makale ile tanıtılmış bir aktivasyon fonksiyonudur (Glorot ve ark. 2011). Basitlik, hesaplama açısından uygunluk ve sınırlı gruplara ait diğer aktivasyon fonksiyonlarına kıyasla hızlı yakınsama yeteneği sayesinde bu fonksiyon derin sinir ağlarında yaygın bir şekilde kullanılmaktadır (Dubey ve ark. 2022). Özellikle çok katmanlı ağ yapıları gerektiren görüntü sınıflandırma problemlerinde gradyan kaybolması ve gradyan patlaması sorunlarının önüne geçtiği için ReLu tercih edilmektedir (Hao ve ark. 2020). ReLu fonksiyonunda tüm negatif girişler 0'a eşitlendiğinden daha az nöron ateşlenir. ReLu, çalışmada kullanılan diğer aktivasyon fonksiyonları ile karşılaştırıldığında; Sigmoid fonksiyonundaki doyumluk ve tanh fonksiyonundaki kaybolan gradyan sorununu çözerek genel olarak daha iyi bir performans gösterir (Alkhouly vd. 2021).

2.5 Deneysel yöntem

Çalışmada kullanılan meyve veri seti %80 eğitim ve %20 test verisi olacak şekilde ayrılmış; eğitim verisinin %25'lik

kısmı ise doğrulama verisi olarak kullanılmıştır. Ön işleme aşamasında veri seti VGG16 ve ResNet50 transfer öğrenme modellerine aktarılmadan önce Keras kütüphanesi kullanılarak RGB renk formatından BGR renk formatına dönüştürülmüş ve ölçeklendirme olmadan her renk kanalı sıfıra ortalanmıştır. 3 kanaldan oluşan görüntü girdilerin boyutu VGG16 için 224x224 ve ResNet50 için 256x256 olarak ayarlanmıştır.

Derin transfer öğrenimi gerçekleştirmek için ImageNet veri seti kullanılarak önceden eğitilmiş VGG16 ve ResNet50 mimarilerinden katmanlar alınmış olup başlangıç katmanlarından itibaren belirlenen sayıda katmanlar dondurularak çalışmada kullanılan veri seti ile yeniden eğitim aşamasında bu katmanlardaki bilgi kaybının önüne geçilmiştir. VGG16 için ilk 10 katman ve ResNet50 için ilk 160 katman layer.trainable için false boolean değeri girilerek dondurulmuştur. VGG16 ve ResNet50 mimarileri 'imageNet' ağırlıkları ile yüklenmiş olup çıktı katmanları ImageNet veri setine göre ayarlandığı için include_top parametresi false yapılarak son katman dahil edilmemiştir. Katmanların üzerine farklı aktivasyon ve nöronlara sahip çeşitli sayıda yeni eğitilebilir katmanlar eklenerek Çizelge 2'de gösterildiği gibi her mimari için on iki farklı model oluşturulmuştur. Eklenen katmanlar arasında batch normları uygulanarak ağırlıkların daha hızlı eğitilmesi ve daha iyi genelleme yapabilmesi sağlanmaya çalışılmıştır.

Eklenen gizli katmanlardan sonra aşırı öğrenmenin azaltılması amacıyla dropout katmanları eklenmiştir. Dropout katmanları 0.5 oranında ayarlanarak her gizli katmanın çıkışı belirlenen oranda rastgele olarak sıfırlanmış yani nöronlar unutulmuştur. Çıktı katmanında 10 çıktılı softmax sınıflandırıcı çoklu sınıflandırma için kullanılmıştır. Model derleme aşamasında çok sınıflı veri seti ile çalışıldığından, etiketler ve tahminler arasındaki

çapraz entropi kaybını hesaplayan "categorical_crossentropy" kayıp fonksiyonu kullanılmıştır (Keras, 2023). Eğitim aşamasında girdilerin gruplandırılarak eğitime sokulması için batch size parametresi kullanılmış olup değeri 16 olarak ayarlanmıştır. Kurulan modeller 10 devir boyunca eğitilmiştir. Eğitim verileri üzerinde aşırı öğrenmenin engellenmesi için modellerin eğitimi aşamasında doğrulama verileri kullanılmıştır. Oluşturulan modeller ile sınıflandırma doğruluğu, duyarlılık, geri çağırma ve f1 ölçütü metrikleri için sonuçlar alınmış, alınan sonuçlar Friedman testi (Friedman 1940) ve Nemenyi post-hoc testi (Nemenyi 1963) kullanılarak istatistiksel olarak karşılaştırılmıştır.

Friedman testi, ilk olarak çalışmada kullanılan iki transfer derin öğrenme mimarisi için modellerin performans dayalı bir sıralamasını üretmektedir. Ardından modellerin ortalama sıralarını karşılaştırır ve mimarilerin sayısı k'ya göre k-1 serbestlik dereceli X_{F^2} Friedman istatistiğini hesaplar. Nemenyi ise oluşturulan modellerin birbirinden farklı olup olmadığını ölçen post-hoc istatistiksel bir testtir (Memiş vd. 2022). İki mimariden elde edilen ortalama değer arasındaki farkın kritik mesafeden fazla olması durumunda sonuçların birbirinden farklı ve az olması durumunda ise sonuçların birbirleri ile ilişkili olduğu sonucuna varılır. İstatistiksel sonuçlara bakıldığında genel olarak kurulan modeller arasında ilişki olduğu sonucuna varılmıştır.

3. Bulgular

Transfer derin öğrenme mimarilerine farklı gizli katmanlar eklenerek oluşturulan modellerin 10 sınıftan oluşan meyveler veri seti ile 10 devir eğitilmesi sonucunda elde edilen doğru sınıflandırma, duyarlılık, geri çağırma ve f1 ölçütü değerleri sırasıyla Çizelge 2 ve Çizelge 3'te verilmiştir.

Çizelge 2. Gizli katman sayısı 1 ve 2 için sınıflandırma doğruluğu, duyarlılık, geri çağırma ve f1 ölçütü metrikleri ile elde edilen sonuç değerleri.

	VGG16					ResNet50				
	Aktivasyon	Doğruluk	Duyarlılık	Geri çağırma	F1 ölçütü	Doğruluk	Duyarlılık	Geri çağırma	F1 ölçütü	
Gizli Katman Sayısı = 1, Nöron Sayısı = VGG16 için 112	sigmoid	0,9583	0,9607	0,9583	0,9587	0,975	0,9755	0,975	0,9751	
ResNet50 için 128	tanh	0,88	0,8964	0,88	0,8783	0,9725	0,9733	0,9725	0,9725	
	ReLu	0,93	0,9331	0,93	0,9299	0,9733	0,9739	0,9733	0,9734	
Gizli Katman Sayısı = 2, Nöron Sayısı = VGG16 için 224, 112	sigmoid	0,9658	0,9689	0,9658	0,9661	0,975	0,9756	0,975	0,975	
ResNet50 için 256, 128	tanh	0,8942	0,8982	0,8942	0,8944	0,9708	0,9714	0,9708	0,9708	
	ReLu	0,6133	0,7118	0,6133	0,5824	0,965	0,9657	0,965	0,965	

Çizelge 3. Gizli katman sayısı 3 ve 4 için sınıflandırma doğruluğu, duyarlılık, geri çağırma ve f1 ölçütü metrikleri ile elde edilen sonuç değerleri.


	VGG16				ResNet50				
	Aktivasyon	Doğruluk	Duyarlılık	Geri çağırma	F1 ölçütü	Doğruluk	Duyarlılık	Geri çağırma	F1 ölçütü
Gizli Katman Sayısı = 3, Nöron Sayısı =	sigmoid	0,9158	0,9268	0,9158	0,9168	0,9583	0,9622	0,9583	0,9584
VGG16 için 224, 112, 56	tanh	0,5908	0,611	0,591	0,5861	0,9625	0,9644	0,9625	0,9626
ResNet50 için 256, 128, 64	ReLu	0,3183	0,3119	0,3184	0,2787	0,9175	0,9235	0,9175	0,9184
Gizli Katman Sayısı = 4, Nöron Sayısı =	sigmoid	0,6442	0,71	0,6442	0,6179	0,91	0,9231	0,91	0,9113
VGG16 için 224, 112, 56, 28	tanh	0,47	0,5152	0,47	0,45	0,9358	0,9394	0,9358	0,9363
ResNet50 için 256, 128, 64, 32	ReLu	0,085	0,15	0,085	0,05	0,7167	0,812	0,7167	0,7292


Eğitilen modellerin test veri seti kullanılarak test edilmesi ile aşağıdaki sonuçlar elde edilmiştir:

- Dört metrik için alınan sonuçlar ele alınarak mimariler karşılaştırıldığında beklenildiği gibi ResNet50 mimarisinin VGG16'ya kıyasla tüm modellerde daha iyi bir performans gösterdiği gözlemlenmiştir.
- Sigmoid, tanh ve ReLu aktivasyon fonksiyonları arasında dört metrik ile en yüksek değerler iki mimari için de sigmoid kullanıldığında alınmış olup sınıflandırma doğruluğu ResNet50 mimarisine 1 ve 2 gizli katman eklendiğinde %97.5 ile en yüksek sonucu vermiştir. VGG16 mimarisi kullanıldığında ise 2 gizli katmanlı model ile %96.58 en yüksek sonuç alınmıştır.
- Sigmoid kullanıldığında duyarlılık için en iyi performansı ResNet50 mimarisine 2 gizli katman eklenerek oluşturulan model %97.56 ile göstermiştir. VGG16 için ise aynı şekilde 2 gizli katmanlı model %96.58 değeri ile en iyi duyarlılık performansını göstermiştir.

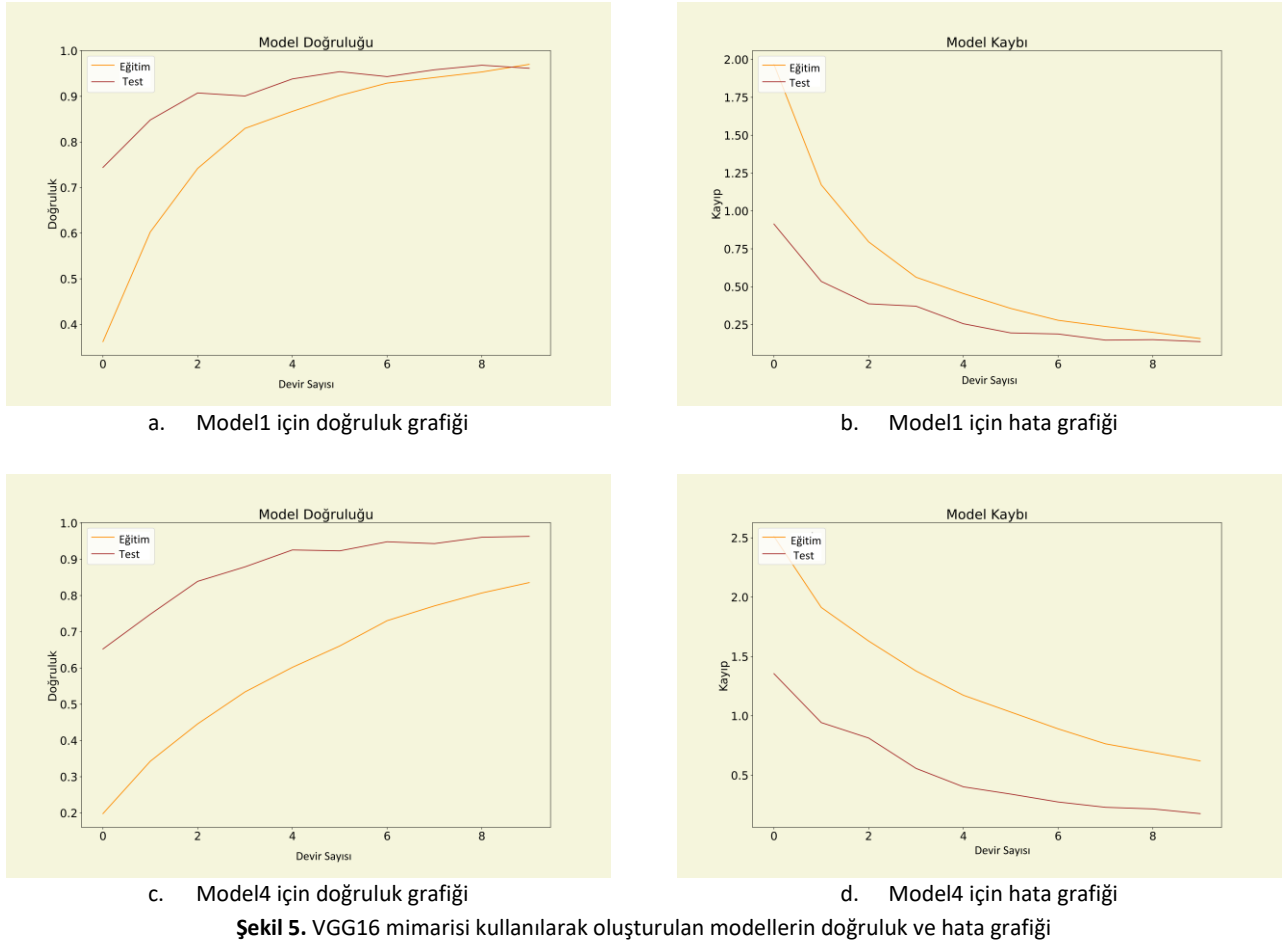
- Geri çağırma metriğine göre en yüksek değer ResNet mimarisine sigmoid aktivasyon fonksiyonlu 1 ve 2 gizli katmanlar eklendiğinde %97.5 ile alınırken VGG16 mimarisinde en iyi sonuca sigmoid aktivasyon fonksiyonlu 2 gizli katman eklendiğinde %96.58 ile ulaşılmıştır.
- Son olarak f1 ölçütü metriği sonuçlarına bakıldığında ResNet50 mimarisine sigmoid aktivasyon fonksiyonlu 1 gizli katman eklendiğinde %97.51 ile ve VGG16 mimarisine sigmoid aktivasyon fonksiyonlu 2 gizli katman eklendiğinde %96.61 ile ulaşılmıştır.

Sonuç olarak kullanılan transfer öğrenme modellerinin sonuna sigmoid aktivasyon fonksiyonlu bir gizli katman ve bir sınıflandırıcı (model1) ile iki gizli katman ve bir sınıflandırıcı katmanı eklenerek (model4) oluşturulan modellerin dört metrik sonuçlarına göre diğer modellere göre daha iyi sonuç verdiği gözlemlenmiş, oluşturulan bu modellerin karmaşıklık matrisleri Şekil 3 ve Şekil 4'te doğruluk-hata grafikleri Şekil 5 ve Şekil 6'da verilmiştir.


**Şekil 3.** VGG16 mimarisi kullanılarak oluşturulan modellerin karmaşıklık matrisi



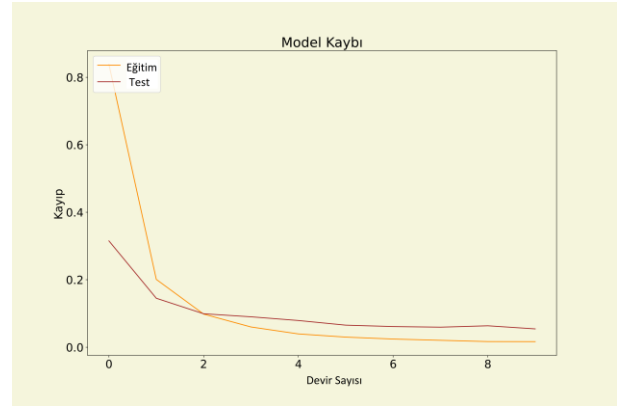
Şekil 4. ResNet50 mimarisi kullanılarak oluşturulan modellerin karmaşıklık matrisi



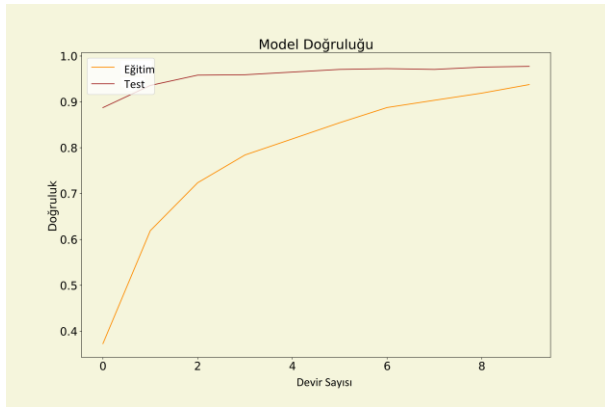
Şekil 5. VGG16 mimarisi kullanılarak oluşturulan modellerin doğruluk ve hata grafiği




a. Model1 için doğruluk grafiği



b. Model1 için hata grafiği



c. Model4 için doğruluk grafiği



d. Model4 için hata grafiği

Şekil 6. ResNet50 mimarisi kullanılarak oluşturulan modellerin doğruluk ve hata grafiği

Sonuçların istatistiksel analizi için uygulanan Friedman ve Nemenyi testlerinde ise öncelikle oluşturulan modellerin ortalama sırası hesaplanmıştır. Friedman testi kullanılarak hesaplanan sınıflandırma doğruluğu, duyarlılık, geri çağırma ve f1 ölçütü için ki kare değerleri sırasıyla 20.21, 20.61, 20.08 ve 20.21 çıkmıştır. Toplam 2 mimari için α değeri 0,05 olarak alınarak 5,99 anlamlılık düzeyi elde edilmiştir. Sıfır hipotez testinin çürütülmesi için Friedman testi ile elde edilen ki kare değerlerinin hesaplanan anlamlılık düzeyinden yüksek olması gerekmektedir. Değerler karşılaştırıldığında sınıflandırma doğruluğu için $20,21 > 5,99$, duyarlılık için $20,61 > 5,99$, geri çağırma için $20,08 > 5,99$ ve f1 ölçütü için $20,21 > 5,99$ eşitsizliği sağlandığından sıfır hipotez testi çürütülerek post-hoc testini uygulamaya geçilmiştir.

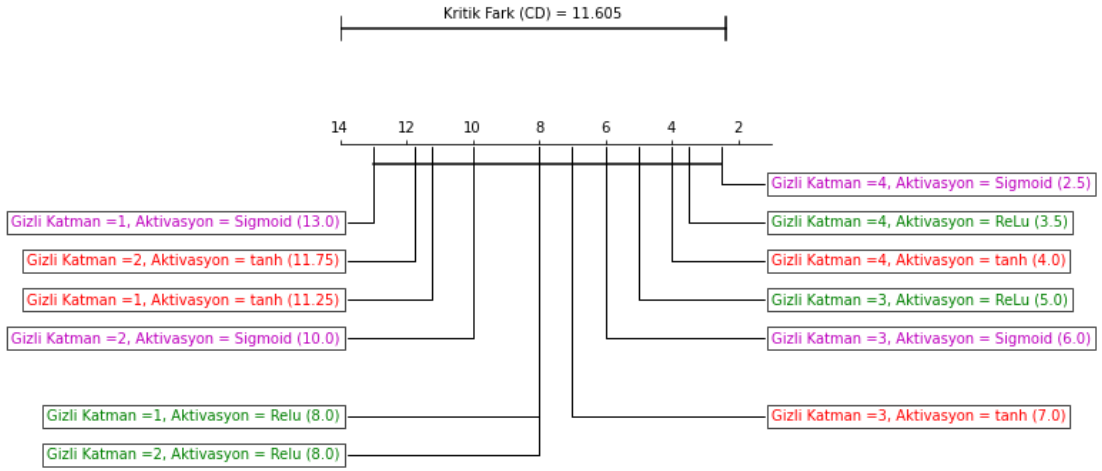
Dört değerlendirme metriği için Nemenyi post-hoc testi ile oluşturulan kritik diyagramlar Şekil 7'de verilmiştir. Denklem 1 Nemenyi testinin kritik fark (Critical Difference, CD) değerini belirlemek için kullanılan formüldür. Formülde q, belirli bir güven seviyesini ifade eden özel bir kritik değerdir. k değeri sistemi değerlendiren model sayısını tutar ve bu çalışma kapsamında $k=12$ 'dir. n ise her gruptaki örnek sayısını

tutan değişkendir. Denklem 1 kullanılarak elde edilen CD değeri 11,605 olarak bulunmuştur. Nemenyi testi ile elde edilen ortalama değer sonuçlarına göre ReLu aktivasyon fonksiyonlu 1 ve 2 katman eklenerek oluşturulan modeller diğer modellerin ortalamalarına göre ortaya en yakın değerlerde olduğu için daha iyi bir sonuç vermiş ve genel olarak kurulan modeller arasında ilişki olduğu gözlemlenmiştir.

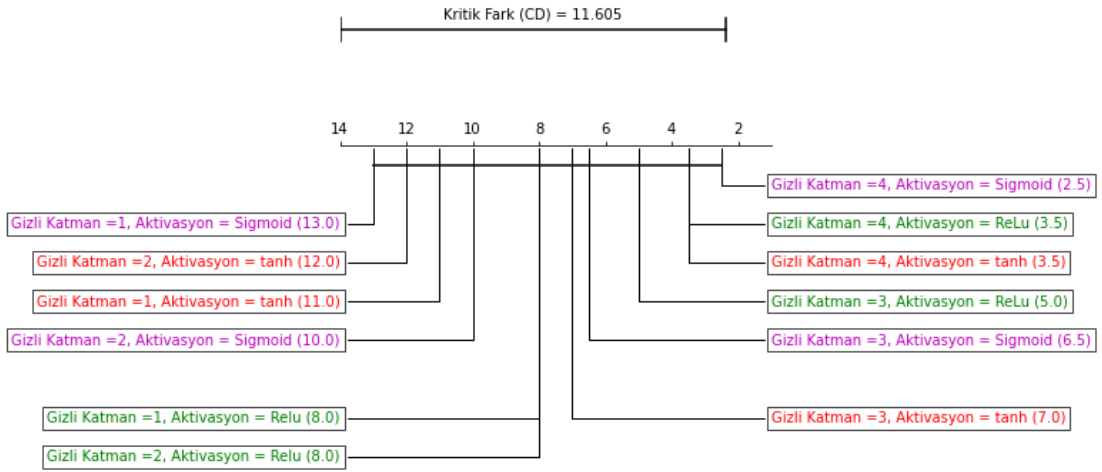
$$CD = q * \sqrt{k * (k + 1) / (6.0 * N)} \quad (1)$$

4. Sonuçlar ve Tartışma


VGG16 ve ResNet50 mimarilerine farklı sayıda gizli katman eklenerek derin transfer öğrenme tekniği ile görüntülerin sınıflandırılması amaçlanan çalışmada sınıflandırma için kullanılan veri seti beş farklı meyve çeşidi için taze ve çürük olmak üzere toplam 10 sınıftan oluşmaktadır. Sınıflandırma için kurulan modeller farklı sayıda gizli katman sayılarına sahiptir ve bu katmanlarda literatürdeki çalışmalarda sıklıkla tercih edilen sigmoid, tanh ve ReLu aktivasyon fonksiyonları kullanılmıştır.



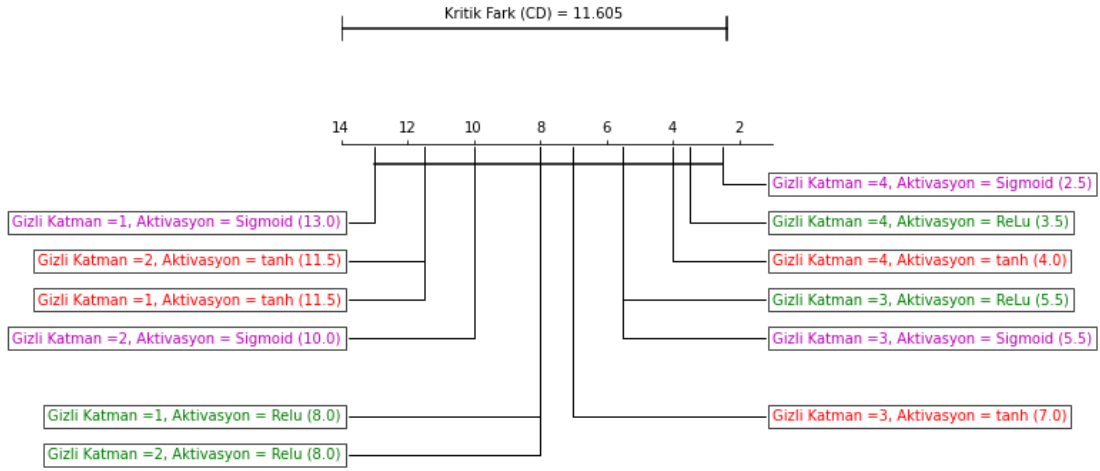
a. Sınıflandırma doğruluğu



b. Duyarlılık



c. Geri çağırma



d. F1-ölçütü

Şekil 7. Nemenyi kritik diyagramı

Çalışmadaki amaç iki farklı transfer öğrenme tekniği kullanılarak yapılan sınıflandırma çalışmalarında eklenen gizli katman sayısı ve kullanılan aktivasyon fonksiyonlarının sınıflandırma performansını hangi yönde ve ölçüde etkilediğini tespit edecek bir performans karşılaştırması yapmaktır. Bu doğrultuda her mimariden on iki farklı model oluşturulup devir sayısı 10 olarak girilmiş; sınıflandırma doğruluğu (accuracy), duyarlılık (precision), geri çağırma (recall) ve f1-ölçütü olmak üzere dört farklı metrik için sonuçlar alınmıştır.

Transfer derin öğrenme tekniği kullanılarak oluşturulan modeller önceden eğitilmiş bir modelin bilgi transferi sayesinde genel olarak veri setindeki verileri sınıflandırmada başarılı olmuştur. Elde edilen performanslar kullanılan iki transfer öğrenme tekniği açısından karşılaştırıldığında ise sahip olduğu derin ağ yapısı, blok düzenlemesi ve bağlantı katmanları sayesinde ResNet50 ile kurulan modeller VGG16 ile kurulan modellere göre daha yüksek performans göstermiştir. Modeller arasında ResNet50 mimarisine sigmoid aktivasyon fonksiyonlu, 256 ve 128 nöronlu iki gizli katman ve 10 nöronlu bir softmax sınıflandırıcı katmanı olmak üzere toplam üç katman eklenerek oluşturulan model %97.5 ile en yüksek sınıflandırma doğruluğu performansını vermiştir. 256 ve 128 nöron içeren gizli katmanlar, modelin daha geniş ve bilgi dolu temsiller öğrenmesine; daha karmaşık örüntüleri ve özellikleri tanımlama yeteneğini arttırmasına yardımcı olur. Ayrıca sigmoid aktivasyon fonksiyonu özellikle ikili sınıflandırma problemlerinde yüksek performans gösterirken softmax sınıflandırıcı ile birleştirildiğinde çoklu sınıflı problemlerde de etkili olabildiğini göstermiştir.

Literatürdeki çalışmalara bakıldığında çalışmada kullanılan veri seti ile yapılan bir sınıflandırma çalışması yoktur. Çalışmada alınan sonuçlar, Rojas-Aranda vd. (2020)'nin benzer bir veri seti kullanarak gerçekleştirmiş oldukları meyve çeşidi sınıflandırması ile karşılaştırıldığında ise literatürdeki çalışmada %95 sınıflandırma doğruluğu değeri elde edilmiş; bu çalışmada kurulan performans en iyi modelin ise %97.5 sınıflandırma doğruluğu değeri ile literatürdeki en yakın çalışmadan daha iyi bir performans gösterdiği gözlemlenmiştir.

Nemenyi testine göre ise modellerin ortalama değerleri hesaplandığında orta değere en yakın modeller ReLU aktivasyon fonksiyonu kullanılan 1 gizli katmanlı ve 2 gizli katmanlı modeller olduğundan en iyi model olarak değerlendirilmiştir. Bu durum, Nemenyi testi sonuçlarına göre, ReLU aktivasyon fonksiyonu kullanılan 1 gizli katmanlı ve 2 gizli katmanlı modellerin performansının diğerlerine göre daha benzer olduğunu ve ortalamalarının birbirine daha yakın olduğunu gösterir. Bu nedenle, en iyi model olarak değerlendirilmiştir. Ayrıca en düşük orta değer ile en yüksek orta değer arasındaki farkın hesaplanan kritik farktan düşük çıkması sebebi ile kurulan modeller arasında ilişki olduğu sonucuna varılmıştır. Bu durum modellerin performans metrikleri arasında anlamlı bir fark olmadığını, yani bu metriklerin istatistiksel olarak benzer olduğunu gösterir.

Gelecekteki çalışmalarda veri setindeki verilerin çoğaltılarak sınıfların çeşitlendirilmesi, farklı derin öğrenme mimarileri eklenip devir sayısının arttırılması ve bu şekilde elde edilen sonuçların karşılaştırılması planlanmaktadır.

Etik Standartlar Bildirgesi

Yazarlar tüm etik standartlara uyduklarını beyan ederler.

Yazarlık Katkı Beyanı

Yazar 1: Fikir Sahibi, Kaynaklar, Araştırma, Deney, Yazma – orijinal taslak
Görselleştirme, Yazma – orijinal taslak

Yazar 2: Kaynaklar, Araştırma, Biçimsel analiz– orijinal taslak,

Yazar 3: Kaynaklar, Araştırma, Biçimsel analiz– orijinal taslak,

Yazar 4: Fikir Sahibi, Kaynaklar, Araştırma, Biçimsel analiz– orijinal taslak

Çıkar Çatışması Beyanı

Yazarların bu makalenin içeriğiyle ilgili olarak beyan edecekleri hiçbir çıkar çatışması yoktur.

Verilerin Kullanılabilirliği

Bu çalışma sırasında oluşturulan veya analiz edilen tüm veriler, yayınlanan bu makaleye dahil edilmiştir. Veri kümeleri istek üzerine mevcuttur. Bu makalenin sonuçlarını destekleyen ham veriler, yazarlar tarafından herhangi bir çekince olmaksızın sunulacaktır.

5. Kaynaklar

Alkhouly, A., Mohammed, A. and Hefny, Hesham, H., 2021, Improving The Performance Of Deep Neural Networks Using Two Proposed Activation Functions, *IEEE Access*, 1-1.
<https://doi.org/10.1109/ACCESS.2021.3085855>

Al-Saedi, D.K.A. and Savaş, S., 2022. Classification of Skin Cancer with Deep Transfer Learning Method, *Computer Science. IDAP-2022, International Artificial Intelligence and Data Processing Symposium*, 202-210.
<https://doi.org/10.53070/bbd.1172782>

Ammatmanee, C. and Gan, L., 2021. Transfer learning for hostel image classification. *Data Technologies and Applications*, 56, 44-59.
<https://doi.org/10.1108/DTA-02-2021-0042>

Behera, S.K., Rath, A.K. and Sethy, P.K., 2021. Maturity status classification of papaya fruits based on machine learning and transfer learning approach. *Information Processing in Agriculture*, 8, 2, 244-250.
<https://doi.org/10.1016/j.inpa.2020.05.003>

Bozkurt, F., 2021/1, Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti, *Avrupa Bilim Ve Teknoloji Dergisi*, (24), 149-156.
<https://doi.org/10.31590/ejosat.898385>

Bozkurt, F., 2021/2, A Study on CNN Based Transfer Learning for Recognition of Flower Species, 2021, *European Journal of Science and Technology*, 32, 883-890.
<https://doi.org/10.31590/ejosat.1039632>

Bozkurt, F., 2022, A Deep And Handcrafted Features-Based Framework For Diagnosis Of COVID-19 From

Chest X-Ray Images, *Concurrency Computat Pract Exper*, 34(5).
<https://doi.org/10.1155/2021/6799202>

Buchanan, B.G., 2005. A (Very) Brief History of Artificial Intelligence. *AI Magazine*, 26, 4, 53-60.
<https://doi.org/10.1609/aimag.v26i4.1848>

Chen, Y., Lin, Y., Xu, X., Ding, J., Li, C., Zeng, Y., Liu, W., Xie, W. and Huang, J., 2022. Classification of lungs infected COVID-19 images based on inception-ResNet. *Computer Methods and Programs in Biomedicine*, 225, 1-9.
<https://doi.org/10.1016/j.cmpb.2022.107053>

Doğan, F., ve Türkoğlu, İ., 2019. Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10, 2, 409-445.
<https://doi.org/10.24012/dumf.411130>

Dubey, S. R., Singh, S. K. and Chaudhuri, B. B., 2022, Activation Functions in Deep Learning: A Comprehensive Survey and Benchmark, *arXiv*.
<https://doi.org/10.48550/arXiv.2109.14545>

Friedman, M.A., 1940. Comparison of alternative tests of significance for the problem of m rankings. *Annals of Mathematical Statistics*, 11, 1, 86-92.
<https://doi.org/10.1214/aoms/1177731944>

Glorot, X., Bordes, A. and Bengio, Y., 2011, Deep sparse rectifier neural networks, In *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, pages, 315–323.

Gulzar, Y., 2023. Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability*, 15, 3, 1906.
<https://doi.org/10.3390/su15031906>

Habek, G.C., 2022. Makine Öğrenmesi Teknikleriyle Kripto Para Duygu Analizi, Yüksek Lisans Tezi, Manisa Celal Bayar Üniversitesi Fen Bilimleri Enstitüsü, Manisa, 75.

Hao, W., Yizhou, W., Yaqin, L. and Zhili, S., 2020, The Role of Activation Function in CNN, 2020 2nd International Conference on Information Technology and Computer Application (ITCA), Guangzhou, China, 429-432.
<https://doi.org/10.1109/ITCA52113.2020.00096>

He, K., Zhang, X., Ren, S. and Sun, J., 2015. Deep Residual Learning for Image Recognition. *arXiv*.
<https://doi.org/10.48550/arXiv.1512.03385>

Hemalatha, N., Sukhetha, P. ve Sukumar, R., 2022. Classification of Fruits and Vegetables using Machine and Deep Learning Approach. In *2022 International Conference on Trends in Quantum Computing and Emerging Business Technologies (TQCEBT)*, 1-4.

- <https://doi.org/10.1109/TQCEBT54229.2022.10041654>
- Mascarenhas, S. and Agarwal, M., 2021. A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification. 2021 *International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications (CENTCON-2021)*, Bengaluru-India, 96-99. <https://doi.org/10.1109/CENTCON52345.2021.9687944>
- Memiş, S., Enginoğlu, S. ve Erkan, U., 2022. A new classification method using soft decision-making based on an aggregation operator of fuzzy parameterized fuzzy soft matrices. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30, 3, 871-890. <https://doi.org/10.55730/1300-0632.3816>
- Mukhiddinov, M., Muminov, A. and Cho, J., 2022. Improved Classification Approach for Fruits and Vegetables Freshness Based on Deep Learning, *Sensors*, 22, 21, 1-20. <https://doi.org/10.3390/s22218192>
- Nemenyi, P.B., 1963. Distribution-free multiple comparisons. PhD, Princeton University, Princeton, New Jersey, USA.
- Nwankpa, C., Ijomah, W., Gachagan, A. and Marshall, S., 2018, Activation Functions: Comparison of trends in Practice and Research for Deep Learning, arXiv. <https://doi.org/10.48550/arXiv.1811.03378>
- Özçelik, Y. B. ve Altan, A., 2021. Diyabetik Retinopati Teşhisi için Fundus Görüntülerinin Derin Öğrenme Tabanlı Sınıflandırılması. *Avrupa Bilim Ve Teknoloji Dergisi*(29), 156-167. <https://doi.org/10.31590/ejosat.1011806>
- Ponce, J.M., Aquino, A. and Andújar, M., 2019. Olive-Fruit Variety Classification by Means of Image Processing and Convolutional Neural Networks. *IEEE Access*, 147629-147641. <https://doi.org/10.1109/ACCESS.2019.2947160>
- Rojas-Aranda, J.L., Nunez-Varela, J.I., Cuevas-Tello, J.C. and Rangel-Ramirez, G., 2020. Fruit Classification for Retail Stores Using Deep Learning. *12th Mexican Conference on Pattern Recognition (MCPR)*, 3-13. https://doi.org/10.1007/978-3-030-49076-8_1
- Simonyan, K. and Zisserman, A., 2014. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv*. <https://doi.org/10.48550/arXiv.1409.1556>
- Talo, M., 2019. Automated classification of histopathology images using transfer learning. *Artificial Intelligence in Medicine*, 101, 1-8.

İnternet kaynakları

1-Probabilistic losses,
https://keras.io/api/losses/probabilistic_losses,
(18.12.2023)