

KIRAZ YAPRAKLARINDA HASTALIK TESPİTİNDE TRANSFER ÖĞRENME YÖNTEMLERİNİN KIYASLANMASI

A Comparison Of Transfer Learning Methods İn Disease Detection On Cherry Leaves

Hazel BOZCU

Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği
hazelkozlu43@gmail.com

Burakhan ÇUBUKÇU

Dr. Öğr. Üyesi, Bilecik Şeyh Edebali Üniversitesi
Mühendislik Fakültesi, Bilgisayar Mühendisliği,
burakhan.cubukcu@bilecik.edu.tr

ÖZET

Bu çalışma, veri setindeki hastalıklı ve sağlıklı yaprakların tespiti için öğrenme temelli transfer yaklaşımlarına katkıda bulunmayı amaçlamaktadır. Bitki hastalıklarının zamanında ve doğru tespiti, tarımsal üretimdeki en önemli endişelerden biridir. Kiraz yaprak hastalıkları ürün kalitesini doğrudan etkiler. Hastalıkların erken teşhisi ve tedavisi ve etkili kontrol önlemleri verimliliği artırır. Yaprakları etkileyen hastalıklar aynı zamanda dalları ve meyveleri de etkiler. Hastalıklı yapraklara sahip bitkiler daha yavaş büyür ve bu da daha küçük ve daha düşük kaliteli meyvelerle sonuçlanır. Kiraz yetiştiriciliği Türkiye'de önemli bir tarımsal faaliyettir. Kiraz yaprağı hastalıklarının tespiti için derin öğrenme teknikleri kullanılarak tarım ekonomisine katkı sağlanabilir. Çiftçiler, hastalık yönetiminde kullanılan kimyasalların kullanımını azaltabilir, böylece kimyasalların doğal çevre üzerindeki olumsuz etkilerini en aza indirebilir. Bu çalışmadaki deneylerde PlantVillage veri setinden kiraz yaprağı örnekleri kullanılmıştır. AlexNet, VGG-16, MobileNet-V2, ResNet-50 ve Inception-V3 dahil olmak üzere transfer öğrenme teknikleri doğruluk, kesinlik, geri çağırma ve F1 puanı gibi performans ölçütleri kullanılarak karşılaştırıldı. MobileNet-V2, %99 doğruluk oranı, %18 kayıp oranı, %99 kesinlik oranı ve %99 geri çağırma oranı ile başarı oranı en yüksek model olarak belirlendi.

Anahtar Kelimeler: CNN, derin öğrenme, kiraz yaprağı, transfer öğrenme.

ABSTRACT

This study aims to contribute to transfer learning-based approaches for detecting diseased and healthy leaves in the dataset. Timely and accurate detection of plant diseases is one of the key concerns in agricultural production. Cherry leaf diseases directly impact the quality of the product. Early diagnosis and treatment of diseases and effective control measures enhance productivity. Diseases affecting the leaves also have implications for the branches and fruits. Plants with diseased leaves exhibit slower growth, resulting in smaller and lower-quality fruits. Cherry cultivation is an important agricultural activity in Turkey. By utilizing deep learning techniques to detect cherry leaf diseases, contributions can be made to the agricultural economy. Farmers can reduce the use of chemicals used in disease management, thereby minimizing the adverse effects of chemicals on the natural environment. The experiments in this study utilized cherry leaf samples from the PlantVillage dataset. Transfer learning techniques, including AlexNet, VGG-16, MobileNet-V2, ResNet-50, and Inception-V3, were compared using performance metrics such as accuracy, precision, recall, and F1 score. MobileNet-V2 was identified as the model with the highest success rate, achieving an accuracy rate of 99%, a loss rate of 18%, a precision rate of 99%, and a recall rate of 99%.

Keywords CNN, deep learning, cherry leaf, transfer learning.

1.GİRİŞ

Gıda, ilaç, hammadde gibi ihtiyaçlarımızı sağlayan sektörlerden biri olan tarım, nüfusumuza iş olanakları sağlayan önemli alanlardandır. Bitki hastalıkları tarımsal alanda çiftçilerimizin pek çok zorluklarla karşılaşmasına neden olmaktadır. Bu hastalıkların artıp diğer bitkileri sarmadan önce tespit edilip hızlı

aksiyon almak önem arz etmektedir. Hastalıkların önlenmesi için çiftçilerimiz genellikle kimyasal ürünleri ilaçlama amacıyla kullanmaktadır. Bu hem doğal çevreye zarar vermekte hem de ekonomik olarak karşılanması zor bir süreçtir. Sosyo-ekonomik açıdan birçok etki yaratan kimyasal ilaçlama yöntemi, bitki zararlılarına işlem yaparak verim artışını sağlayabilir. Ancak bunun yanı sıra çevre ve insan sağlığı açısından da zararlı etkileri olabilmektedir. Kimyasal ilaçlama toprak ve su ekosistemine de zarar verebilir. İlaçlama işlemlerini yapan çiftçilerimize de gerekli tedbirleri almazlarsa olumsuz etkilerle karşılaşabilirler.

Bu nedenlerle derin öğrenme tabanlı çalışmaların tarım alanında genişlemesi önemli bir konudur. Sosyo-ekonomik olarak kimyasal ilaç kullanımını azaltmak, hastalık tespitlerini otomatikleştirip alternatif tarım yöntemlerini kullanmak önemlidir. Evrişimli sinir ağları (CNN) kimyasal kullanımına göre daha az zararlı alternatifler sunabilir. Bunun yanı sıra bitki hastalıklarının erken teşhisi için yapılan çalışmalar sayesinde bitki hastalıklarıyla doğru mücadele yöntemleri bulunabilir. Bitkilerin büyüme ve gelişimi takip edilerek verim artırıcı çalışmalar yapılabilir (Bharman vd., 2022).

Çıplak gözle hastalık tespiti emek-yoğun işlerdir. CNN modelleri kullanılarak sınıflandırma, görüntü analizi gibi işlemler hem zamandan tasarruf hem de birçok olası senaryo örneği sunması açısından önerilen yöntemler arasındadır. Daha sağlıklı ürünler elde edebilmek için yapılan çalışmalar vardır. Bu çalışmalar, bitkini hasta olup olmadığını, eğer hasta ise hastalığın türünü tespit edebilir (Chellapandi vd., 2021). Literatürde bitkilerdeki hastalıkları derin öğrenme tabanlı çalışmalarla tespit eden çalışmalar bulunmaktadır.

Ekin yaprak hastalıklarının tespit edilmesi amacıyla literatürde transfer öğrenme tekniği kullanılarak çalışmalar yapılmıştır. Paymode ve diğerleri yaptığı çalışmada VGG-16 modelinin son katmanları değiştirilerek önerilen modelde bitki hastalık tespiti amacıyla eğitilen bir sınıflandırıcı sunulmuştur. Çalışmada veri artırma ve görüntü ön işleme teknikleri VGG16 modeline uygulanmıştır. Sonuç olarak VGG16 modeli etkili bir yaprak hastalık tespiti yaklaşımı olarak sunulmuş. Yapılan testler modelin yüksek doğruluk oranı elde ettiğini göstermektedir (Paymode ve Malode, 2022).

Domates yaprakları üzerinde yapılan başka bir çalışmada 9 farklı yaprak hastalık türü ile sağlıklı yaprakların karşılaştırılması yapılmış. İlgili bu çalışmada transfer öğrenme modelleri kullanılarak performans ölçüm sonuçları değerlendirilmiştir (Ecemiş ve İlhan, 2022).

Derin topluluk sinir ağları (DENN) kullanılarak yapılan çalışmada otomatik bir bitki hastalık tespiti önerilmiştir. Transfer aktarım tekniğinden yararlanılmıştır. Fazla uydurmanın üstesinden gelmek amacıyla veri artırma, veri büyütme, döndürme, ölçeklendirme fazla uydurmanın üstesinden gelmek amacıyla kullanılmıştır. Bu çalışmada önerilen DENN modelinin performansının, çalışmada kullanılan önceden eğitilmiş modellerden daha iyi sonuç verdiği söz edilmiştir (Vallabhajoyula vd., 2022). Yapılan çalışmalarda etkin olarak AlexNet, VGG-16, MobileNet-V2, Inception-V3, Resnet-50 modelleri eğitilmiş. Bu modellere veri artırma, veri seti ön işleme, renk eşikleme teknikleri uygulandığı gözlemlenmiştir.

Bu çalışmada kiraz yaprak hastalıklarının transfer öğrenme yöntemleri ile tespit edilmesi amaçlanmıştır. Kullanılan AlexNet, VGG-16, MobileNet-V2, Inception-V3, Resnet-50 gibi birbirinden farklı modeller üzerinde veri seti deneyleri yapılmıştır. Elde edilen sonuçlar üzerinde performans metriklerine göre karşılaştırma yapılmıştır. Elde edilen sonuçlara göre hastalıklı yapraklar %99'a varan oranda doğrulukla tespit edilebilmiştir. Bitki sağlığı açısından ve çiftçinin ekonomik açıdan da tasarruf edebilmesi için bu çalışmada çeşitli transfer aktarım yöntemleri performans ölçümleri sunulmuştur.

2.METHODOLOJİ

Bu bölümde kullanılan transfer öğrenme yöntemleri ve veri seti detayları verilmiştir. Sağlıklı ve hasta yaprakları içeren PlantVillage veri seti Kaggle den indirilmiştir. Eğitim sınıfında 1826 sağlıklı yaprak ve 1683 hasta yaprak bulunurken, doğrulama sınıfında ise 456 sağlıklı yaprak ve 421 hasta yaprak içeren toplamda 877 adet yaprak görüntüsü kullanılmıştır. İlk adımda veri ön işleme yapılmıştır. Görüntüler, OpenCV kütüphanesi kullanılarak okunmuştur ve boyutları 224x224 piksele yeniden boyutlandırılmıştır. Görüntülerin piksel değerleri normalize edildi (0-1 aralığına ölçeklendirildi) ve veri seti eğitim, doğrulama ve test olarak ayrılmıştır. AlexNet (Krizhevsky vd., 2012), MobileNetV2 (Sandler vd., 2018), InceptionV3 (Szegedy vd., 2014), VGG16 (Simonyan ve Zisserman, 2015), Resnet-50 (He vd., 2016) transfer öğrenme mimarileri temel alınarak yeni modeller oluşturuldu. Modellerde evrişimli, tam bağlantı katmanları kullanılmıştır. Dropout(bırakma) ve Batch Normalization (topak normalleştirme) düzleştirme teknikleri kullanılmıştır. Modellerde bazı katmanlar üzerinde ekleme çıkarma işlemleri yapılarak modelin

karmaşıklık ve derinlik tanımları yapılandırılmaya çalışılmıştır. Modelin derinlik ve karmaşıklık seviyesi, Conv2D, MaxPooling2D, Dense ve Dropout gibi katmanların yapılandırmasıyla belirlenir. Bu katmanlar, modelin mimarisini ve karmaşıklığını tanımlar. Örneğin, daha fazla Conv2D ve MaxPooling2D katmanları eklemek, modelin derinliğini ve karmaşıklığını artırırken, Dropout ve BatchNormalization gibi düzleştirme katmanlarının eklenmesi, aşırı uydurma riskini azaltabilir. Eğitim veri seti üzerinde veri artırma tekniği uygulanmıştır. Görüntülere rastgele dönüşüm, kaydırma, parlaklık değişimi, kesme, yakınlaştırma ve yatay düzlemde çevirme gibi işlemler uygulanmıştır. Bu sayede modelin genelleme yeteneğini arttırmak, aşırı uydurma riskini azaltmak amaçlanmıştır.

Model eğitim veri seti üzerinde eğitilmiştir. Eğitilen model doğrulama veri seti üzerinde değerlendirilmiştir. Sınıflandırma algoritmalarının performans değerlendirmesi yapılırken yaygın olarak kullanılan metrikler; hassasiyet(precision), duyarlılık(recall), F1 puanı (F1score) 'dur (Selvi, 2019). Bu çalışmada da Eşitlik 1-3 de verilen modelin doğruluk, F1 puanı, hassasiyet, başarı metrikleri üzerinde performans değerlendirmesi sunulmuştur. Eşitliklerde TP: Doğru pozitif (True Positive), doğru şekilde pozitif olarak tahmin edilen örneklerin sayısını, FP: Yanlış pozitif (False Positive), yanlış şekilde pozitif olarak tahmin edilen örneklerin sayısı, FN: Yanlış negatif (False Negative), yanlış şekilde negatif olarak tahmin edilen örneklerin sayısını ifade etmektedir.

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (1)$$

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

$$\text{F1 Score} = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall}) \quad (3)$$

Çok sınıflı sınıflandırma işlemlerinde, performans metriklerinin hesaplanmasında kullanılan "average" parametresi (Sokolova ve Lapalme, 2009), metriklerin sınıf bazında mı yoksa toplu olarak mı hesaplanacağını belirler. Average parametresine değer verildiğinde, bu formüller ilgili sınıf veya tüm sınıflar üzerinde hesaplanır. Örneğin: "binary" average, iki sınıflı bir problemde pozitif sınıf üzerinde hesaplanır. "micro" average, tüm sınıfların toplam TP, FP ve FN değerlerine dayanarak hesaplanır. "macro" average, her sınıfın ayrı ayrı hassasiyet, duyarlılık ve F1 puanı hesaplayarak ortalamasını alır. "weighted" average, sınıfların örnek sayılarına göre ağırlıklı bir ortalama hesaplar. "samples" average, her örneğin ayrı ayrı sınıflandırıldığı kabul edilerek hesaplanır (Sokolova ve Lapalme, 2009). Bu çalışmada sınıflandırma problemlerine bakılırken average parametresine 3 farklı değer verilerek kıyaslanmıştır.

2.1. Veri Seti

Bu çalışmada PlantVillage (Mohanty, vd., 2016) veri seti kullanılmıştır. Kiraz yaprakları üzerinde hastalık tespiti 2 sınıf üzerinde değerlendirildi. PlantVillage veri seti, külleme (Sengar vd., 2018). hastalığına sahip ve sağlıklı kiraz yapraklarından oluşuyor. Eğitim sınıfı 1826 sağlıklı, 1683 hasta yaprak olmak üzere toplam 3509 yaprak görüntüsü içermektedir. Doğrulama sınıfında 456 sağlıklı, 421 hasta yaprak olmak üzere toplamda 877 kiraz yaprak görüntüsü bulunmaktadır.

2.2. AlexNet

2012 yılında ImageNet ILSVRC yarışmasında birinci olan bir evrişimli sinir ağı modelidir. Modelde 5 evrişim katmanı 3 tam bağlantı katmanı kullanılmıştır. Bunların yanı sıra bırakma (dropout), havuzlama katmanları kullanılırken, aktivasyon fonksiyonu olarak ReLU kullanılmıştır (Krizhevsky vd., 2012).

Bu çalışmada önerilen sistemde kullanılan modelin çıktısı 2 sınıfın hasta ya da sağlıklı olma olasılığını tahmin etmeye çalışmaktır. İlk katmanda 11x11 boyutlu görüntünün 96 tane filtre kullanılarak işlenmesinin ardından girdinin boyutunu küçültmek için 3x3 boyutunda olan havuzlama katmanına geçilmektedir. İkinci katman 5x5 boyutunda 256 adet filtre kullanır. Yeniden boyutlandırmak için bir max-pooling katmanı daha kullanır. Birkaç evrişim ve düzleştirme (flatten) katmanı sonra, son katmanda 2 nörona sahiptir ve softmax aktivasyonu ile iki sınıfın olasılıklarını hesaplar.

2.3. VGG-16

VGG-16 mimarisi 16 katmandan oluşan her katmanında 3x3 boyutlu filtreler kullanılan bir evrişimli sinir ağı mimarisidir. ImageNet kümesi üzerinde görüntü sınıflandırma yarışmasında (ILSVRC-2014) başarılı sonuçlar elde etmiştir. Evrişim katmanları, ReLU aktivasyon fonksiyonu, 2x2 boyutlu havuzlama katmanı, tam bağlantı katmanları kullanılmaktadır. Literatürde transfer öğrenme için oldukça yaygın kullanılmaktadır (Simonyan ve Zisserman, 2015).

Çeşitli sınıflandırma problemlerinde VGG16 mimarisi TensorFlow Keras kütüphanesinden kullanılabilir. Bu çalışmada önceden eğitilmiş VGG16 modeli “weights” parametresi “imagenet” olarak yüklenir. Girdi katmanı, flatten katmanı, tam bağlantı katmanları eklenir. 2 nöronlu softmax aktivasyonu içeren çıkış katmanı tanımlanır. Model derlenir. Eğitim sonrasında kayıp fonksiyonu ve doğruluk metriklerine göre kıyaslamalar yapılır.

2.4.MobileNet-V2

MobileNet-V1 den sonra geliştirilen MobileNet-V2, V1’den daha yüksek doğruluk oranı hedeflemiştir. Dar kıvrımlı evrişim bloklarına sahip olması temel özelliklerindedir. Parametre sayısını azaltan ve çıktı boyutunu azaltan bu bloklar modelin daha hafif bir hale gelmesini sağlar. Dropout(bırakma) ve çıkış aktivasyon tekniklerini kullanır. Bu teknikler aşırı uyumu(overfitting) önlemeye çalışır. Çok sayıda katmandan oluşan Mobilenet-v2 çeşitli tiplerde evrişim katmanları, aktivasyon katmanları, dar boğaz katmanları, normalizasyon ve yoğun katmanlardan oluşur (Sandler vd., 2018).

2.5.Inception-V3

Büyük veri setlerinde yüksek doğruluk oranı elde edebilen bir CNN modelidir. Önceki inception modellerine kıyasla daha az hata yaptığı gözlemlenmiştir. Birçok katmandan oluşan bu mimari evrişim katmanları, havuzlama, tam bağlantı katmanları, dropout, normalizasyon ve aktivasyon katmanları içerir. Birden fazla inception modülünü paralel olarak kullanır (Szegedy vd., 2014).

2.6.ResNet-50

Microsoft tarafından geliştirilmiş olan bu model 50 katmandan meydana gelir. Sahip olduğu özgün ağları sayesinde derinliği bir yandan arttırırken, aşırı öğrenmeyi azaltarak iyi sonuçlar elde etmeyi hedefler. Bu CNN modeli birbiriyle bağlantılı farklı tiplerde evrişim katmanlarından oluşur. Boyutları büyük olan veriler üzerinde doğruluk oranı yüksek değerler elde edilebilir. Residual Connection adı verilen kalan bağlantı tekniğiyle özgündür. Bu bağlantılar modeli derinleştirerek gradientlerin akmasını kolaylaştırır. Öğrenme verimliliğini arttırır[4].Resnet-50 Imagenet veri setinde eğitilmiştir. Görüntü sınıflandırma, yüz tanıma, özellik çıkartma, nesne tespiti gibi birçok farklı uygulamada kullanılabilir. Transfer öğrenme tekniği ile önceden eğitilmiş ağırlıkları kullanılarak tahminlerde bulunulabilir.

3.TRANSFER ÖĞRENME YÖNTEMLERİ İLE KİRAZ YAPRAKLARINDA HASTALIK TESPİTİ

3.1. Veri arttırma (Data augmentation)

Bu çalışmada transfer öğrenme modeli ile birleştirilmiş veri arttırma tekniğine dayalı bir sinir ağı kullanılmıştır. Çalışmadaki algoritma veri arttırma yöntemi ile modelin genelleştirme yeteneğini iyileştirmek üzere tasarlanmıştır. Modelin genelleştirilmesindeki amaç, eğitim verilerine geniş bir perspektif kazandırarak farklı örnekleri doğru şekilde tanımayı öğrenmesini sağlamaktır. Transfer öğrenmeye dayalı bir evrişimli sinir ağı modeli oluşturularak modelin eğitiminde kullanılır. Veri setindeki örnek çeşitliliğini artırma işlemi sayesinde model farklı görüntüleri tanıyarak daha genelleştirilmiş bir şekilde öğrenir ve aşırı uyumu(overfitting) önleyebilir. Veri arttırma sayesinde, eğitim verilerine rastgele dönüşümler, kaydırmalar, rastgele parlaklıklar verebilir (Pandian vs., 2022).

Bu çalışmada Tensorflow keras kütüphanesinden ImageDataGenerator sınıfı kullanılarak verilere rastgele döndürme açısı, rastgele yatay kayma, rastgele dikey kayma, rastgele parlaklık, rastgele kesme, rasgele yakınlaştırma ve veri normalizasyon işlemleri uygulanmıştır. Görüntülerin her bir piksel değeri 0-255 aralığından 0-1 aralığına ölçeklendirilip verinin daha kolay işlenebilmesi için normalize edilmiştir. Kullanılan parametreler rotation_range (dönüş aralığı), width_shift_range (genişlik kaydırma aralığı), height_shift_range (yükseklik kaydırma aralığı), brightness_range (parlaklık aralığı), shear_range (eğim aralığı), zoom_range (yakınlaştırma aralığı), horizontal_flip (yatay çevirme), rescale (ölçeklendirme) = 1/255.0’dir. Çalışmadaki görüntüleri 25 dereceye kadar döndürme, genişlik ve yükseklik açısından %20 oranında kaydırma, parlaklık aralığını [0.4,1.5] aralığında değiştirme, yana doğru %20 oranında kesme, %20 oranında yakınlaştırma, yatay olarak yansıtma ve ölçeklendirme gibi değerler verilmiştir.

3.2. Görüntü Ön İşleme


Görüntü ön işleme, görüntü segmentasyonu, nesne tanıma ve daha birçok alan da kullanılan yaygın bir işlemdir. Külleme hastalığına sahip yaprak yüzeylerindeki belirli alanlar açık renklidir. Bu çalışmada

görüntü ön işleme yöntemlerinden olan renk eşikleme kullanılarak açık renkli alanlar tespit edilmeye çalışılmıştır. Görüntü ön işleme tekniklerinden olan histogram eşikleme ile hastalıklı yüzeylerin aydınlık olduğu gözlemlenmiştir. Bu çalışmada birden fazla ön işleme adımı uygulanarak deneyler yapılmıştır.

3.3. Renk eşikleme

Renk eşikleme görüntü ön işleme yöntemlerindedir. Öncelikle görüntü HSV(ton, doygunluk ve değer) formatına dönüştürülür. Ardından belirlenmiş alt üst sınır değerleri arasında kalan piksellerin olduğu maske oluşturulur. Bu maske eşikleme sonrasında ayrılacak pikselleri belirler. Bu maske ile orijinal görüntü üzerinde bir başka maskeleme işlemi yapılır. Belirlenen piksellerin kaldığı görüntü elde edilir. Bu işlem belirlediğimiz aralıktaki renklerin vurgulanmasını sağlar. Bu çalışmada önerilen sistemde belirlenen aralıktaki pikselleri 1(beyaz), diğer pikselleri 0 (siyah) yaparak renkler vurgulanmıştır. HSV renk uzayı kullanılarak ölçülen yaprakların hastalıklı olan yaprakların vurgulandığı gözlemlenmiştir (Patil ve Bodhe, 2011). Külleme hastalığına sahip yapraklar. Şekil 1. 'de görüldüğü gibi açık renklidir.

Şekil 1. Renk eşikleme uygulanmış eğitim sınıfı örnek görüntüleri




3.4. Histogram Eşikleme Ve Gri Seviye Segmentasyonu


Tarımsal sektörde yaprak hastalık tespiti önemli uygulama alanıdır. Histogram eşikleme gibi yapay zeka teknikleri yaprak hastalıklarının tespitinde kullanılmaktadır. Bu sayede önceden belirlenmiş özellikleri analiz ederek, sağlıklı yaprakları hastalıklı yapraklardan ayırt edebilir. Histogram eşikleme görselin histogramını analiz eder ve belirlenmiş eşik değerinin altında ve üstünde kalan pikselleri ayırır. Bu işlem sonrasında örneklerin aydınlık karanlık bölgeler arasındaki farklılıklar netleşir (Türkoğlu, 2019).

Bu çalışmada geliştirilen sistemde renkli renk uzayından gri renk uzayına dönüşüm yapıldı. Elde edilen gri görüntü üzerinde histogram eşikleme işlem gerçekleştirilerek siyah beyaz görüntü elde edildi. Bu işlem eğitim verilerine OpenCV kütüphanesi kullanılarak uygulandı. Döngü kurularak gri seviye dönüşüm fonksiyonu ile görüntüler dönüştürüldü. Eşikleme değerinin belirlenmesinde otsu eşikleme algoritması kullanıldı. Histogram eşikleme ile görüntüdeki piksellerin dağılımında dengelemeler yaparak görüntüyü netleştirme amaçlanmıştır. Gri seviye segmentasyonu ile görüntüdeki nesnelere daha iyi tanımayaya yardımcı olması amaçlanmıştır (Karhan, 2011).

Şekil 2. Histogram Eşikleme Ve Veri Arttırma Uygulanmış Eğitim Sınıfı Örnek



Şekil 3. Histogram Eşikleme Ve Gri Seviye Segmentasyonu Uygulanmış Eğitim Sınıfı Örnek Görüntüleri



4.SONUÇLAR VE TARTIŞMALAR

Bu çalışmada veri setine uygulanan veri artırma, histogram ve renk eşikleme teknikleri ve AlexNet, VGG-16, MobileNet-V2, Inception-V3, Resnet-50 mimarisini kullanan modeller ile gerçekleştirilen görüntü sınıflandırma deneyinde, eğitim ve doğrulama veri setlerinde başarılı sonuçlar elde edildi. Eğitim sürecinde kullanılan erken durdurma ve öğrenme hızı azaltma gibi geri çağırma işlevleri sayesinde modelin genel performansı iyileştirildi. En iyi performansa ulaşan model kaydedildi ve ilgili metrikler üzerinde test veri setiyle değerlendirme yapıldı.

Renk eşikleme tekniği uygulanmadan önce en iyi doğruluk oranı 0.97 iken renk eşikleme ile birlikte aynı modelde deney yapıldığında performans oranı 0.99'a yükselmiştir. Çeşitli parametreler üzerinde rastgele değişiklikler yapılarak örneğin öğrenme oranının veri setinin boyutuna, modelin derinliğine ve olası başka parametrelere bağlı olarak farklılıklar gösterdiği görülmüştür. İlgili veri setinde yaklaşık 3500 örnek eğitim görüntüsüne uygulanan eğitim sırasında öğrenme(learning rate) oranını azaltmak doğruluk oranını arttırmıştır. ResNet50 modelinde renk eşikleme uygulanmadan önce doğruluk 0.59 çıkarken, renk eşikleme işlemi sonrasında doğruluk oranı 0.90 seviyesine kadar artmıştır. Transfer öğrenme aktarımında resnet50 modelinin son 5 katmanını hariç tutarak diğer katmanları eğitilemez olarak ayarladık. Eğitilebilir katman sayısında değişiklikler yapmak deney sonucumuzu olumsuz etkileyerek 5 katmanda karar kılmamıza neden oldu, bu önceden eğitilmiş ağırlıkları koruma amacıyla yapıldı. Çıktıları düzleştirme uygulandı.1024 nöronlu tam bağlantı katmanı ekleyerek model üzerinde özelleştirme işlemi yapıldı. Aktivasyon fonksiyonu olarak ReLU kullanıldı. Sinir ağının genelleştirmek için dropout(bırakma) fonksiyonu kullanıldı. Yapılan deneyde son katmanlar değiştirilerek modelin özelleştirilmesi doğruluk oranını pozitif olarak etkiledi. Aynı modelde renk eşikleme uygulamadan önce çıkan sonuçlara göre renk eşikleme uygulanmış sonuçlar arasındaki fark veri ön işlemenin modelin hızına ve performansına doğrudan etki ettiğini gösteriyor. Tablo 1 de görünen Precision (Kesinlik), Recall (Duyarlılık), F1Score (F1 Puanı) değerleri average parametresine weighted değeri verilerek hesaplanmış sonuçlardır.

Tablo 1. Çalışmada Kullanılan Tüm Modellerin Performans Sonuçları


	AlexNet	VGG-16	MobileNet-V2	Inception-V3	Resnet50
Loss	0.692933	0.575958	0.186793	0.596128	0.657336
Accuracy	0.529076	0.882554	0.990878	0.898518	0.591790
Precision	0.704912	0.903284	0.990922	0.900766	0.771322
Recall	0.529076	0.882554	0.990876	0.898518	0.591790
F1Score	0.377689	0.880405	0.990879	0.898192	0.498355

Tablo 1'de, doğrulama sınıfı performans metrik sonuçlarını bulabilirsiniz. Bu metrikler, farklı derin öğrenme modellerinin performansını ölçmek için kullanılmaktadır. MobileNet-V2 modeli, en düşük kayıp değeri olan 0.186793'e sahiptir, bu da modelin gerçeğe yakın tahminlerde bulunduğunu gösterir. Ayrıca, doğru tahmin etme oranı 0.990878'dir. Precision (hassasiyet) metriği, yanlış pozitif tahminlerin ne kadar düşük olduğunu gösterir ve MobileNet-V2 modeli, en yüksek hassasiyet değeri olan 0.990922'yi elde

etmiştir. Recall (hatırlatma) değeri ise gerçekten pozitif olan örneklerin model tarafından doğru bir şekilde tahmin edilme oranını gösterir ve MobileNet-V2 modeli için bu değer 0.990876'dır. Yanlış negatif tahminlerin azlığını gösteren B değeri ise MobileNet-V2 modelinde en yüksektir. Precision ve recall değerlerinin harmonik ortalaması olan f1 skoru değeri de MobileNet-V2 modelinde en yüksektir. Sonuç olarak, elde edilen sonuçlara göre, Resnet-50 ve AlexNet düşük performans oranlarına sahipken, MobileNet-V2 modeli en yüksek performans oranına ulaşmıştır.

MobileNet-V2 diğer modeller arasında en iyi performansı sergiledi. Görüntü ön işleme adımında değişiklik yapmadan farklı modeller uyguladığımızda ortaya çıkan sonuç yine MobileNet-V2 modelinin daha iyi sonuçlar elde edeceği yönündedir. Şekil 5'te verilen karışıklık matrisinde görüldüğü gibi 1 değerine karşılık gelen sağlıklı görüntülerin 450 tanesini doğru tahmin ederek sağlıklı olduğu sonucunu göstermiştir. 0 değerine karşılık gelen hasta yaprakların 419 tanesini doğru bir şekilde hasta olarak tahmin edilip 2 tanesini yanlış tahmin etmiştir.

Şekil 4. En İyi Performans Sonucu Veren Mobilenet-V2 Modelinin Karışıklık Matrisi Görseli



Tablo 2,3,4'te sunulan sonuçlar, farklı derin öğrenme mimarileri (AlexNet, VGG-16, MobileNet-V2, Inception-V3, ResNet50) kullanarak elde edilen sınıflandırma performansını göstermektedir. Sonuçlar, üç farklı "average" parametresi değeri ("weighted", "macro", "binary") için hesaplanmıştır.

İlk olarak, "weighted" average parametresi değeri kullanıldığında elde edilen sonuçlar incelenmiştir. Bu parametre değeri, sınıf dengesini dikkate alarak her bir sınıfın önemini hesaplar. Precision, Recall ve F1-Score değerlerine bakıldığında, MobileNet-V2 ve Inception-V3 modellerinin yüksek performans gösterdiği görülmektedir. Bu modeller, yüksek hassasiyet (Precision) ve hatırlama (Recall) değerlerine sahiptir. AlexNet ve ResNet50 modelleri ise diğer modellere kıyasla daha düşük performans sergilemektedir. İkinci olarak, "macro" average parametresi değeri kullanıldığında elde edilen sonuçlar incelenmiştir. Bu parametre değeri, her sınıfın eşit öneme sahip olduğunu varsayar. Precision, Recall ve F1-Score değerlerine bakıldığında, VGG-16 ve Inception-V3 modellerinin en yüksek performansı sergilediği görülmektedir. Bu modeller, diğer modellere göre daha yüksek hassasiyet ve hatırlama değerlerine sahiptir. AlexNet ve Resnet50 modelleri ise diğer modellere göre daha düşük performans göstermektedir.

Tablo 2. Avarage Parametresine "Weighted" Deđeri Verildiđinde Sonular

	AlexNet	VGG-16	MobileNet-V2	Inception-V3	Resnet50
Precision	0.704912	0.903284	0.990922	0.900766	0.771322
Recall	0.529076	0.882554	0.990876	0.898518	0.591790
F1Score	0.377689	0.880405	0.990879	0.898192	0.498355

Tablo 3. Avarage Parametresine "Macro" Deđeri Verildiđinde Sonular

	AlexNet	VGG-16	MobileNet-V2	Inception-V3	Resnet50
Precision	0.712399	0.906876	0.990728	0.901889	0.780098
Recall	0.509592	0.877764	0.991046	0.896761	0.574822
F1Score	0.364797	0.87966	0.990867	0.897867	0.489220

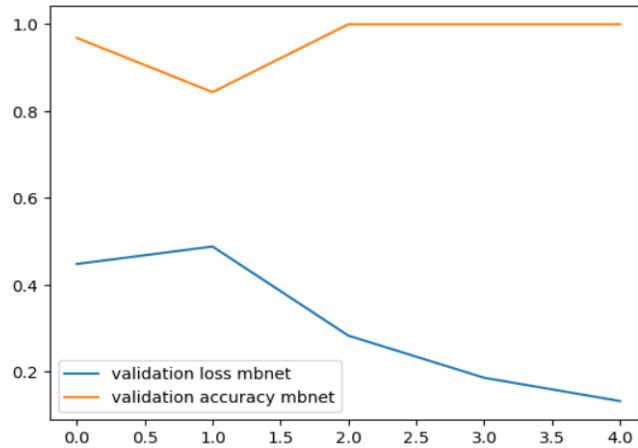
Tablo 4. Avarage Parametresine "Binary" Deđeri Verildiđinde Sonular

	AlexNet	VGG-16	MobileNet-V2	Inception-V3	Resnet50
Precision	0.524798	0.816876	0.995575	0.873727	0.560196
Recall	0.997807	0.997807	0.986842	0.940789	1.0
F1Score	0.687831	0.898321	0.991189	0.906019	0.718110

Son olarak, "binary" average parametresi deđeri kullanıldıđında elde edilen sonular incelenmiřtir. Bu parametre deđeri, sınıflandırma sonularını birleřtirerek tek bir sınıf gibi ele alır. Precision, Recall ve F1-Score deđerleri incelendiđinde, MobileNet-V2 ve Inception-V3 modellerinin yüksek performans sergilediđi grlmektedir. Bu modeller, diđer modellere gre daha yüksek hassasiyet ve hatırlama deđerlerine sahiptir. AlexNet ve Resnet50 modelleri ise diđer modellere gre daha dřuk performans gstermektedir.

Bu sonular "average" parametresinin sınıflandırma performansını etkilediđini gstermektedir. Farklı parametre deđerleri sınıfların nemini ve dengesini farklı řekillerde hesapladıđından dolayı modelin performansı zerinde farklı etkiler yaratmaktadır.

řekil 5. En İyi Performans Sonucu Veren Mobilenet-V2 Modelinin Dođruluk Grafiđi



5. DEĐERLENDİRMELER

Bu alıřmada, transfer đrenme yntemleri kullanılarak PlantVillage veri seti zerinde yaprak sınıflandırması gerekleřtirilmiřtir. alıřmanın metodoloji blmnde, veri seti detayları ve kullanılan yntemler detaylı bir řekilde aıklanmıřtır. AlexNet, MobileNetV2, InceptionV3, VGG16 ve Resnet-50 transfer đrenme mimarileri temel alınarak yeni modeller oluřturulmuřtur. Eđitim veri seti zerinde veri arttırma tekniđi kullanılmıřtır. Grntlere rastgele dnřm, kaydırma, parlaklık deđiřimi, kesme, yakınlılařtırma ve yatay dzlemde evirme gibi iřlemler uygulanarak modelin genelleme yeteneđi arttırılmıřtır. Eđitilen model dođrulama veri seti zerinde deđerlendirilmiřtir.

Performans deęerlendirmesi için doęruluk, F1 puanı, hassasiyet ve başarı metrikleri kullanılmıştır. Bu metrikler, farklı derin öğrenme modellerinin performansını ölçmek için kullanılan yaygın metriklerdir. Ayrıca, "average" parametresi kullanılarak sınıf bazlı veya toplu olarak metriklerin hesaplanması sağlanmıştır. Sonuç olarak, farklı "average" parametresi deęerleri kullanıldığında elde edilen sonuçlar modellere baęlı olarak deęişiklik göstermektedir. Hangi parametre deęerinin kullanılacağı, sınıflandırma probleminin gereksinimlerine ve veri setinin özelliklerine baęlı olarak belirlenmelidir. Çalışmada doęruluk metrięi baz alındığı durumda, en yüksek doęruluk deęerine sahip aęırlık parametresi en iyi performansı sağlamış oldu. Sonuçlara baktığımızda, "Average Parametresine 'weighted' deęeri verildiğinde MobileNet-V2 modelinin Precision, Recall ve F1-Score metriklerinde en yüksek deęerlere sahip olduğunu görüyoruz. Bu nedenle, weighted aęırlık parametresi MobileNet-V2 modeli için en iyi performansı sağlamış gibi görünmektedir.

Colab ortamından yararlanılarak çalıştırılan proje toplam bellek kapasitesinin %96'sını kullandı. Toplam bellek kapasitesi 15360.0 MB'tır. Kullanılan 14799.1875 MB'tır. %23 oranında CPU kullanılmıştır. Ek olarak yapılan çalışmada en düşük başarı oranına sahip modeller arasında Resnet50 modelini seçerek, bu modele renk eşikleme uygulandığında doęruluk oranının yüzde 59'dan yüzde 99 oranına yükseldięi görüldü. Yapılan çalışmada renk eşikleme uygulanmış görüntüler kullanıldığında, doęru tahmin edilen görsel sayısının arttığı gözlemlendi. Birbirinden farklı modeller üzerinde deneyler yapılarak derin öğrenme tabanlı çalışmalara katkı sunmayı amaçlamıştır. Gelecekte Eskişehir Kozlu köyünde bulunan kiraz bahçelerinden toplanmış kiraz yaprakları ile birden fazla modeli üzerinde çalışma yapılarak hastalık tespiti yapmayı amaçlıyoruz.

KAYNAKLAR

- Bharman, P., Ahmad Saad, S., Khan, S., Jahan, I., Ray, M., & Biswas, M. (2022). Deep Learning in Agriculture: A Review. *Asian Journal of Research in Computer Science*, February, 28–47. <https://doi.org/10.9734/ajrcos/2022/v13i230311>
- Chellapandi, B., Vijayalakshmi, M., & Chopra, S. (2021). Comparison of pre-trained models using transfer learning for detecting plant disease. *Proceedings - IEEE 2021 International Conference on Computing, Communication, and Intelligent Systems, ICCIS 2021*, 383–387. <https://doi.org/10.1109/ICCIS51004.2021.9397098>
- Ecemiş, İ. N., & O.İlhan, H. (2022). Domates yapraklarında hastalık tespiti için önerilen hafif evrişimli sinir aęı ile önceden eğitilmiş aęların performans karşılaştırması. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 2, 693–705. <https://doi.org/10.17341/gazimmfd.1003730>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Karhan, M. (2011). İmge işleme yöntemleri ile kayısılarda yaprak delen hastalığı sonucu oluşan lekelerin tespiti (Master's thesis, Namık Kemal Üniversitesi).
- Krizhevsky, B. A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7(September), 1–10. <https://doi.org/10.3389/fpls.2016.01419>
- Pandian, J. A., Kumar, V. D., Geman, O., Hnatiuc, M., Arif, M., & Kanchanadevi, K. (2022). Plant Disease Detection Using Deep Convolutional Neural Network. *Applied Sciences (Switzerland)*, 12(14). <https://doi.org/10.3390/app12146982>
- Patil, S. B., & Bodhe, S. K. (2011). Leaf disease severity measurement using image processing.

International Journal of Engineering and Technology, 3(5), 297–301.

- Paymode, A. S., & Malode, V. B. (2022). Transfer Learning for Multi-Crop Leaf Disease Image Classification using Convolutional Neural Network VGG. *Artificial Intelligence in Agriculture*, 6, 23–33. <https://doi.org/10.1016/j.aiia.2021.12.002>
- Sandler, M., Howard, A., Zhu, M., & Zhmoginov, A. (2018). MobileNetV2 : Inverted Residuals and Linear Bottlenecks. 4510–4520.
- Sengar, N., Dutta, M. K., & Travieso, C. M. (2018). Computer vision based technique for identification and quantification of powdery mildew disease in cherry leaves. *Computing*, 100(11), 1189–1201. <https://doi.org/10.1007/s00607-018-0638-1>
- Sevli, O. (2019). Göğüs Kanseri Teşhisinde Farklı Makine Öğrenmesi Tekniklerinin Performans Karşılaştırması Performance Comparison of Different Machine Learning Techniques in Diagnosis of Breast Cancer. 16, 176–185. <https://doi.org/10.31590/ejosat.553549>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. 3rd International Conference on Learning Representations, ICLR 2015 – Conference Track Proceedings, 1–14.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Szegedy, C., Vanhoucke, V., & Shlens, J. (2014). Rethinking the Inception Architecture for Computer Vision.
- Türkoğlu, M. (2019). Görüntü işleme tabanlı bitki türleri ve hastalıkları tanıma. *Ayran*, 8(5), 55.
- Vallabhajosyula, S., Sistla, V., & Kolli, V. K. K. (2022). Transfer learning-based deep ensemble neural network for plant leaf disease detection. *Journal of Plant Diseases and Protection*, 129(3), 545–558. <https://doi.org/10.1007/s41348-021-00465-8>