



LeNet ve ResNet Derin Öğrenme Modelleri ile Asma Yapraklarının Sınıflandırması

Kıyas Kayaalp^{1*}, Aygün Varol²

¹*Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Isparta*

²*Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Isparta*

Özet

Bu çalışmanın temel amacı, asma yapraklarının türlerine göre doğru bir şekilde sınıflandırılmasında derin öğrenme tekniklerinin etkinliğini araştırmaktır. LeNet ve ResNet mimarilerinin entegrasyonu, bu sınıflandırmayı gerçekleştirmenin bir yolu olarak kullanılmıştır. Gerekli veri seti için, beş farklı türü temsil eden 500 asma yaprağı görüntüsünden oluşan kapsamlı bir koleksiyon kullanılmıştır. Sınıflandırma performansını optimize etmek için kritik bir bileşen olarak özellik seçimine önemli bir vurgu yapıldı. İlgili özelliklerin dikkatli bir şekilde seçilmesi ve gereksiz olanların ortadan kaldırılmasıyla, kullanılan modellerin doğruluğunun artırılması amaçlanmıştır. Seçilen derin özelliklerle birlikte LeNet-5 yaklaşımından yararlanılarak %93.99 gibi iyi bir doğruluk oranına ulaşılmıştır. Bu, asma yaprağı sınıflandırması için kullanılan diğer son teknoloji yöntemlerin performansını aşmıştır. Bu kayda değer bulgulara dayanarak, gelecekteki araştırmalar için umut verici birkaç yol belirlenmiştir. Bunlar arasında alternatif derin öğrenme mimarilerinin araştırılması, çeşitli özellik seçim yöntemlerinin kapsamlı bir şekilde incelenmesi ve bu tekniklerin diğer bitki türlerinden yaprakların tanımlanmasını kapsayacak şekilde genişletilmesi yer almaktadır.

Ahtar Kelimeler: LeNet-5, ResNet, Derin öğrenme, Evrimsel sinir ağları, Görüntü İşleme

Classification of Grapevine Leaves with LeNet and ResNet Deep Learning Models

Abstract

The main objective of this study is to investigate the effectiveness of deep learning techniques in accurately classifying grapevine leaves according to their species. The integration of LeNet and ResNet architectures has been used as a way to realise this classification. For the required dataset, a comprehensive collection of 500 grapevine leaf images representing five different species was used. A significant emphasis was placed on feature selection as a critical component to optimise classification performance. By careful selection of relevant features and elimination of redundant ones, it was aimed to improve the accuracy of the models used. By utilizing the LeNet-5 approach with the selected deep features, a good accuracy of 93.99% was achieved. This exceeded the performance of other state-of-the-art methods used for grapevine leaf classification. Based on these remarkable findings, several promising avenues for future research have been identified. These include the exploration of alternative deep learning architectures, a thorough investigation of various feature selection methods, and the extension of these techniques to cover the identification of leaves from other plant species.

Keywords: LeNet-5, ResNet, Deep Learning, Convolutional Neural Networks, Image Processing

Makale Bilgisi

Başvuru:

17/05/2024

Kabul:

03/06/2024

* İletişim e-posta: kiyaskayaalp@isparta.edu.tr

1 Giriş

Günümüzün teknolojik ortamında derin öğrenme, görüntü sınıflandırma görevleri için güçlü bir araç olarak ortaya çıkmıştır. Konvolüsyonel sinir ağlarının (CNN) ve LeNet, VGGNet, ResNet ve Inception gibi mimarilerin ortaya çıkmasıyla, görüntülerdeki nesnelere doğru bir şekilde kategorize etme ve tanıma konusunda önemli ilerlemeler kaydedilmiştir. Derin öğrenme modelleri, ham piksel verilerinden hiyerarşik temsilleri öğrenme yeteneğine sahiptir ve bu sayede otomatik olarak anlamlı özellikler ve desenler çıkarabilirler. Bu, doğru görüntü sınıflandırmasının hayati bir rol oynadığı bilgisayarla görme, tıbbi görüntüleme, otonom sürüş ve tarım gibi alanlarda devrim yaratmıştır. Büyük ölçekli veri kümeleri üzerinde eğitilen derin öğrenme modelleri, geleneksel makine öğrenimi yaklaşımlarını geride bırakarak görüntüleri olağanüstü doğrulukla sınıflandırmak için öğrendikleri bilgilerden yararlanabilir. Önceden eğitilmiş modellerin belirli görevler için ince ayarının yapıldığı transfer öğrenmenin kullanılması, verimli ve doğru görüntü sınıflandırıcılarının geliştirilmesini daha da hızlandırmıştır. Derin öğrenme ilerlemeye devam ettikçe, görüntü sınıflandırmada devrim yaratma ve çeşitli alanlarda yeni olasılıkların kilidini açma konusunda büyük bir potansiyele sahiptir.

Asma yapraklarını türlerine göre doğru bir şekilde sınıflandırmak, bağcılık ve tarımsal araştırmalarda önemli bir görevdir. Bu çalışmada, asma yapraklarını sınıflandırmak için iki popüler derin öğrenme modeli olan LeNet ve ResNet-50'nin kullanımı araştırılmıştır. LeNet, birçok görüntü sınıflandırma görevinde kullanılmış, yaygın olarak bilinen ve başarılı bir evrimsel sinir ağı mimarisidir. Görüntülerden özelliklerin çıkarılmasına yardımcı olan ve desenleri etkili bir şekilde tanımasını sağlayan farklı katmanlara sahiptir. Öte yandan ResNet-50, çok derin ağlarla başa çıkabilen güçlü bir derin öğrenme modelidir. Gradyanların kaybolması sorunu olmadan derin modelleri eğitmek için artık bağlantılar adı verilen özel bağlantılar kullanılır.

Çalışmamız, asma yaprağı görüntülerinden oluşan bir veri kümesi kullanarak LeNet ve ResNet-50 modellerinin performansını karşılaştırmaya odaklanmaktadır. Beş farklı asma türünden 500 yüksek çözünürlüklü yaprak görüntüsü kullanılmıştır [1].

Modellerimizi daha da iyi hale getirmek için transfer öğrenimi kullanılmıştır, yani büyük ölçekli görüntü veri kümeleri üzerinde eğitilmiş modellerin önceden eğitilmiş ağırlıklarından yararlanılmaktadır. Buna ek olarak, doğru özelliklerin seçilmesinin doğru sınıflandırma ve hesaplama karmaşıklığının azaltılması için çok önemli olduğu bilinmektedir. Bu nedenle, asma yapraklarını sınıflandırmak için en önemli ve bilgilendirici özellikleri bulmak için farklı özellik seçim teknikleri denenmektedir.

Çalışmamızın ana hedefleri LeNet ve ResNet-50 modellerinin performansını değerlendirmek ve karşılaştırmak, transfer öğrenmenin etkisini araştırmak ve çeşitli özellik seçim yöntemlerinin etkinliğini analiz etmektir. Bulgularımız, bağcılık ve bitki türlerinin tanımlanması için faydalı olacak asma yaprağı sınıflandırmasının doğruluğunu ve verimliliğini artırmaya katkıda bulunacaktır.

Bu makalenin organizasyonu şu şekilde planlanmıştır; Bölüm 2'de, özellikle bitki yaprağı sınıflandırmasındaki uygulamalara odaklanarak, görüntü sınıflandırması için derin öğrenme teknikleriyle ilgili literatürün kapsamlı bir incelemesi sunulmaktadır. Bölüm 3'de, çalışmamızda kullanılan materyal ve yöntemler ele alınmaktadır. Bu bölümde veri kümesi, kullanılan LeNet ve ResNet-50 modellerinin mimari diyagramları ve veri kümesinin yapısının bir özeti hakkında bilgi verilmektedir. Ek olarak, kullanılan derin öğrenme algoritmalarına kısa bir genel bakış sağlanmaktadır. Bölüm 4, deneylerimizin sonuçlarından elde edilen bulgular sunulmuştur. Bu bölüm, seçilen hiperparametrelerle ilgili tartışmaları, kayıp ve doğruluk fonksiyonu grafiklerini kullanarak model performanslarının karşılaştırılmasını, kesinlik, geri çağırma ve F1-skor gibi metrikleri gösteren tabloların yanı sıra eğitim, doğrulama ve test doğruluk tablolarını kapsamaktadır. Ayrıca, sınıflandırma sonuçları hakkında daha fazla bilgi edinmek için karışıklık matrisleri ve ROC eğrileri sunulmaktadır. Son olarak, Bölüm 5'de, temel bulguları ve bunların çıkarımlarını özetleyerek makaleyi sonuçlandırıyoruz.

2 Literatür Taraması

Bu bölümde, yaprak görüntülerinin sınıflandırılmasına özel olarak odaklanarak, görüntü sınıflandırma görevleri için derin öğrenme tekniklerinin etkinliğini vurgulayan mevcut literatürün kapsamlı bir incelemesi sunulmaktadır.

Bharadi [2] ve Krishna [3], sırasıyla sinir ağlarının ve AlexNet CNN'in kullanımını önererek görüntü sınıflandırmada yüksek doğruluklarını sergilemektedir. Hu [4], belge görüntülerinin sınıflandırılmasında olağanüstü performans gösteren özel bir model olan MSCNN'yi tanıtmaktadır. Yadav [5], görüntü sınıflandırması için derin öğrenme algoritmalarının kapsamlı bir incelemesini sunmakta ve bu bağlamda derin öğrenmeden yararlanmanın avantajlarını vurgulamaktadır. Ayrıca, You [6], Yang [7], Thanh [8] ve Liu [9] özellikle yaprak görüntülerinin sınıflandırılmasına odaklanmakta ve derin öğrenme yaklaşımlarının geleneksel yöntemlere kıyasla üstün sonuçlar elde etmedeki etkinliğini sergilemektedir. Bu çalışmalar toplu olarak, derin öğrenme tekniklerinin yaprak görüntülerinin sınıflandırılması da dâhil olmak üzere görüntü sınıflandırması için büyük umut vaat ettiğine dair ikna edici kanıtlar sunmaktadır.

You [6], derin öğrenme yöntemlerinin yaprak çeşitlerini ayırt etmek için geleneksel yöntemlerden daha iyi performans gösterdiğini bulmuştur. Yang [7], derin öğrenmenin karmaşık bir arka plana sahip yaprak görüntülerini etkili bir şekilde segmentlere ayırmak ve sınıflandırmak için kullanılabileceğini göstermiştir. Thanh [8], yaprak sınıflandırıcı için eşikleme yaprak ön işleme ekstresi damar şekli verilerine ve eğitim verilerinin görüntünün yansımaları ve döndürülmesi ile artırılmasına dayanan bir CNN modeli önermiştir; bu, yaprak tanıma için %95'ten daha yüksek bir doğrulukla etkili olmuştur. Liu [9], AutoEncoder ve evrişimli sinir ağını içeren yeni bir sinir ağı olan hibrit derin öğrenmeyi tanıtmış ve sınıflandırma görevi için daha iyi özellikler çıkarabileceğini kanıtlamıştır. Hibrit derin öğrenme yönteminin yaprakları sınıflandırmak için saf DVM, saf AE ve saf CNN'den daha iyi olduğu bulunmuştur.

Minowa [10], birden fazla yaprağın fotoğraflarına dayanarak geniş yapraklı ağaç türlerini tanımlamak için derin öğrenme algoritmaları kullanmış ve ortalama %97.0 doğruluk oranı elde etmiştir. Shah [11], yaprak görüntüsü sınıflandırması için önceki yaklaşımlardan daha iyi performans gösteren, daha yüksek doğruluk ve tutarlılık elde eden çift yönlü bir derin evrişimli sinir ağı önermiştir. Sugata [12] yaprak tanıma için derin evrişimli sinir ağları kullanmış ve veri kümesini büyütme için veri artırma yöntemini kullanarak son teknoloji sistemlere yakın doğruluk elde etmiştir. Genel olarak, bu makaleler yaprak görüntülerini doğru bir

şekilde sınıflandırmak için derin öğrenmenin potansiyelini göstermektedir.

Araújo [13], önceden eğitilmiş CNN'ler kullanarak küresel ve yama tabanlı yaprak özelliklerini birleştiren ince taneli bir hiyerarşik sınıflandırma yöntemi önermekte ve ImageCLEF 2015 bitki tanıma veri setinde en iyi sonuçları elde etmektedir. Beikmohammadi [14], önceden eğitilmiş bir derin sinir ağı modeli ve lojistik regresyon sınıflandırıcısı kullanarak iki iyi bilinen botanik veri kümesi olan Flavia ve Leafsnap üzerinde yüksek doğruluk elde eden transfer öğrenme tabanlı bir yöntem sunmaktadır. Işık [15], k-en yakın komşu algoritmasını kullanarak Flavia ve SLID veri kümelerinde yüksek doğruluk oranları elde eden, küresel ve yerel özelliklere dayalı yaprak sınıflandırması için otomatik bir sistem önermektedir. Genel olarak, makaleler derin öğrenme tabanlı yöntemlerin yaprak sınıflandırma sistemlerinin doğruluğunu artırabileceğini göstermektedir.

Hasan vd. [16] konvolüsyonel sinir ağını (CNN) kullanarak toplam 1000 görüntüden oluşan veri seti ile asma yaprağına ait üç hastalıklı ve bir sağlıklı durumu sınıflandırmışlardır. Nagarju vd. [17] elma ve asma yaprak hastalıklarının sınıflandırması çalışmasını gerçekleştirmişlerdir. Elma ve asma yaprakları için üç hastalıklı ve bir sağlıklı olmak üzere sekiz farklı sınıfı VGG-16 modeli ile %97.87 doğruluk oranında sınıflandırmışlardır. Ji, Zhang ve Wu [18] çalışmalarında asma yaprağına ait üç hastalıklı, bir sağlıklı toplam 1619 görüntünün bulunduğu veri setini kullanmışlardır. InceptionV3 ile ResNet50 modellerinin birleştirilerek elde edilen UnitedModel'in kullanıldığı çalışmada %98.57 test doğruluk oranına elde etmişlerdir. Liu vd. [19], 2020 yılında yaptıkları çalışmalarında yedi farklı sınıfa ait asma yaprağını sınıflandırmışlardır. Kendilerinin topladıkları 4023 ve kamuya açık veri setlerinden toplanan 3646 görüntü kullanılmıştır. DICNN ismini verdikleri yeni oluşturdukları model ile asma yapraklarının hastalıklı ve sağlıklı durumlarını %97.22 doğruluk oranı ile sınıflandırmışlardır. Padol vd. [20], SVM sınıflandırıcı tabanlı asma yaprağı hastalığı tespiti isimli çalışmalarında, 137 asma yaprağı görüntüsü kullanmışlardır. Çalışmalarında sadece Tüylü Küf ve Külleme hastalıklarının sınıflandırılması gerçekleştirilmiştir ve ortalama %88.89 başarı oranını elde etmişlerdir. Ghory, Sungur ve Durdu [21], Faster R-CNN ve SSD MobileNet modelleri ile gerçek zamanlı olarak asma yapraklarının

sınıflandırmasını gerçekleştirmişlerdir. Kamuya açık bir veri setinden 136 sağlıklı ve 124 hastalıklı asma yaprağı görüntüsü elde edilmiştir. Faster R-CNN ile %95.57, SSD MobileNet ile %59.29 başarımları elde edilmiştir. Kayaalp [22], 2024 yılında yaptığı tıbbi bitki yapraklarının tür ve hastalıklarına göre hibrit derin öğrenme yöntemleri ile sınıflandırılması isimli çalışmada, 4503 yaprak görüntüsünü kullanmıştır. Çalışmada, 7 derin öğrenme modeli 10 farklı kategoriden oluşan veri seti üzerinde test edilmiştir. DenseNet121 derin öğrenme modeli ile %98.69 doğruluk oranı elde edilmiştir.

3 Materyal ve Yöntemler

Bu bölümde, derin öğrenme tekniklerini kullanarak asma yaprağı sınıflandırması için kullanılan materyal ve yöntemleri özetlenmektedir. Çalışmada kullanılan veri kümesi, tutarlı aydınlatma koşulları ve görüntü kalitesi sağlamak için özel kendinden aydınlatmalı bir sistem kullanılarak toplanan beş farklı türe ait 500 asma yaprağı görüntüsünden oluşmaktadır [1]. Veri setinin çeşitliliğini ve temsil kabiliyetini sağlamak için alınan önlemler ve elde etme süreçleri açıklanmaktadır. Daha sonra, veri setini model eğitimi ve değerlendirmesine hazırlamak için gerçekleştirilen ön işleme adımlarını ele alınmaktadır. Bu, veri kümesini genişletmek ve çeşitliliğini artırmak için uygulanan veri artırma tekniklerinin yanı sıra piksel değerlerini normalleştirmek ve model yakınsamasını iyileştirmek için veri normalleştirme prosedürlerini içerir. Ayrıca, kullanılan derin öğrenme modellerinin genelleme kabiliyetini değerlendirmek için eğitim-doğrulama-test ayrımını detaylandırılmaktadır.

3.1 Veri Seti

Bu çalışmada kullanılan veri seti, beş farklı sınıfa temsil eden asma yaprağı görüntülerinden oluşmaktadır: Ak, Ala İdris, Büzgülü, Dimnit ve Nazlı. Veri kümesindeki her yaprak görüntüsü 511x511 piksel çözünürlükte standartlaştırılmıştır ve RGB renk kanallarını içermektedir. Veri kümesi, beş farklı asma türünü kapsayan 500 yüksek çözünürlüklü görüntüden oluşmaktadır. Örnek görüntüleri Şekil 1'de verilen, asma yaprağı türlerinin çeşitli şekil, doku ve renk varyasyonlarını kapsayacak şekilde temsil edilmesini sağlamak için özenle seçilmiştir. Standartlaştırılmış görüntü


boyutlarının ve RGB renk kanallarının kullanılması, sınıflandırma işlemi sırasında asma yaprağı özelliklerinin tutarlı ve doğru bir şekilde analiz edilmesini sağlar.



Şekil 1. Asma yaprakları

3.2 Kullanılan Modellerin Mimarileri


Literatürde bugüne kadar asma yaprakları ile ilgili yapılan çalışmalarda, genellikle yaprak hastalıklarının tespiti gerçekleştirilmiştir [16-21]. Asma yapraklarının çeşitlerine göre sınıflandırılması için sadece MobileNet'in kullanıldığı bir çalışma tespit edilmiştir [1]. Çalışmamızda kullanılan LeNet-5 ve ResNet modellerinin kullanıldığı çalışmalara pek rastlanmamıştır. Bu algoritmalar, görüntü sınıflandırma görevlerindeki olağanüstü performanslarıyla bilinmektedir. LeNet-5 ve ResNet modelleri ilgili görüntü özelliklerini yakalamada ve yüksek doğruluk elde etmede kayda değer bir başarı gösteren Evrişimsel Sinir Ağlarının bir alt sınıfıdır. Çalışmamızda kullanılan bu modeller, çeşitli bilgisayarla görme uygulamalarında yaygın olarak kullanılmış ve benzer sınıflandırma görevlerinde etkinliği kanıtlanmıştır. Şekil 2, çalışmada kullanılan LeNet-5 modelin ayrıntılı mimarisi gösterilmektedir. Model çoklu evrişimli katmanlar, ardından havuzlama ve tam bağlantılı katmanlardan oluşmaktadır. Bu mimari, asma yaprağı görüntülerinden etkili özellik çıkarımı ve hiyerarşik temsil öğrenimi sağlamaktadır.



Şekil 2. Yaprak sınıflandırması için LeNet-5 modeli

Ayrıca asma yapraklarının doğru sınıflandırılması için ResNet-50 mimarisi de kullanılmıştır. Şekil 3, çalışmada kullanılan ResNet-50 modelinin ayrıntılı mimarisini göstermektedir. ResNet-50, çeşitli görüntü sınıflandırma görevlerinde dikkate değer bir performans sergilemiş olan derin bir evrişimli sinir ağıdır. Artık bağlantılar sunarak, kaybolan gradyan sorunları olmadan çok daha derin ağların eğitilmesine olanak tanır. ResNet-50 mimarisi, her biri konvolüsyonel katmanlar, toplu normalizasyon ve kısayol bağlantıları içeren birkaç artık bloktan

oluşmaktadır. Bu mimari, asma yaprağı görüntülerinden son derece ayırt edici özelliklerin çıkarılmasını kolaylaştırmaktadır ve modelin karmaşık desenleri ve varyasyonları yakalama yeteneğini geliştirmektedir. Bu çalışmada, hem LeNet hem de ResNet-50 mimarilerini bir araya getirerek, bu modellerin güçlü yönlerinden yararlanmayı ve asma yaprağı tanımlama için sağlam ve doğru sınıflandırma sonuçları elde etmek amaçlanmıştır.



Şekil 3. Resnet50 model mimarisi

Tablo 1, her bir asma türü için mevcut görüntü sayısı da dahil olmak üzere veri setinin bir özeti sunmaktadır. Bu bilgi, verilerin farklı sınıflar arasındaki dağılımını anlamamızı sağlayarak model eğitimi ve değerlendirmesi sırasında dengeli bir temsil sağlamaktadır.

Tablo 1. Veri kümesinin içerdiği görüntü sayısı.

Yaprak Cinsi	Görüntü sayısı
Ak	100
Ala idris	100
Büzgülü	100
Dimnit	100
Nazlı	100

3.3 Performans Değerlendirmesi

Derin öğrenme modellerinin performansını değerlendirmek için performans değerlendirme yapılmıştır. Modelin asma yaprağı görüntülerini doğru şekilde sınıflandırma becerisini ölçmek için formülasyonları (1, 2, 3, 4) nolu denklemlerde verilen doğruluk, kesinlik, geri çağırma ve F1-skoru [23], ROC ve karışıklık matrisi gibi çeşitli değerlendirme ölçütleri kullanılmıştır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Geri çağırma} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{F1 - Skor} = 2 \times \left(\frac{\text{Kesinlik} \times \text{Geri çağırma}}{\text{Kesinlik} + \text{Geri çağırma}} \right) \quad (4)$$

4 Bulgular

4.1 Hiperparametreler

Bu bölümde, ResNet-50 ve LeNet derin öğrenme modelleri için sonuçlar ve tartışmalar sunulmuştur. Bu modeller beş farklı sınıftan (Ak, Ala_Idris, Buzgulu, Dimnit ve Nazlı) oluşan bir görüntü veri kümesi üzerinde eğitilmiş ve değerlendirilmiştir.

ResNet modeli, derin bir evrişimli sinir ağı olan ResNet-50 mimarisi kullanılarak eğitilmiştir. Model ImageNet veri kümesi üzerinde ön eğitime tabi tutulmuş ve ardından özel veri kümesi üzerinde ince ayar yapılmıştır. ResNet modelini eğitmek için seçilen hiperparametreler 0,001'lik bir öğrenme oranı, 32'lik bir yığın boyutu ve döndürme, genişlik-yükseklik kaydırmaları ve yatay çevirme gibi veri artırma tekniklerini içermektedir. Optimizer olarak Adam kullanılmış ve çok sınıflı sınıflandırma için kategorik çapraz entropi kayıp fonksiyonu kullanılmıştır.

LeNet modeli ise klasik LeNet-5 mimarisini takip etmiştir. Bu model konvolüsyonel ve havuzlama katmanlarının ardından tam bağlantılı katmanlardan oluşmaktadır. LeNet modelini eğitmek için kullanılan hiperparametreler arasında Adam optimizer tarafından belirlenen bir öğrenme oranı, 45'lik bir yığın boyutu ve veri artırma teknikleri yer almaktadır. Model ayrıca kategorik çapraz entropi kayıp fonksiyonu kullanılarak eğitilmiştir.

4.2 Modellerin performanslarının karşılaştırılması

Bu çalışmada kullanılan modellerin performansını değerlendirmek ve karşılaştırmak için kayıp ve doğruluk fonksiyonu grafikleri kullanılmıştır. Bu grafikler, eğitim sürecine ilişkin içgörü sağlamakta ve eğitim aşamasında modellerin yakınsamasını ve kararlılığını göstermektedir. Farklı modellerin kayıp ve doğruluk eğrileri karşılaştırılarak, altta yatan desenlerin yakalanması ve asma yaprağı türleri arasında ayırım yapma konusundaki etkinlikler daha iyi anlaşılabilir. Bu analiz, olası aşırı uyum veya yetersiz uyum sorunlarını belirlememize ve modellerin genel performansını değerlendirmemize olanak tanımaktadır.

LeNet modeli ile 0.1028'lik bir test kaybı ve %93.99'lük bir test doğruluğu elde edilmiştir. Bu, modelin çok düşük bir kayıp değeri ve yüksek bir doğruluk yüzdesi ile test veri kümesinde olağanüstü

iyi performans gösterdiğini göstermektedir. Düşük kayıp değeri LeNet modelinin doğru tahminler yaptığını, yüksek doğruluk ise test verilerinin önemli bir kısmının model tarafından doğru sınıflandırıldığını göstermektedir.

ResNet modeli 1.3139 ile daha yüksek bir test kaybı ve %51.99 ile daha düşük bir test doğruluğu sergilemiştir. Bu ölçümler ResNet modelinin doğru tahminler yapmakta zorlandığını ve gerçek etiketlerden daha yüksek bir sapma gösterdiğini ortaya koymaktadır. Daha yüksek kayıp değeri, modelin tahminlerinde daha fazla hata olduğunu, daha düşük doğruluk ise test verilerinin daha küçük bir kısmının model tarafından doğru sınıflandırıldığını göstermektedir.

İki modelin performansları karşılaştırıldığında, LeNet modelinin hem kayıp hem de doğruluk açısından ResNet modelinden daha iyi performans gösterdiği açıktır. LeNet modeli önemli ölçüde daha düşük bir kayıp değeri ve daha yüksek bir doğruluk yüzdesi elde ederek veri kümesindeki görüntüleri sınıflandırmada üstün performans göstermiştir. Bu sonuçlar, görüntü sınıflandırma görevlerinde daha iyi performans elde etmek için uygun bir model mimarisi seçmenin ve hiperparametrelerini optimize etmenin önemini vurgulamaktadır.

4.3 Hassasiyet, Geri Çağırma ve F1-Skor metrik sonuçları

Modellerimizin sınıflandırma performansını değerlendirmek için kesinlik, geri çağırma ve F1-skoru gibi ölçümlerin sonuçlarını gösteren tablolar sunulmaktadır. Bu ölçütler, modellerin her bir asma yaprağı türünü doğru bir şekilde sınıflandırma becerisine ilişkin değerli bilgileri sunmaktadır. Kesinlik, pozitif tahminlerin doğruluğunu ölçer, geri çağırma pozitif örnekleri belirleme yeteneğini temsil eder ve F1-skoru hem kesinlik hem de geri çağırma metriklerini birleştirir. Her sınıf için bu metrikler incelenerek, modellerin performansı sınıf bazında değerlendirilebilir ve farklı asma yaprağı türleri arasında doğrulukta herhangi bir varyasyonu belirlenebilir.

Tablo 2'de, hem ResNet hem de LeNet modelleri için Kesinlik, Geri Çağırma ve F1-Skor metrikleri sunulmaktadır. Bu metrikler, modellerin sınıflandırma görevindeki her bir sınıf üzerindeki performansını değerlendirmek için kullanılır.

Tablo 2. ResNet ve LeNet için Kesinlik, Geri Çağırma ve F1-Skor metrik sonuçları.

ResNet				LeNet			
Sınıf	Hassasiyet	Geri Çağırma	F1-Skor	Sınıf	Hassasiyet	Geri Çağırma	F1-Skor
Ak	0.63	0.57	0.60	Ak	1.00	0.92	0.96
Ala İdris	0.83	0.28	0.42	Ala İdris	1.00	1.00	1.00
Büzgülü	0.78	0.67	0.72	Büzgülü	0.86	1.00	0.93
Dimnit	1.00	0.10	0.17	Dimnit	0.85	0.85	0.85
Nazlı	0.35	1.00	0.51	Nazlı	0.95	0.91	0.93

ResNet modeli için hassasiyet değerleri 0.35 ile 1.00 arasında değişmektedir ve her bir sınıf içindeki doğru sınıflandırılmış örneklerin oranını göstermektedir. Geri çağırma değerleri 0.10 ile 1.00 arasında değişmekte olup model tarafından doğru şekilde tanımlanan gerçek örneklerin oranını temsil etmektedir. Hem kesinlik hem de geri çağırma dikkate alan F1-Skor değerleri 0.17 ile 0.60 arasında değişmektedir.

Buna karşılık, LeNet modeli tüm ölçümlerde daha yüksek performans göstermektedir. Kesinlik değerleri 0.85 ile 1.00 arasında değişmektedir ve bu da her bir sınıftaki örneklerin sınıflandırılmasında yüksek doğruluğa işaret etmektedir. Geri çağırma değerleri 0.85 ile 1.00 arasında değişmektedir ve bu da modelin gerçek örneklerin yüksek bir oranını başarıyla yakaladığını göstermektedir. F1-Skor değerleri 0.85 ile 1.00 arasında değişmekte olup hassasiyet ve geri çağırma arasındaki dengeyi yansıtmaktadır.

Genel olarak, LeNet modeli kesinlik, geri çağırma ve F1-Skoru açısından ResNet modelinden daha iyi performans göstererek verilen veri kümesinde üstün sınıflandırma performansı sergilemektedir.

4.4. Modellerin Eğitim, Doğrulama ve Test Doğrulukları

Bu bölümde, modellerimizin eğitim, doğrulama ve test doğruluğunu gösteren tablolar sunulmaktadır. Bu tablolar, modellerin eğitim sürecinin farklı aşamalarındaki performanslarına ilişkin kapsamlı bir genel bakış sunmaktadır. Her aşama için doğruluk değerlerini analiz ederek, modellerin asma yapıklarını doğru bir şekilde sınıflandırmayı ne ölçüde öğrendiği belirlenebilmektedir. Ayrıca, eğitim, doğrulama ve test setlerindeki doğrulukların karşılaştırılması, modellerin genelleme kabiliyetini ve görünmeyen veriler üzerinde iyi performans gösterme kapasitelerini değerlendirilmesini sağlar.

Tablo 3'de ResNet ve LeNet modelleri için eğitim, doğrulama ve test doğruluk değerleri sunulmaktadır. Bu doğruluk değerleri, ilgili her bir veri kümesindeki doğru sınıflandırılmış örneklerin yüzdesini göstermektedir. ResNet modeli, %93.99'luk daha yüksek bir eğitim doğruluğu elde eden LeNet modeline kıyasla %51.99'luk daha düşük bir eğitim doğruluğu elde etmiştir. Benzer şekilde, LeNet modeli, %54.35'e kıyasla %95.82 ile doğrulama doğruluğu açısından ResNet modelinden daha iyi performans göstermiştir.

Tablo 3. DL modellerinin doğrulukları


ResNet			LeNet		
Eğitim	Doğrulama	Test	Eğitim	Doğrulama	Test
58.27%	54.35%	51.99%	96.28%	95.82%	93.99%

4.5. Karışıklık Matrisi ve ROC eğrileri


Modellerimizin performansını daha fazla değerlendirmek için karışıklık matrisleri veya ROC eğrileri sunulmaktadır. Karışıklık matrisi, her sınıf için doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif tahminleri göstererek modellerin sınıflandırma sonuçlarının ayrıntılı bir dökümünü sağlar. Bu, farklı asma yaprağı türleri arasındaki yanlış sınıflandırmaları veya karışıklık matrislerini belirlememize olanak tanır. LeNet ve Resnet modellerinin karışıklık matrisleri Şekil 4'te verilmiştir. Şekil 4 (a)'da LeNet modelinin karışıklık matrisinde Ala İdris ve Büzgülü asma yapraklarının tam olarak sınıflandırıldığı, Dimnit asma yaprağının ise diğer yapraklara göre daha düşük oranda sınıflandırıldığı görülmektedir. Şekil 4(b)'de ResNet modelinin karışıklık matrisinde Nazlı asma

yaprağının tam olarak sınıflandırıldığı, Dimnit asma yaprağının çok düşük bir oranda sınıflandırıldığı görülmektedir.

Alternatif olarak, farklı sınıflandırma eşikleri için yanlış pozitif oranına karşı gerçek pozitif oranını çizerek modellerin ayrımcılık yeteneklerini gösteren ROC eğrileri sunulmaktadır. Bu görselleştirmeler, modellerin genel performansı ve asma yaprağı türleri arasında ayırım yapma yetenekleri hakkında değerli bilgiler sağlar. LeNet ve ResNet modellerinin ROC grafikleri Şekil 5'te verilmiştir. Şekil 5 (a)'da LeNet modelinin tüm asma yapraklarında 1.0 AUC değeri elde ettiği görülmektedir. Şekil 5(b)'de ResNet modelinin AUC değerlerine bakıldığında en iyi sonuçların sırasıyla Nazlı ve Büzgülü'den elde edildiği görülmektedir.





(a)



(b)

Şekil 4. (a) LeNet ve (b) ResNet modellerinin karışıklık matrisleri



Şekil 5. (a) LeNet ve (b) ResNet modellerinin ROC grafikleri

5 Sonuçlar

Bu çalışmada, derin öğrenme modelleri kullanılarak asma yapraklarının sınıflandırılması amaçlanmıştır. Bu görev için iki popüler derin öğrenme modeli olan ResNet ve LeNet kullanılmıştır. Deneylerden elde edilen sonuçlar aşağıdaki gibi özetlenmiştir.

ResNet modeli, 1.3139 gibi nispeten yüksek bir test kaybıyla %51.99'luk bir test doğruluğu elde etmiştir. Model, Ala İdris ve Dimnit sınıfları için daha yüksek hassasiyet, Ak, Büzgülü ve Nazlı sınıfları için daha düşük hassasiyet ile farklı sınıflar arasında değişen performans göstermiştir. Model, Nazlı sınıfı için en yüksek geri çağırma değerine sahipken, diğer sınıflar için geri çağırma değerleri nispeten düşüktü. F1-skorları da sınıflar arasında karışık bir performansı yansıtmaktadır.

Öte yandan, LeNet modeli %93.99'luk test doğruluğu ve 0.1028'lik önemli ölçüde daha düşük test kaybıyla üstün performans sergilemiştir. Model, tüm sınıflarda yüksek hassasiyet, geri çağırma ve F1-skor puanları göstererek farklı kategorilerdeki örnekleri doğru bir şekilde sınıflandırmadaki etkinliğini göstermiştir.

Sonuçlar, LeNet modelinin doğruluk, kesinlik, geri çağırma ve F1-skor puanları açısından ResNet modelinden daha iyi performans gösterdiğini ve asma yaprağı sınıflandırmasında üstün performansını ortaya koyduğunu göstermektedir.

Kaynaklar

- [1] Koklu M, Unlarsen MF, Ozkan IA, Aslan MF, Sabanci K. "A CNN-SVM study based on selected deep features for grapevine leaves classification". *Measurement*. 188,110425,2022.
- [2] Bharadi V, Mukadam AI, Panchbhai MN, Rode NN. "Image classification using deep learning". *Int J Eng Res Technol*. 2017.
- [3] Krishna MM, Neelima M, Harshali M, Rao MVG. "Image classification using deep learning". *Int J Eng Technol*, 7(2.7),614-7, 2018.
- [4] Hu B, Ergu D, Yang H, Liu K, Cai Y. "Document images classification based on deep learning". *Procedia Comput Sci.*,162,514-22,2019.
- [5] Yadav S, Sawale MD. "A review on image classification using deep learning". *World J Adv Res Rev.*, 17(1),480-2, 2023.
- [6] You J. "Leaf Image Classification Using Deep Learning Network". *Acad J Comput Inf Sci.*, 4(3),109-15, 2021.
- [7] Yang K, Zhong W, Li F. "Leaf segmentation and classification with a complicated background using deep learning". *Agronomy*, 10(11),1721, 2020.
- [8] Nguyen Thanh TK, Truong QB, Truong QD, Huynh Xuan H. "Depth learning with convolutional neural network for leaves classifier based on shape of leaf vein". In: *Intelligent Information and Database Systems: 10th Asian Conference, ACIIDS 2018*, Dong Hoi City, Vietnam, March 19-21, 2018, Proceedings, Part I 10. Springer, p. 565-75, 2018.
- [9] Liu Z, Zhu L, Zhang X-P, Zhou X, Shang L, Huang Z-K, et al. "Hybrid deep learning for plant leaves classification." In: *Intelligent Computing Theories and Methodologies: 11th International Conference, ICIC 2015*, Fuzhou, China, August 20-23, 2015, Proceedings, Part II 11. Springer, p. 115-23, 2015.
- [10] Minowa Y, Kubota Y. "Identification of broad-leaf trees using deep learning based on field photographs of multiple leaves". *J For Res.*, 27(4),246-54, 2022.
- [11] Shah MP, Singha S, Awate SP. "Leaf classification using marginalized shape context and shape+ texture dual-path deep convolutional neural network". In: *2017 IEEE International conference on image processing (ICIP)*. IEEE, p. 860-4, 2017.
- [12] Sugata TLI, Yang CK. "Leaf App: Leaf recognition with deep convolutional neural networks". In: *IOP Conference Series: Materials Science and Engineering*. IOP Publishing. p. 12004, 2017.
- [13] Araújo VM, Britto AS, Brun AL, Koerich AL, Oliveira LES. "Fine-grained hierarchical classification of plant leaf images using fusion of deep models". In: *2018 IEEE 30th International Conference on Tools with Artificial Intelligence (ICTAI)*. IEEE, p. 1-5, 2018.
- [14] Beikmohammadi A, Faez K. "Leaf classification for plant recognition with deep transfer learning". In: *2018 4th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS)*. IEEE, p. 21-6, 2018.
- [15] Işık Ş, Özkan K. "Overview of handcrafted features and deep learning models for leaf recognition". *J Eng Res.*, 9(1), 2021.
- [16] Hasan MA, Riana D, Swasono S, Priyatna A, Pudjiarti E, and Prahartiwi LI. "Identification of grape leaf diseases using convolutional neural network," in *Journal of Physics: Conference Series*, vol. 1641, no. 1, p. 12007, 2020.
- [17] Nagaraju Y, Swetha S, and Stalin S. "Apple and grape leaf diseases classification using transfer learning via fine-tuned classifier," in *2020 IEEE International Conference on Machine Learning and Applied Network Technologies (ICMLANT)*, pp. 1-6, 2020.
- [18] Ji M, Zhang L, and Wu Q. "Automatic grape leaf diseases identification via UnitedModel based on multiple convolutional neural networks," *Inf. Process. Agric.*, vol. 7, no. 3, pp. 418-426, 2020.
- [19] Liu B, Ding Z, Tian L, He D, Li S, and Wang H. "Grape

leaf disease identification using improved deep convolutional neural networks," *Front. Plant Sci.*, vol. 11, p. 1082, 2020.

- [20] Padol PB and Yadav AA. "SVM classifier based grape leaf disease detection," in *2016 Conference on advances in signal processing (CASP)*, pp. 175–179, 2016.
- [21] Ghoury S, Sungur C, and Durdu A. "Real-time diseases detection of grape and grape leaves using faster r-cnn and ssd mobilenet architectures," in *International conference on advanced technologies, computer engineering and science (ICATCES 2019)*, pp. 39–44, 2019.
- [22] Kayaalp K. "Classification of Medicinal Plant Leaves for Types and Diseases with Hybrid Deep Learning Methods," *Inf. Technol. Control*, vol. 53, no. 1, pp. 19–36, 2024.
- [23] Kayaalp K. "A deep ensemble learning method for cherry classification," *Eur. Food Res. Technol.*, vol. 250, no. 5, pp. 1513–1528, 2024.