

Bitki Hastalıklarının Tespit Eden Görüntü İşleme Sistemli Mobil Uygulama

Yiğitcan Soylu^{1*}, Mustafa Altıok²

¹ Bilgisayar Mühendisliği Bölümü, Tokat Gaziosmanpaşa Üniversitesi, Tokat, Türkiye (yigitcansoylu19@outlook.com)

² Bilgisayar Mühendisliği Bölümü, Tokat Gaziosmanpaşa Üniversitesi, Tokat, Türkiye (mustafa.altok@gop.edu.tr)

Özet – Bitkilerde hastalıkların erken teşhisi, tarımsal verimliliğin artırılması ve ürün kayıplarının önlenmesi açısından büyük öneme sahiptir. Bu çalışmada, tarımsal üretimde önemli kayıplara yol açan bitki yaprak hastalıklarının erken teşhisine yönelik bir yapay zekâ destekli mobil sistem geliştirilmiştir. Derin öğrenme temelli model, PlantVillage [1] veri seti kullanılarak ResNet50 mimarisi üzerinden transfer öğrenme ve fine-tuning teknikleriyle eğitilmiştir. Eğitim süreci boyunca veri artırma, normalize etme ve katman dondurma gibi yöntemlerle modelin öğrenme başarısını optimize edilmiştir. Eğitimin ilk aşamasında yalnızca sınıflandırma katmanları eğitilmiş, ardından ResNet50'nin son katmanları açılarak ince ayar uygulanmıştır. Elde edilen sonuçlar doğrultusunda, modelin doğruluğu %97 seviyesine ulaşmıştır ve modelin genelleme kabiliyetinin yüksek olduğu görülmüştür. Model, FastAPI altyapısıyla mobil uygulamaya entegre edilmiş ve Flutter kullanılarak kullanıcı dostu bir arayüz geliştirilmiştir. Uygulama, kullanıcıların kamera veya galeri aracılığıyla yüklediği yaprak görsellerini analiz ederek hastalık teşhisi yapmakta, teşhis edilen hastalıklara göre öneriler sunmakta ve önceki sonuçları kayıt altına alarak kullanıcıya geri bildirim sağlamaktadır. Geliştirilen bu sistem, bitki hastalıklarının sahada hızlı ve doğru şekilde tespit edilmesine olanak tanıyarak, hem tarımsal sürdürülebilirliğe katkı sağlamayı hem de çiftçilerin karar destek süreçlerini kolaylaştırmayı hedeflemektedir.

Anahtar Kelimeler – Bitki Hastalığı Tespiti, Görüntü İşleme, Derin Öğrenme, Convolutional Neural Networks (CNN), Tarımsal Verimlilik

Mobile Application with Image Processing System for Plant Disease Detection

Abstract – Early diagnosis of plant diseases is of great importance for improving agricultural productivity and preventing crop losses. In this study, an AI-powered mobile system was developed for the early detection of leaf diseases in plants, which cause significant losses in agricultural production. The deep learning-based model was trained using the PlantVillage [1] dataset through the ResNet50 architecture with transfer learning and fine-tuning techniques. During the training process, methods such as data augmentation, normalization, and layer freezing were applied to optimize model performance. In the initial phase, only the classification layers were trained; then, the final layers of ResNet50 were unfrozen for fine-tuning. Based on the results obtained, the model achieved an accuracy rate of 97%, demonstrating strong generalization capability. The model was integrated into a mobile application using the FastAPI framework, and a user-friendly interface was developed with Flutter. The application analyzes leaf images uploaded via camera or gallery, diagnoses plant diseases, provides recommendations based on the diagnosis, and stores previous results to offer feedback to users. This system aims to contribute to agricultural sustainability and facilitate farmers' decision-making processes by enabling fast and accurate on-field detection of plant diseases.

Keywords – Plant Disease Detection, Image Processing, Deep Learning, Convolutional Neural Networks (CNN), Agricultural Productivity

I. GİRİŞ

Tarım sektörü, artan dünya nüfusu, iklim değişiklikleri ve doğal kaynakların kısıtlılığı gibi nedenlerle sürdürülebilirliğini tehdit eden birçok zorlukla karşı karşıyadır. Bu zorlukların başında, tarımsal üretimde ciddi kayıplara neden olan bitki hastalıkları yer almaktadır. Birleşmiş Milletler Gıda ve Tarım Örgütü'ne (FAO) göre, bitki hastalıkları ve zararlılar dünya genelinde gıda üretiminin %20 ila %40'ını tehdit etmektedir [2]. Ayrıca, dünya genelinde yaşanan tarımsal verim kayıplarının yaklaşık %13'ü doğrudan bitki hastalıklarından kaynaklanmaktadır [3]. Bu kayıplar yalnızca ekonomik değil, aynı zamanda çevresel ve sosyal etkiler de doğurarak küresel gıda güvenliği sorununu derinleştirmektedir.

Bu proje, bitki hastalıklarının erken teşhisini ve önlenmesini hedefleyerek tarımda yenilikçi çözümler sunmayı amaçlamaktadır. Geleneksel yöntemler, hastalıkların hızla yayılmasını durdurmada yetersiz kalabilirken, derin öğrenme ve yapay zeka temelli yaklaşımlar bu sorunlara güçlü çözümler sunmaktadır. Literatürde bitki hastalığı teşhisine yönelik çalışmalar bulunsada, bu projede özgün olarak geliştirilmiş hastalık önleyici öneri sistemi ve akıllı ilaçlama rehberi yer alacaktır. Bu sistem, kimyasal kullanımını optimize ederek maliyetleri düşürmeyi, çevresel etkiyi azaltmayı ve ürünlerin sağlık ve pazar değerini artırmayı hedeflemektedir. Proje, yalnızca bireysel çiftçiler ve tarım sektörü için değil, aynı

zamanda ülke ekonomisi, küresel gıda güvenliği, toplum sağlığı ve çevresel sürdürülebilirlik açısından geniş bir öneme sahiptir. Türkiye gibi tarım odaklı ekonomilerde hastalık kaynaklı verim kayıpları, sürdürülebilir gıda üretimini tehdit etmektedir. Bu kapsamda akıllı tarım çözümleri, bu kayıpların önlenmesinde kritik bir rol oynamaktadır. Artan dünya nüfusuyla birlikte gıda talebi yükselmekte ve hastalık kaynaklı kayıplar, tarımın ekonomik ve ekolojik yükünü artırmaktadır. Bu proje, bitki sağlığını korurken verimliliği artırmayı, çevresel etkiyi azaltmayı ve tarımsal sürdürülebilirliğe katkıda bulunmayı amaçlamaktadır. Ek olarak, proje, yapay zekanın tarım sektöründe kullanılmasını teşvik ederek tarımın dijitalleşme sürecine katkı sunmakta ve yenilikçi çözümler geliştirilmesini sağlamaktadır. Hastalık önleyici öneri ve akıllı ilaçlama rehberi, çiftçilere hastalık önleme ve kontrol sürecinde etkin rehberlik sunarken kimyasal kullanımını azaltarak ekosistemin korunmasına yardımcı olacaktır. Sonuç olarak, bu yönleriyle çalışma, gıda güvenliği, sürdürülebilirlik ve verimlilik alanlarında bütüncül bir çözüm sunmaktadır.

Derin öğrenme tabanlı çözümlerin başarısı için, şu anda kullanılan insan manuel tanımlamasından daha iyi performans göstermesi hayati önem taşır. İnsanlar nesnelere %94'lük bir doğrulukla tanımlayabilir [4]. Bu projede, bitki yapraklarındaki hastalık belirtilerini tanımlamak amacıyla geliştirilecek derin öğrenme modelinin %95 ve üzeri bir doğruluk oranına ulaşması hedeflenmektedir.

Günümüzde derin öğrenme tabanlı çözümler, özellikle CNN gibi modeller, bitki hastalıklarının teşhisinde yüksek doğruluk oranları sunarak umut vadetmektedir. Cihan Topçu ve Peri Güneş'in çalışmasında olduğu gibi, ResNet derin öğrenme modeli kullanılarak sağlıklı ve hastalıklı yaprakları yüksek doğrulukla ayırt eden modeller geliştirilmiş ve %99 oranında bir doğruluk elde edilmiştir [5].

SE Lindow ve arkadaşları (1983) tarafından yapılan bir çalışmada, saksıda yetiştirilen domatesler ve kararmış eğrelti otlarının siyah-beyaz yaprak görüntüleri ile videolarını kullanan otomatik bir hastalık değerlendirme cihazı, bitki hastalıklarını analiz etmek için geleneksel görüntü işleme tekniklerini kullanan en erken çalışmalardan biri olarak öne çıkmıştır. [6].

DP Martin ve arkadaşları, mısırdaki şerit hastalığını nicelendirmek amacıyla görüntü işleme teknikleri de kullanılmış ve bilgisayar tabanlı yöntemlerin geleneksel görsel analizlere kıyasla daha yüksek doğruluk sağladığı bildirilmiştir [7].

J. G. A. Barbedo vd. literatürde derin öğrenme çözümlerinin dengeli veri setleri ile %99'un üzerinde doğruluk oranları elde ettiği belirtilmektedir. Ancak, dengesiz veri setlerinde doğruluğun ciddi oranda düştüğü görülmüştür [8-11]. Bu çalışmada ise PlantVillage[1] veri seti ile derin öğrenme modelleri geliştirilerek, yüksek doğruluk oranları elde etmek hedeflenmektedir.

Fu ve arkadaşlarının çalışmasında, geleneksel makine öğrenimi çözümleri hastalıkları %94'ten daha yüksek bir doğrulukla tanımlayabilmesine rağmen [12-14], özellik çıkarma ve tanımlama gereksinimleri nedeniyle kullanımları sınırlıdır. Bu nedenle, derin öğrenme tabanlı CNN modellerini kullanarak, bitki hastalıklarını daha verimli bir şekilde tanımlanması hedeflenmektedir. CNN'ler, otomatik özellik çıkarımı sağladığı için modelin genelleme yeteneğini artırır ve bu da farklı veri kümelerinde daha doğru sonuçlar elde edilmesini sağlar ve böylece farklı veri kümelerinde daha güvenilir sonuçlar üretir. Bu yaklaşım, hastalıkların

tanımlanmasında daha yüksek doğruluk ve esneklik sunmayı mümkün kılacaktır.

Bitki hastalığı teşhisi ve şiddet tahmini, doğru yönetim tekniklerinin uygulanabilmesi için kritik öneme sahiptir [15]. Bu bağlamda, veri dengesizliği ve sınırlı genelleme yeteneği gibi mevcut modellerin sınırlamalarını aşmak amacıyla daha sağlam ve genellebilir bir derin öğrenme modeli geliştirilmesi hedeflenmektedir.

Mevcut derin öğrenme çözümleri genellikle yalnızca tek bir ürün hastalığı tanımlamasına odaklanmakta ve farklı veri kümelerinde etkisiz kalmaktadır [15]. Bu çalışma kapsamında önerilen çözüm, birden fazla hastalık türünü aynı anda tanıyabilecek bir model geliştirmeyi amaçlamaktadır. Bu çoklu hastalık tanımlama yeteneği, hassas tarım uygulamaları için önemli bir adım olacaktır.

Agrio uygulaması, bitki hastalıklarını, zararlıları ve eksiklikleri hızlı bir şekilde teşhis etmek için yapay zeka destekli bir sistem kullanarak kullanıcılara anında tanı ve tedavi önerileri sunmaktadır. Bu süreç, yüklenen görüntüler veya konuşma verilerinin, kapsamlı bir bitki hastalıkları ve zararlılar veritabanı ile karşılaştırılması yoluyla gerçekleşir ve saniyeler içinde doğru sonuçlar üretir [16].

MagicScout, bitki hastalığı teşhisi için entegre görüntü tanıma ve makine öğrenimini kullanarak hastalıkları, zararlıları ve yabancı otları doğrudan tarladan tanımlama yetenekleri sunar [17].

Proje özgün değeri, bitki hastalıklarının teşhisinde derin öğrenme yöntemlerinin kullanımını temel alarak, daha sağlam ve verimli bir sistem geliştirmeyi amaçlamaktadır. Mevcut literatürde derin öğrenme tabanlı sistemler genellikle tek bir hastalık türünü tanımaya yönelik çözümler sunmakta ve çoğu zaman veri setlerinin dengesizliği nedeniyle doğruluk oranlarında düşüşler yaşanabilmektedir [8-11]. Özellikle PlantVillage veri seti gibi zengin ve çeşitli veri setlerinden faydalanarak, farklı bitki hastalıklarını yüksek doğruluk oranlarıyla tanımak ve teşhis etmek mümkündür. Projede ayrıca Hastalık Önleyici Öneri Sistemi ve Akıllı İlaçlama Rehberi modülleriyle, yalnızca hastalık teşhisi yapmakla kalmayıp, hastalıkların önlenmesine yönelik bilimsel ve çevresel faktörleri göz önünde bulunduran tedavi yöntemleri önerilmektedir. Mevcut uygulamalar (Agrio [16], MagicScout [17], vb.) yalnızca hastalık tespiti yaparken, bu proje öneri sistemleriyle kullanıcıların daha bilinçli ve etkili ilaçlama yöntemleri seçmelerini sağlayacak, böylece hem verimliliği artıracak hem de çevre dostu çözümler sunacaktır. Bunların yanı sıra, bu projede kullanılacak derin öğrenme modelleri, geleneksel makine öğrenimi yöntemlerine göre daha etkili bir şekilde özellik çıkarımı yapabilmekte ve bu da modelin genelleme yeteneğini artırarak, farklı veri kümelerinde daha doğru sonuçlar elde edilmesine olanak tanımaktadır. Bu özgün yaklaşım, hastalıkların teşhis edilmesinin ötesine geçerek, doğru yönetim ve tedavi önerileriyle tarımsal süreçleri daha verimli hale getirmeyi hedeflemektedir.

II. MATERYAL VE YÖNTEM

A. Kullanılan veri seti

Bu çalışmada, bitki yapraklarında görülen hastalıkların teşhis edilmesi amacıyla derin öğrenme temelli bir modelin eğitimi için **PlantVillage** [1] veri seti kullanılmıştır. Söz konusu veri seti, 2015 yılında Pennsylvania State Üniversitesi araştırmacıları tarafından oluşturulmuş açık erişimli ve tarımsal görüntü işleme alanında yaygın olarak kullanılan bir

kaynaktır. Veri seti; 14 farklı kültür bitkisine ait, hem sağlıklı hem de hastalıklı örneklerden oluşan toplam 54.306 etiketli yaprak görüntüsü içermektedir.

Görüntüler, ilgili hastalık türlerine göre kategorize edilmiş olup tamamı RGB formatındadır ve yüksek çözünürlüklü kare boyuttadır. Görsellerin yapay ışık altında stüdyo ortamında çekilmiş olması, arka planın homojen kalmasını sağlamış; bu da modelin eğitiminde gürültü etkisini azaltarak öğrenme performansını olumlu yönde etkilemiştir.

Veri seti, sınıflar arasında örnek sayısı açısından ciddi dengesizlikler barındırdığından, bu çalışma kapsamında sınıf dengesi sağlanmış ve her sınıftan eşit sayıda örnek alınarak eğitim, doğrulama ve test alt kümeleri oluşturulmuştur. Görseller, modele uygun giriş boyutu olan 224×224 piksel ölçüsüne yeniden boyutlandırılmış ve piksel değerleri 0 ile 1 arasına normalize edilmiştir. Ek olarak, modelin genel performansını artırmak ve overfitting'i önlemek amacıyla yatay çevirme, döndürme, yakınlaştırma gibi çeşitli veri artırma (data augmentation) işlemleri uygulanmıştır.

PlantVillage veri setinin hem sınıf çeşitliliği hem de etiket doğruluğunun yüksek olması, bu çalışmada geliştirilecek derin öğrenme tabanlı modelin güvenilir biçimde eğitilebilmesine olanak sağlamaktadır. Veri setinde yer alan hastalık türleri arasında domateste yaprak küfü, elmada kara leke, patatesten erken yanıklık ve üzümde siyah çürüklük gibi yaygın ve ekonomik değeri yüksek hastalıklar bulunmaktadır. Bu hastalıkların yapraklarda oluşturduğu belirgin görsel semptomlar, modelin ayırt edici örüntüler öğrenmesini kolaylaştırmakta ve sınıflandırma başarımını artırmaktadır. Tablo 1'de kullanılan veri setinin özellikleri verilmiştir.

Tablo 1. Veri seti özellikleri

Özellik	Açıklama	Örnek Değer
Toplam görüntü sayısı	Etiketli örnek sayısı	54.309
Bitki Türü Sayısı	Farklı bitki türü sayısı	14
Hastalık Sınıfı Sayısı	Sınıflandırılan hastalık kategorisi sayısı	38
Görüntü Formatı	Kaydedilen dosya formatı	JPEG (RGB)
Yeniden Boyutlandırma	Modelin kabul ettiği piksel boyutu	224×224 px
Eğitim/Doğrulama/Test	Alt küme bölünme oranları	%80/ %10 / %10

B. Görüntü ön işleme aşamaları


Modelin yüksek doğrulukla eğitilebilmesi için, kullanılan görüntülerin uygun formata getirilmesi ve modelin öğrenme sürecine katkı sağlayacak şekilde işlenmesi kritik bir adımdır. Bu bağlamda, öncelikle PlantVillage veri setindeki tüm görüntüler, model giriş boyutlarına uyumlu olacak şekilde 224×224 piksel ölçüsüne yeniden ölçeklendirilmiştir. Bu işlem, tüm verilerin sabit bir boyutta olmasını sağlayarak modelin giriş katmanındaki yükünü azaltmakta ve hesaplama sürelerini optimize etmektedir.

Veri işleme sürecinin ikinci adımında, tüm görüntülerdeki piksel değerleri 0 ile 255 aralığından 0 ile 1 aralığına normalize edilmiştir. Böylece modelin öğrenme sürecinde daha istikrarlı bir ağırlık güncellemesi sağlanmış ve ani sapmaların önüne geçilmiştir.

Görüntü işleme sürecinde dikkat edilen en önemli konulardan biri, modelin aşırı öğrenmesini (overfitting)

önleyerek genelleme yeteneğini artırmaktır. Bu amaçla eğitim verisi üzerinde çeşitli veri artırma (data augmentation) teknikleri uygulanmıştır. Bu işlemler arasında yatay çevirme (horizontal flip), rasgele döndürme (random rotation) ve yakınlaştırma (random zoom) yer almaktadır. Uygulanan bu artırma yöntemleri, modelin farklı görüntü varyasyonları karşısında daha dayanıklı hale gelmesini sağlamış ve sınırlı sayıda veriyle daha geniş bir örüntü uzayı öğrenmesini mümkün kılmıştır.

Tüm bu işlemler, TensorFlow veri pipeline'ı içerisinde GPU uyumlu olacak şekilde optimize edilmiş ve her bir adım otomatik olarak eğitim sırasında uygulanmıştır. Bu sayede hem ön işleme süreci hızlandırılmış hem de eğitim verisinin çeşitliliği artırılmıştır. Bu sürecin genel akışı Şekil 2'de görsel olarak sunulmuştur.



Şekil 2. Görüntü Ön İşleme ve Model Girişine Hazırlık Akış Şeması

C. Derin Öğrenme Modeli

Bu çalışmada, bitki yapraklarında görülen hastalıkların sınıflandırılması amacıyla derin öğrenme temelli bir görüntü işleme yaklaşımı benimsenmiştir. Modelin temel yapı taşı olarak, yaygın şekilde kullanılan ve ImageNet veri seti üzerinde önceden eğitilmiş ResNet50 (Residual Network) mimarisi tercih edilmiştir. ResNet50, özellikle derin modellerde karşılaşılan öğrenme güçlüklerini artık bağlantılar (residual connections) sayesinde aşmakta ve derinlik arttıkça doğruluk kaybını engelleyebilmektedir.

Modelin başlangıç kısmı, ResNet50'nin önceden eğitilmiş katmanlarından oluşmakta ve bu katmanlar, ilk eğitim aşamasında dondurularak (freeze) yalnızca özellik çıkarımı amacıyla kullanılmıştır. Bu yaklaşım sayesinde model, genel görsel desenlere dair daha önce öğrenilmiş bilgileri doğrudan kullanarak, eğitim sürecini hızlandırmakta ve küçük veri kümeleriyle bile etkili performans göstermektedir.

ResNet50 mimarisinin üstüne, bu çalışmaya özel bir sınıflandırma bloğu (head) eklenmiştir. Bu blok; sırayla Global Average Pooling, Batch Normalization, Dropout (oran: 0.5), 256 nöronlu ReLU aktivasyonlu bir Dense katman ve son olarak 38 sınıfı temsil eden softmax aktivasyonlu çıkış katmanından oluşmaktadır. Modelin çıkış katmanı, PlantVillage veri kümesindeki 38 hastalık sınıfına karşılık gelen olasılık dağılımını üretmektedir.

Modelin eğitimi sırasında, GPU kaynaklarının daha verimli kullanılabilmesi için TensorFlow'un mixed precision (karma hassasiyetli hesaplama) politikası uygulanmıştır. Bu yöntem, eğitim sürecinde hesaplamaların bir kısmını 16-bit

hassasiyetle gerçekleştirerek daha hızlı ve daha az bellek tüketen bir süreç sunar.

Eğitim süreci iki aşamalı olarak gerçekleştirilmiştir:

1. **Ön Eğitim (head eğitimi):** İlk aşamada, sadece sonradan eklenen sınıflandırma katmanları eğitime açık bırakılmıştır. Bu aşamada, Adam optimizasyon algoritması (öğrenme oranı: $1e-4$), categorical crossentropy kayıp fonksiyonu ve batch size: 64 parametreleri kullanılmıştır.
2. **İnce Ayar (fine-tuning):** Başarı oranları değerlendirildikten sonra, ResNet50'nin son 10 katmanı yeniden eğitime açılmış ve model, öğrenme oranı $1e-5$ ile tekrar eğitilmiştir. Bu süreç, modelin hem genel hem de veri kümesine özgü özellikleri daha iyi öğrenmesini sağlamıştır.

Modelin aşırı öğrenmesini (overfitting) engellemek ve en iyi sonuçları alabilmek amacıyla aşağıdaki erken durdurma stratejileri uygulanmıştır:

- **EarlyStopping:** Doğrulama kaybı belirli bir sürede iyileşmezse eğitimi sonlandırır.
- **ReduceLRonPlateau:** Doğrulama kaybı sabit kalırsa öğrenme oranını düşürür.
- **ModelCheckpoint:** En düşük doğrulama kaybına sahip modeli kaydeder.

Veri kümesi; eğitim, doğrulama ve test olarak %80-%10-%10 oranında üçe ayrılmış ve TensorFlow tf.data API kullanılarak optimize edilmiş veri akışları oluşturulmuştur. Ayrıca eğitim verisine, gerçekçilikten ödün vermeden çeşitlilik katmak amacıyla veri artırma (data augmentation) uygulanmıştır. Bu kapsamda, RandomFlip, RandomRotation ve RandomZoom gibi işlemler kullanılmıştır. Bu teknikler sayesinde modelin genelleme yeteneği artırılmıştır.

Model eğitimi sonucunda elde edilen başarı oranları, eğitim ve doğrulama setlerindeki doğruluk ve kayıp değerleri ile takip edilmiş; süreç sonunda test verisi üzerinde modelin performansı değerlendirilmiştir. Değerlendirme sürecinde, modelin sınıflandırma başarısını confusion matrix ve classification report gibi metriklerle detaylı şekilde analiz edilmiştir.

Sonuç olarak, geliştirilen model, yüksek doğruluk oranıyla bitki hastalıklarını sınıflandırabilmekte ve mobil uygulama entegrasyonuna uygun, hızlı ve hafif bir yapıya sahiptir. Model, .keras formatında dışa aktarılmış ve kullanıcıların yükleyeceği bitki yaprağı görüntüleri üzerinden gerçek zamanlı teşhis yapabilecek şekilde kullanıma hazır hale getirilmiştir.

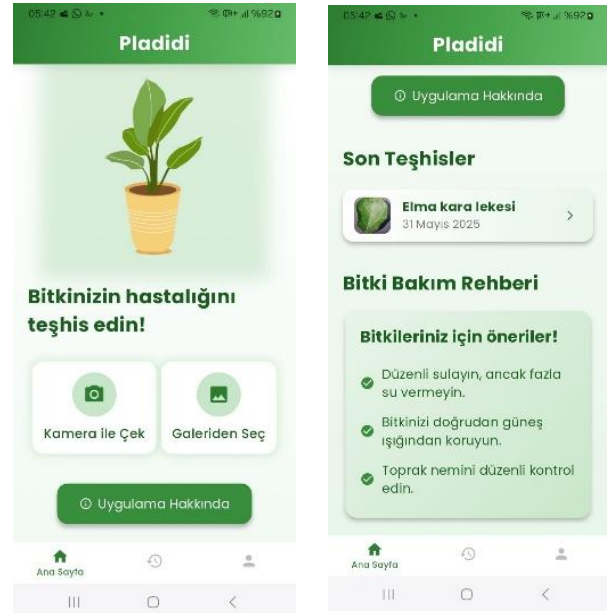
Modelin katman yapısı ve her bir bileşenin teknik özellikleri, Tablo 2. Modelin Katman Yapısı başlığı altında detaylı bir şekilde sunulmuştur. Bu tablo, modelin girişten çıkışa kadar olan tüm bileşenlerini; çıkış boyutları, aktivasyon türleri ve işlevleri ile birlikte özetlemektedir.

Tablo 2. Modelin Katman Yapısı

Katman Adı	Çıkış Şekli	Aktivasyon	Açıklama
Input	(224, 224, 3)	-	Giriş görüntüsü
ResNet50 (dondurulmuş)	(7, 7, 2048)	-	Özellik çıkarım katmanları
GlobalAveragePooling 2D	(2048,)	-	Özellik özetleme
BatchNormalization	(2048,)	-	Normalize
Dense (256)	(256,)	ReLU	Tam bağlantı katmanı
Dropout (0.5)	(256,)	-	Aşırı öğrenmeyi önleme
Dense (38)	(38,)	Softmax	Sınıf tahmini

D. Mobil uygulama arayüzü ve kullanıcı deneyimi

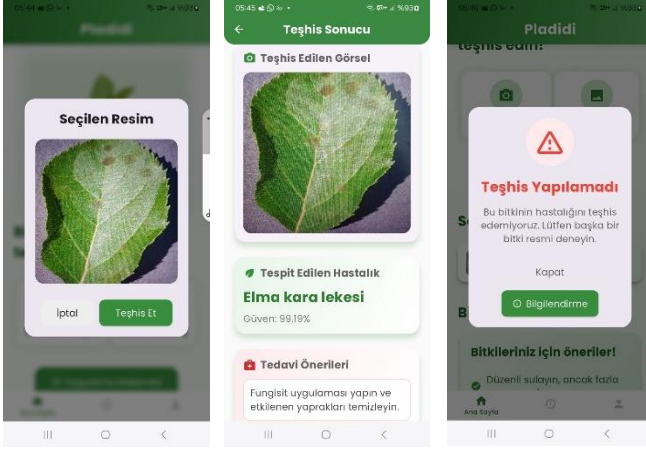
Uygulamanın tasarımında sade ve kullanıcı dostu bir arayüz tercih edilmiştir. Özellikle kırsal bölgelerde yaşayan ve dijital teknolojilere çok aşina olmayan kullanıcılar düşünülerek, ekranlar basit ve anlaşılır şekilde düzenlenmiştir. Kullanıcı arayüzü flutter ile model entegrasyonu için FastAPI tabanlı bir REST servis altyapısı kullanıldı. Şekil 3'te görüldüğü üzere, kullanıcı uygulamaya giriş yaptığında karşısına çıkan ana ekran ile karşılaşılıyor. Kullanıcı eğer daha önce kayıt olup giriş yaptıysa, bu ekrandan kamerayla anlık yaprak fotoğrafı çekebilir ya da galeriden görsel seçerek teşhis sürecini başlatabilir. Uygulamanın nasıl çalıştığına dair tüm bilgilere "Uygulama Hakkında" butonu aracılığıyla ulaşılabilmektedir. Şekil 3- Şekil 5'te geliştirilen uygulamanın ekran görüntüleri sunulmuştur. Eğer ki kullanıcı daha önce teşhis yapmışsa son iki teşhis sonucu tarih bilgisiyile birlikte listelenmektedir. Ayrıca sayfanın alt kısmında, bitki sağlığına yönelik genel önerilerin yer aldığı sabit bir "Bitki Bakım Rehberi" alanı da bulunmaktadır.



Şekil 3. Uygulama Ana Sayfa Ekranı



Şekil 4. Bilgilendirme Sayfası



Şekil 5. Görsel Seçimi ve Sonuç Ekranı

Kullanıcı, galeriden ya da kamerayla bir yaprak görseli seçtikten sonra bu ekran karşısına çıkmaktadır. Seçilen görselin netliğini kontrol ettikten sonra kullanıcı "Teşhis Et" butonuna tıklayarak teşhis sürecini başlatabilir. Eğer seçilen yaprak modeli eğitim verisinde yer alıyorsa, sistem bu görseli tanıır ve kullanıcının karşısına hastalığın adı, teşhis güven oranı ve önerilen tedavi bilgileriyle birlikte detaylı bir sonuç ekranı getirir. Eğer sistem, yüklenen yaprak görüntüsünü tanımlayamazsa ya da eğitim veri setinde benzer bir sınıf bulunmuyorsa, "Teşhis Yapılamadı" uyarısı ile kullanıcı bilgilendirilir ve yeni bir görsel denemesi istenir.

III. BULGULAR

Bu çalışmada geliştirilen ResNet50 tabanlı derin öğrenme modeli, PlantVillage veri seti üzerinde yürütülen eğitim ve doğrulama süreçlerinde yüksek sınıflandırma başarımları sergilemiştir. Modelin eğitim süreci iki aşamalı olarak tasarlanmıştır. İlk aşamada yalnızca son katmanlar eğitime açık bırakılmış ve bu bölüm 30 epoch boyunca sürdürülmüştür. Ardından modelin son 10 katmanı eğitime dahil edilerek fine-tuning uygulanmıştır. Bu sayede, modelin hem genel hem de veri kümesine özgü özellikleri öğrenmesi

sağlanmıştır. Eğitim süreci boyunca erken durdurma (EarlyStopping), öğrenme oranı azaltma (ReduceLROnPlateau) ve en iyi ağırlıkları kaydetme (ModelCheckpoint) gibi stratejiler kullanılmıştır. Bu yöntemler, modelin doğrulama verisi üzerinde istikrarlı performans göstermesine önemli katkı sağlamıştır.

Eğitim sonuçları incelendiğinde, modelin doğruluk sonuçları her iki aşamada da hızlı bir artış göstermiş ve birkaç epoch içinde stabil bir hale gelmiştir. Başlangıç eğitiminin sonunda doğrulama doğruluğu %96,35, eğitim doğruluğu ise %95,30 olarak gerçekleşmiştir (Bkz. Tablo 3). Fine-tuning sonrasında bu değerler sırasıyla %97,15 ve %96,99 düzeyine yükselmiştir (Bkz. Tablo 4). Bu bulgular, modelin dengeli ve aşırı öğrenmeden uzak bir yapı kazandığını göstermektedir.

Benzer şekilde, kayıp değerleri de eğitim boyunca düzenli olarak azalmış, eğitim ve doğrulama kayıpları arasında belirgin bir fark oluşmamıştır. Bu durumsa, modelin hem öğrenme verisine hem de hiç görmediği doğrulama verisine karşı yüksek genelleme yeteneğine sahip olduğunu ortaya koymaktadır.

Ayrıca, eğitim sürecinde uygulanan veri artırma (data augmentation) teknikleri özellikle yatay çevirme, döndürme ve yakınlaştırma işlemleri modelin farklı görüntü varyasyonlarına karşı da daha esnek ve dayanıklı hale gelmesine katkı sağlamıştır.

Sonuç olarak, geliştirilen sistem, bitki yapraklarındaki hastalık belirtilerini yüksek doğrulukla sınıflandırmış, PlantVillage veri setinde güçlü bir performans ortaya koymuş ve mobil sistemlerle entegre edilebilecek verimlilikte bir mimari sunmuştur.

Tablo 3. Başlangıç Eğitimi Sonuçları

Metrik	Eğitim verisi	Doğrulama verisi
Doğruluk (Accuracy)	%95,30	%96,35
Kayıp (Loss)	0,1414	0,1026
Öğrenme Oranı (LR)	2.5×10^{-5}	-
Epoch Sayısı	30	30

Tablo 4. İnce Ayar (Fine-tuning) Sonuçları

Metrik	Eğitim verisi	Doğrulama verisi
Doğruluk (Accuracy)	%96,99	%97,15
Kayıp (Loss)	0,0863	0,0847
Öğrenme Oranı (LR)	1.0×10^{-5}	-
Epoch Sayısı	10	10

IV. TARTIŞMA

Bu çalışmada, ResNet50 tabanlı derin öğrenme mimarisi kullanılarak PlantVillage veri seti üzerinde gerçekleştirilen sınıflandırma işlemi yüksek doğruluk oranları ile tamamlanmıştır. Model, başlangıçta donuk (frozen) olarak kullanılan ağırlıklarla eğitilmiş; ardından son 10 katmanın açılmasıyla birlikte düşük öğrenme oranı ile fine-tuning yapılmıştır. Bu iki aşamalı strateji, modelin hem genel hem de sınıf bazlı doğruluğunu önemli ölçüde artırmıştır.

Elde edilen sonuçlar, benzer çalışmalardaki bulgularla tutarlılık göstermektedir. Mohanty, Hughes ve Salathé (2016) tarafından yürütülen ve aynı veri setine dayalı bir çalışmada, AlexNet ve GoogLeNet gibi mimarilerle sırasıyla %94,3 ve %99,3 doğruluk elde edildiği bildirilmiştir [18]. Bizim çalışmamızda kullanılan ResNet50 modeli, daha derin katman yapısı ve residual bağlantılar sayesinde sınıflar arası görsel benzerliklerin neden olabileceği sınıflandırma hatalarını azaltma konusunda daha başarılı olmuştur. Nitekim, fine-

tuning sonrası doğrulama doğruluğu %97 seviyelerine ulaşmıştır.

Modelin başarısındaki bir diğer etken, veri artırma (augmentation) tekniklerinin etkin şekilde uygulanmasıdır. Özellikle yatay çevirme, döndürme ve yakınlaştırma gibi basit ama etkili augmentasyonlar sayesinde model, çeşitli görsel varyasyonlara karşı dayanıklılık kazanmıştır. Bu da özellikle veri dengesizliğinin bulunduğu sınıflarda modelin genelleme gücünü artırmıştır.

Bununla birlikte, sınıflar arasında bazı yapısal benzerliklerin sınıflandırma performansını sınırladığı durumlar gözlenmiştir. Örneğin, bazı domates hastalıkları arasında görsel benzerlik çok yüksek olup, bu sınıflar arasında karışıklık yaşanabilmektedir. Bu durum, Confusion Matrix gibi detaylı analizlerle desteklenerek tespit edilmiştir. Bu tür sınıflar için ileride özellik çıkarımında dikkat çekici bölgelerin ön plana çıkarıldığı dikkat mekanizmalarının (attention mechanisms) entegrasyonu önerilebilir.

Ayrıca, model yalnızca sabit veri kümesi üzerinde test edilmiştir. Bu nedenle saha koşullarındaki doğal ışık, arka plan gürültüsü, yaprak deformasyonu gibi etkenlerin model performansı üzerindeki etkisi henüz değerlendirilmemiştir. Gelecekte, bu sistemin mobil uygulamalara entegre edilerek farklı çevre koşullarında da test edilmesi planlanmaktadır.

Sonuç olarak, bu çalışma, ResNet50 mimarisinin bitki hastalıklarının sınıflandırılması görevinde hem literatürle uyumlu hem de pratikte uygulanabilir bir çözüm sunduğunu göstermektedir.

V. SONUÇ

Bu çalışma kapsamında, ResNet50 tabanlı derin öğrenme mimarisi kullanılarak bitki hastalıklarının sınıflandırılması gerçekleştirilmiş ve model, PlantVillage veri seti üzerinde yüksek doğruluk oranlarıyla başarılı bir şekilde eğitilmiştir. Transfer öğrenme ve fine-tuning stratejilerinin yanı sıra veri artırma tekniklerinin de etkin kullanımı sayesinde modelin doğrulama doğruluğu %97'nin üzerine çıkmıştır. Bu başarı, modelin farklı sınıflar arasında güçlü ayırt edici özellikler öğrenebildiğini göstermektedir.

Literatürde benzer hedeflere sahip farklı modellerle yürütülen çalışmalarda da benzer başarılar elde edilmiştir. Örneğin, Brahimi et al. 2017 yılında yaptığı bir çalışmada, LeNet, AlexNet ve VGG16 mimarilerini kullanarak bitki hastalıklarının sınıflandırılmasında en yüksek %96,3 doğruluk elde ettiklerini rapor etmişlerdir [19]. Diğer bir çalışmada, Ferentinos (2018), yedi farklı CNN mimarisini kıyaslayarak VGG-16 ve AlexNet ile %99'un üzerinde doğruluk oranlarına ulaşmıştır; ancak bu oranların çoğu overfitting riski taşıyan küçük test kümelerine dayalıdır [20]. Bizim çalışmamızda ise model yalnızca eğitim başarımı ile değil, doğrulama sürecindeki kararlılığı ve genellenebilirliği ile de öne çıkmıştır.

Ayrıca eğitim sürecinde kullanılan gelişmiş callback stratejileri (erken durdurma, öğrenme oranı azaltma, en iyi modeli kaydetme) ve GPU tabanlı veri artırma yaklaşımları, modelin aşırı öğrenme eğiliminden uzak durmasına katkı sağlamıştır. Tüm bu faktörler, sadece teorik değil, pratik olarak da sahada uygulanabilecek bir sınıflandırma sisteminin temel taşlarını oluşturmaktadır.

Gelecekte, bu modelin gerçek tarla görüntüleri ile test edilmesi, mobil sistemlere entegre edilerek gerçek zamanlı analiz yapabilmesi ve kullanıcı arayüzü geliştirilmesi

hedeflenmektedir. Bu tür uygulamalar, küçük ve orta ölçekli çiftçiler için tarımsal üretimde karar destek mekanizması sunma potansiyeline sahiptir.

TEŞEKKÜR

Bu çalışma, 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında TÜBİTAK tarafından desteklenmiştir. (1919B012452587 referans numaralı proje)

REFERANSLAR

- [1] A. Ali. (2019). *PlantVillage Dataset*. Available: <https://www.kaggle.com/datasets/abdallahalidev/plantvillage-dataset>
- [2] G. Lilienthal, N. Ahmad, and P. Hodgkinson. "The conflict between farmers rights in the Food and Agriculture Organization (FAO) treaty and corporate plant breeder laws," Intellectual Property Forum, 2018.
- [3] E.-C. Oerke and H.-W. Dehne, "Safeguarding production—losses in major crops and the role of crop protection," *Crop protection*, vol. 23, pp. 275-285, 2004.
- [4] J. Hearty, *Advanced machine learning with Python*: Packt Publishing Ltd, 2016.
- [5] C. Topçu and P. Güneş, "Bitki hastalıklarını tespit için derin öğrenme: ResNet modelinin etkinliği," *Anadolu Bil Meslek Yüksekokulu Dergisi*, vol. 19, pp. 31-65, 2024.
- [6] S. Lindow and R. Webb, "Quantification of foliar plant disease symptoms by microcomputer-digitized video image analysis," *Phytopathology*, vol. 73, pp. 520-524, 1983.
- [7] D. P. Martin and E. P. Rybicki, "Microcomputer-based quantification of maize streak virus symptoms in Zea mays," *Phytopathology*, vol. 88, pp. 422-427, 1998.
- [8] J. G. A. Barbedo, "A review on the main challenges in automatic plant disease identification based on visible range images," *Biosystems engineering*, vol. 144, pp. 52-60, 2016.
- [9] J. Boulent, S. Foucher, J. Théau, and P.-L. St-Charles, "Convolutional neural networks for the automatic identification of plant diseases," *Frontiers in plant science*, vol. 10, p. 941, 2019.
- [10] S. H. Lee, C. S. Chan, S. J. Mayo, and P. Remagnino, "How deep learning extracts and learns leaf features for plant classification," *Pattern recognition*, vol. 71, pp. 1-13, 2017.
- [11] M. Loey, A. ElSawy, and M. Afify, "Deep learning in plant diseases detection for agricultural crops: a survey," *International Journal of Service Science, Management, Engineering, and Technology (IJSSMET)*, vol. 11, pp. 41-58, 2020.
- [12] N. Fu, C. Wang, and X. Ji, "Study on Visual Detection Device of Plant Leaf Disease," in *2019 IEEE International Conference on Mechatronics and Automation (ICMA)*, 2019, pp. 86-90.
- [13] M. A. Iqbal and K. H. Talukder, "Detection of potato disease using image segmentation and machine learning," in *2020 international conference on wireless communications signal processing and networking (WiSPNET)*, 2020, pp. 43-47.
- [14] F. Qin, D. Liu, B. Sun, L. Ruan, Z. Ma, and H. Wang, "Identification of alfalfa leaf diseases using image recognition technology," *PloS one*, vol. 11, p. e0168274, 2016.
- [15] A. Ahmad, D. Saraswat, and A. El Gamal, "A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools," *Smart Agricultural Technology*, vol. 3, p. 100083, 2023.
- [16] S. Ltd. (2019). *Agrio*. Available: <https://agrio.app/Tree-Doctor-App-Revolutionizing-Agronomy-with-AI/>
- [17] Bayer. (2022). *MagicScout*. Available: <https://magicscout.app/en>
- [18] Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. <https://doi.org/10.3389/fpls.2016.01419>
- [19] Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep Learning for Tomato Diseases: Classification and Symptoms Visualization. *Applied Artificial Intelligence*, 31(4), 299-315. <https://doi.org/10.1080/08839514.2017.1315516>
- [20] Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318. <https://doi.org/10.1016/j.compag.2018.01.009>