

Derin Öğrenme Tabanlı Bitki Hastalıkları Tespit ve Tahmin Sistemi: PlantVillage Veri Seti ile Uygulama

B. Demir^{1*}, A. Aksoy², Y. Dokuz³, B. Şen⁴

¹ Niğde Ömer Halisdemir Üniversitesi, Ayhan Şahenk Tarım Bilimleri ve Teknolojileri Fakültesi, Disiplinlerarası Dijital Tarım Anabilim Dalı, 51240, Niğde, Türkiye.

² Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, 51240, Niğde, Türkiye. E-mail: abdurrahman_aksoy@outlook.com.tr

³ Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, 51240, Niğde, Türkiye. E-mail: ytorun@ohu.edu.tr

⁴ Niğde Ömer Halisdemir Üniversitesi, Ayhan Şahenk Tarım Bilimleri ve Teknolojileri Fakültesi, Biyosistem Mühendisliği, 51240, Niğde, Türkiye. E-mail: bsen@ohu.edu.tr

Sorumlu Yazar: Betül Demir, Ömer Halisdemir Üniversitesi, Ayhan Şahenk Tarım Bilimleri ve Teknolojileri Fakültesi, Disiplinlerarası Dijital Tarım Anabilim Dalı, 51240, Niğde, Türkiye.

Tel: +90 551 884 92 58; E-mail: betuldemir339@gmail.com

Betül Demir ORCID: <https://orcid.org/0000-0002-4388-1122>

Abdurrahman Aksoy ORCID: <https://orcid.org/0009-0009-1077-7925>

Yeşim Dokuz ORCID: <https://orcid.org/0000-0001-7202-2899>

Burak Şen ORCID: <https://orcid.org/0000-0001-8105-1106>

Özet

Bitki hastalıkları, tarımsal verimliliği tehdit eden en önemli faktörlerden biri olup, küresel gıda güvenliği açısından ciddi riskler oluşturmaktadır. Geleneksel hastalık teşhis yöntemleri; zaman alıcı, maliyetli ve insan hatasına açık yapılarından ötürü geniş tarım alanlarında yetersiz kalmaktadır. Bu çalışmada, bitki hastalıklarının otomatik ve yüksek doğrulukla teşhisine yönelik bir derin öğrenme yaklaşımı geliştirilmiştir. Kapsamlı, etiketlenmiş ve yüksek kaliteli görsellerden oluşan PlantVillage veri seti kullanılarak Evrişimli Sinir Ağı (Convolutional Neural Network - CNN) tabanlı özel bir model tasarlanmış ve 9 farklı bitki türüne ait 29 sınıf üzerinde çoklu sınıflandırma gerçekleştirilmiştir. Veri setinde gözlenen sınıf dengesizliği sorununu azaltmak amacıyla veri artırımı gibi çeşitli dengeleme teknikleri uygulanmıştır. Modelin aşırı öğrenmesini (overfitting) önlemek için bırakma (dropout), erken durdurma (early stopping) ve model kayıt noktası (model checkpoint) gibi düzenleme yöntemlerinden yararlanılmıştır. Eğitim süreci boyunca doğruluk, kesinlik, duyarlılık gibi performans metrikleri ile model başarımları detaylı olarak izlenmiş ve grafiksel olarak görselleştirilmiştir. Elde edilen sonuçlar, önerilen yaklaşımın hem genel doğruluk hem de azınlık sınıflardaki performans açısından başarılı olduğunu göstermektedir. Geliştirilen sistemin, gelecekte insansız hava araçlarına veya gömülü sistemlere entegre edilerek geniş tarım alanlarında gerçek zamanlı hastalık takibi ve erken müdahale imkânı sunabileceği öngörülmektedir. Bu yönüyle çalışma, sürdürülebilir ve akıllı tarım uygulamalarına katkı sağlamayı amaçlamaktadır.

Anahtar Kelimeler: Bitki hastalıkları, Derin öğrenme, CNN, Görüntü işleme, Akıllı tarım

Deep Learning-Based Plant Disease Detection and Prediction System: An Application Using the PlantVillage Dataset

Abstract

Plant diseases are among the most significant threats to agricultural productivity and pose serious risks to global food security. Traditional disease diagnosis methods are time-consuming, costly, and prone to human error, making them insufficient for large-scale agricultural applications. In this study, a deep learning-based approach was developed for the automatic and highly accurate detection of plant diseases. A custom Convolutional Neural Network (CNN) model was designed using the comprehensive, labeled, and high-quality images from the

PlantVillage dataset, and multi-class classification was performed on 29 classes across 9 different plant species. To mitigate the issue of class imbalance observed in the dataset, various balancing techniques such as data augmentation were applied. Regularization methods including dropout, early stopping, and model checkpointing were employed to prevent overfitting. During the training process, model performance was closely monitored using metrics such as accuracy, precision, and recall, and visualized through graphical representations. The results demonstrate that the proposed approach performs successfully in terms of overall accuracy as well as in recognizing minority classes. It is anticipated that the developed system could be integrated into unmanned aerial vehicles or embedded systems in the future, enabling real-time disease monitoring and early intervention across large agricultural areas. In this regard, the study aims to contribute to sustainable and smart farming practices.

Keywords: Plant diseases, Deep learning, CNN, Image processing, Smart agriculture

Giriş

Tarım, yalnızca insan yaşamının sürdürülebilirliği için değil, aynı zamanda ekosistem içindeki canlıların besin zincirinin devamı açısından da kritik bir öneme sahiptir. Günümüzde hızla artan dünya nüfusu, tarımsal üretime olan talebi önemli ölçüde artırmakta; bu artış, verimli ve sürdürülebilir üretim yöntemlerinin benimsenmesini zorunlu kılmaktadır. Ancak tarımsal üretimi tehdit eden en önemli faktörlerden biri bitki hastalıklarıdır (Topçu ve Güneş, 2024). Özellikle yaprak kaynaklı hastalıklar, bitkinin fotosentez kapasitesini azaltarak gelişimini engellemekte ve ciddi ürün kayıplarına yol açmaktadır (Sethy ve diğerleri, 2020b; Kaur ve Gautam, 2021).

Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO)'ne göre zararlı organizmalar ve hastalıklar, küresel tarımsal üretimin %20 ila %40'ına kadar kayıplara neden olabilmektedir (Savary, 2020). 2050 yılına kadar dünya nüfusunun 9 milyarı aşacağı öngörülmekte ve bu doğrultuda mevcut tarım üretiminin en az %60 oranında artırılması gerektiği belirtilmektedir (Tripathi vd., 2019). Bu da, üretim verimliliğini artıracak, doğru ve zamanında müdahale imkânı sunacak teknolojilere olan ihtiyacı daha da kritik hâle getirmiştir. Bitki hastalıklarının erken ve doğru teşhisi, hastalıkla mücadelenin etkinliği açısından büyük önem taşımaktadır (Erdoğan, 2024).

Geleneksel hastalık teşhis yöntemleri; mikroskopik analizler, moleküler testler, kimyasal değerlendirmeler ve görsel gözlemler gibi yöntemlere dayanmaktadır. Ancak bu yöntemler yüksek maliyetli, zaman alıcı ve geniş tarım alanlarında uygulanması zor sistemlerdir. Ayrıca bu süreçler, çoğunlukla uzman yorumlarına dayandığından hataya açık ve subjektiftir (Al-Hiary ve diğerleri, 2011; Luckey, 2012).

Bu noktada bilgisayarlı görü, makine öğrenmesi ve yapay zekâ tabanlı çözümler ön plana çıkmaktadır. Görüntü işleme ve örüntü tanıma teknikleri, bitki yapraklarındaki semptomları analiz ederek hastalıkların otomatik ve yüksek doğrulukla teşhis edilmesine imkân tanımaktadır (Chen vd., 2020). Evrişimli Sinir Ağı (Convolutional Neural Network - CNN) gibi derin öğrenme mimarileri, bu doğruluk oranlarını artırarak yaygın uygulama alanı bulmuştur (Guo, 2020).

Bitki hastalıklarının tespiti için geliştirilen yapay zekâ destekli sistemler; erken müdahale süreçlerini hızlandırmakta, pestisit kullanımını optimize ederek çevresel etkileri azaltmakta ve üretim maliyetlerini düşürerek çiftçilerin ekonomik sürdürülebilirliğini artırmaktadır (Waheed vd., 2020). Bu doğrultuda derin öğrenme temelli sistemlerin tarıma entegrasyonu, akıllı tarım uygulamalarının önünü açmakta ve gıda güvenliğini sağlamada önemli katkılar sunmaktadır (Malhi ve diğerleri, 2021; Martinelli ve diğerleri, 2015).

Bu çalışmada kullanılan PlantVillage veri seti, yapay ve doğal arka planlara sahip toplam 67.118 yaprak görüntüsünden oluşmakta olup, 9 farklı bitki türüne ait 29 sınıf içermektedir (AbdallahAliDev,2022). Veri seti, hem sağlıklı hem de çeşitli hastalıklarla enfekte yaprak görüntülerini içeren, etiketlenmiş ve yüksek kaliteli bir veri kümesidir. Bu yönüyle PlantVillage veri seti, tarımda yaygın şekilde kullanılan referans bir kaynak niteliğindedir.

Araştırmanın temel amacı, geleneksel yöntemlerin sınırlı kaldığı noktalarda yapay zekâ destekli sistemlerin verimliliğini ortaya koymak ve sınıf dengesizliği, veri artırımı, erken durdurma gibi stratejilerle model başarımını artırmaktır. Eğitim süreci boyunca uygulanan dropout, early stopping ve model checkpoint gibi düzenleme tekniklerinin aşırı öğrenmeyi önlediği; grafiksel analizlerle yapılan değerlendirmelerde ise modelin özellikle azınlık sınıflardaki başarı düzeyinin yükseldiği görülmüştür. Çalışmada geliştirilen sistemin, ilerleyen dönemlerde insansız hava araçları veya gömülü sistemler ile entegre edilerek geniş tarım arazilerinde gerçek zamanlı hastalık takibi ve erken müdahale süreçlerinde kullanılması hedeflenmektedir (Guo, 2020; Sethy ve diğerleri, 2020). Böylelikle hem ürün verimliliği artırılabilecek hem de pestisit kullanımının azaltılması yoluyla çevre dostu tarım uygulamalarına katkı sağlanacaktır. Sonuç olarak bu çalışma, hem akademik hem de pratik anlamda modern tarımın dijitalleşme sürecine katkı sunmayı; çiftçiler ve tarım uzmanları için güvenilir, ölçeklenebilir ve kolay erişilebilir bir tanı sistemi geliştirmeyi amaçlamaktadır.

Materyal ve Yöntem

PlantVillage Veri Seti ve Kullanılan Sınıflar:

Bu çalışmada kullanılan PlantVillage veri seti, yapay ve doğal arka planlara sahip toplam 67.118 yaprak görüntüsünden oluşur ve 9 farklı bitki türüne ait 29 sınıfı içerir (AbdallahAliDev, 2022). Bu sınıflar, her bir bitki türüne özgü çeşitli hastalıkları ve sağlıklı yaprakları kapsamaktadır. Söz konusu çeşitlilik, geliştirilen modelin sınıflandırma performansını değerlendirmek açısından zengin ve dengeli bir test ortamı sunmaktadır. Tablo 1, veri setinde yer alan bitki türlerine ait sınıflar ile bunlara karşılık gelen görüntü sayılarını göstermekte, veri setinin kapsamı hakkında genel bir bakış sağlamaktadır.

Tablo 1. PlantVillage veri setinde yer alan bitki türleri, sınıflar (hastalık/sağlıklı) ve görüntü sayıları.

Sınıf	Bitki Türü	Hastalık/Sağlıklı Sınıf	Görüntü Sayısı
1	Elma (Apple)	Apple Scab (Elma Kabuk Lekesi Hastalığı)	2016
		Black Rot (Elma Kara Çürüklüğü)	1987
		Cedar Apple Rust (Sedir Elma Pası)	1760
		Healthy (Sağlıklı)	2008
2	Şeftali (Peach)	Bacterial Spot (Bakteriyel Leke)	1838
		Healthy (Sağlıklı)	1728
3	Üzüm (Grape)	Black Rot (Kara Çürüklük)	1888
		Esca (Black Measles) (Esca Hastalığı - Siyah Kızamık)	1920
		Leaf Blight (Yaprak Yanıklığı)	1722
		Healthy (Sağlıklı)	1692
4	Patates (Potato)	Early Blight (Erken Yanıklık)	1939
		Late Blight (Geç Yanıklık)	1939
		Healthy (Sağlıklı)	1824
5	Çilek (Strawberry)	Leaf Scorch (Yaprak Yanığı)	1774
		Healthy (Sağlıklı)	1824
6	Domates (Tomato)	Bacterial Spot (Bakteriyel Leke)	1702
		Early Blight (Erken Yanıklık)	1920
		Late Blight (Geç Yanıklık)	1851
		Leaf Mold (Yaprak Küfü)	1746
		Mosaic Virus (Mozaik Virüsü)	1676
		Yellow Leaf Curl Virus (Sarı Yaprak Kıvrıklık Virüsü)	1961
		Healthy (Sağlıklı)	1926
7	Dolmalık Biber (Bell Pepper)	Bacterial Spot (Bakteriyel Leke)	1913
		Healthy (Sağlıklı)	1988
8	Mısır (Corn)	Cercospora Leaf Spot (Cercospora Lekeli Yaprak Hastalığı)	1642
		Common Rust (Ortak Pas Hastalığı)	1907
		Northern Leaf Blight (Kuzey Yaprak Yanıklığı)	1908
		Healthy (Sağlıklı)	1859
9	Kiraz (Cherry)	Powdery Mildew (Külleme Hastalığı)	1683
		Healthy (Sağlıklı)	1826

Veri Ön İşleme

Derin öğrenme modellerinin etkinliğini artırmak ve genelleme kabiliyetini geliştirmek amacıyla bu çalışmada çeşitli veri ön işleme teknikleri uygulanmıştır. Bu adımlar, görüntülerin modele uygun formata dönüştürülmesini sağlayarak, öğrenme sürecinin daha kararlı ve doğru bir şekilde gerçekleşmesini hedeflemiştir. Uygulanan işlemler dört ana başlıkta özetlenmektedir:

Görüntü Normalizasyonu

Ham görüntü verileri genellikle 0 ile 255 aralığında piksel değerlerine sahiptir. Modelin daha kararlı bir şekilde öğrenmesini sağlamak amacıyla, bu çalışmada tüm görüntüler ImageDataGenerator sınıfı kullanılarak 1/255 oranında ölçeklendirilmiş ve böylece tüm piksel değerleri [0, 1] aralığına indirgenmiştir. Bu normalizasyon işlemi, öğrenme sürecinde ağırlıkların daha dengeli güncellenmesine ve hesaplama istikrarının artmasına katkı sağlamıştır.

Veri Artırma

Modelin sınırlı eğitim verisiyle daha iyi genelleme yapabilmesi için eğitim verilerine veri artırma (data augmentation) teknikleri uygulanmıştır. Bu teknikler, görüntülerin rastgele ve kontrollü biçimlerde dönüştürülmesi yoluyla modelin farklı varyasyonları tanıma yeteneğini artırmayı ve aşırı öğrenmenin önlenmesini hedeflemektedir. Uygulanan işlemler aşağıda sıralanmıştır:

Döndürme (Rotation): Görüntüler $\pm 20^\circ$ rastgele döndürülmüştür (rotation_range=20). Bu sayede model, farklı açılarda gelen yaprakları tanıyabilmektedir.

Genişlik ve Yükseklik Kaydırma (Width and Height Shift): Görüntüler, genişlik ve yükseklik eksenlerinde %20 oranında kaydırılmıştır (width_shift_range, height_shift_range).


Kesme (Shear): Görüntüler üzerinde perspektif bozulmaları yaratılarak, yapay açısal varyasyonlar oluşturulmuştur.

Yakınlaştırma (Zoom): Görüntüler %20 oranında yakınlaştırılarak (zoom_range=0.2) farklı ölçeklerde tanıma yetisi kazandırılmıştır.

Yatay Çevirme (Horizontal Flip): Görüntüler simetrik olarak yatay ekseninde çevrilmiştir.

Dolgu Modu (Fill Mode): Dönüştürme sonrası oluşan boş alanlar, en yakın piksel değerleriyle doldurularak görsel bütünlük korunmuştur.

Bu işlemler yalnızca eğitim verilerine uygulanmış; doğrulama ve test verileri ise yalnızca normalizasyon işlemine tabi tutulmuştur. Böylece modelin genel performansı, eğitilmeyen yeni veriler üzerinde daha doğru bir şekilde değerlendirilebilmiştir. Aşağıda, uygulanan bazı veri artırma tekniklerinin örnek sonuçları görsel olarak sunulmuştur (Şekil 1):



Şekil

1. Veri artırma tekniklerinin örnek yaprak (1)

Normalizasyon,

Döndürme (Rotation), (3) Kaydırma (Shift), (4) Kesme (Shear), (5) Yakınlaştırma (Zoom), (6) Yatay Çevirme (Flip), (7) Dolgu (Fill Mode)

uygulandığı görüntüleri:

(2)

Eğitim, Doğrulama ve Test Veri Setlerinin Yapılandırılması

Modelin yüksek doğruluk ve güçlü genelleme performansı sergilemesi amacıyla, veri seti split_data() fonksiyonu aracılığıyla eğitim, doğrulama ve test alt kümelerine ayrılmıştır. Bu işlem, her bir sınıf için ayrı ayrı uygulanmış ve train_test_split() fonksiyonu ile sınıf dengesi korunarak gerçekleştirilmiştir. Görüntüler, shutil.copy() komutu kullanılarak ilgili klasör yapılarına aktarılmış ve model eğitimi için uygun hale getirilmiştir. Ayrılan alt kümeler şu şekildedir:

Eğitim Seti (%80 – 53.693 görüntü): Modelin öğrenme sürecini destekleyen bu alt küme, veri çeşitliliğini artırmak amacıyla veri artırma teknikleriyle zenginleştirilmiştir. Bu sayede modelin aşırı öğrenme eğilimi azaltılmış ve sınıf dengesizliklerinin etkisi en aza indirilmiştir.

Doğrulama Seti (%18 – 12.067 görüntü): Eğitim sürecinde modelin performansını değerlendirmek ve hiperparametre ayarlarını optimize etmek amacıyla kullanılmıştır. Her eğitim döngüsü (epoch) sonunda modelin bu küme üzerindeki başarımı izlenmiş ve aşırı öğrenme (overfitting) kontrol altında tutulmuştur.

Test Seti (%2 – 1.358 görüntü): Modelin eğitim sürecinde hiç görmediği, gerçek dünya senaryolarını temsil eden verilerden oluşan bu küme, nihai başarıyı değerlendirmek için kullanılmıştır. Bu aşamada yalnızca doğruluk değil; precision, recall ve F1-score gibi kapsamlı metrikler de hesaplanarak, özellikle azınlık sınıfların öğrenme düzeyi analiz edilmiştir.

Her bir görüntü, modelin giriş boyutuna uygun şekilde 256×256 piksele yeniden ölçeklendirilmiş; eğitim aşamasında batch_size=32 olarak belirlenmiş ve çok sınıflı sınıflandırma problemi kapsamında class_mode='categorical' olarak tanımlanmıştır.

Tüm bu yapılandırma ve ön işleme adımları, modelin istikrarlı, genelleştirilebilir ve verimli bir şekilde öğrenmesini sağlamış; hem eğitim kalitesini hem de değerlendirme doğruluğunu artırmıştır.

Veri Dağılımı ve Dengesizlik Sorunları:

Modelin eğitimi ve değerlendirme sürecinde dikkat çeken önemli bir husus, sınıflar arasında örnek sayısı bakımından belirgin dengesizliklerin bulunmasıdır. Bu durum, veri dengesizliği (data imbalance) problemi olarak tanımlanmakta olup, özellikle azınlık sınıflarda düşük model başarımına yol açabilir. Yapılan ön analizlerde bazı sınıfların örnek sayısının oldukça düşük olduğu tespit edilmiştir (bkz. Tablo 1).

Bu analiz sonuçları, veri artırma stratejilerinin belirlenmesi ve modelin eğitim parametrelerinin optimize edilmesi süreçlerinde temel referans olarak kullanılmıştır. Veri dengesizliğinin olumsuz etkilerini azaltmak ve azınlık sınıfların temsiliyetini artırmak amacıyla aşağıdaki stratejiler değerlendirilmiştir:

Veri Artırma

Uygulanan döndürme, kaydırma, yakınlaştırma ve çevirme gibi teknikler, yalnızca genelleme kapasitesini artırmakla kalmamış; aynı zamanda örnek sayısı az olan sınıflarda çeşitlilik sağlayarak modelin bu sınıfları daha iyi öğrenmesine katkı sunmuştur.

Model Performansının İzlenmesi:

Veri dengesizliğiyle mücadelede, model başarımının yalnızca doğruluk (accuracy) değeriyle değil; aynı zamanda precision, recall ve F1-score gibi sınıf duyarlı metriklerle değerlendirilmesi büyük önem taşımaktadır. Bu çalışmada, eğitim ve doğrulama süreçlerinde söz konusu metrikler ayrı ayrı izlenmiş ve özellikle azınlık sınıflar üzerindeki performans dikkatle analiz edilmiştir. Böylece sınıflar arası dengesizlikten kaynaklanan başarımların sapmaları daha sağlıklı biçimde gözlemlenebilmiştir.

Elde edilen bulgular, uygulanan veri ön işleme adımları ve dengesizlikle mücadele stratejilerinin, modelin genelleme kapasitesini anlamlı ölçüde artırdığını ve özellikle azınlık sınıflarda performans iyileşmesine katkı sağladığını ortaya koymaktadır.

Model Mimarisi ve Eğitim Süreci

Bu çalışmada geliştirilen derin öğrenme modeli, CNN mimarisi temel alınarak oluşturulmuştur. Model, bitki hastalıklarını görüntü sınıflandırması yoluyla tespit etmeye yönelik tasarlanmıştır. Eğitim sürecinde aşırı öğrenmeyi önlemeye yönelik çeşitli stratejiler benimsenmiş, model başarımı çok boyutlu metriklerle değerlendirilmiştir.

Model Mimarisi

Model mimarisi; üç konvolüsyon katmanı, bunları takip eden maksimum havuzlama katmanları, bir düzleştirme katmanı, iki adet tam bağlantılı katman, bir dropout katmanı ve bir çıkış katmanını içermektedir.

Giriş Katmanı: Modelin giriş katmanı, her biri 256×256 piksel boyutunda RGB formatında olan görüntüleri kabul edecek şekilde tanımlanmıştır.

Konvolüsyon Katmanları: Üç konvolüsyon katmanı sırasıyla 32, 64 ve 128 filtre içermektedir. Bu katmanlarda ReLU aktivasyon fonksiyonu kullanılmış ve her katmanda filtre sayısı artırılarak daha karmaşık görsel örüntülerin öğrenilmesi hedeflenmiştir.

Maksimum Havuzlama Katmanları: Her konvolüsyon katmanının ardından gelen maksimum havuzlama katmanları, uzamsal boyutları azaltarak hem modelin hesaplama yükünü azaltmakta hem de öğrenilen özelliklerin genellenebilirliğini artırmaktadır.

Düzleştirme Katmanı: Çok boyutlu uzamsal veriler bu katman aracılığıyla tek boyutlu bir vektöre dönüştürülmüştür, böylece dense katmanlara aktarılabilir hale gelmiştir.

Tam Bağlantılı Katmanlar: İlk iki dense katman sırasıyla 256 ve 128 nöron içermekte ve her biri ReLU aktivasyon fonksiyonu ile çalışmaktadır. Bu katmanlar, öğrenilen özelliklerin daha soyut temsillerini oluşturarak sınıflandırma görevine hazırlar.

Dropout Katmanı: Aşırı öğrenmeyi önlemek amacıyla yerleştirilen bu katman, eğitim sırasında belirli oranda nöronları rastgele devre dışı bırakarak modelin genelleme yeteneğini artırmayı hedefler.

Çıkış Katmanı: Son katman, sınıflandırılması hedeflenen 29 sınıfı temsil eden 29 nöron içerir. Bu katmanda softmax aktivasyon fonksiyonu kullanılarak her sınıfa ait olasılık değeri hesaplanmış ve toplamı 1 olan bir dağılım elde edilmiştir.

Bu yapı, görüntülerin içerdiği bilgiyi katmanlar aracılığıyla giderek daha soyut temsillere dönüştürmekte ve nihai olarak olasılığa dayalı doğru sınıf tahmini sağlamaktadır. CNN mimarisi, özellikle görsel örüntülerin öğrenilmesinde güçlü bir yaklaşım sunmakta ve bu çalışmada da başarılı bir sınıflandırma performansı ortaya koymuştur.

Modelin Derlenmesi

Modelin öğrenme sürecinin daha hızlı ve kararlı şekilde ilerlemesini sağlamak amacıyla, optimizasyon algoritması olarak Adam (Adaptive Moment Estimation) tercih edilmiştir. Adam algoritması, her bir parametre için öğrenme oranını adaptif olarak güncelleyebilme özelliğine sahiptir ve özellikle büyük veri kümeleri ile karmaşık mimarilerde etkili ve istikrarlı sonuçlar vermesiyle öne çıkmaktadır.

Modelin çıktısı çok sınıflı bir sınıflandırma problemine ait olduğundan, kayıp fonksiyonu olarak CategoricalCrossentropy kullanılmıştır. Bu fonksiyon, modelin tahmin ettiği olasılık dağılımı ile gerçek etiketler arasındaki farkı ölçerek modelin öğrenme sürecini yönlendirmektedir. Model performansının takibi için ise şu metrikler kullanılmıştır:

Doğruluk (Accuracy): Modelin genel başarı oranını yansıtır. Formülü:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Kesinlik (Precision): Pozitif olarak tahmin edilen örneklerin ne kadarının doğru olduğunu gösterir. Formülü:

$$Precision = \frac{TP}{TP + FP}$$

Duyarlılık (Recall): Gerçek pozitif örneklerin ne kadarının doğru şekilde tahmin edildiğini ifade eder. Formülü:

$$Recall = \frac{TP}{TP + FN}$$

Kısaltmalar:

TP (True Positive): Doğru pozitif tahmin

TN (True Negative): Doğru negatif tahmin

FP (False Positive): Yanlış pozitif tahmin

FN (False Negative): Yanlış negatif tahmin

Eğitim Süreci ve Geri Çağırma Yöntemleri

Modelin aşırı öğrenmesini engellemek ve eğitim sürecini daha kontrollü bir şekilde yürütmek amacıyla, EarlyStopping ve ModelCheckpoint gibi geri çağırma fonksiyonlarından yararlanılmıştır.

EarlyStopping: Doğrulama kaybı (validation loss), belirli bir süre boyunca (örneğin 5 ardışık epoch) iyileşme göstermediğinde eğitim süreci durdurularak, modelin aşırı öğrenme eğiliminin önüne geçilmiştir.

ModelCheckpoint: Her epoch sonunda, doğrulama başarımı en yüksek olan modelin ağırlıkları ayrı bir dosyaya kaydedilmiştir. Böylece eğitim süreci sonunda en iyi genel performansı gösteren modelin korunması sağlanmıştır.

Bu stratejiler sayesinde eğitim süreci hem zaman açısından verimli hale getirilmiş hem de genelleme başarımı en yüksek olan modelin elde edilmesi mümkün olmuştur.

Eğitim Sonuçlarının Görselleştirilmesi

Eğitim süreci boyunca izlenen performans metrikleri, modelin öğrenme dinamiklerini analiz edebilmek amacıyla grafiksel olarak görselleştirilmiştir. Bu kapsamda:

Eğitim ve doğrulama aşamalarına ait doğruluk (accuracy) ve kayıp (loss) değerlerinin epoch bazında değişimleri grafikler aracılığıyla sunulmuştur.

Ayrıca, sınıf duyarlılığını daha ayrıntılı değerlendirebilmek adına, kesinlik ve duyarlılık metriklerinin zamana bağlı değişimi de izlenmiştir.

Bu görselleştirme adımı, modelin eğitim sürecinde gösterdiği öğrenme eğilimlerini değerlendirmek açısından önemli içgörüler sağlamış; özellikle erken aşamalarda **aşırı öğrenme (overfitting)** veya **yetersiz öğrenme (underfitting)** durumlarının tespit edilmesine olanak tanımıştır.

Modelin ve Sınıf Etiketlerinin Kaydedilmesi

Modelin ileride yeniden kullanılabilirliğini sağlamak ve tahmin süreçlerinde kullanılmak üzere eğitim tamamlandıktan sonra aşağıdaki kayıt işlemleri gerçekleştirilmiştir:

Eğitilen modelin ağırlıkları, keras formatında kalıcı olarak kaydedilmiştir.

Sınıflara karşılık gelen sayısal etiketler, class_indices sözlüğü olarak JSON formatında ayrı bir dosyada saklanmıştır.

Bu kayıt işlemleri, modelin yeniden yüklenmesi sırasında elde edilen çıktılarıdaki sayısal sınıf indekslerinin anlamlı sınıf adlarına dönüştürülmesini kolaylaştırmakta; böylece model tahminlerinin daha kolay yorumlanmasına olanak tanımaktadır.

Sonuç

Bu çalışmada geliştirilen CNN tabanlı mimari, görüntü verilerinden anlamlı özellikler çıkararak çok sınıflı bir sınıflandırma görevini başarıyla gerçekleştirmiştir. Model, veri artırımı, dropout ve early stopping gibi yöntemlerle aşırı öğrenme riskine karşı korunmuş; böylece genelleme kabiliyeti önemli ölçüde artırılmıştır.

Eğitim sürecinde yalnızca doğruluk (accuracy) metriğiyle yetinilmeyip, aynı zamanda kesinlik (precision), duyarlılık (recall) ve F1 skoru gibi sınıf duyarlılığı yüksek metrikler de izlenmiş; bu sayede model performansı çok boyutlu olarak değerlendirilmiştir. Eğitim ve doğrulama aşamalarında elde edilen metriklerin yanı sıra, test veri kümesi üzerindeki sonuçlar da ayrıntılı şekilde analiz edilmiştir.

Elde edilen bulgular, önerilen CNN mimarisinin yüksek sınıflandırma doğruluğu sağladığını ve aynı zamanda veri dengesizliğinin olumsuz etkilerini azaltarak özellikle azınlık sınıflarda da tatmin edici bir performans ortaya koyduğunu göstermektedir.

Bulgular ve Tartışma

Bu bölümde, geliştirilen CNN tabanlı modelin test veri seti üzerindeki performansı ve üç farklı model eğitimi altında elde edilen sonuçlar karşılaştırmalı olarak sunulmakta ve tartışmalarla desteklenmektedir.

Modelin Test Performansının Değerlendirilmesi

Eğitim sürecinin tamamlanmasının ardından model, daha önceden ayrılan test veri kümesi üzerinde değerlendirilmiştir. Bu kapsamda:

Model tahminleri, test setindeki gerçek etiketlerle karşılaştırılmış,

Her bir sınıfa ait precision, recall ve F1-score değerleri classification_report yardımıyla hesaplanmış,

Ayrıca karmaşıklık matrisi kullanılarak, doğru ve hatalı sınıflandırılan örnekler görselleştirilmiştir.

Bu analizler, modelin sadece genel doğruluk oranını değil, aynı zamanda azınlık sınıflardaki performansını da objektif bir şekilde ortaya koymuş ve veri dengesizliğinin model üzerindeki etkilerini gözlemlemek açısından değerli içgörüler sağlamıştır.

Eğitim Denemeleri ve Performans Karşılaştırması

Bu bölümde, bitki hastalıklarının sınıflandırılmasına yönelik geliştirilen CNN mimarisinin farklı yapılandırmalar altında gösterdiği performans değerlendirilmektedir. Üç farklı eğitim denemesi gerçekleştirilmiş ve her biri; epoch sayısı, dropout kullanımı, eğitim süresi, öğrenme oranı ve performans metrikleri açısından karşılaştırılmış ve şu önemli bulgular elde edilmiştir:

Tablo 2. Üç farklı CNN model denemesine ait eğitim parametreleri ve performans metriklerinin karşılaştırması.

Not: Bu tabloda sunulan veriler, yazar tarafından eğitilen modellerin çıktılarından oluşturulmuştur.

Özellik	1. Eğitim	2. Eğitim	3. Eğitim
Epoch Sayısı	9	20	30
Öğrenme Oranı	0,001	0,001	0,001
Dropout Kullanımı	Hayır	Evet	Evet
Eğitim Doğruluğu (Accuracy)	0,997	0,9621	0,938
Doğrulama Doğruluğu	0,9436	0,9775	0,9512
Eğitim Kayıp (Loss)	0,0163	0,1211	0,1992
Doğrulama Kayıp	0,2998	0,0731	0,1472
Eğitim Precision	0,9932	0,9671	0,9484
Doğrulama Precision	0,9473	0,9823	0,9594
Eğitim Recall	0,9911	0,9573	0,928
Doğrulama Recall	0,9261	0,9731	0,9423
Overfitting Gözlemi	Evet	Hafif	Evet
	(Erken durdu)		(Uzun eğitim)

Tablodan görüldüğü üzere, özellikle **2. Eğitim Denemesi**, düşük doğrulama kaybı (0.0731) ve yüksek doğruluk oranı (0.9775) ile ön plana çıkmaktadır. Ayrıca, yüksek precision (0.9823) ve recall (0.9731) değerleri bu modelin hem doğru tahmin üretme hem de gerçek pozitifleri yakalama konusunda oldukça başarılı olduğunu göstermektedir. Dropout uygulamasının aktif olduğu bu modelde overfitting etkisinin azaldığı da gözlemlenmiştir.

Tablo Başlıklarının Açıklamaları:

Epoch Sayısı: Modelin eğitim süresince veri seti üzerinde kaç tam geçiş yaptığı.

Öğrenme Oranı (Learning Rate): Modelin ağırlıklarını güncellerken yaptığı adım büyüklüğünü belirtir.

Dropout Kullanımı: Aşırı öğrenmeyi önlemeye yönelik düzenleme (regularization) tekniğinin uygulanıp uygulanmadığını belirtir.

Accuracy (Doğruluk): Modelin genel doğru tahmin oranıdır.

Precision (Kesinlik): Pozitif tahminlerin ne kadarının doğru olduğunu gösterir.


Recall (Duyarlılık): Gerçek pozitiflerin ne kadarının doğru tahmin edildiğini ifade eder.

Loss (Kayıp): Tahmin edilen değer ile gerçek değer arasındaki farkı temsil eder; daha düşük olması beklenir.


Overfitting Gözlemi: Modelin eğitim verisine aşırı uyum gösterip göstermediğine dair gözlemdir.

Grafiksel Performans Analizi

Eğitim sürecindeki doğruluk (accuracy), kayıp (loss), kesinlik (precision) ve duyarlılık (recall) metriklerinin epoch bazında değişimi grafiksel olarak izlenmiştir. Bu grafikler, modelin öğrenme eğrisini, potansiyel aşırı öğrenme (overfitting) noktalarını ve genel performans eğilimini değerlendirmede kullanılmıştır.



Şekil 2. 1. Eğitim




Şekil 3. 2. Eğitim

1. Eğitim (Şekil 2): Dropout katmanı içermeyen ve 9 epoch süresince eğitilen bu modelde eğitim doğruluğu yüksek seviyelere ulaşsa da doğrulama metriklerinde dalgalanmalar gözlemlenmiştir. Özellikle validation loss değerindeki erken yükseliş, modelin eğitim verisine aşırı uyum sağladığını ve erken durdurma (early stopping) mekanizmasının devreye girdiğini göstermektedir.

2. Eğitim (Şekil 3): Dropout kullanılarak 20 epoch boyunca eğitilen bu model, hem eğitim hem de doğrulama verisinde dengeli ve yüksek başarı sağlamıştır. Validation accuracy, precision ve recall değerlerinin birlikte yüksek olması, modelin genelleme kabiliyetinin güçlü olduğunu ortaya koymaktadır. Bu deneme, en başarılı model olarak öne çıkmaktadır.

3. Eğitim (Şekil 4): 30 epoch süresince eğitilen ve dropout içeren bu modelde de yüksek doğruluk oranları elde edilmiştir. Ancak epoch sayısının artmasıyla birlikte validation loss değerinde artış gözlemlenmiş, bu da modelin aşırı öğrenme (overfitting) eğiliminde olduğunu göstermektedir.

Bu grafikler, modelin öğrenme eğrisini, potansiyel aşırı öğrenme noktalarını ve genelleme başarısını ayrıntılı şekilde ortaya koyarak değerlendirme sürecine önemli katkı sağlamıştır.



Şekil 4. 3. Eğitim

Gerçek Tahmin


Bir

Modelin genel başarımına bir test görseli tahmin

değerlendirilmiştir. Şekil 5'te görüldüğü üzere, model "Apple__Apple_scab" (Elma Kabuk Hastalığı) sınıfını %93.36 olasılıkla doğru bir şekilde tahmin etmiştir. Bu yüksek olasılık değeri, modelin gerçek veriler üzerinde sağlam bir sınıflama kabiliyetine sahip olduğunu göstermektedir.

Görselden Alınan Örnek

doğrulama seti üzerindeki ek olarak, rastgele seçilen kullanılarak modelin tekil performansı da



Şekil 5. Test setinden seçilen bir elma yaprağı görseline ait sınıflandırma sonucu ve modelin olasılık tahmini (Apple__Apple_scab, %93.36)

Genel Değerlendirme

Yukarıda sunulan sonuçlar ve grafikler doğrultusunda şu temel çıkarımlar yapılabilir:

Dropout Kullanımının Etkisi: Dropout uygulaması, modelin eğitim verisine aşırı uyum sağlamasını engelleyerek genelleme yeteneğini belirgin şekilde artırmıştır. Özellikle 2. eğitim denemesinde bu durum net şekilde gözlemlenmiş, doğrulama metriklerinde elde edilen yüksek değerler (precision: 0.9823, recall: 0.9731) dropout'un başarısını desteklemiştir (bkz. Şekil 1 ve Şekil 3).

Epoch Sayısının Sınırlı Faydası: Eğitim süresinin (epoch sayısının) artırılması, ilk etapta modelin doğruluğunu iyileştirse de belirli bir eşikten sonra aşırı öğrenmeye yol açarak doğrulama performansında düşüşe neden olmuştur. Bu durum 3. eğitim denemesinde açıkça gözlemlenmiş ve validation loss değerlerinde artışla kendini göstermiştir (bkz. Şekil 4).

Precision ve Recall Metriklerinin Önemi: Özellikle sınıf dengesizliği gibi durumların model performansı üzerindeki etkisini analiz edebilmek için precision ve recall gibi sınıf duyarlı metriklerin izlenmesi kritik önem taşımaktadır. Bu metrikler sayesinde modelin yalnızca çoğunluk sınıflarda değil, azınlık sınıflarda da nasıl performans gösterdiği anlaşılabilmiştir.

Grafiksel Analizlerin Katkısı: Eğitim sürecini görselleştiren doğruluk, kayıp, precision ve recall eğrileri, modelin öğrenme eğrisini, potansiyel overfitting noktalarını ve genelleme başarısını detaylı biçimde yansıtarak değerlendirme sürecine önemli katkı sağlamıştır.

Kaynaklar

- AbdallahAliDev. (2022). *PlantVillage Dataset* [Dataset]. Kaggle. <https://www.kaggle.com/datasets/abdallahalidev/plantvillage-dataset>
- Aksoy, B., Halis, H. D., & Salman, O. K. M. (2020). Elma bitkisindeki hastalıkların yapay zekâ yöntemleri ile tespiti ve yapay zekâ yöntemlerinin performanslarının karşılaştırılması. *International Journal of Engineering and Innovative Research*, 2(3), 194–210.
- Al Hiary, H., Bani Ahmad, S., Reyalat, M., Braik, M., & AlRahamneh, Z. (2011). Fast and accurate detection and classification of plant diseases. *International Journal of Computer Applications*, 17, 31–38. <https://doi.org/10.5120/2183-2754>
- Ali, H., Shifa, N., Benlamri, R., Farooque, A. A., & Yaqub, R. (2025). A fine-tuned EfficientNet-B0 convolutional neural network for accurate and efficient classification of apple leaf diseases. *Scientific Reports*, 15, Article 25732. <https://www.nature.com/articles/s41598-025-25732-7>
- Altaş, Z., Özgüven, M. M., & Adem, K. (2023). Automatic detection and classification of some vineyard diseases with faster R-CNN model. *Turkish Journal of Agriculture - Food Science and Technology*, 11(1), 97–103. <https://doi.org/10.24925/turjaf.v11i1.97-103.5665>
- Arıcı, Ş., & Özkaya, H. Ö. (2014). Yağ güllerinde (*Rosa damascena* Mill.) pas hastalığı [*Phragmidium mucronatum* (Pers.) Schltdl.]'nın yaygınlık ve şiddetinin belirlenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 18(1), 66–71.
- Aslan, M. (2021). Derin öğrenme ile şeftali hastalıklarının tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (23), 540–546.
- Baran, M. F., Altuntaş, A., & Seydoşoğlu, S. (2023). *6th International Conference on Global Practice of Multidisciplinary Scientific Studies*.
- Boyar, T. (2024). *Bitki görüntülerinden hastalık tespiti için derin öğrenme modeli* (Yüksek lisans tezi, Marmara Üniversitesi). Marmara Üniversitesi Kurumsal Akademik Arşivi.
- Chen, J., Yin, H., & Zhang, D. (2020). A self-adaptive classification method for plant disease detection using GMDH-logistic model. *Sustainable Computing: Informatics and Systems*, 28, Article 100415. <https://doi.org/10.1016/j.suscom.2020.100415>
- Cuenca-Romero, R., González-Caballero, A., Rodríguez-González, P., Torres-Sánchez, J., & Peña, J. M. (2024). A machine learning approach to wheat rust detection using SMOTE and spectral data. *Frontiers in Plant Science*, 15, 1392409. <https://www.frontiersin.org/articles/10.3389/fpls.2024.1392409/full>
- Erdoğan, C. (2024). Türkiye’de ve Dünya’da bitki koruma ürünlerinin kullanımının değerlendirilmesi ve öneriler. *KSU Tarım ve Doğa Dergisi*, 27(2), 382–392. <https://doi.org/10.18016/ksutarimdog.vi.1402605>
- Göksu, M., Sünneci, K. M., & Alkan, A. (2021). Derin öğrenme ağları kullanılarak mısır yapraklarında hastalık tespiti. *Computer Science, (Special)*, 208–216.
- Guo, Y., Zhang, X., Zhang, Y., & Zhao, X. (2020). Plant disease identification based on deep learning algorithm in smart farming. *Discrete Dynamics in Nature and Society*, 2020, 1–11.
- Kaur, P., & Gautam, V. (2021). Plant biotic disease identification and classification based on leaf image: A review. In *Proceedings of the 3rd International Conference on Computing, Informatics and Networks (ICCIN 2020)*.
- Kılınç, N., Dikilitaş, M., & Tohumcu, E. (2021). Adıyaman ilinde Septoria leke hastalığının [*Zymoseptoria tritici* (Desm. Quaedvlieg & Crous)] çıkış zamanı üzerinde iklim faktörlerinin etkisinin belirlenmesi. *Harran Tarım ve Gıda Bilimleri Dergisi*, 25(3), 304–314.

- Luckey, A. (2012). *Assessing youth perceptions and knowledge of agriculture: The impact of participating in an agventure program.*
- Malhi, G. S., Kaur, M., & Kaushik, P. (2021). Impact of climate change on agriculture and its mitigation strategies: A review. *Sustainability*, 13(3), 1318.
- Martinelli, F., Scalenghe, R., Davino, S., Panno, S., Scuderi, G., Ruisi, P., Villa, P., Stroppiana, D., Boschetti, M., Goulart, L. R., Davis, C. E., & Dandekar, A. M. (2015). Advanced methods of plant disease detection: A review. *Agronomy for Sustainable Development*, 35(1), 1–25. <https://doi.org/10.1007/s13593-014-0246-1>
- Ozturk, M., Soylu, S., & Kayaaslan, Z. (2021). Yozgat ili elma ve armut üretim alanlarında ateş yanıklığı [*Erwinia amylovora* (Burrill) Winslow et al.] hastalığının mevcut durumunun belirlenmesi. *Mustafa Kemal Üniversitesi Tarım Bilimleri Dergisi*, 26(1), 200–210.
- Ökten, İ., & Yüzgeç, U. (2022). Evrişimli sinir ağı ile çeltik bitkisi hastalığının tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 11(1), 203–217.
- Özcan, R. (2022). *Görüntü işleme ve evrişimsel sinir ağları yöntemleriyle bitki tespiti için bilgisayarlı görüş sistemi geliştirilmesi (Development of a computer vision system for plant detection using image processing and convolutional neural networks)* (Doktora tezi, Selçuk Üniversitesi, Türkiye).
- Özdemir, C. (2023). Derin öğrenme modelleri ve veri ön işleme yöntemleri ile çeltik yaprak hastalıklarının erken teşhisi. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 38(3), 807–817.
- Özgüven, M. M., Altaş, Z., Güven, D., & Çam, A. (2022). Tarımda drone kullanımı ve geleceği. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 12(1), 64–83.
- Savary, S. (2020). Plant health and food security. *Journal of Plant Pathology*, 102, 605–607. <https://doi.org/10.1007/s42161-020-00611-5>
- Sazak, S., Balsak, S. C., & Badem, H. (2025). Transfer öğrenme temelli bitki yaprak hastalıklarının tespiti için karşılaştırmalı bir çalışma. *Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi*, 28(1), 154–170.
- Sethy, P. K., Barpanda, N. K., Rath, A. K., & Behera, S. K. (2020a). Deep feature based rice leaf disease identification using support vector machine. *Computers and Electronics in Agriculture*, 175, 105527. <https://doi.org/10.1016/j.compag.2020.105527>
- Sethy, P. K., Barpanda, N. K., Rath, A. K., & Behera, S. K. (2020b). Image processing techniques for diagnosing rice plant disease: A survey. *Procedia Computer Science*, 167, 516–530. <https://doi.org/10.1016/j.procs.2020.03.308>
- Topçu, C., & Güneş, P. (2024). Bitki hastalıklarını tespitite derin öğrenme: ResNet modelinin etkinliği. *Anadolu Bil Meslek Yüksekokulu Dergisi*, 19(69), 31–65.
- Tripathi, A. D., Mishra, R., Maurya, K. K., Singh, R. B., & Wilson, D. W. (2019). Estimates for world population and global food availability for global health. In A. D. Tripathi (Ed.), *The role of functional food security in global health* (pp. 3–24). Elsevier.
- Türkoğlu, M., Hanbay, K., Sivrikaya, I. S., & Hanbay, D. (2020). Derin evrişimsel sinir ağı kullanılarak hastalıklarının sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334–345.
- Veziroğlu, E., Paçal, İ., & Coşkunçay, A. (2023). Derin evrişimli sinir ağları kullanılarak pirinç hastalıklarının sınıflandırılması. *Journal of the Institute of Science and Technology*, 13(2), 792–814.
- Waheed, A., Goyal, M., Gupta, D., Khanna, A., Hassanien, A. E., & Pandey, H. M. (2020). An optimized dense convolutional neural network model for disease recognition and classification in corn leaf. *Computers and Electronics in Agriculture*, 175, 105456.