

Atf İçin: Veziroglu, E., Pacal, I. ve Coskuncay, A. (2023). Derin Evrişimli Sinir Ağları Kullanılarak Pirinç Hastalıklarının Sınıflandırılması. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(2), 792-814.

To Cite: Veziroglu, E., Pacal, I. & Coskuncay, A. (2023). Classification Of Rice Diseases Using Deep Convolutional Neural Networks. *Journal of the Institute of Science and Technology*, 13(2), 792-814.

Derin Evrişimli Sinir Ağları Kullanılarak Pirinç Hastalıklarının Sınıflandırılması

Erkan VEZİROĞLU^{1*}, Ishak PACAL², Ahmet COSKUNCAY¹

Öne Çıkanlar:

- Bitki hastalığı sınıflandırması
- Pirinç hastalığı tespiti
- Evrişimli sinir ağları

Anahtar Kelimeler:

- Bitki hastalığı sınıflandırması
- Pirinç hastalığı tespiti
- Evrişimli sinir ağları
- Derin öğrenme
- Öğrenme aktarımı

ÖZET:

Çeltik, temel bir gıda kaynağıdır ve endüstride sıkça kullanılan nadir bitkilerden biridir. Çeltik yaprak hastalıklarının erken teşhisi, ekin hasarını en aza indirmek için büyük önem taşımaktadır. Son yıllarda, derin öğrenme tabanlı bilgisayar destekli sistemler, ziraat sektöründe oldukça önem kazanmış ve çeşitli uygulamalarda etkin rol almıştır. Bu sistemler, hastalıkların erken teşhis edilmesine yardımcı olmakla kalmayıp, aynı zamanda tarım alanında çalışanlara da ikincil bir yardımcı olarak katkı sağlamaktadır. Bu çalışma, çeltik yapraklarında bulunan hastalıkların erken teşhisinde derin öğrenme yöntemlerinin etkinliğini araştırmayı amaçlamaktadır. Bu amaç doğrultusunda, VGG, ResNet, DenseNet, EfficientNet, Inception ve Xception gibi en popüler evrişimsel sinir ağları (CNN), halka açık Paddy Doctor veri seti üzerinde değerlendirilmiştir. Her bir modele, veri ön işleme, veri artırma, hiper-parametre optimizasyonu ve öğrenme aktarımı gibi güncel teknikler uygulanarak test setindeki teşhis doğruluğunun başarıyı artırılmıştır. Ayrıca her bir mimarideki modellerin birbirine ve diğer mimarilerdeki modellere göre çeltik yapraklarındaki hastalıkların teşhisindeki başarımları detaylı bir şekilde karşılaştırılmıştır. Deneysel sonuçlar, EfficientNetv2_Small modelinin %98.01 test doğruluğu ve %97.99 F1-skor değerleriyle tüm modellerden daha iyi performans sergilediğini ve literatürdeki diğer çalışmaları geride bıraktığını göstermiştir. Bu çalışma, CNN mimarilerinin yüksek bir performans gösterdiğini ve bu tür hastalıkların erken teşhisinde ziraat mühendislerine ve çiftçilere etkili bir şekilde yardımcı olabileceğini göstermektedir.

Classification Of Rice Diseases Using Deep Convolutional Neural Networks

Highlights:

- Crop disease classification
- Rice disease detection
- Convolutional neural networks

Keywords:

- Crop disease classification
- Rice disease detection
- Convolutional neural networks
- Deep learning
- Transfer learning

ABSTRACT:

Rice is a primary food source and is one of the rare plants commonly used in industry. Early diagnosis of leaf diseases in rice is crucial to minimize crop damage. Recently, deep learning-based computer-aided systems have gained importance in the agricultural sector and have played an effective role in various applications. These systems not only help with early disease diagnosis but also serve as a secondary aid to those working in agriculture. This study aims to investigate the effectiveness of deep learning methods in the early diagnosis of diseases in rice leaves. To this end, the most popular convolutional neural networks (CNNs), such as VGG, ResNet, DenseNet, EfficientNet, Inception and Xception, were evaluated on the public Paddy Doctor dataset. Current techniques, such as data preprocessing, data augmentation, hyperparameter optimization, and transfer learning, were applied to each model to increase the diagnostic accuracy of the test set. Additionally, the success of each model in diagnosing diseases in rice leaves was compared in detail to other models. The experimental results showed that the EfficientNetv2_Small model performed better than all other models with a test accuracy of 98.01% and F1-score of 97.99%, outperforming other studies in the literature. This study demonstrates that CNN architectures perform well and can effectively assist agricultural engineers and farmers in the early diagnosis of such diseases.

¹ Erkan VEZİROĞLU (Orcid ID: 0000-0002-3358-8467), Ahmet COSKUNCAY (Orcid ID: 0000-0002-7411-310X), Atatürk Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Erzurum, Türkiye

² Ishak PACAL (Orcid ID: 0000-0001-6670-2169), İğdır Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İğdir, Türkiye

*Sorumlu Yazar/Corresponding Author: Erkan VEZİROĞLU, e-mail: catmaerkan@gmail.com

GİRİŞ

Küresel ekonominin en önemli alanlarından biri, insanlara gıda da dahil olmak üzere yaşamın temel gereksinimlerini sağlayan tarımdır. İnsan yaşamının devamı için tarımsal faaliyetler çok önemlidir (Malhi ve ark., 2021). Dünya nüfusunun 2050 yılına kadar 9 milyarı aşması beklendiğinden, gıda güvenliği ve sürdürülebilir tarım, dünya çapında büyük zorluklar haline gelmiştir (Tripathi ve ark., 2019). Sürdürülebilir ve akıllı tarım yöntemleri için bitki hastalıkları, haşereler ve diğer çevresel faktörlerin ürün verimi ve kalitesi üzerindeki etkisi önemli bir endişe kaynağıdır.

Tarımda otomatik algılama ve tanımlama yöntemleri kullanmanın bir dizi önemli avantajı vardır (Udotalapally ve ark., 2020). Tarımdaki araştırmacılar ve uygulayıcılar, yüksek kaliteli mahsul üretiminin sürdürülmesine yardımcı olan derin öğrenme yöntemlerini kullanarak bitki hastalıklarını daha etkili bir şekilde tanımlayabilir ve tedavi edebilir. Tedavilerin ve müdahalelerin hedefe yönelik uygulanması, pestisit kullanımının azaltılması ve nihai olarak mahsul veriminin ve kalitesinin iyileştirilmesi gibi mahsul yönetimi uygulamalarının iyileştirilmesi, bitki hastalıkları tespiti ve sınıflandırması için doğru ve etkili modellerin geliştirilmesiyle sağlanabilir (Waheed ve ark., 2020; An ve ark., 2022).

Yetiştiricilikte en önemli ve pratik ürün çeltiktir (pirinç bitkisi diğer adıyla). Tarımsal hasadın verimi, bir ülkenin ekonomisini büyütme üzerinde önemli bir etkiye sahiptir. Hastalıklar, haşereler ve çevre koşulları, mahsulün büyümesini ve verimini etkileyen değişkenlerden sadece birkaçıdır. Ürün kalitesini önemli ölçüde düşüren en önemli unsurlardan biri mahsul hastalığıdır (Martinelli ve ark., 2015; van Eeuwijk ve ark., 2019; Kaur ve Gautam, 2021). Bitkilerdeki yaprak enfeksiyonlarının tespit edilmesi, ürün verimindeki kayıpları azaltmaya yardımcı olabilir. Hastalıkları erken ve doğru teşhis etmek, bunları başlangıç aşamalarında kontrol etmenin en etkili yoludur. Başlangıçta, bitki yaprak hastalıklarını yaprak dokusu temel alarak teşhis etmenin tek yolu manuel kontrol yoluydu (Sethy ve ark., 2020b). Hastalık tespiti için eğitimli ve uzman kişilere ihtiyaç duyulmaktaydı ve bu işlem için harcanan zamanın çokluğu ve ürün verimindeki azalma nedeniyle daha etkili bir hastalık tespit yöntemi gerekmektedir.

Son yıllarda, araştırmacılar, verim tahmini, besin eksikliklerinin tanınması (Xu ve ark., 2011; Baresel ve ark., 2017; Tao ve ark., 2020), ürün boyutunun ölçülmesi (Liu ve ark., 2019) ve yabancı ot tespiti (Zhang ve ark., 2005; Asad ve Bais, 2020; Jiang ve ark., 2020; Liu ve Bruch, 2020; Ngugi ve ark., 2021; Mishra ve ark., 2022) gibi çeşitli sorunları ele almak için görüntü işleme ve bilgisayar görüşü teknolojilerini kullanmışlardır. Bitki yaprak hastalıklarının tanınması, tarım için önemli faydalar sağlamaktadır. Bununla birlikte, bu görev, tarım uygulamaları için sınırlı sayıda yapay zeka aracı bulunması nedeniyle hala sorunlu olmaya devam etmektedir (Strange ve Scott, 2005; Li ve ark., 2009; Islam ve ark., 2018; Zhu ve ark., 2018; Gautam, 2020).

Birçok araştırmacı, aşağıda ayrıntıları verildiği gibi makine öğrenimi teknikleri (Gautam, 2020), derin öğrenme ve hibrit teknikler (Yang ve ark., 2013; Ozguven ve Adem, 2019) ve öğrenme aktarımı teknikleri (Szegedy ve ark., 2015; Szegedy ve ark., 2016; Chen ve ark., 2020; Peng ve ark., 2020; Uğuz ve Uysal, 2021; Sharma ve ark., 2022) gibi farklı yapay zeka teknikleri kullanarak bu sorunu ele almıştır. En etkili hastalık tanımlayıcı Yapay Sinir Ağı (YSA) tasarımı, dört giriş seviyesi nöron (Gunawan ve ark., 2021), beş gizli seviye nöron ve bir çıkış seviyesi nörondan oluşmaktadır. Bu mimari farklı çeltik hastalıklarını tespit etmede %66.3 doğruluğa sahiptir.

Ozguven ve Adem (Ozguven ve Adem, 2019) tarafından güncellenmiş bir Hızlı R-Evrişimli Sinir Ağı (CNN) kullanılarak şeker pancarı yapraklarındaki hastalıklar sınıflandırılmış ve tespit edilmiştir. 155 görüntü ile eğitilen modelden %95.48 doğruluk elde edilmiştir. Soya yapraklarındaki

hastalıkları tespit etmek için, SoyNet adlı iki modüllü bir yaklaşım kullanılmış, öncelikle görüntülerin gizli kısımları segmente edilmiş, daha sonra derin öğrenme tabanlı el yapımı modeller kullanılmıştır (Karlekar ve Seal, 2020).

Önceden eğitilmiş derin öğrenme modelleri, PlantVillage veri kümesi kullanılarak domates yaprak hastalığını makul doğrulukla tespit etmek için kullanılmıştır (Rangarajan ve ark., 2018; Agarwal ve ark., 2020; Trivedi ve ark., 2021). Manyok yapraklarındaki hastalığı teşhis etmek için bir derin öğrenme tekniği kullanılmıştır (Sambasivam ve Opiyo, 2021). Başka bir çalışmada, lale yapraklarındaki hastalığı tespit etmek için derin bir evrişimli ağ kullanılmıştır (Polder ve ark., 2019). Ayrıca, darı bitkisinde hastalık tespiti için bir yaklaşım önerilmiştir (Coulibaly ve ark., 2019). Tespit oranını iyileştirmek için MobileNet ile birleştirilmiş derin işlemlerli CNN kullanılarak geliştirilmiştir. Exodus bilgisine sahip gelişmiş klasik modeller kullanılarak yaprak hastalığı %92 doğrulukla tespit edilmiştir (Kamal ve ark., 2019). Pirinç yaprağı hastalıklarını tanımlamak için iki aşamalı bir CNN mimarisi kullanılmış ve önerilen yöntem %93,3'lük bir doğruluk oranına ulaşmıştır (Hossain ve ark., 2020). Bir veri seti kullanılarak, bağlamsal olmayan görüntü meta verilerini dahil etmek için üç farklı CNN önerilmiştir. 79 farklı hastalığa sahip 14 bitkiyi dikkate alan ve daha iyi doğruluk sağlayan yaprak hastalıklarını belirlemek için görüntü sınıflandırmasına dayalı bir yöntem önerilmiştir (Arnal Barbedo, 2019). Ayrıca, PlantVillage veri seti, elma kara çürüklüğü hastalığının dört önemli aşamasını saptamak için kullanılmıştır (Kovalskaya ve Hammond, 2014; Wang ve ark., 2017).

Domates tarımında hastalıkları tanımlamak için üç adet evrişimli ve max-pooling katmanıyla birleştirilmiş bir sinir ağı (CNN) geliştirilmiştir. Deneysel sonuçlar, önerilen modelin VGG16, MobileNet ve InceptionV3 gibi önceden eğitilmiş modellere kıyasla rekabetçi bir performans gösterdiğini ortaya koymuştur ve önerilen modelin ortalama doğruluğu %91.2 olmuştur. Ayrıca, pirinç yapraklarındaki hastalıkları tanımlamak için bir görüntü işleme algoritması kullanılmıştır (Sladojevic ve ark., 2016).

Yaprakların ve lezyonların boyutu, lezyonların miktarı ve tipi, lezyonların renk özellikleri ve bozulmamış kesitler girdileri elde etmek için kullanılmıştır (Fuentes ve ark., 2017). Lezyonu tanımlamak ve kategorize etmek için derin evrişim tabanlı bir CNN modeli kullanılmış ve %96.43'lük bir doğruluk elde edilmiştir (Bhagawati ve ark., 2015). Çeltik çiftçileri için görüntüleri alan ve bunları hastalıktan etkilenecek ekin alanlarını belirlemek için derin bir öğrenme modeli kullanarak işleyen bir uygulamanın bir çalışma özetini sunulmuştur (Narmadha ve Arulvadivu, 2017; Atole ve Park, 2018; Chawathe, 2020).

CNN'lerin resimleri sınıflandırmadaki etkinliği, derin öğrenme tekniklerinin temelini oluşturmuştur (Vesela ve ark., 2020). Ayrıca, pirinç hastalıklarını tespit etmede basit bir CNN modelini eğitmek için ince ayar konseptine dayalı yeni bir iki aşamalı eğitim konsepti kullanılmıştır (Masood ve ark., 2020). Bununla birlikte, farklı girdi parametrelerinin doğruluğu değiştiğinden, hastalıkları tahmin etmek için sınıflandırma algoritmalarını kullanmak zordur. Bu yöntemler son yıllarda elma (Baranwal ve ark., 2019), çay (Karmokar ve ark., 2015) ve guava (Srinivas ve ark., 2021) gibi ürünlerde lezyonları görselleştirmek için kullanılmıştır. Goluguri ve arkadaşları (Goluguri ve ark., 2021) tarafından sıcaklık, bağıl nem, yağış ve rüzgar hızı gibi meteorolojik parametreler kullanılarak çeltik blast hastalığını tahmin etmek için bir sinir ağı geliştirilmiştir.

Birçok uygulama, yüksek sonuçlar elde etmek için derin öğrenme kullanmıştır. Çeltik yaprak hastalığını tespit etmek için nöro-fuzzy tabanlı bir yaklaşım kullanılmış ve %74.21 doğruluk elde edilmiştir (Kahar ve ark., 2015). Çeltik yaprak hastalığını belirlemek için hibrit bir yaklaşım kullanılmış ve %90 doğruluk sağlanmıştır (Htun ve Htwe, 2018; Ganesan ve Chinnappan, 2022). Bir ileri beslemeli sinir ağı, %88 doğrulukla yaprak hastalığını tanımlamak için kullanılmıştır (Akila ve

Deepan, 2018). Çeltik yaprak hastalıklarını tespit etmek için optimize edilmiş bir DNN ve Jaya algoritması kullanılmış ve ortalama %93.5 doğruluk elde edilmiştir (Ramesh ve Vydeki, 2020). ESforRPD2 adlı bir uzman sistem, çeltik yaprak hastalıklarını tespit etmek için geliştirilmiş ve %87.5 sınıflandırma doğruluğu oranı elde etmiştir (Agus ve ark., 2019). Yaprak hastalıklarını tanımak için radyal fonksiyonla çıkarılan ve işlenen hibrit özellikleri kullanan başka bir yaklaşım %83.34 doğruluk oranına ulaşmıştır (Verma ve Dubey, 2018).

Birincil bileşen analizi (PCA) ve sinir ağı tabanlı bir yaklaşım önerilmiş ve %95.83 doğrulukla bakteriyel hastalıkları tanımlamada başarılı olmuştur (Xiao ve ark., 2018). Bir parçacık sürü optimizasyonu (PSO) merkezli artımlı sınıflandırıcı, pirinç yapraklarında bakteri ve mantar enfeksiyonlarını tespit etmek için (Sengupta ve Das, 2017) önerilmiş ve %84.02 doğruluk oranı elde edilmiştir. Hiperspektral veriler, pirinçte mantar enfeksiyonunu tespit etmek için kullanılmış ve %82 doğruluk sağlanmıştır (Huang ve ark., 2012). Son olarak, bakteri ve mantar enfeksiyonlarını tespit etmek için desene bağımlı gürültü tahmini (PdNP) sistemi kullanılmış ve %85 doğruluk oranı elde edilmiştir (Yang ve ark., 2013).

Öğrenme aktarımı, önceden eğitilmiş modellerin performansını geliştirmek için bir başka görevde önceden öğrenilmiş bilginin kullanımına dayanır. Öğrenme aktarımına dayalı bir derin öğrenme modeli, eğitim verilerini önceden eğitilmiş bir ağdan kullanımı ile yaprak hastalıklarını %91.50 doğrulukla tahmin etmiştir (Chen ve ark., 2020). Büyük bir pirinç veri seti, bitki yaprak hastalığını tahmin etmek için kullanılmıştır (Sharma ve ark., 2022). Zeytin yaprak hastalığını tespit etmek için öğrenme aktarımına dayalı bir derin sinir ağı kullanılmış ve %88 doğruluk elde edilmiştir (Uğuz ve Uysal, 2021). Pirinç yaprağı veri seti ile yapılan bir başka çalışmada, öğrenme aktarımına dayalı bir makine öğrenimi yaklaşımı kullanılarak, yaprak hastalığı tespiti için daha iyi bir doğruluk oranı elde edilmiştir (Sharma ve ark., 2022). Yaprak hastalığını tespit etmek için bilgisayar görüşü teknikleri arasında, incelemeli bir ağ kullanılmıştır (Szegedy ve ark., 2015; Szegedy ve ark., 2016). Öğrenme aktarımına dayalı RestNet kullanılmış ve %84.3 doğruluk elde edilmiştir (Peng ve ark., 2020).

Derin öğrenme teknolojisi, yaprak sorunlarını tanımda yüksek bir başarı oranına sahiptir. Çeltik tarlalarında çalışılan çeltik hastalıkları arasında çeltik yaprağı patlaması, yalancı is, boyun patlaması, kılıf yanıklığı, bakteriyel şerit hastalığı ve kahverengi lekeler sayılabilir. Bu çalışmanın ana katkısı, çeltik yaprak hastalıklarının erken teşhisi için derin öğrenme yöntemlerinin etkinliğini araştırmaktır. Bu amaçla çeltik yapraklarında meydana gelen hastalıkların etkili bir şekilde teşhis edilmesi ve görüntü dönüştürücü modellerinin performansının karşılaştırılması için en popüler CNN modelleri kullanılmıştır. Bu modeller arasında yaygın kullanılan VGG, ResNet, DenseNet, EfficientNet, Inception ve Xception gibi 12 CNN modeli yer almaktadır.

Bu çalışma, çeltik yaprak hastalıklarını tespit etmek ve sınıflandırmak için yapılmış en kapsamlı çalışma özelliğine sahiptir. Çeltik yapraklarındaki farklı hastalık türlerinin tanımlanması ve bu hastalıkların benzer görüntülerinin ayrıştırılması çalışmayı zorlaştırmıştır. Bununla birlikte, veri kümesinin sınırlı sayıda örneği ve yüksek çözünürlüklü görüntülerin işlenmesindeki zorluklar da çalışmanın zorlukları arasındadır.

Genel olarak, çalışmamız bitki hastalıklarının sınıflandırılması için derin öğrenme yöntemlerinin kullanımını hakkındaki artan bilgi birikimine katkıda bulunmakta ve sürdürülebilir akıllı tarım uygulamaları için doğru hastalık tanımlamasının önemini vurgulamaktadır. Bu çalışmanın arkasındaki motivasyon, çiftçilere ve tarım uzmanlarına çeltik hastalıklarının doğru teşhisi ve sınıflandırılması için pratik ve etkili bir araç sunmaktır. Bu da ürün yönetimini geliştirebilir ve ürün verimliliğini artırabilir.

MATERYAL VE METOT


Veri Seti

Çeltik yapraklarındaki hastalıkları etkin bir şekilde tespit etmek amacıyla kullandığımız veri seti, halka açık bir veri seti olan Paddy Doctor (Kiruba ve Arjunan, 2023) veri setidir. Paddy Doctor veri seti, sağlıklı ve hastalıklı örnekler de dahil olmak üzere 10 hastalık sınıfına ait 10.407 yaprak görüntüsü içermektedir. Güncel ve yüksek çözünürlüklü Paddy Doctor veri seti: Bakteriyel yaprak yanıklığı, bakteriyel yaprak çizgisi, bakteriyel salkım yanıklığı, blast, kahverengi benek, dead heart, tüylü küf, hispa, tungro ve normal sınıflarından oluşmaktadır ve bu sınıflara ait görüntü sayıları Tablo.1'de verilmiştir.

Tablo 1. Paddy Doctor Veri Kümesindeki Çeltik Hastalarına Ait Sınıfların İstatistiksel Verileri

Sınıf Adı (Çeltik Hastalığı)	Toplam (%100)	Eğitim (%70)	Doğrulama (%15)	Test (%15)
Bacterial Leaf Blight (BLB)	479	335	72	72
Bacterial Leaf Streak (BLS)	380	266	57	57
Bacterial Panicle Blight (BPB)	337	237	50	50
Blast	1738	1218	260	260
Brown Spot	965	675	145	145
Dead Heart	1442	1010	216	216
Downy Mildew	620	434	93	93
Hispa	1594	1114	240	240
Normal	1764	1234	265	265
Tungro	1088	762	163	163

Şekil 1, rastgele seçilmiş çeşitli Paddy Doctor veri setinden bazı çeltik geçiş örneklerini göstermektedir.



Şekil 1. Sağlıklı ve Hastalıklı Çeltik Yapraklarının Görüntüleri

Aşağıda, bu sistem için incelenen çeltik mahsulü hastalıklarının kısa bir özeti verilmiştir:

- 1. Bakteriyel Yaprak Solgunluğu (Bacterial Leaf Blight (BLB)):** *Xanthomonas oryzae* pv. *oryzae* bakterisi tarafından neden olunan ciddi bir hastalıktır. Çeltik yaprakların sararmasına ve kurummasına yol açarak büyümeyi ve verimi azaltır. BLB, enfekte tohumlar ve bitki artıkları aracılığıyla yayılır. Kontrol yöntemleri arasında dirençli çeşitlerin kullanımı, uygun tohum işlemi ve ürün rotasyonu yer alır (CM Vera Cruz, 2023).
- 2. Bakteriyel Yaprak Lekesi (Bacterial Leaf Streak (BLS)):** Pirinç bitkilerinin yapraklarına ve yaprak kınına enfekte olan *Xanthomonas oryzae* pv. *oryzicola* bakterisi tarafından neden olunur. Belirtiler, uzunlamasına su dolu lezyonları içerir ve sarıya dönüşür ve daha sonra kahverengiye dönüşür ve bitki ölümüne neden olabilir. BLS, enfekte tohumlar ve bitki artıkları aracılığıyla da

yayılır. Kontrol yöntemleri arasında dirençli çeşitlerin kullanımı ve bakterisit uygulaması yer alan bakır esaslıdır (Sparks, 2023a).

3. **Bakteriyel Başak Solması (Bacterial Panicle Blight (BPB)):** Pirinç bitkilerinin başaklarını etkileyen *Burkholderia glumae* bakterisi tarafından neden olunan bir bakteriyel hastalıktır. Belirtiler, başaklarda kahverengi lekelerdir ve bu da tahıl kalitesi ve veriminde azalmaya neden olur. BPB, enfekte tohumlar ve bitki artıkları aracılığıyla yayılır. Kontrol yöntemleri arasında dirençli çeşitlerin kullanımı, antibiyotikle tohum işlemi ve bakır esaslı bakterisit uygulaması yer alır (Ham ve ark., 2011).
4. **Blast:** Tüm pirinç bitkisini etkileyen *Magnaporthe oryzae* mantar hastalığıdır. Belirtiler, yapraklar, gövdeler ve başaklarda eliptik veya mızrak şeklinde lezyonları içerir ve bu da büyümeyi ve verimi azaltır. Blast, havada taşınan sporlar ve enfekte bitki artıkları aracılığıyla yayılır. Kontrol yöntemleri arasında dirençli çeşitlerin kullanımı, uygun tohum işlemi ve mantar ilacı uygulaması yer alır (Dean ve ark., 2012).
5. **Kahverengi Lekeler (Brown Spot):** Pirinç bitkilerinin yaprakları ve kılıflarını etkileyen *Cochliobolus miyabeanus* mantarı tarafından oluşturulur. Belirtileri, koyu kahverengi merkezleri ve sarı sınırları olan oval şekilli lezyonları içerir, bu da büyüme ve verimi azaltır. Kahverengi Lekeler, enfekte tohumlar ve bitki artıkları yoluyla yayılır. Kontrol önlemleri arasında dirençli çeşitlerin kullanımı, uygun tohum işlemi ve fungusit uygulaması yer alır (Zeigler ve Barclay, 2008).
6. **Ölü Kalp (Dead Heart):** Pirinç bitkilerinin büyüme noktalarını etkileyen BLB, BLS, BPB ve Blast gibi çeşitli hastalıkların belirtisidir. Genç yapraklar ve gövde öldüğünde, ölü bir kalbi andıran kahverengi, solmuş doku bırakır. Ölü Kalp, azalan büyüme ve verime neden olabilir ve çoğunlukla bakteriyel ve mantar hastalıklarından kaynaklanır. Kontrol önlemleri arasında dirençli çeşitlerin kullanımı, uygun tohum işlemi ve bitki sağlığını teşvik eden kültürel uygulamalar yer alır (Jena ve Kim, 2010).
7. **Tüylü Küf (Downy Mildew):** *Peronosclerospora oryzae* mantarı tarafından oluşturulur ve pirinç bitkilerinin yapraklarını etkiler. Belirtileri, yaprakların üst yüzeyinde sarımsı yeşil veya sarı lekeler ve alt yüzeyde beyaz veya gri lekeler içerir. Küf, azalan büyüme ve verime neden olabilir. Havada bulunan sporlar ve enfekte bitki artıkları yoluyla yayılır. Kontrol önlemleri arasında dirençli çeşitlerin kullanımı, uygun tohum işlemi ve fungusit uygulaması yer alır (Sujithra & Ukrit, 2020).
8. **Hispa:** *Diuraphis armigera* böceği tarafından oluşturulan yaygın bir çeltik hastalığıdır. Bu böcekler, yapraklarda pencere benzeri delikler oluştururken, larvalar köklerde beslenerek büyümeyi ve verimi azaltır. Hispa, böcek göçleri ve enfekte bitki artıklarının hareketi yoluyla yayılır. Kontrol önlemleri arasında dirençli çeşitlerin kullanımı, zararlı böceğin doğal düşmanlarını teşvik eden kültürel uygulamalar ve insektisit uygulaması yer alır (Catindig, 2023).
9. **Tungro:** iki farklı virüs, Rice tungro bacilliform virüsü (RTBV) ve Rice tungro spherical virüsü (RTSV) tarafından neden olunan bir pirinç viral hastalığıdır. Belirtileri arasında gelişimin durması, yaprakların sararması, tahıl kalitesinde ve veriminde azalmalar bulunur. Tungro, enfekte bitkiler üzerinde beslenen yeşil yapraklı bir böcek olan yeşil yapraklı çekirge aracılığıyla yayılır ve sağlıklı bitkilere virüs bulaştırır. Kontrol önlemleri arasında dirençli çeşitlerin kullanımı, uygun tohum işlemi ve yeşil yapraklı çekirgelerin varlığını azaltan kültürel uygulamalar yer alır (Sparks, 2023b).

Derin Öğrenme Mimarileri

Derin öğrenme, doğal dil işleme, karar verme, görüntü tanıma ve konuşma tanıma gibi görevleri yerine getirmek için çok katmanlı sinir ağlarının eğitimine odaklanan makine öğrenimi dallarından biridir (Karaman ve ark., 2023). Bu sinir ağları, insan beyninin bilgi işleme şeklini taklit etmeyi amaçlar ve

büyük eğitim veri setleri ve güçlü bilgisayar kaynakları kullanarak performanslarını zamanla artırmaya çalışırlar (Pacal ve ark., 2020). Yaygın derin öğrenme mimarileri arasında CNN'ler ve tekrarlayan sinir ağları (RNN'ler) yer alır ve bunlar otonom araçlar, konuşma tanıma, doğal dil işleme ve bilgisayar görüşü gibi uygulamalarda kullanılır. Derin öğrenme modelleri, büyük veri kümelerini analiz etmek için birbirine bağlı yapay sinir hücrelerini kullanır (Gündüz ve Işık, 2023). Geniş veri kümeleri üzerinde eğitilirler ve daha fazla veri eklenerek performansları sürekli olarak iyileştirilir. Popüler derin öğrenme çerçeveleri arasında TensorFlow, Keras ve PyTorch yer alır. CNN'ler, her katmanın girdi verilerinde giderek daha karmaşık desenleri tanımayı öğrendiği çok katmanlı sinir ağlarıdır. Girdi verilerini taramak ve özellikleri çıkarmak için filtreler kullanan evrişimli katmanların kullanımı, CNN'lerin ayırt edici özelliğidir. Bu katmanları takip eden özetleme katmanları, verinin mekânsal boyutunu azaltır ve tam bağlantılı katmanlar, çıkarılan özellikleri birleştirerek tahminler yapar.

Derin öğrenme modelleri

VGG mimarisi, Oxford Üniversitesi'ndeki Görsel Geometri Grubu tarafından geliştirilmiş bir CNN modelidir. Mimarisi evrişimsel, maksimum havuzlama ve birkaç tam bağlantı katmanlarından oluşan tutarlı bir yapıya sahiptir. Temel amacı görüntü tanıma ve sınıflandırmadır. VGG, ImageNet dahil olmak üzere çeşitli görüntü sınıflandırma testlerinde etkileyici sonuçlar göstermiştir ve diğer CNN'leri tasarlamak için bir temel olarak sıkça kullanılmaktadır (Simonyan ve Zisserman, 2014).

ResNet, derin ağlardaki yok olan gradyan problemiyle başa çıkmak için katmanlar arasında artık bağlantılar olarak da bilinen atlama bağlantıları kullanan bir CNN mimarisidir. Bu bağlantıların kullanımı, ağırlık fonksiyonlarını öğrenmesine olanak tanır ve ağırlık gradyanları öğrenip aktarmasını kolaylaştırır. ResNet, ImageNet veri kümesi de dahil olmak üzere çeşitli görüntü sınıflandırma işlemlerinde mükemmel sonuçlar göstermiş ve bilgisayar görüşü alanında yaygın bir mimari haline gelmiştir (He ve ark., 2016).

DenseNet, derin sinir ağlarında kaybolan gradyan problemini çözmeyi amaçlayan özel bir CNN tasarımıdır. Bu, her katmanın önceki tüm katmanlardan özellik haritalarını alması ve kendi özellik haritalarını tüm sonraki katmanlara ileterek yoğun bağlantılar oluşturmasıyla yapılır. Bu yoğun blok yapısı, güvenilir özellik iletimini sağlar ve parametrelerin verimli paylaşımına izin verir. DenseNet, çeşitli görüntü sınıflandırma kıyaslamalarında olağanüstü performans sergilemiş ve geniş bir bilgisayarlı görüş denetimi uygulama yelpazesinde yaygın olarak kullanılmaktadır (Huang ve ark., 2017).

Xception, Inception mimarisine dayanan bir CNN tasarımı türüdür. Geleneksel evrişimli katmanlar yerine, Xception, bir standart konvolüsyonu bir derinlik bazlı konvolüsyon ve bir noktasal konvolüsyona ayıran derinlik bazlı ayrıştırılabilir konvolüsyonları kullanır. Bu yaklaşım, ağı tarafından gereken parametre ve hesaplamaların sayısını önemli ölçüde azaltırken aynı zamanda doğruluğu artırır. Xception, çeşitli görüntü sınıflandırma kriterlerinde olağanüstü sonuçlar göstermiş ve bilgisayarlı görüş işleme uygulamalarında yaygın olarak kullanılmaktadır (Szegedy ve ark., 2015; Chollet, 2017).

VovNet veya VGG-style Oxford Visual Geometry Group Network (Oxford Görsel Geometri Grubu Ağı) genellikle derin öğrenme için kullanılan bir sinir ağı mimarisidir. İsmi, mimarisinin, 2014 yılında VGG ekibi tarafından geliştirilen VGG ağı mimarisine benzerliğinden dolayı almıştır. VovNet, CNN tabanlı bir mimariye sahiptir ve özellikle görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi görsel görevler için tercih edilir. VovNet ayrıca, sınıf sayısının çok olduğu görsel sınıflandırma problemlerinde de yüksek performans gösterir (Lee ve ark., 2019).

MobileNet, derin öğrenme modeli için bir mimaridir ve özellikle mobil cihazlar gibi düşük güç tüketimine sahip cihazlarda kullanım için tasarlanmıştır. MobileNet, geleneksel derin sinir ağlarından

farklı olarak, hesaplama maliyetini azaltmak için özellik çıkarma işlemi sırasında düşük boyutlu filtreler kullanır. Bu sayede, model boyutu ve hesaplama yükü önemli ölçüde azaltılabilir ve mobil cihazlarda gerçek zamanlı uygulamalara olanak tanır. MobileNet, görüntü sınıflandırma, nesne tespiti ve yüz tanıma gibi görevlerde başarılı sonuçlar verir (Howard ve ark., 2017).

EfficientNet, Google tarafından 2019 yılında geliştirilen ve ImageNet veri kümesi üzerindeki görüntü sınıflandırma performansını büyük ölçüde artıran bir derin öğrenme modelidir. EfficientNet, önceki birçok görüntü sınıflandırma modelinin aksine, aynı anda birden fazla hiperparametreyi optimize etmek için bir ölçeklendirme yöntemi olan "Compound Scaling" kullanır. Bu, modelin hem daha az parametreye sahip hem de daha yüksek doğruluk sağlamasına olanak tanır. EfficientNet ayrıca, önceki modellere göre daha hafif bir yapıya sahip olmasına rağmen, "MobileNet" ve "ResNet" gibi diğer popüler modellere göre daha iyi bir performans gösterir. Bu nedenle, özellikle kaynak sınırlı cihazlar üzerinde görüntü sınıflandırma uygulamaları için idealdir (Tan ve Le, 2019).

Veri ön işleme ve artırma teknikleri

Görüntü ön işleme

Gerçek resim işlemeye başlamadan önce, veri kümesindeki görüntülerden toz, su damlacıkları ve gölgeler gibi gürültüleri çıkarmak, segmentasyon ve özellik çıkarma aşamalarında sorunların önüne geçmek için gereklidir (Nixon ve Aguado, 2019). Yakalanan fotoğraflar düşük kontrasta, arka plan gürültüsüne ve bulanıklığa sahip olabilir (Ebrahimi ve ark., 2017; Thomas ve Raj, 2021) ve bu nedenle görüntüler, sonraki analizler için bu aşamada ön işleme tabi tutulur.

- 1. Görüntü yeniden boyutlandırma:** Algoritmalarımıza verilen tüm görüntülerin hesaplama bellek gücünü azaltmak için standart bir boyuta sahip olması gerektiğinden, 224×224 piksel çözünürlüğe ölçeklendirilmişlerdir (Brownlee, 2019).
- 2. Görüntü filtreleme:** Görüntüler kaydedildiğinde, toz, kir ve çığ damlacıkları gibi kirleticiler içerebilirler (Brownlee, 2019). Bunu çözmek için, görüntüleri düzleştirmek ve Gauss gürültüsünü gidermek için bir Gauss filtresi kullanılır. Bu işlem, Gauss dağılımına dayanarak yakındaki piksellerin ağırlıklı ortalamasını hesaplar (Zeng ve Liu, 2013; Athiraja ve Vijayakumar, 2021). Ardından, bir düşük geçişli filtre çekirdeğiyle görüntü konvolüsyonu yapılır, bu da görüntünün bulanıklaşmasına ve gürültü ve kenar gibi yüksek frekans bileşenlerinin çıkarılmasına neden olur.
- 3. Kontrast artırma:** Farklı fotoğraf bölümleri, örneğin normal ve hastalıklı bölgeler gibi farklı kısımlar arasındaki ayrımı daha kolay hale getirmek için, fotoğrafların kontrastı kontrast artırma adı verilen bir teknik kullanılarak iyileştirildi (Athiraja ve Vijayakumar, 2021). Bu teknik, gri tonlamalı bir görüntü alınarak histogram eşitleme işlemi uygulanarak bir çıktı görüntüsü oluşturmayı içerir (Barbedo, 2016).

Veri artırma

Derin öğrenme için geniş miktarda veri gereklidir ve binlerce veya milyonlarca görüntüyü toplamak her zaman mümkün olmayabilir. Bu nedenle, aşırı öğrenmeyi önlemek için görüntü artırma kullanılır (Nagaraju ve Chawla, 2020; Pacal ve ark., 2022). Görüntü artırma, bir eğitim veri kümesinin boyutunu yapay olarak artırmak için veri kümesindeki görüntülerin değiştirilmiş versiyonlarının oluşturulmasını içeren bir tekniktir (Mikołajczyk ve Grochowski, 2018; Shorten ve Khoshgoftaar, 2019). Yeni veriler toplamak yerine, mevcut verileri değiştiririz. Görüntü artırma işlemleri arasında döndürme, kırpma, yakınlaştırma, çevirme ve parlaklık seviyesini değiştirme gibi işlemler yer alır (Khirade ve Patil, 2015; Nagaraju ve Chawla, 2020). Verilerimiz üzerinde gerçekleştirilen çeşitli artırma işlemleri aşağıdaki gibidir:

- 1. Döndürme:** Bir kaynak görüntü, nesnenin konumunu değiştirerek rastgele sayıda saat yönünde veya saat yönünün tersine döndürülür. Oluşturulan veriler, dönüş aralığı parametresi derece olarak belirtildiğinde +dönüş aralığı ile -dönüş aralığı arasındaki açıda rastgele olarak döndürülür.
- 2. Kesme:** Kesme dönüşümü uygulandığında, görüntü şekli eğik hale gelir. Bir eksen sabit tutulurken, diğer eksen kesme açısı olarak bilinen bir açıda gerilir, bu da görüntünün gerildiği görünümüne neden olur. Eğim derecesi, kesme aralığı kullanılarak belirtilebilir ve bu etki, görüntü döndürüldüğünde görünmez.
- 3. Yakınlaştırma:** Yakınlaştırma aralığını ayarlamak, görüntü üzerinde rastgele bir yakınlaştırma etkisi oluşturur. 1,0'dan küçük bir yakınlaştırma faktörü görüntünün boyutunu küçültürken, 1,0'dan büyük bir faktör boyutunu artırır.
- 4. Kırpma:** Eğitim verilerindeki nesnelere her zaman orijinal görüntüde görünür veya aynı ölçekte olmayabilir. Bu nedenle, rastgele kesme adı verilen bir veri artırma tekniği kullanılarak orijinal görüntünün rastgele bir alt kümesi oluşturulur.
- 5. Yatay ve dikey döndürme:** Bir görüntü yatay veya dikey olarak çevrildiğinde, yönü değişir. Dikey bir çevirme, görüntünün yatay olarak çevrilmeden önce 180 derece döndürülmesine eşdeğerdir.
- 6. Parlaklık seviyesini değiştirme:** Bir görüntünün parlaklığı rastgele olarak artırılarak veya azaltılarak veya her ikisi birden artırılarak geliştirilebilir. Parlaklık aralığı, parlaklık değişimi için rastgele seçilecek bir değerin aralığını belirtir. Bu, modelin farklı aydınlatma seviyelerine sahip görüntüler arasında daha iyi genelleme yapmasına yardımcı olur.


Öğrenme aktarımı

Öğrenme aktarımı, bir önceki eğitilmiş modelin performansını geliştirmek için kullanılan bir makine öğrenmesi tekniğidir (Pacal, 2022). Geleneksel olarak, makine öğrenmesi modelleri bağımsız olarak çalışacak şekilde tasarlanır ve yeni özellikler ve veriler sunulduğunda yeniden oluşturmak için büyük çaba gerektirir. Öğrenme aktarımı, edinilen bilgi ve modellerin yeniden kullanımıyla bu çabayı azaltmayı ve böylece geliştirme süresini dramatik olarak kısaltmayı ve performansı artırmayı hedefler. Öğrenme aktarımı, yazılım hata tahmini (Nam ve Kim, 2015), duygu sınıflandırması (Wang ve Mahadevan, 2011) ve aktivite tanıma (Cook ve ark., 2013) gibi çeşitli alanlarda uygulanmaktadır. Öğrenme aktarımının yaygın bir uygulaması, bilgisayar görüşü görevleri için önceden eğitilmiş ImageNet veri kümesindeki modellerin kullanılmasıdır (Karaman ve ark., 2023). ImageNet, görsel nesne tanıma araştırmaları için kullanılan geniş bir resim koleksiyonudur ve birçok derin öğrenme modeli, ImageNet'te eğitildikten sonra görüntü sınıflandırma alanında en iyi sonuçları elde etmiştir. Araştırmacılar, benzer görsel özelliklere sahip küçük veri kümeleri için önceden eğitilmiş ImageNet modellerini kullanarak zaman ve kaynak tasarrufu yaparken daha iyi sonuçlar elde edebilirler (BAYAT ve Gültekin, 2022; KILIÇARSLAN, 2022). Önceden eğitilmiş ImageNet modellerini kullanmak için araştırmacılar, modeli yeni bir veri kümesinde ince ayarlayabilir veya özellik çıkarıcısı olarak kullanabilirler. Genel olarak, önceden eğitilmiş ImageNet modellerini kullanarak öğrenme aktarımı, bilgisayar görüşü alanında etkili bir yaklaşımdır (Karaman ve ark., 2022). Bu çalışmada mevcut derin öğrenme modellerine ImageNet ön eğitilmiş ağırlıklar kullanılarak öğrenme aktarımı gerçekleştirilmiş ve bu modellerin performansları değerlendirilmiştir.

Önerilen yaklaşım

Çeltik yaprak hastalıklarının tespit edilmesi ve sınıflandırılması için yapılan çalışmanın temel bileşenleri Şekil 2'de gösterilmektedir. Derin öğrenme tabanlı bu çalışmanın ilk aşamasını Veri Seti birimi oluşturmaktadır. 10.407 görüntüden oluşan veri seti, derin öğrenme yaklaşımları için ideal bir

veri setidir. Veri setinden sonraki aşama ise Veri İşleme aşamasıdır. Bu aşamada temel amaç, veri setindeki görüntülerin aynı boyuta indirgenmesi, bölünmesi ve bazı temel veri artırma tekniklerinin uygulanmasıdır. Çeltik yaprak hastalıklarına ait 10.407 görüntüden oluşan veri seti, derin öğrenme yaklaşımlarında kullanılmak üzere rastgele eğitim (%70), doğrulama (%15) ve test (%15) verileri olarak üç kısma ayrılmıştır. Daha sonra sınıf dağılımlarını dengelemek için veri setine eğitim esnasında çevirme, döndürme ve kaydırma gibi temel veri artırma teknikleri uygulanmıştır. Büyük ölçekli veri setlerinde veri artırma çok etkili olmasa da küçük ölçekli ve çeşitliliğin az olduğu veri setlerinde veri artırma oldukça etkilidir. Üçüncü aşama öğrenme yaklaşımlarının olduğu birimdir. Bu birimde öğrenme aktarımı ve sınıflandırma için CNN modelleri yer almaktadır. Transfer öğrenme ya da öğrenme aktarımı bir alanda eğitilen bir modelin ağırlıklarının farklı bir alan için kullanılması yani ağırlıkların aktarılması işlemidir. Bu çalışmada, ImageNet (Russakovsky ve ark., 2015) veri seti üzerinde eğitilen CNN model ağırlıkları Paddy Doctor veri seti için kullanılmıştır. Öğrenme aktarımı özellikle küçük ölçekli veri setlerinde çok ciddi performans sağlar. Bu veri setinde öğrenme aktarımı ile hem performansın hem de yakınsamanın sıfırdan eğitime göre daha hızlı olması sağlanmıştır. Öğrenme aktarımından sonra sınıflandırma işlemi için 12 CNN modeli, doğrulama ve test işlemine tabi tutulmuştur. Modeller, Test Verisi üzerinde test edilerek her modelin performans metrikleri belirlenmiştir. Son olarak sınıflandırma işlemi için bu modellerin çıktıları gözlemlenmiştir.



Şekil 2. Çeltik Yaprak Hastalığı Tespiti İçin Genel Yaklaşım

BULGULAR VE TARTIŞMA

Uygulama Detayları

Bu araştırma, Ubuntu 22.04 işletim sistemiyle çalışan bir Linux bilgisayarında gerçekleştirilmiştir. Derin öğrenme modellerinin eğitildiği ve test edildiği bilgisayar, Intel Core i9 9900X 10 çekirdekli 3,50 GHz işlemci, 19,25 MB Intel Smart Cache bellek, 16GB DDR4 RAM ve tek bir NVIDIA RTX 3090 (24 GB GDDR6X, 10496 CUDA çekirdeği ve 328 tensör çekirdeği) özelliklerine sahiptir. Deneyler, NVIDIA CUDA ile PyTorch framework'ünün en son kararlı sürümü kullanılarak gerçekleştirilmiştir. Tüm mimariler için eğitim ve test için aynı ortamlar kullanılmış ve tüm modeller aynı parametrelerle eğitilmiştir.

Değerlendirme metrikleri

Derin öğrenme modellerinin etkililiğini değerlendirmede ve bilinçli kararlar vermede performans metrikleri kritik bir rol oynamaktadır. Bu metrikler, modellerin performansını değerlendirmek, optimizasyon sürecini yönlendirmek, sonuçları raporlamak, hataları ve önyargıları belirlemek, referans noktaları oluşturmak ve aşırı uyum tespit etmek gibi görevler için önemlidir. Bu çalışmada, özellikle

çeltik hastalıklarının tanımlanmasında etkili olan ve yaygın olarak kullanılan metrikler kullanılmıştır. Derin öğrenmede yaygın olarak kullanılan metrikler arasında doğruluk, kesinlik, duyarlılık ve F1 skoru bulunur. Doğruluk, tüm tahminlerin doğru yapılan tahminlere oranını temsil eder ve genel bir model performansı gösterir. Kesinlik, modelin tüm pozitif tahminlerine oranla başarılı tahminlerin oranını belirtir. Duyarlılık, tüm pozitif örneklerin doğru pozitif tahminlerine oranını ölçer ve modelin kaç gerçek pozitif örneğin doğru bir şekilde tanımlandığını gösterir. F1 skoru, kesinlik ve duyarlılık arasında bir denge kurmak için kullanılan harmonik ortalamadır. Tüm metrikler aşağıdaki denklemlerle verilen matematiksel formüllere sahiptirler:

$$\text{Doğruluk} = \frac{\text{Doğru tahmin sayısı}}{\text{Toplam tahmin sayısı}} \quad (1)$$

$$\text{Kesinlik} = \frac{\text{Doğru pozitif}}{\text{Doğru pozitif} + \text{Yanlış pozitif}} \quad (2)$$

$$\text{Duyarlılık} = \frac{\text{Doğru pozitif}}{\text{Doğru pozitif} + \text{Yanlış negatif}} \quad (3)$$

$$\text{F1 - skor} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

Deneysel sonuçlar

Yapılan çalışmada, her bir modelin başlangıç değerleri kullanılarak eğitim ve değerlendirme gerçekleştirilmiştir. Tek bir klasöründe bulunan veri setindeki tüm sınıflar, eğitilmiş modellerde genelleme gözlemlenmesi için %70'i eğitim verisi, %15'i doğrulama ve kalan %15'i test verisi olarak rastgele atanmıştır. Derin öğrenme modellerinin hızını ve doğruluğunu artırmak için kullanılacak çeşitli teknikler ve parametreler vardır. Öğrenme aktarımı ve veri artırma en etkili tekniklerden ilk ikisidir. Ayrıca, giriş görüntüsü boyutu, küme boyutu, epok sayısı, optimizasyon algoritması, öğrenme oranı, momentum gibi bazı temel parametreler kullanılarak modelin performansını artırılabilir. Tutarlılığı korumak ve performansı artırmak için, ölçeklendirme, yumuşatma, karıştırma, renk değiştirme ve yansıtma gibi temel veri artırma teknikleri tüm modellere uygulanmıştır. ImageNet veri kümesi ağırlıkları da öğrenme aktarımı için kullanılmış ve yakınsama sürecini hızlandırmak ve doğruluğu artırmak için entegre edilmiştir. Çoğu modelde, eğitim ve doğrulama verileri için varsayılan giriş çözünürlük değeri olan 224x224 kullanılmıştır. Bazı diğer önemli parametreler, lr: 0.0001, momentum: 0.9, optimizasyon algoritması: SGD değerleri seçilirken, bu parametrelerle beraber diğer parametreler bütün derin öğrenme modelleri için sabit tutularak modellerin birbiri ile daha nesnel bir karşılaştırılması sağlanmıştır.

Bulgular

Bu bölüm, CNN'nin deneysel sonuçlarına ilişkin performans ölçütleri ve karışıklık matrisinin sonuçlarını ve tartışmasını kapsar. Ayrıca bu modellerin veri kümesi üzerinde nasıl performans gösterdiğini ve hangi modelin diğerinden üstün olduğunu inceler.

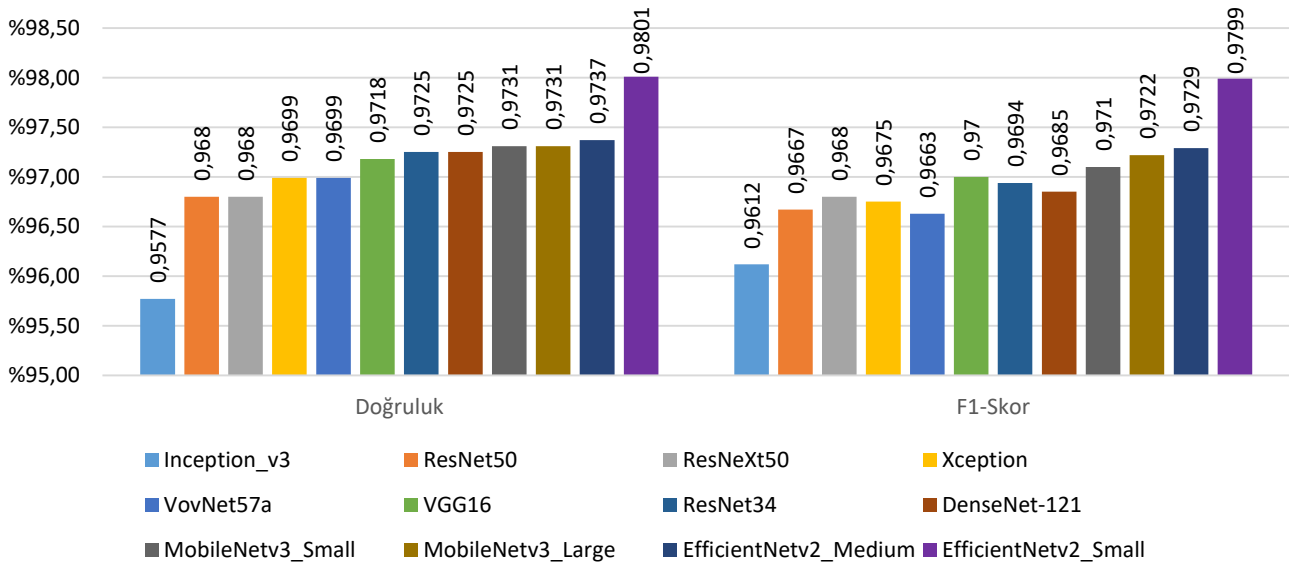
Paddy Doctor, bitki hastalıklarını teşhis etmek için kullanılan yeni veri kümesidir. Son zamanlarda CNN, bilgisayarlı görü alanında giderek daha popüler hale geldi ve daha yüksek doğruluğu ve daha az parametresi nedeniyle özellikle tarımsal görüntü analizinde yüksek performans gösterdi. Bu çalışmada, literatürde nesne sınıflandırması için yaygın olarak kullanılan CNN modelleri, Paddy Doctor veri setinde çeltik hastalıkları üzerinde eğitilmiş ve değerlendirilmiştir. Modellerin performansları CNN'in parametre değerleri ve hiperparametreleri kullanılarak değerlendirilmiştir. Birçok bitki hastalığının erken teşhisi, üretim için önemlidir ve çeltik yaprağı hastalıklarının erken tespiti, çiftçilerin hastalığın yayılmasını kontrol altına almak ve ürün kaybını en aza indirmek için hızlı

harekete geçmesine yardımcı olabilir. Tablo 2, çeltik yaprağı görüntülerinden elde edilen Paddy Doctor veri setinde çeltik yaprağı hastalıklarının sınıflandırılmasının deneysel sonuçlarını göstermektedir.

Tablo 2. Paddy Doctor Veri Kümesindeki Derin Öğrenme Modellerinin Sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1-skor
ResNet34	0.9725	0.9714	0.9677	0.9694
ResNet50	0.968	0.9683	0.9651	0.9667
VGG16	0.9718	0.9718	0.9683	0.9700
DenseNet-121	0.9725	0.9713	0.9657	0.9685
Xception	0.9699	0.9702	0.9649	0.9675
Inception_v3	0.9577	0.9627	0.9597	0.9612
ResNeXt50	0.968	0.9712	0.9649	0.9680
VovNet57a	0.9699	0.9694	0.9632	0.9663
MobileNetv3_Small	0.9731	0.9744	0.9676	0.9710
MobileNetv3_Large	0.9731	0.9752	0.9698	0.9722
EfficientNetv2_Small	0.9801	0.9800	0.9799	0.9799
EfficientNetv2_Medium	0.9737	0.9735	0.9724	0.9729

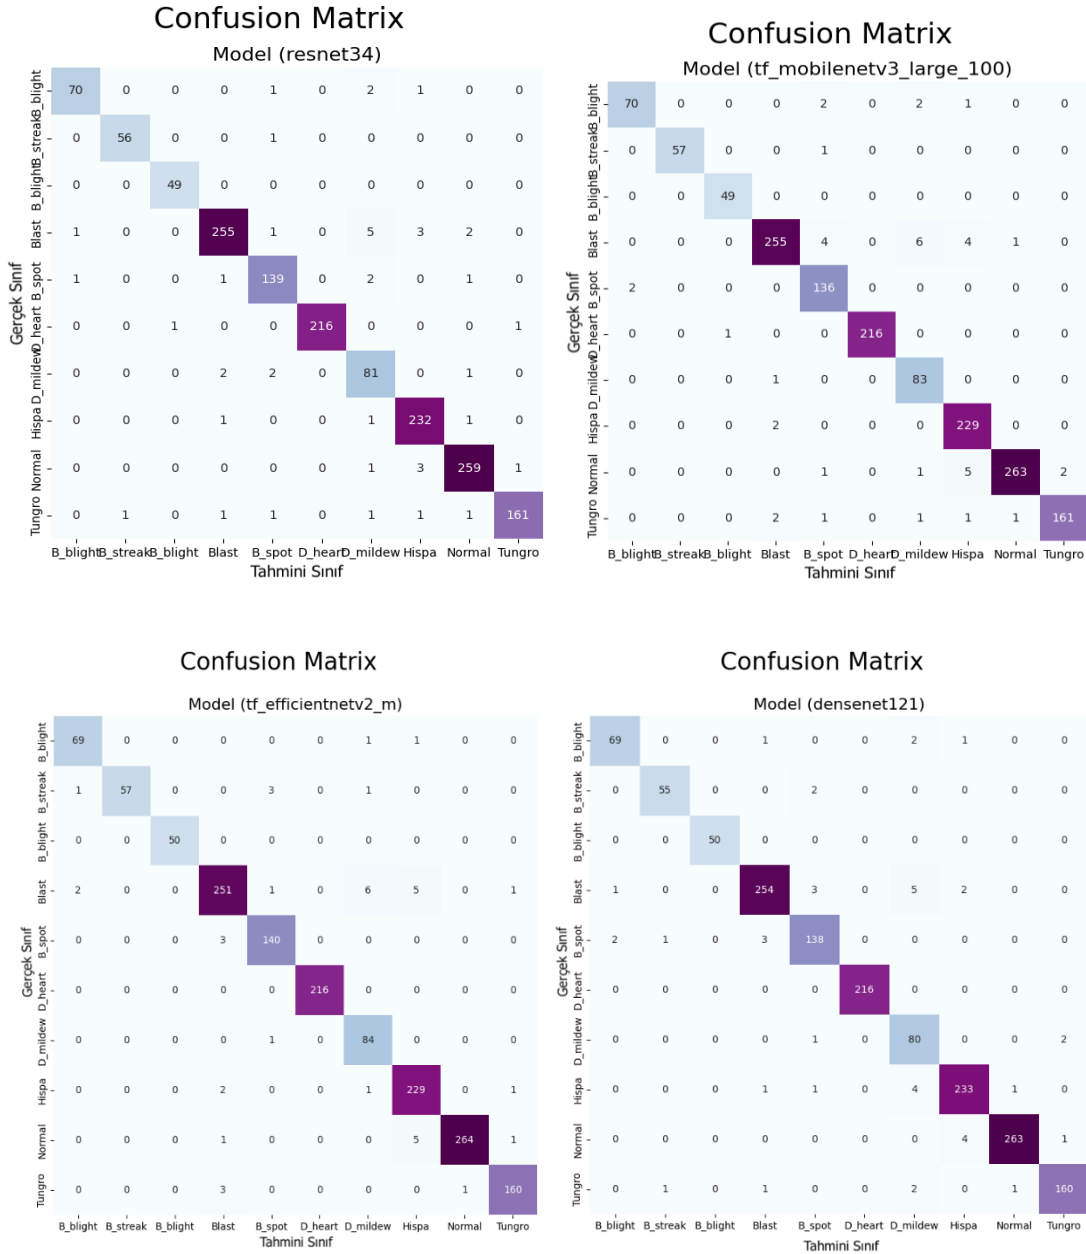
Tablo 2 incelendiğinde, tüm derin öğrenme modellerinin %95'in üzerinde bir doğruluğa sahip olduğu görülmektedir. CNN tabanlı modellerde, aynı doğruluk değerlerine sahip ResNet34 ve DenseNet-121 modelleri, ResNet-50, VGG16 ve Xception modellerine kıyasla önemli ölçüde daha yüksek metrik değerlere sahiptir. EfficientNetv2_Small modeli %98.01 doğruluk ve %97.99 F1 puanına sahipken, Inception_v3 modeli %95.77 doğruluk ve %96.12 F1 puanına sahiptir. Genel olarak, EfficientNetv2_Small modeli en yüksek doğruluğa sahipken, Inception_v3 modeli en düşük doğruluk değerlerine sahiptir. Modellere ait performans metriklerinin karşılaştırmalı analizi için Şekil 3'te her bir modele ait doğruluk ve F1 skoru görselleştirilmiştir.




Şekil 3. Modellere Ait Doğruluk ve F1-Skoru Değerlerinin Karşılaştırmalı Analizi

Şekil 4, Şekil 5 ve Şekil 6, çeltik yaprak hastalıklarının tespiti için kullanılan farklı CNN modellerinin karışıklık matrislerini göstermektedir. Bulgular ışığında Şekil 4'teki karışıklık matrisleri dikkate alındığında, çeltik yaprak hastalıklarının teşhisi için çeltik yaprak görüntülerinden elde edilen Paddy Doctor veri kümesinde, EfficientNetv2_Small modelinin diğer modellere göre daha iyi performans gösterdiği, Inception_v3 mimarisinin ise daha düşük bir performansa sahip olduğu görülmektedir. Karışıklık matrislerine bakıldığında, neredeyse tüm modellerin %96 ve üzeri başarı elde ettiği görülmektedir.

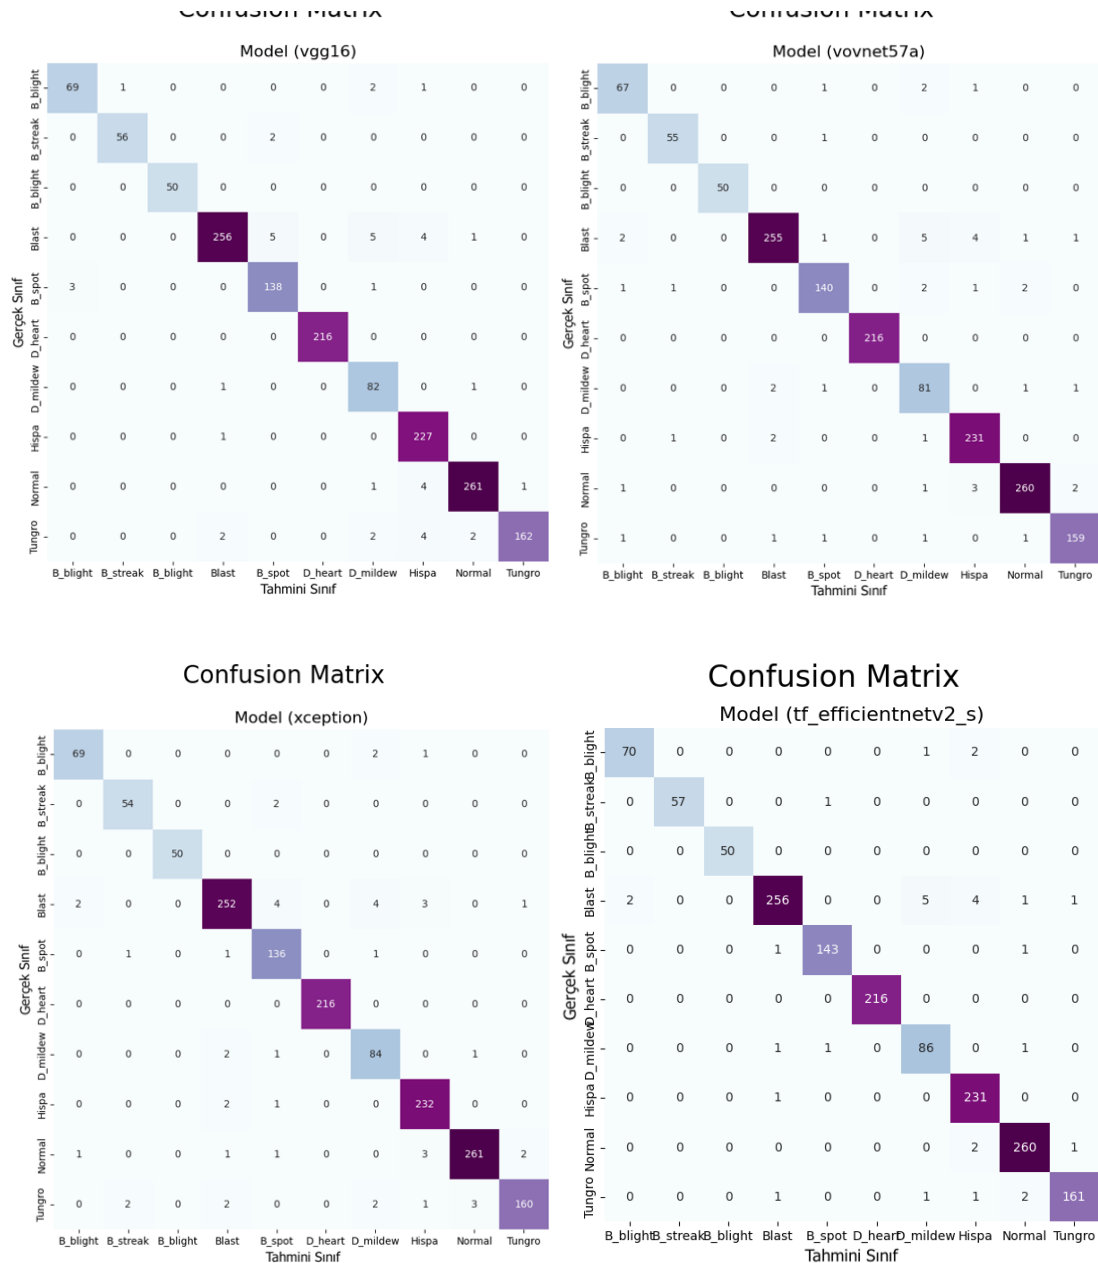
Derin öğrenme, tarım görüntü analizinde en popüler yöntemlerden biridir. Farklı ağ mimarilerine sahip algoritmaları olan derin öğrenme, özellikle tarım görüntüleri alanında yaygın olarak kullanılmaktadır. Derin öğrenme modelleri için yeterli veriye erişememek ve kötü matematiksel modeller gibi bazı problemler olsa da literatürde %90'ın üzerinde başarı oranına sahip birçok çalışmanın olması, derin öğrenme algoritmalarının bu alanda ne kadar umut vaat ettiğini göstermektedir. Bu çalışmada, pirinç yaprak hastalıklarının tespiti için elde edilen yaprak görüntülerine derin öğrenme yöntemleri uygulanarak çeltik yaprak hastalığının türünün belirlenmesi amaçlanmıştır. Sonuç olarak, CNN modellerinin, çeltik yaprak hastalıklarının teşhisinde yüksek bir sınıflandırma başarısı sunduğu gözlemlenmiştir.



Şekil 4. Modellere Ait Karışıklık Matrisleri



Şekil 5. Modellere Ait Karışıklık Matrisleri



Şekil 6. Modellere ait Karışıklık Matrisleri

Önerilen yaklaşımının diğer yaklaşımlarla karşılaştırılması

Önerilen modelin literatürde çeltik görüntülerinin kullanıldığı çalışmalara göre performans değerlendirmesi Tablo 3'te verilmiştir. Çeltik hastalıklarının doğru tespit edilmesi daha önemli olduğu için Tablo 3'te doğruluk ve F1-skor değerleri dikkate alınmıştır. Paddy Doctor (Kiruba ve Arjunan, 2023) çalışması dışındaki diğer çalışmalar farklı veri setleri kullanmıştır. Paddy Doctor (Kiruba ve Arjunan, 2023) çalışmasında öğrenme aktarımı yöntemlerini incelemiştir. İlgili çalışmada 16.225 çeltik hastalık görüntüsü kullanılmıştır. Test edilen modeller arasında en yüksek doğruluk (%97.50) ve F1-skor (%97.50) değerlerine ResNet34 modeli ulaşmıştır. Kaggle'da (Paddy Doctor: Paddy Disease Classification, 2022) düzenlenen yarışmada Paddy Doctor veri setinin sadece eğitim (10.407) görüntüleri paylaşılmıştır. Paylaşılan görüntülerden oluşan veriler, rastgele eğitim (%70), doğrulama (%15) ve test (%15) olarak bölünerek çalışmamızda çeltik hastalıklarının tespiti ve sınıflandırılması için öğrenim aktarımı ile farklı CNN modelleri üzerinde test edilmiştir. Test sonucunda EfficientNetv2_Small modeli %98.01 doğruluk ve %97.99 F1-skor değerleri ile en başarılı model

olmuştur. Önerilen modelin Paddy Doctor (2022) çalışmasında kullanılan görüntü sayılarından az olmasına rağmen literatürdeki çalışmalarda çeltik görüntüleri temel alan tüm modellerden daha yüksek performans gösterdiği görülmüştür. İlerleyen zamanlarda Paddy Doctor veri setine ait tüm görüntülerle yapılacak bir çalışmanın daha yüksek sonuçlar vereceği düşünülmektedir.

Tablo 3. Önerilen Yaklaşımın Literatürde Var Olan Diğer Çalışmalarla Karşılaştırılması

Çalışma	Yöntem	Görüntü sayısı	Veri seti	Doğruluk (%)	F1-skor (%)
Senthil Pandi ve ark. (2022)	DCNN +GAP	5.932	Mendeley	96.50	94.32
Sethy ve ark. (2020a)	Mobilenetv2	5.932	Mendeley	97.96	97.96
Gautam ve ark. (2022)	InceptionV3	1.500	Mendeley ve Kaggle	96.47	96.47
Krishnamoorthy ve ark. (2021)	InceptionResNetV2	5.200	Kaggle & Google Images	95.67	95.67
Kiruba ve Arjunan (2023)	Resnet34	16.225	Paddy Doctor	97.50	97.50
Önerilen yaklaşım	EfficientNetv2_Small	10.407	Paddy Doctor	98.01	97.99

SONUÇ

Çeltik yaprak hastalıklarının zamanında tespit edilmesi mahsulün zarar görmesini en aza indirmek için çok önemlidir. Bilgisayar destekli sistemler, bu bitki hastalıklarını erken aşamada teşhis etmek için çiftçiler ve ziraat mühendisleri tarafından yaygın olarak kullanılmaktadır. Bu çalışmada, çeltik yaprak hastalıklarının tespiti için Paddy Doctor veri setinden alınan yaprak görüntülerini analiz etmek için yaygın derin öğrenme yaklaşımları kullanılmıştır.

Son zamanların en popüler derin öğrenme mimarilerinin birçok modelini bir araya getiren bu çalışma, literatürdeki çeltik hastalıkları üzerine yapılmış en kapsamlı çalışmadır. Deneysel sonuçlar, EfficientNetv2_Small modelinin tüm çeltik hastalıklarını %98.01 test doğruluğu ile doğru bir şekilde teşhis ettiğini göstermiştir. Bulgular, CNN tabanlı mimarilerin yüksek iyi performans gösterdiğini ve ziraat mühendislerine ve çiftçilere bu hastalığın erken teşhisinde ve ayrıca potansiyel olarak gelecekteki diğer tarımsal problemlerde yardımcı olmada etkili olduğunu göstermektedir.

Bu çalışma, çeltik yaprak hastalıklarının tespiti için derin öğrenme yaklaşımlarının kullanımının etkisini gösteren önemli bir çalışmadır. Ancak, gelecekte bu alanda daha fazla çalışma yapılabilir. Bu çalışmada sadece Paddy Doctor veri seti kullanılarak gerçekleştirilmiştir. Gelecekte, daha geniş veri setleri kullanılarak daha fazla çeltik hastalığı tespit edilebilir ve daha iyi sonuçlar elde edilebilir. Ayrıca Özellikle CNN tabanlı yaklaşımlar üzerine odaklanmıştır. Gelecekte, farklı derin öğrenme yöntemleri de dahil olmak üzere başka yaklaşımlar da incelenebilir.

Çıkar Çatışması Beyanı

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder.

KAYNAKLAR

- Agarwal, M., Singh, A., Arjaria, S., Sinha, A., ve Gupta, S. (2020). ToLeD: Tomato Leaf Disease Detection using Convolution Neural Network. *Procedia Computer Science*, 167, 293-301. <https://doi.org/https://doi.org/10.1016/j.procs.2020.03.225>
- Agus, F., Ihsan, M., Khairina, D. M., ve Candra, K. P. (2019). Expert System for Rice Plant Disease Diagnosis. In: vol.

- Akila, M., ve Deepan, P. (2018). Detection and classification of plant leaf diseases by using deep learning algorithm. *International Journal of Engineering Research ve Technology (IJERT)*, 6(7), 1-5.
- An, C., Sun, C., Li, N., Huang, B., Jiang, J., Shen, Y., Wang, C., Zhao, X., Cui, B., ve Wang, C. (2022). Nanomaterials and nanotechnology for the delivery of agrochemicals: strategies towards sustainable agriculture. *Journal of Nanobiotechnology*, 20(1), 1-19.
- Arnal Barbedo, J. G. (2019). Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, 180, 96-107. <https://doi.org/https://doi.org/10.1016/j.biosystemseng.2019.02.002>
- Asad, M. H., ve Bais, A. (2020). Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network. *Information Processing in Agriculture*, 7(4), 535-545. <https://doi.org/https://doi.org/10.1016/j.inpa.2019.12.002>
- Athiraja, A., ve Vijayakumar, P. (2021). RETRACTED ARTICLE: Banana disease diagnosis using computer vision and machine learning methods. *Journal of Ambient Intelligence and Humanized Computing*, 12(6), 6537-6556.
- Atole, R. R., ve Park, D. (2018). A multiclass deep convolutional neural network classifier for detection of common rice plant anomalies. *International Journal of Advanced Computer Science and Applications*, 9(1).
- Baranwal, S., Khandelwal, S., ve Arora, A. (2019). Deep learning convolutional neural network for apple leaves disease detection. Proceedings of international conference on sustainable computing in science, technology and management (SUSCOM), Amity University Rajasthan, Jaipur-India,
- Barbedo, J. G. A. (2016). A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems Engineering*, 144, 52-60.
- Baresel, J. P., Rischbeck, P., Hu, Y., Kipp, S., Hu, Y., Barmeier, G., Mistele, B., ve Schmidhalter, U. (2017). Use of a digital camera as alternative method for non-destructive detection of the leaf chlorophyll content and the nitrogen nutrition status in wheat. *Computers and Electronics in Agriculture*, 140, 25-33. <https://doi.org/https://doi.org/10.1016/j.compag.2017.05.032>
- Bayat, S. ve Işık, G. (2022). "Aras Kuş Türlerinin Ses Özellikleri Bakımından Derin Öğrenme Yöntemleriyle Tanınması." *Journal of the Institute of Science and Technology* 12(3): 1250-1263
- Bhagawati, R., Bhagawati, K., Singh, A., Nongthombam, R., Sarmah, R., ve Bhagawati, G. (2015). Artificial neural network assisted weather based plant disease forecasting system. *International Journal on Recent and Innovation Trends in Computing and Communication*, 3(6), 4168-4173.
- Brownlee, J. (2019). *Deep learning for computer vision: image classification, object detection, and face recognition in python*. Machine Learning Mastery.
- Catindig, J. (2023). *Hispa*. <http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/insects/item/rice-hispa>
- Chawathe, S. S. (2020). Rice disease detection by image analysis. 2020 10th Annual Computing and Communication Workshop and Conference (CCWC),
- Chen, J., Chen, J., Zhang, D., Sun, Y., ve Nanekaran, Y. A. (2020). Using deep transfer learning for image-based plant disease identification. *Computers and Electronics in Agriculture*, 173, 105393. <https://doi.org/https://doi.org/10.1016/j.compag.2020.105393>
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition,

- CM Vera Cruz, I. O., NP Castilla, and R Oplencia. (2023). *Bacterial Leaf Blight* <http://www.knowledgebank.irri.org/decision-tools/rice-doctor/rice-doctor-fact-sheets/item/bacterial-blight>
- Cook, D., Feuz, K. D., ve Krishnan, N. C. (2013). Transfer learning for activity recognition: A survey. *Knowledge and information systems*, 36, 537-556.
- Coulibaly, S., Kamsu-Foguem, B., Kamissoko, D., ve Traore, D. (2019). Deep neural networks with transfer learning in millet crop images. *Computers in Industry*, 108, 115-120. <https://doi.org/https://doi.org/10.1016/j.compind.2019.02.003>
- Dean, R., Van Kan, J. A., Pretorius, Z. A., Hammond-Kosack, K. E., Di Pietro, A., Spanu, P. D., Rudd, J. J., Dickman, M., Kahmann, R., ve Ellis, J. (2012). The Top 10 fungal pathogens in molecular plant pathology. *Molecular plant pathology*, 13(4), 414-430.
- Ebrahimi, M., Khoshtaghaza, M. H., Minaei, S., ve Jamshidi, B. (2017). Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*, 137, 52-58.
- Fuentes, A., Yoon, S., Kim, S. C., ve Park, D. S. (2017). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, 17(9), 2022.
- Ganesan, G., ve Chinnappan, J. (2022). Hybridization of ResNet with YOLO classifier for automated paddy leaf disease recognition: An optimized model. *Journal of Field Robotics*, 39(7), 1085-1109.
- Gautam, V. (2020). Qualitative model to enhance quality of metadata for data warehouse. *International Journal of Information Technology*, 12, 1025-1036.
- Gautam, V., Trivedi, N. K., Singh, A., Mohamed, H. G., Noya, I. D., Kaur, P., ve Goyal, N. (2022). A Transfer Learning-Based Artificial Intelligence Model for Leaf Disease Assessment. *Sustainability*, 14(20), 13610.
- Goluguri, N. R. R., Devi, K. S., ve Srinivasan, P. (2021). Rice-net: an efficient artificial fish swarm optimization applied deep convolutional neural network model for identifying the *Oryza sativa* diseases. *Neural Computing and Applications*, 33(11), 5869-5884.
- Gunawan, P., Kencana, E., ve Sari, K. (2021). Classification of rice leaf diseases using artificial neural network. *Journal of Physics: Conference Series*,
- Gündüz, M. Ş., ve Işık, G. (2023). A new YOLO-based method for real-time crowd detection from video and performance analysis of YOLO models. *Journal of Real-Time Image Processing*, 20(1), 5.
- Ham, J. H., Melanson, R. A., ve Rush, M. C. (2011). *Burkholderia glumae*: next major pathogen of rice? *Molecular plant pathology*, 12(4), 329-339.
- He, K., Zhang, X., Ren, S., ve Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*,
- Hossain, S. M. M., Tanjil, M. M. M., Ali, M. A. B., Islam, M. Z., Islam, M. S., Mobassirin, S., Sarker, I. H., ve Islam, S. R. (2020). Rice leaf diseases recognition using convolutional neural networks. *Advanced Data Mining and Applications: 16th International Conference, ADMA 2020, Foshan, China, November 12–14, 2020, Proceedings 16*,
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., ve Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Htun, K. W., ve Htwe, C. S. (2018). Development of Paddy Diseased Leaf Classification System Using Modified Color Conversion. *International Journal of Software ve Hardware Research in Engineering*, 6(8).

- Huang, G., Liu, Z., Van Der Maaten, L., ve Weinberger, K. Q. (2017). Densely connected convolutional networks. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Huang, J., Liao, H., Zhu, Y., Sun, J., Sun, Q., ve Liu, X. (2012). Hyperspectral detection of rice damaged by rice leaf folder (*Cnaphalocrocis medinalis*). *Computers and Electronics in Agriculture*, 82, 100-107. <https://doi.org/https://doi.org/10.1016/j.compag.2012.01.002>
- Islam, T., Sah, M., Baral, S., ve Choudhury, R. R. (2018). A faster technique on rice disease detection using image processing of affected area in agro-field. 2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT),
- Jena, K. K., ve Kim, S.-M. (2010). Current status of brown planthopper (BPH) resistance and genetics. *Rice*, 3(2), 161-171.
- Jiang, H., Zhang, C., Qiao, Y., Zhang, Z., Zhang, W., ve Song, C. (2020). CNN feature based graph convolutional network for weed and crop recognition in smart farming. *Computers and Electronics in Agriculture*, 174, 105450. <https://doi.org/https://doi.org/10.1016/j.compag.2020.105450>
- Kahar, M. A. A., Mutalib, S., ve Rahman, S. A. (2015). Early Detection and Classification of Paddy Diseases with Neural Networks and Fuzzy Logic Recent Advances in Mathematical and Computational Method.
- Kamal, K., Yin, Z., Wu, M., ve Wu, Z. (2019). Depthwise separable convolution architectures for plant disease classification. *Computers and Electronics in Agriculture*, 165, 104948.
- Karaman, A., Karaboga, D., Pacal, I., Akay, B., Basturk, A., Nalbantoglu, U., Coskun, S., ve Sahin, O. (2022). Hyper-parameter optimization of deep learning architectures using artificial bee colony (ABC) algorithm for high performance real-time automatic colorectal cancer (CRC) polyp detection. *Applied Intelligence*, 1-18.
- Karaman, A., Pacal, I., Basturk, A., Akay, B., Nalbantoglu, U., Coskun, S., Sahin, O., ve Karaboga, D. (2023). Robust real-time polyp detection system design based on YOLO algorithms by optimizing activation functions and hyper-parameters with artificial bee colony (ABC). *Expert Systems with Applications*, 221, 119741. <https://doi.org/https://doi.org/10.1016/j.eswa.2023.119741>
- Karlekar, A., ve Seal, A. (2020). SoyNet: Soybean leaf diseases classification. *Computers and Electronics in Agriculture*, 172, 105342.
- Karmokar, B. C., Ullah, M. S., Siddiquee, M. K., ve Alam, K. M. R. (2015). Tea leaf diseases recognition using neural network ensemble. *International Journal of Computer Applications*, 114(17).
- Kaur, P., ve Gautam, V. (2021). Plant biotic disease identification and classification based on leaf image: A review. Proceedings of 3rd International Conference on Computing Informatics and Networks: ICCIN 2020,
- Khirade, S. D., ve Patil, A. (2015). Plant disease detection using image processing. 2015 International conference on computing communication control and automation,
- KILIÇARSLAN, S. (2022). "Kurum Üzüm Tanelerinin Sınıflandırılması İçin Hibrit Bir Yaklaşım." *Mühendislik Bilimleri ve Araştırmaları Dergisi* 4(1): 62-71.
- Kiruba, B., ve Arjunan, P. (2023). Paddy Doctor: A Visual Image Dataset for Automated Paddy Disease Classification and Benchmarking. Proceedings of the 6th Joint International Conference on Data Science ve Management of Data (10th ACM IKDD CODS and 28th COMAD),

- Kovalskaya, N., ve Hammond, R. W. (2014). Molecular biology of viroid–host interactions and disease control strategies. *Plant Science*, 228, 48-60.
- Krishnamoorthy, N., Prasad, L. N., Kumar, C. P., Subedi, B., Abraha, H. B., ve Sathishkumar, V. (2021). Rice leaf diseases prediction using deep neural networks with transfer learning. *Environmental Research*, 198, 111275.
- Lee, Y., Hwang, J.-w., Lee, S., Bae, Y., ve Park, J. (2019). An energy and GPU-computation efficient backbone network for real-time object detection. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops,
- Li, B., Liu, Z., Huang, J., Zhang, L., Zhou, W., ve Shi, J. (2009). Hyperspectral identification of rice diseases and pests based on principal component analysis and probabilistic neural network. *Transactions of the Chinese Society of Agricultural Engineering*, 25(9), 143-147.
- Liu, B., ve Bruch, R. (2020). Weed detection for selective spraying: a review. *Current Robotics Reports*, 1, 19-26.
- Liu, H., Ma, X., Tao, M., Deng, R., Bangura, K., Deng, X., Liu, C., ve Qi, L. (2019). A Plant Leaf Geometric Parameter Measurement System Based on the Android Platform. *Sensors (Basel)*, 19(8). <https://doi.org/10.3390/s19081872>
- Malhi, G. S., Kaur, M., ve 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., ve 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>
- Masood, M. H., Saim, H., Taj, M., ve Awais, M. M. (2020). Early disease diagnosis for rice crop. *arXiv preprint arXiv:2004.04775*.
- Mikołajczyk, A., ve Grochowski, M. (2018). Data augmentation for improving deep learning in image classification problem. 2018 international interdisciplinary PhD workshop (IIPhDW),
- Mishra, A. M., Harnal, S., Mohiuddin, K., Gautam, V., Nasr, O. A., Goyal, N., Alwetaishi, M., ve Singh, A. (2022). A Deep Learning-Based Novel Approach for Weed Growth Estimation. *Intelligent Automation ve Soft Computing*, 31(2).
- Nagaraju, M., ve Chawla, P. (2020). Systematic review of deep learning techniques in plant disease detection. *International journal of system assurance engineering and management*, 11, 547-560.
- Nam, J., ve Kim, S. (2015). Heterogeneous defect prediction. Proceedings of the 2015 10th joint meeting on foundations of software engineering,
- Narmadha, R., ve Arulvadiyu, G. (2017). Detection and measurement of paddy leaf disease symptoms using image processing. 2017 International Conference on Computer Communication and Informatics (ICCCI),
- Ngugi, L. C., Abelwahab, M., ve Abo-Zahhad, M. (2021). Recent advances in image processing techniques for automated leaf pest and disease recognition – A review. *Information Processing in Agriculture*, 8(1), 27-51. <https://doi.org/https://doi.org/10.1016/j.inpa.2020.04.004>
- Nixon, M., ve Aguado, A. (2019). *Feature extraction and image processing for computer vision*. Academic press.
- Ozguven, M. M., ve Adem, K. (2019). Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A: Statistical Mechanics and its Applications*, 535, 122537. <https://doi.org/https://doi.org/10.1016/j.physa.2019.122537>

- Pacal, I. (2022). Deep Learning Approaches for Classification of Breast Cancer in Ultrasound (US) Images. *Journal of the Institute of Science and Technology*, 12(4), 1917-1927.
- Pacal, I., Karaboga, D., Basturk, A., Akay, B., ve Nalbantoglu, U. (2020). A comprehensive review of deep learning in colon cancer. *Computers in Biology and Medicine*, 126, 104003. <https://doi.org/https://doi.org/10.1016/j.combiomed.2020.104003>
- Pacal, I., ve ark. (2022). "An efficient real-time colonic polyp detection with YOLO algorithms trained by using negative samples and large datasets." *Computers in Biology and Medicine* 141: 105031.
- Peng, J., Kang, S., Ning, Z., Deng, H., Shen, J., Xu, Y., Zhang, J., Zhao, W., Li, X., ve Gong, W. (2020). Residual convolutional neural network for predicting response of transarterial chemoembolization in hepatocellular carcinoma from CT imaging. *European radiology*, 30, 413-424.
- Polder, G., Westeringh, N. v. d., Kool, J., Khan, H. A., Kootstra, G., ve Nieuwenhuizen, A. (2019). Automatic Detection of Tulip Breaking Virus (TBV) Using a Deep Convolutional Neural Network**This work was partially funded by the Dutch Product Board for Horticulture and the Dutch Ministry of Economic Affairs, Agriculture and Innovation. The research is part of the public private partnership BollenRevolutie 4.0 funded under the grant TKI-TU-1806. *IFAC-PapersOnLine*, 52(30), 12-17. <https://doi.org/https://doi.org/10.1016/j.ifacol.2019.12.482>
- Ramesh, S., ve Vydeki, D. (2020). Recognition and classification of paddy leaf diseases using Optimized Deep Neural network with Jaya algorithm. *Information Processing in Agriculture*, 7(2), 249-260. <https://doi.org/https://doi.org/10.1016/j.inpa.2019.09.002>
- Rangarajan, A. K., Purushothaman, R., ve Ramesh, A. (2018). Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia Computer Science*, 133, 1040-1047. <https://doi.org/https://doi.org/10.1016/j.procs.2018.07.070>
- Russakovsky, O., ve ark. (2015). "Imagenet large scale visual recognition challenge." *International journal of computer vision* 115: 211-252.
- Sambasivam, G., ve Opiyo, G. D. (2021). A predictive machine learning application in agriculture: Cassava disease detection and classification with imbalanced dataset using convolutional neural networks. *Egyptian Informatics Journal*, 22(1), 27-34. <https://doi.org/https://doi.org/10.1016/j.eij.2020.02.007>
- Sengupta, S., ve Das, A. K. (2017). Particle Swarm Optimization based incremental classifier design for rice disease prediction. *Computers and Electronics in Agriculture*, 140, 443-451.
- Senthil Pandi, S., Senthilselvi, A., Gitanjali, J., ArivuSelvan, K., Gopal, J., ve Vellingiri, J. (2022). Rice plant disease classification using dilated convolutional neural network with global average pooling. *Ecological Modelling*, 474, 110166. <https://doi.org/https://doi.org/10.1016/j.ecolmodel.2022.110166>
- Sethy, P. K., Barpanda, N. K., Rath, A. K., ve 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/https://doi.org/10.1016/j.compag.2020.105527>
- Sethy, P. K., Barpanda, N. K., Rath, A. K., ve Behera, S. K. (2020b). Image Processing Techniques for Diagnosing Rice Plant Disease: A Survey. *Procedia Computer Science*, 167, 516-530. <https://doi.org/https://doi.org/10.1016/j.procs.2020.03.308>
- Sharma, M., Kumar, C. J., ve Deka, A. (2022). Early diagnosis of rice plant disease using machine learning techniques. *Archives of Phytopathology and Plant Protection*, 55(3), 259-283.
- Shorten, C., ve Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.

- Simonyan, K., ve Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., ve Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational intelligence and neuroscience, 2016*.
- Sparks, A. (2023a). *Bacterial Leaf Streak* <http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/bacterial-leaf-streak>
- Sparks, A. (2023b). *Tungro*. <http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/tungro#:~:text=Rice%20tungro%20disease%20is%20caused,commonly%20found%20in%20rice%20paddies>.
- Srinivas, B., Satheesh, P., Rama Santosh Naidu, P., ve Neelima, U. (2021). Prediction of guava plant diseases using deep learning. ICCCE 2020: Proceedings of the 3rd International Conference on Communications and Cyber Physical Engineering,
- Strange, R. N., ve Scott, P. R. (2005). Plant disease: a threat to global food security. *Annu. Rev. Phytopathol.*, 43, 83-116.
- Sujithra, J., & Ukrit, M. F. (2020). A review on crop disease identification and classification through leaf images. *European Journal of Molecular & Clinical Medicine*, 7(09), 2020.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., ve Rabinovich, A. (2015). Going deeper with convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., ve Wojna, Z. (2016). Rethinking the inception architecture for computer vision. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Tan, M., ve Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. International conference on machine learning,
- Tao, M., Ma, X., Huang, X., Liu, C., Deng, R., Liang, K., ve Qi, L. (2020). Smartphone-based detection of leaf color levels in rice plants. *Computers and Electronics in Agriculture*, 173, 105431. <https://doi.org/https://doi.org/10.1016/j.compag.2020.105431>
- Thomas, J., ve Raj, E. D. (2021). Effectual single image dehazing with color correction transform and dark channel prior. Data Science and Computational Intelligence: Sixteenth International Conference on Information Processing, ICInPro 2021, Bengaluru, India, October 22–24, 2021, Proceedings 16,
- Tripathi, A. D., Mishra, R., Maurya, K. K., Singh, R. B., ve Wilson, D. W. (2019). Estimates for world population and global food availability for global health. In *The role of functional food security in global health* (pp. 3-24). Elsevier.
- Trivedi, N. K., Gautam, V., Anand, A., Aljahdali, H. M., Villar, S. G., Anand, D., Goyal, N., ve Kadry, S. (2021). Early detection and classification of tomato leaf disease using high-performance deep neural network. *Sensors*, 21(23), 7987.
- Udotalapally, V., Mohanty, S. P., Pallagani, V., ve Khandelwal, V. (2020). sCrop: A novel device for sustainable automatic disease prediction, crop selection, and irrigation in Internet-of-Agro-Things for smart agriculture. *Ieee Sensors Journal*, 21(16), 17525-17538.
- Uğuz, S., ve Uysal, N. (2021). Classification of olive leaf diseases using deep convolutional neural networks. *Neural Computing and Applications*, 33(9), 4133-4149.

- van Eeuwijk, F. A., Bustos-Korts, D., Millet, E. J., Boer, M. P., Kruijer, W., Thompson, A., Malosetti, M., Iwata, H., Quiroz, R., Kuppe, C., Muller, O., Blazakis, K. N., Yu, K., Tardieu, F., ve Chapman, S. C. (2019). Modelling strategies for assessing and increasing the effectiveness of new phenotyping techniques in plant breeding. *Plant Science*, 282, 23-39. <https://doi.org/10.1016/j.plantsci.2018.06.018>
- Velesaca, H. O., Mira, R., Suárez, P. L., Larrea, C. X., ve Sappa, A. D. (2020). Deep learning based corn kernel classification. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops,
- Verma, T., ve Dubey, S. (2018). Optimizing Rice Plant Diseases Recognition in Image Processing and Decision Tree Based Model. Smart and Innovative Trends in Next Generation Computing Technologies: Third International Conference, NGCT 2017, Dehradun, India, October 30-31, 2017, Revised Selected Papers, Part II 3,
- Waheed, A., Goyal, M., Gupta, D., Khanna, A., Hassanien, A. E., ve 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.
- Wang, C., ve Mahadevan, S. (2011). Heterogeneous domain adaptation using manifold alignment. IJCAI proceedings-international joint conference on artificial intelligence,
- Wang, G., Sun, Y., ve Wang, J. (2017). Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning. *Comput Intell Neurosci*, 2017, 2917536. <https://doi.org/10.1155/2017/2917536>
- Xiao, M., Ma, Y., Feng, Z., Deng, Z., Hou, S., Shu, L., ve Lu, Z. (2018). Rice blast recognition based on principal component analysis and neural network. *Computers and Electronics in Agriculture*, 154, 482-490. <https://doi.org/https://doi.org/10.1016/j.compag.2018.08.028>
- Xu, G., Zhang, F., Shah, S. G., Ye, Y., ve Mao, H. (2011). Use of leaf color images to identify nitrogen and potassium deficient tomatoes. *Pattern Recognition Letters*, 32(11), 1584-1590. <https://doi.org/https://doi.org/10.1016/j.patrec.2011.04.020>
- Yang, W., Chen, J., Chen, G., Wang, S., ve Fu, F. (2013). The early diagnosis and fast detection of blast fungus, *Magnaporthe grisea*, in rice plant by using its chitinase as biochemical marker and a rice cDNA encoding mannose-binding lectin as recognition probe. *Biosensors and Bioelectronics*, 41, 820-826.
- Zeigler, R. S., ve Barclay, A. (2008). The relevance of rice. In (Vol. 1, pp. 3-10): Springer.
- Zeng, F., ve Liu, L. (2013). Contrast enhancement of mammographic images using guided image filtering. Advances in Image and Graphics Technologies: Chinese Conference, IGTA 2013, Beijing, China, April 2-3, 2013. Proceedings,
- Zhang, M., Qin, Z., ve Liu, X. (2005). Remote sensed spectral imagery to detect late blight in field tomatoes. *Precision Agriculture*, 6, 489-508.
- Zhu, W., Chen, H., Ciechanowska, I., ve Spaner, D. (2018). Application of infrared thermal imaging for the rapid diagnosis of crop disease. *IFAC-PapersOnLine*, 51(17), 424-430. <https://doi.org/https://doi.org/10.1016/j.ifacol.2018.08.184>