

Evrişimli Sinir Ağı ile Çeltik Bitkisi Hastalığının Tespiti

İrfan ÖKTEN^{1*}, Uğur YÜZGEÇ²

¹Bitlis Eren Üniversitesi, Tatvan Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Bitlis

²Bilecik Şeyh Edebali Üniversitesi, Bilgisayar Mühendisliği Bölümü, Bilecik
(ORCID: [0000-0001-9898-7859](https://orcid.org/0000-0001-9898-7859)) (ORCID: [0000-0002-5364-6265](https://orcid.org/0000-0002-5364-6265))



Anahtar kelimeler: Derin öğrenme, Evrişimli sinir ağı, Hassas tarım, Yapay zekâ, Çeltik bitkisi.

Öz

Dünya çapında pirinç tüketimi göz önüne alındığında pirincin önemli bir yere sahip olduğu görülür. Çeltik bitkisi, buğdaygiller ailesinden mısır ve buğdaydan sonra en fazla ekimi yapılan bitkidir. Tarım alanındaki son araştırma konularından biriside, bir bitkinin yaprak görüntülerinden hastalıkların tanınması veya sınıflandırılmasıdır. Yaprak görüntülerinden çeltik hastalığının otomatik bir şekilde teşhis edilmesi, geliştirme aşamasında olan bir araştırma konusudur. Bu gelişime katkı sağlamak amacıyla farklı öğrenme yöntemleri kullanılarak hastalığın erken teşhisi için önemli çalışmalar yapılmaktadır. Bu çalışmada temel olarak hastalıkları tespit etmek için bir makine öğrenme yöntemi olan derin öğrenme modelleri kullanılmıştır. Bu çalışmada derin Evrişimli Sinir Ağı (ESA) kullanılarak çeltik bitkisinin hastalıklı olup olmadığı tespit edilmiştir. Çalışmada kullanılan 5000 adet çeltik bitkisi yaprağına ait veri seti Kaggle sitesinden alınmıştır. Hastalığın tespiti için çeltik bitkisine ait üç hastalık (BrowSpot, LeafBlast ve Hispa) ve sağlıklı olmak üzere toplam iki sınıflı sınıflandırma yapılmıştır. Çeltik bitkisinin hastalığının tespiti için kullanılan ESA'nın hiper-parametrelerinde değişiklik yapılarak %91,54'lük bir başarı oranı elde edilmiştir. Veri artırma yöntemiyle veri setindeki 5000 görüntüden 8000 çeltik bitki yaprağı görüntüsü elde edilmiş ve ESA için bu görüntüler üzerinden yapılan eğitimden sonra %94,87'lik bir başarı oranı elde edilmiştir. Kullanılan veri setindeki görüntüler üzerinden ön işlem yapıldıktan sonra ESA ile eğitim işleminden sonra %97,57'lik bir başarı oranı elde edilmiştir.

Detection of Disease of Rice Plant with Convolutional Neural Network

Keywords: Deep learning, Convolutional Neural network, Precision agriculture, Artificial intelligence, Rice plant.

Abstract

Considering the worldwide rice consumption, it is seen that rice has an important place. The rice plant is the most cultivated plant after corn and wheat from the grass family. One of the latest research topics in agriculture is the recognition or classification of diseases from images of a plant's leaves. Automatic diagnosis of rice disease from leaf images is a research subject under development. In order to contribute to this development, important studies are carried out for the early diagnosis of the disease by using different learning methods. In this study, deep learning models, which is a machine learning method, were used to detect diseases. In this study, it was determined whether the rice plant was diseased or not by using the deep Convolutional Neural Network (CNN). The data set of 5000 rice plant leaves used in the study was taken from the Kaggle website. In order to detect the disease, a total of two classifications were made as three diseases of the rice plant (BrowSpot, LeafBlast and Hispa) and healthy. An accuracy rate of 91.54% was obtained by modifying the hyper-parameters of ESA, which is used to detect the disease of rice plant. With the data augmentation method, 8000 rice plant leaf images were obtained from 5000 images in the data set and an accuracy rate of 94.87% was

*Sorumlu yazar: iokten@beu.edu.tr

Geliş Tarihi: 25.10.2021, Kabul Tarihi: 11.02.2022

obtained after training on these images for ESA. After preprocessing on the images in the used dataset, an accuracy rate of 97.57% was obtained after training with ESA.

1. Giriş

Dünya nüfusunun artmasıyla tarım ürünlerindeki toplam mahsul önem kazanmıştır. Bu nedenle toplam mahsulü etkileyen bitki hastalıklarının tespiti de önemli araştırma konuları arasına girmiştir. Bitki hastalıkları, tarım ürünlerindeki verimi ve kaliteyi düşüren nedenlerden biridir [1]. Hem verim hem de kalitenin düşmesine neden olan bu hastalıkların önüne geçilmediği takdirde elde edilen toplam mahsul doğrudan etkilenecektir. Temel sorun bitkilerin düzenli aralıklarla izlenememesidir. Bitkide çıkabilecek hastalıkların, hava şartlarına göre senelik değişkenlik arz ettiği için sürekli izlenmesi önemlidir. Özellikle bu çalışma konusu olan çeltik bitkisi gibi sulak alanlarda yetişen bitkilerin izlenmesi diğer bitki türlerine göre biraz daha zordur. Bu çalışma, dünyada hemen hemen her ülkede tüketilen çeltik bitkisinin hastalıklarını yapay zekâ yöntemlerinden biri olan derin öğrenme yöntemleriyle tespit etmek üzerinedir. Genellikle bitkilerde görünen hastalıklar çeşitli mantar, bakteri veya virüsler neden olmaktadır. Çeltik bitkilerinde bulunan en yaygın hastalıklar ise Bakteriyel Yaprak Yanığı (Bacterial Leaf Blight), Kahverengi Leke (Brown Spot), Yaprak İsi (Leaf Smut), Yaprak Patlaması (Leaf Blast) ve Kovan Yanığı (Sheath) hastalıklarıdır [2]. Bu hastalıklar yetiştirilen bölgeye göre farklılıklar göstermektedir. Bu hastalıkların bazıları belirli bölgelerde hiç görülmemektedir. Bu yüzden tüm hastalıkların sınıflandırılması için gerekli olan verilerin elde edilmesi zorlaşmaktadır. Bu çalışmada temel olarak elde edilen veri setine göre iki sınıflandırma yapılacaktır. Brown Spot, Hispa ve Leaf Blast hastalıklarına ait görüntüler hastalıklı ilk sınıf, sağlıklı çeltik bitkilerine ait görüntülerde sağlıklı ikinci sınıf olacak şekilde toplam iki sınıflandırma işlemi yapılacaktır. Çeltik bitkisi hastalıkları renk, boyut ve şekil olarak birbirlerinden ayrılmaktadır.

Derin öğrenme teknikleri, günümüzde tarım alanlarındaki hastalıkların tespitinde büyük umut vaat etmektedir. Son yıllarda bu teknikler çay [3], elma [4], domates [5], asma, seftali ve armut [6], buğday [7] hastalıklarını analiz etmek için kullanılmaktadır.

Bhagawati, Bhagawati, Singh, Nongthombam, Sarmah ve Bhagawati (2015) [8], çeltik patlaması hastalığını tahmin etmek için sıcaklık, bağıl nem, yağış ve rüzgâr hızı gibi hava parametreleriyle bir sinir ağını eğitmiştir. Mohanty, Hughes ve Salathé (2016) [9] 26 hastalığı temsil eden 14 mahsul türünün 54.306 görüntüsünü kullanarak yapraklardan hastalığı tespit etmek için derin ESA kullanırken, Sladojevic, Arsenovic, Anderla, Culibrk ve Stefanovic (2016) [6] 13 farklı bitki hastalık türünü tanımak için CaffeNet modelini kullanmıştır. 2011 yılından itibaren literatürde son teknoloji makine ve derin öğrenme tabanlı tanıma algoritmaları etkisini göstermeye başlamıştır. Özellikle AlexNet [10] ve daha sonrasında bu yönde benzer yaklaşımlarla geliştirilen VGGNet [11], GoogleNet- Inception [12], ResNet [13], vb. derin öğrenme bazı algoritmaların sistem performansı bağlamında birçok farklı kullanım alanında diğer kullanılan klasik algoritmalara nazaran çok daha iyi sonuçlar verdiği gösterilmiştir. Literatürdeki derin öğrenme modelleri üzerine bazı çalışmalar aşağıda özetlenmektedir.

Kerkech ve ark. (2018) [14] çalışmasında üzüm bitkisi yaprakları üzerinde oluşan hastalıkların tespitinde ESA bazlı yöntemleri bazı bitki endekslerini kullanarak test etmişler. Benzer bir çalışma Ma ve ark. (2018) [15] tarafından salatalık bitkisi yaprakları üzerinde oluşan hastalıkların tespitinde yapılmıştır. Lu ve ark. (2017) [16] yayınladıkları çalışmada ise 10 çeşit çeltik bitkisi hastalığı üzerinde çalışmışlardır. Elde ettikleri sonuç geleneksel yöntemlere göre daha iyi olmakla beraber kullandıkları veri setinin büyüklüğünün ESA tabanlı modeller eğitimi için yeterli olmayabilir. Bu bağlamda, Lua ve ark. çalışmasının üzerine yapılabilecek araştırmaların ucunun açık olduğu söylenebilir. Harshadkumar ve arkadaşları (2017) [17], çeltik bitkisine ait üç farklı hastalığı tespit etmek için görüntü işleme yöntemi ve Destek Vektör Makinesi (SVM) kullanarak %73,33 doğruluk oranı elde etti. Chowdhury ve arkadaşları (2020) [18] ESA ile çeltik bitkisinin hastalığını %93,3 doğruluk oranında tespit etti. DeChant, Wiesner-Hanks, Chen, Stewart, Yosinski, and Gore (2017) [19], görüntüleri daha küçük bir boyuta yeniden boyutlandırmak ve bir modeli uçtan uca eğitmek yerine, üç aşamalı bir mimari (birden fazla ESA'den oluşan) kullandı ve tek bir görüntüyü çok sayıda küçük görüntüye bölerek tam ölçekli görüntüler üzerinde birinci aşama modelini eğitti.

Liu, Zhang, He ve Li (2018) [20], dört elma hastalığını tespit etmek için AlexNet ve GoogLeNet ağlarını birleştiren bir ESA oluşturdu. Lu ark. (2017) [16], LeNet-5 ve AlexNet gibi eski derin öğrenme çerçevelerinden esinlenerek, 500 görüntü kullanarak, küçük bir el yapımı ESA mimarisini kullanarak 10 farklı çeltik bitkisi hastalığının tespit edilmesi üzerine bir çalışma yürüttü. Atole ve Park (2018) [21], AlexNet'i (büyük mimari) kullanarak 227 görüntü kullanarak normal çeltik bitkisi, hastalıklı çeltik bitkisi ve salyangoz istilasına uğramış çeltik bitkisi olmak üzere üç sınıf arasında bir ayrım yaptı.

Sonuç olarak literatürden de görüleceği gibi çalışmada ele alınan konu birçok araştırmacı tarafından üzerinde çalışılan popüler ve aktif bir çalışma alanıdır. Bu çalışma için, ilk olarak çeltik bitkisine ait hastalıklı ve sağlıklı yaprakların bulunduğu 5000 adet görüntü verisi elde edilmiştir. Başarılı sonuçlar elde edebilmek için görüntü artırma yöntemi ile daha fazla hastalıklı ve sağlıklı görüntü verileri üretilmiştir. Derin öğrenme yöntemlerinden birisi olan ESA yapısına göre bir model oluşturuldu. ESA'daki hiper-parametrelerde değişiklikler yapılarak hastalığın tespiti için modelin eğitimi yapılmıştır. Eğitilen modelde hiç kullanılmayan görüntüler test için modele verildiğinde %91,54 oranında bir doğruluk elde edilmiştir. Kullanılan veri setindeki tüm görüntüler üzerinde ön işlemler yapıldıktan

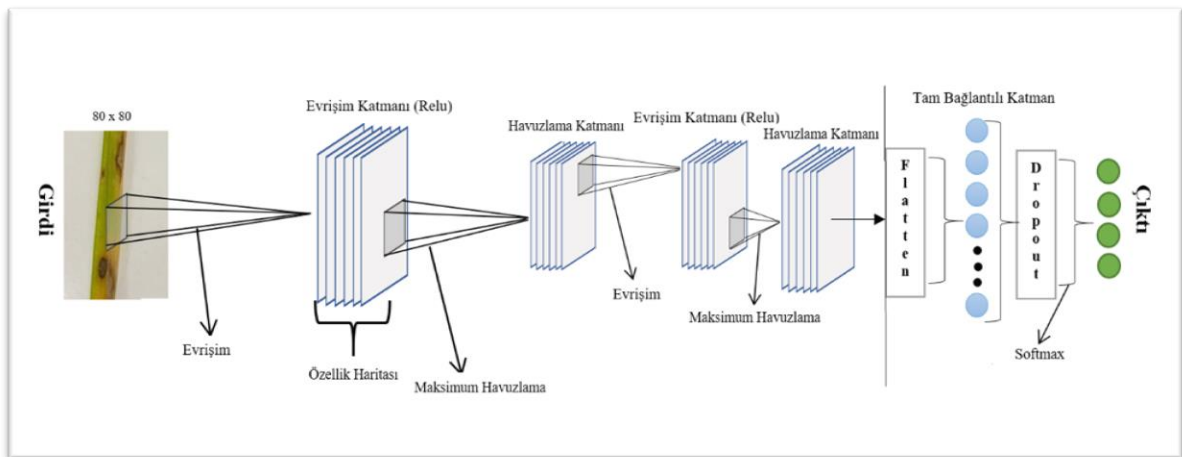
sonra ESA ile eğitim işlemi tekrar yapılmıştır. Eğitilen bu son modelde eğitim sırasında kullanılmayan 1600 görüntü modele test için uygulandığında %97,57 oranında bir doğruluk oranı bulunmuştur.

2. Materyal ve Metot

2.1. Evrişimli Sinir Ağları

Derin öğrenme, sıralı katmanlara sahip bir makine öğrenme algoritmasıdır. Her katman, önceki katmanın çıktısını girdi olarak kullanır. Öğrenme süreci denetimsiz, denetimli veya yarı denetimli olabilir. LeCun ve arkadaşları derin öğrenmeyi bir temsil öğrenme yöntemi olarak tanımlar [22]. Temsil öğrenme algoritmaları, verileri temsil etmenin en uygun yolunu bulmak için optimizasyon yaparlar [23]. Önceki yöntemlerde görüntü işleme yöntemi ile görüntülerden öznitelik çıkarma işlemi yapılırdı. Derin öğrenme ile öznitelik çıkarma işlemi için ayrı bir görüntü işleme yöntemi uygulamaya gerek kalmamıştır. Derin öğrenme bu işlemi ağırlık eğitiminde kullanılan katmanlarda yapmaktadır.

ESA çok katmanlı yapısı ile görüntüleri tek yapıyı yapay sinir ağlarına göre daha hızlı ve daha başarılı sonuçlar ile sınıflandırabilmektedir. ESA modeli evrişimli katman, havuz katmanı, aktivasyon işlevi katmanı ve tam bağlantılı katman olarak dört ana katmandan oluşmaktadır. Şekil 1'de genel bir ESA mimarisi gösterilmektedir.




Şekil 1. ESA mimarisi.

a-) Evrişim Katmanı (Convolution Layer)

ESA modeli adını evrişim katmanından alır. Bu katmanda, giriş görüntüsünün özellik haritasını

çıkarmak için bir takım matematiksel işlemler gerçekleştirilir. Giriş resmi, filtre kullanılarak daha küçük bir boyuta küçültülüp ya da aynı boyutta bırakılabilir. Filtre, görüntünün sol üst köşesinden başlayarak adım adım kaydırılır. Her adımda,

görüntüdeki değerler filtrenin katsayıları ile çarpılır ve sonuç toplanır. Giriş görüntüsünden daha küçük boyutlu yeni bir matris oluşturulur. Şekil 2'de 4x4 boyuta sahip bir giriş görüntüsü ve 2x2 örnek bir filtre için evrişim katmanındaki evrişim işlemin gösterilmektedir.

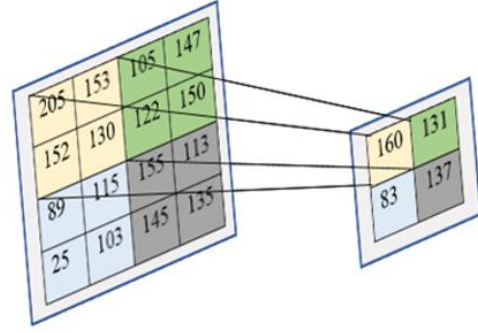


Şekil 2. 4x4 giriş görüntüsüne 2x2 filtre ile evrişim işlemi.

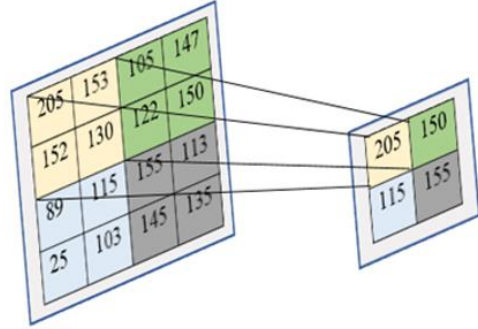
b-) Havuzlama Katmanı (Pooling Layer)

Bu katman, ESA modelinde görüntülerdeki piksel sayısını azaltmak için ardışık evrişim katmanları arasına sıklıkla eklenen bir katmandır. Bu katmanın görevi gösterimin kayma boyutunu, ağ içindeki parametreleri ve hesaplama sayısını azaltmak içindir. Bu işlem yardımıyla ağdaki uyumsuzluk kontrol edilmiş olur. Havuzlama katmanlarında maksimum havuzlama (max pooling), ortalama havuzlama (average pooling) ve L2-norm havuzlama (L2-norm pooling) yöntemleri kullanılmaktadır. Bu yöntemlerden maksimum havuzlama daha sıklıkla kullanılmaktadır. Bu çalışmada evrişim katmanları arasında maksimum havuzlama kullanılmıştır. Şekil 3'te örnek bir havuzlama işlemi gösterilmiştir.

Ortalama Havuzlama (Average Pooling)



Maksimum Havuzlama (Max Pooling)



Şekil 3. 2x2lik görüntüye maksimum havuzlama ve ortalama havuzlama işlemi (adım=2).

c-) Aktivasyon Katmanı (Activation Layer)

ESA modelinde genellikle tüm katmanlardan sonra doğrusal olmayan bir katman gelir. Bu katmana aktivasyon katmanı adı verilir. Bu çalışmada aktivasyon katmanında ReLU (Rectifier Linear Unit) fonksiyonu kullanılmıştır. Önceki çalışmalarda genellikle doğrusal olmayan sigmoid, hiperbolik ve tanjant fonksiyonları kullanılmıştır. Ancak derin öğrenme sinir ağı modellerinin eğitiminde, hızlı cevap süresinden dolayı en iyi sonucu ReLU fonksiyonu verdiği için bu fonksiyon kullanılmaya başlanmıştır.

d-) Tam Bağlantılı Katman (Fully-Connected Layer)

Evrişim, havuzlama ve aktivasyon işlemi bitikten sonra düzleştirme işlemi ile veriler düzeltilir. Düzleştirme işleminden sonra tam bağlantılı katman gelir. Bu katman ESA modelinin son ve en önemli katmanıdır. Bu katmanda sinir ağı ile sınıflandırma ve tanıma işlemi yapılmaktadır. Çeltik bitkisi hastalığının tespiti için bu çalışmadaki tam bağlantılı katmanın sonucunda iki sınıf oluşmaktadır.

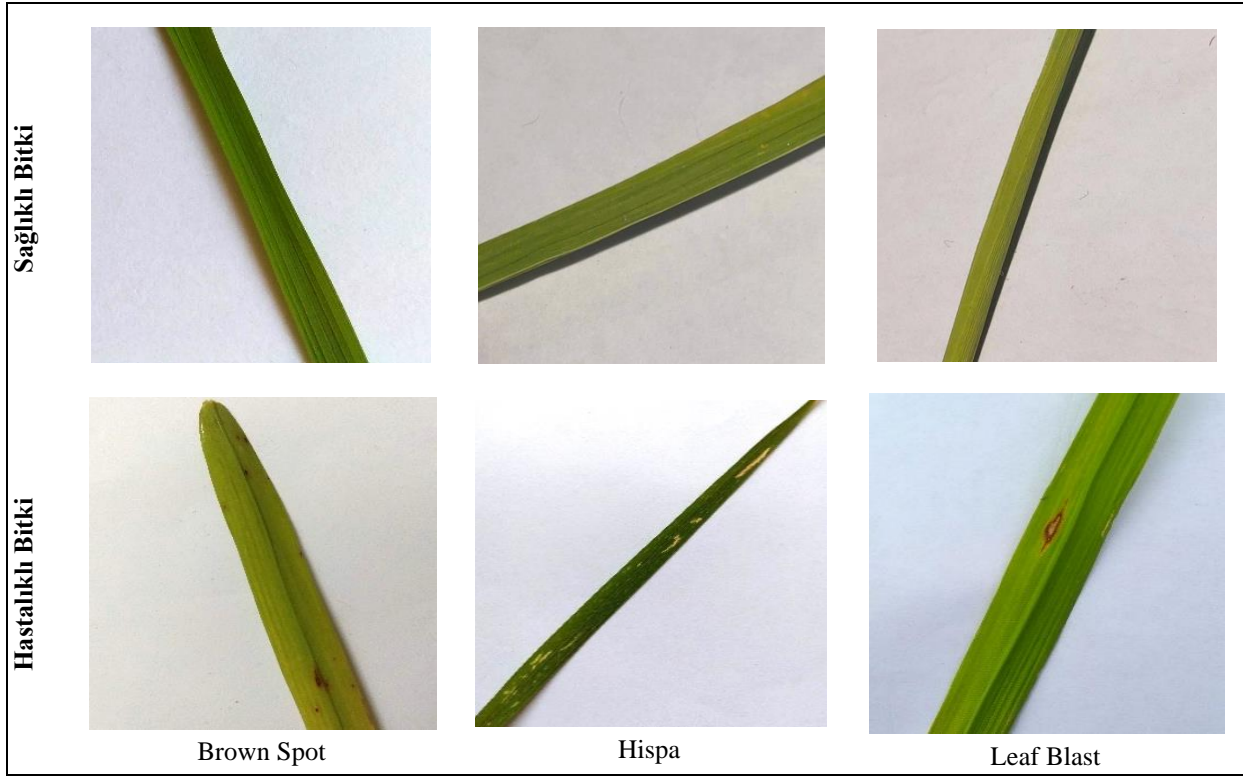
2.2. Veri seti (Data Set)

Çeltik bitkisinin farklı bölgelerinde hastalıklar görülür. Bu hastalıkların oluşumu sıcaklık, nem, yağış, çeltik bitkilerinin çeşitliliği, mevsim, beslenme gibi birçok faktöre bağlıdır. Çeltik bitkisinde çok yaygın bir şekilde görülebilen Brown Spot, Leaf Blast ve Hispa hastalıklarına ait veri seti Kaggle internet sayfasından alınmıştır. Bu

hastalıkların bitkinin neresinde olduğu, şekilsel belirtilerin ne olduğu ve gösterdikleri lezyon renkleri Tablo 1’de gösterilmiştir. Bu veri setinde bulunan sınıflara örnek görüntüler Şekil 4’te gösterilmektedir. Çeltik bitkisine ait 5000 adet resimden 4000 tanesi eğitim aşaması için ve geri kalan 1000 tanesi ise test aşaması için kullanılmıştır.

Tablo 1. Farklı çeltik bitki hastalıkları türleri ve temel hastalık belirtileri

Hastalık	Etkilenen kısımları	Belirtilerin şekli	Lezyon rengi
Leaf Blast	Yaprakları	Yapraklarda patlamalar oluşur	Koyu kahverengi, siyah
Brown Spot	Yaprakları	Oval şekillerde noktalar oluşur	Kırmızımsı kahverengi, koyu kahverengi
Hispa	Yaprakları	Yaprağın üst yüzeyini sıyrarak orta şeride paralel beyaz çizgiler oluşur	Yarı saydam beyaz noktalar



Şekil 4. Çeltik bitkisinin hastalıklı ve sağlıklı yaprak görüntüleri.

2.3. Veri Artırımı (Data Augmentation)

Boyutu küçük olan veri setlerinde özellikle makine öğrenmesi modellerinin başarımını artırmak için verilerin çeşitli bozulma etkilerine maruz bırakılarak veri sayısı artırılabilir. Bu şekilde

modelin farklı koşulları da öğrenmesi sağlanmaktadır.

- Görüntünün eksenlere göre simetriklerinin alınması,
- Rastgele görüntünün bir kısmının kesilip alınması,

- Eksenlerinin değiştirilmesi,
- Renk oranlarının değiştirilmesi,

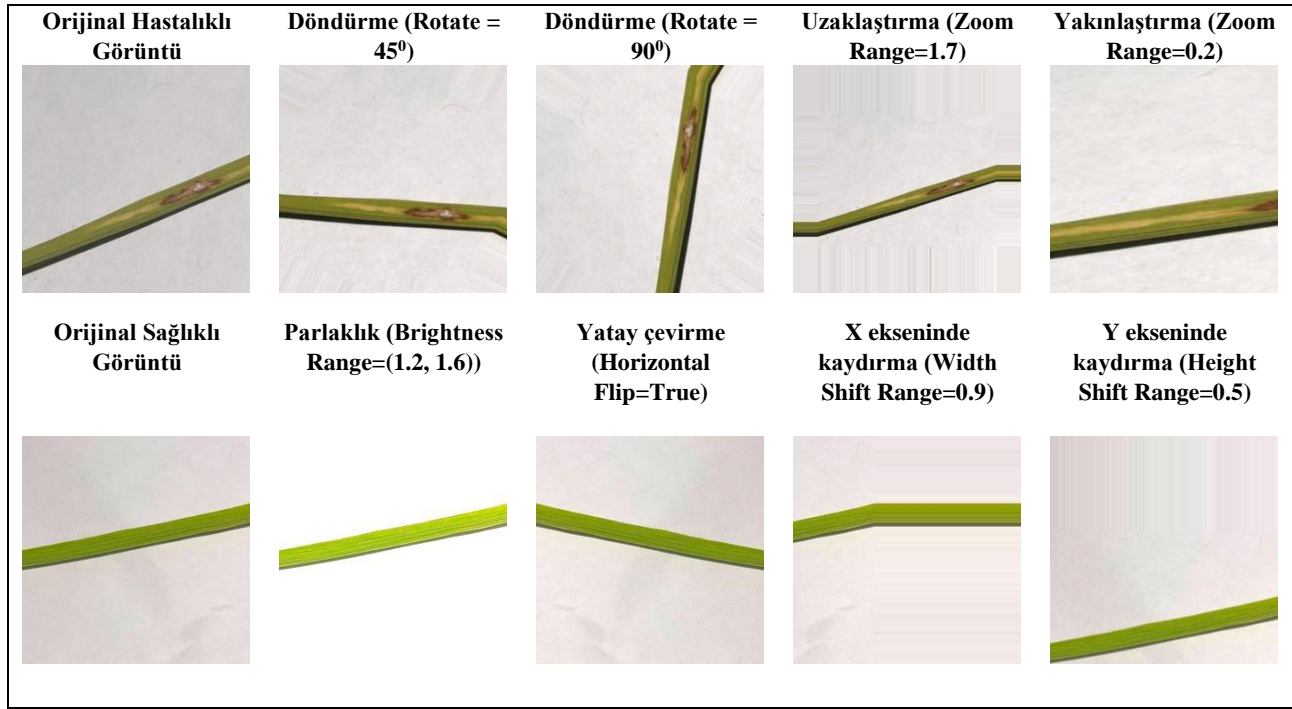
gibi birçok farklı şekilde veriden elde edilen yeni veri parçaları oluşturularak veri artırma yapılabilir. Böylece model ezberleme (overfit) eğiliminden

uzaklaşmaktadır. Bu çalışmada veri artırma yöntemi kullanılarak 5000 görüntüden 8000 görüntü oluşturulmuştur. Her sınıf için kullanılacak çeltik bitkisi yaprak görüntü sayısı, sınıflandırma adı ve veri artırımından sonraki görüntü sayısı Tablo 2'de verilmiştir.

Tablo 2. Çeltik bitkisinin sınıf adları, veri sayısı ve veri artırımından sonraki veri sayısı

Sınıf Adı	Veri Sayısı	Veri artırımından sonraki veri sayısı
Hastalıklı	2500 (eğitim [2000], test[500])	4000 (eğitim [3200], test[800])
Sağlıklı	2500 (eğitim [2000], test[500])	4000 (eğitim [3200], test[800])
Toplam	5000 (eğitim [4000], test[1000])	8000 (eğitim [6400], test[1600])

Veri artırımından sonra elde edilen görüntüler ile ağız eğitimi ve test işlemi yapılmıştır. Şekil 5'te veri artırma teknikleri ile elde edilen sağlıklı ve hastalıklı pirinç bitkisi yaprak görüntüleri gösterilmiştir.



Şekil 5. Çeltik bitkisinin hastalıklı ve sağlıklı yaprak görüntüleri.

Veri setimizde bulunan çeltik bitkisinin yaprak görüntülerine döndürme, yakınlaştırma, uzaklaştırma, x ve y ekseninden kaydırma, yatay veya dikey çevirme ve parlaklık seviyesini değiştirme işlemleri uygulanmıştır. Bu artırım işlemi gerçekleştirme için *TensorFlow*'un apilerinden biri olan *Keras* kütüphanesinden *ImageDataGenerator* fonksiyondan yararlanılmıştır [24].

2.4. Donanım ve Yazılım Ortamı

Bu çalışmada çeltik bitkisine ait hastalıkları ve sağlıklı olduğunu tespit etmek için *Python* programlama dili kullanılmıştır. Evrimsel Sinir Ağı modeli kullanılarak özelliklerin çıkarılmasında *Tensorflow* ve *Theano* gibi derin öğrenme kütüphanelerini kullanan üst düzey bir API olan *Keras* kütüphanesi, veri artırımı için *Keras* kütüphanesine ait *ImageDataGenerator* fonksiyonu, matematiksel işlemler için gerekli olan

yapılar için *numpy*, verileri görselleştirmek için python kütüphanesi olan *matplotlib* kütüphanesi kullanılmıştır.


Bu çalışmada önerilen derin öğrenme uygulaması için ekran kartı NVIDIA GeForce MX150 4GB, İşlemci Intel(R) Core(TM) i7-8550U ve yüklü bellek (RAM) 20GB özelliklere sahip bir kişisel bilgisayar kullanılmıştır. Derin öğrenme yöntemi ile ağı eğitmek için TensorFlow kütüphanesinin CPU veya GPU birimlerinden birinin seçilmesi gerekmektedir. Ağın eğitiminde CPU'nun yanında GPU'da kullanılırsa işlem daha hızlı olacaktır. GPU'nun kullanılması için bilgisayarda NVIDIA ekran kartına sahip olunması ve ekran kartının grafik işlem birimini kullanarak hesaplama performansında büyük ölçüde artışlara olanak veren paralel hesaplama mimarisi CUDA desteğine sahip olması gerekir.

3. Bulgular ve Tartışma

Bu çalışma kapsamında çeltik bitkisine ait hastalıkların tespiti ESA modeli ve geleneksel görüntü işleme yöntemleri ile yapay sinir ağı modeli kullanılarak yapılmıştır. Bu iki yöntemin sonuçları karşılaştırılmıştır. Bu karşılaştırmalar iki başlık altında toplanmıştır. Birinci yöntem görüntü işleme yöntemleri ile yapay sinir ağı kullanılarak çeltik bitkisi hastalığının tespit edilmesidir. İkinci yöntem ise ESA ile çeltik bitkisi hastalığının tespit edilmesi işlemidir.

3.1. Görüntü işleme ve yapay sinir ağı ile çeltik bitkisi hastalığının tespiti

Hastalık tespiti yazılımını öncelikle RGB görüntü veri setleri üzerinde uygulanması planlanmıştır. Bu amaç için Matlab GUI ortamında hastalık tespitini sağlayacak bir arayüz tasarımı yapılmıştır. Şekil 6'da hastalık tespitini yapan programın arayüzü gösterilmiştir.



Şekil 6. Matlab GUI ile hazırlanan Bitki Hastalığı Tespit Programı arayüzü.

Çeltik bitkisinin hastalıklarını tespit edecek olan arayüzde öncelikle görüntü ön işleme metotlarından median filtresi çeltik bitkisi yaprak görüntülerine uygulandı. Daha sonra bölütleme (segmentasyon) işlemi için OTSU yöntemi kullanıldı. Görüntülerin özelliklerini çıkarmak için GLCM (Gray Level Co-occurrence Matrix) algoritması kullanıldı. Son olarak sınıflandırma aşamasında PNN (Probabilistic Neural Network)

kullanılarak hastalığın tespiti sağlandı. Bitki hastalığını tespit eden programa yeni bir çeltik bitkisinin yaprak görüntüsü verildiğinde görüntü ön işlemede kullanılacak imnoise, average, gaussian, unsharp ve median filtrelerinden herhangi biri kullanılabilir. Eğitilmiş ağı test işlemi uygulandığında %77'lik bir doğruluk oranı elde edilmiştir.

Yapay Sinir Ağı modelinde kullanılan test veri setindeki sonuçları kullanılarak elde edilen karmaşıklık matrisi Tablo 3 de gösterilmiştir. Karmaşıklık matrisin elde edilmesi için toplamda 100 çeltik bitkisi yaprak görüntüsü (50 hastalıklı

görüntü, 50 sağlıklı görüntü) kullanılmıştır. Karmaşıklık matrisinde Özgüllük (Specificity), Hatırlama (Recall), Doğruluk (Accuracy), Hassaslık (precision) ve Negatif tahmin gibi ölçütlerde verilmiştir.

Tablo 3. Bitki hastalığının tespitinde kullanılan YSA ile çıkan sonuçların karmaşıklık matrisi

		Tahmin		
		Hastalıklı	Sağlıklı	
Gerçek	Hastalıklı	41	9	Özgüllük (Specificity) :0,82
	Sağlıklı	14	36	Hatırlama (Recall) :0,72
		Negatif Tahmin: 0,74	Hassaslık(Precision) :0,80	Doğruluk (Accuracy) :0,77

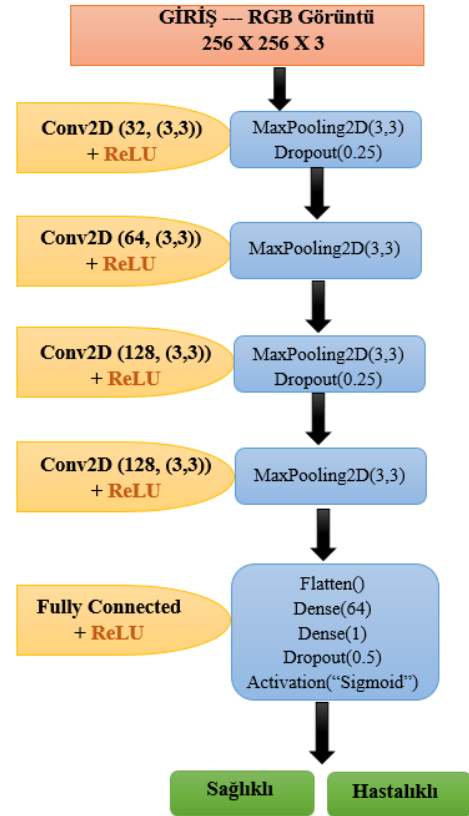
Karmaşıklık matrisi Doğru Pozitif (TP – True Positive), Yanlış Pozitif (FP – False Positive), Doğru Negatif (TN - True Negative) ve Yanlış Negatif (FN – False Negative) değerlerinden oluşmaktadır. Yapılan test işleminde TN, FN, FP ve TP değerleri sırayla 41, 14, 9, 36 olarak bulunmuştur.

3.2. Evrişimsel sinir ağı ile çeltik bitkisi hastalık tespiti

Çeltik bitkisi hastalıklarının tespit için görüntü işleme ile yapay sinir ağı kullanılarak elde edilen başarı oranı düşük çıkmıştır. Bu başarı oranının çeltik bitkisi hastalığının tespitinde kullanılması durumunda sağlıklı bitkilerde hastalıklı olarak etiketlenebildiği Tablo 3 te karmaşıklık matrisinde gösterilmiştir. Bu yüzden başarı oranını arttırmak için bu çalışmada derin öğrenme yöntemlerinden Evrişimli Sinir Ağı tercih edilmiştir. ESA ile bitki hastalığını tespit etmek için Şekil 7’de gösterilen bir model oluşturulmuştur. Önerilen bu ESA modeli 5 evrişim katmanından oluşmaktadır. Aktivasyon fonksiyonu için ReLU fonksiyonu kullanılmıştır.

Önerilen model hastalıklı ve sağlıklı olmak üzere iki sınıflı sınıflandırma yapmaktadır. Çeltik bitkisi görüntülerinin boyutu OpenCV Kütüphanesi kullanılarak 256x256 boyutuna dönüştürüldükten sonra ESA modeline giriş olarak verilmektedir. Çeltik bitkisi hastalığının tespiti için yapay sinir ağı ile evrişimli sinir ağı kullanılarak başarı oranları elde edilmiştir. Tablo 4’de bu iki

yöntemde kullanılan ön işleme, segmentasyon, özellik çıkarma ve test başarı oranı sonuçları gösterilmiştir. ESA modeli ile sınıflandırma yapıldığında daha başarılı sonuçlar elde edildiği görülmüştür.



Şekil 7. Önerilen ESA derin öğrenme modeli.

ESA modelinde özellik çıkarma ve bölütleme işlemleri evrişimli katmanlarda yapıldığı için ayrı bir işlem olarak bunların uygulanmasına gerek duyulmamaktadır. Buna rağmen ESA modeli ile yapılan sınıflandırmalarda daha başarılı sonuçlar elde edilmiştir. ESA ile sınıflandırma yapılırken çeltik bitkisi yaprağına ait görüntülerin arka plandaki görüntüleri kaldırılmıştır. Veri setindeki çeltik bitkisi yaprak görüntülerin arka plandaki gürültüleri kaldırmak

için OpenCV kütüphanesinden yararlanılmıştır. Bu işlemi yapmak için veri setindeki tüm görüntülerin tüm pikselleri kontrol edildi ve daha sonra belirlediğimiz eşik (170) üstünde olan piksel değerleri beyaz renk (255) pikseli ile değiştirildi. Yapılan işlem sonucunu görmek için Şekil 8 de çeltik bitkisi yaprak görüntüsünün orijinal ve arka plan kaldırıldıktan sonraki görüntüleri verilmiştir.



Şekil 8. Çeltik bitkisine ait orijinal ve arka planı temizlenmiş görüntüler.

Arka plan görüntüsü temizlendikten sonra model tekrar eğitilip test işlemi yapıldığında %97,57 başarımlı oranı elde edilmiştir.

Tablo 4. YSA ve ESA modellerinin çeltik bitkisi hastalığı sınıflandırma sonuçları

Sınıflandırma	Ön İşleme	Bölütleme	Özellik Çıkarması	Test Sonucu
PNN	Median filtre	OTSU	GLCM	%77
ESA	Filtresiz	-	-	%91,54
ESA	Arka planı temizleme	-	-	%97,57

Çeltik bitkisine ait hastalıkların bulunduğu görüntüler ile bitkinin sağlıklı olduğu görüntüler olmak üzere iki sınıflı sınıflandırma yapılmıştır. Görüntü ön işleme kısmında görüntülerin boyutu küçültülüp ve daha sonra görüntülerdeki arka plan kaldırılmıştır. Daha sonra her bir sınıf için 3200

görüntü kullanılarak eğitim işlemi yapılmıştır. Eğitim verisi ile ESA ağı eğitilmiş ve ağınlıkları kaydedilmiştir. Kaydedilmiş bu ağırlık ve model ile her sınıf için 800 görüntü kullanılarak test işlemi yapılmıştır. Yapılan test işlemleri

sonucunda sınıf bazında çıkan başarımlar oranları Tablo 5'te özetlenmiştir.

Tablo 5. Sağlıklı ve Hastalıklı çeltik bitkisi sınıfları için sınıflandırma doğruluk sonuçları

Sınıflandırma adı	Test edilen veri sayısı	Doğruluk oranı
Hastalıklı	800	98,45
Sağlıklı	800	96,68
Toplam	1600	97,57

Tablodan da görüldüğü gibi test işleminden sonra %98,45'lik başarımlar oranı Hastalıklı sınıf ve 96,68'lik başarımlar oranı Sağlıklı sınıf için elde edilmiştir. Derin öğrenmede kullanılan bazı hiper-parametreler vardır. Hiper-parametreler, derin öğrenme ağını tasarlayan kişiler tarafından belirlenir. Ağı oluşturan kişi tarafından belirlenen hiper-parametreler, probleme veya veri setine göre değişiklik gösterebilmektedir. Bu çalışma kapsamında hiper-parametrelerde değişiklik yapılarak ağın başarımlar oranı tespit edilmiştir. Veri seti boyutu modelin öğrenmesi için önem taşıyan bir faktördür. Yapılan test sonuçlarında her sınıf için 1000 görüntünün altında

veri kullanıldığında test sonucunda doğruluk oranının çok yüksek çıkmadığı görülmüştür. Bu yüzden modelin öğrenmesi için en az 1000 ve üzeri görüntü kullanılması uygun görülmüştür. Ama veri setinin boyutunun artması, eğitimin başarısının doğru orantılı bir şekilde artacağı anlamına gelmez. Veri setinin boyutunu artırırken çeşitliliği göz önünde bulundurmak gerekir. Bu çalışmada veri artırma yöntemi ile veri seti boyutu artırılmıştır. 5000'lik görüntü veri seti ile yapılan sınıflandırma işlemi ile 8000'lik görüntü veri seti ile yapılan sınıflandırma işleminin sonucu Tablo 6 da verilmiştir.

Tablo 6. Veri seti büyüklüğünün ESA modeli başarımlar oranı üzerindeki etkisi

Sınıflandırma	Ön işleme	Veri seti boyutu	Başarımlar oranı
ESA	-	5000	%91,54
ESA	-	8000	%94,87

Derin öğrenmede doğrusal olmayan problemlerin çözümünde en uygun değeri bulmak için optimizasyon yöntemleri kullanılmaktadır. Yapılan çalışmalar incelendiğinde günümüzde yaygın bir şekilde kullanılan optimizasyon yöntemleri Stochastic Gradient Descent (SGD), Adadelta, Adam ve RMSprop yöntemleridir. Bu çalışmada bu dört yöntem için eğitim işlemi uygulanmıştır. Eğitim sonucunda elde edilen ağırlıklar ile ESA modelinin test işlemlerinde en yüksek başarımlar oranı Adam optimizasyon yöntemi ile elde edilmiştir. Bu yüzden çalışmada Adam optimizasyon yöntemi kullanılmıştır. Bu çalışmada hiper-parametrelerden olan küme boyutu (batch size) ve öğrenme oranı (learning rate) değerlerini seçmek için birkaç test işlemi yapıldı. Küme boyutu değeri 32 olarak seçildi. Kullanılan verilerin çok olması ve modelin eğitildiği bilgisayarda çalışabilmesi için bu değer seçilmiştir. Genelde bu tarz çalışmalarda öğrenme oranı $10e-3$

ile $10e-4$ kullanılmaktadır. Oluşturulan model için Öğrenme oranı $10e-4$ seçildiğinde daha başarılı sonuçlar elde edildiği görülmüştür.

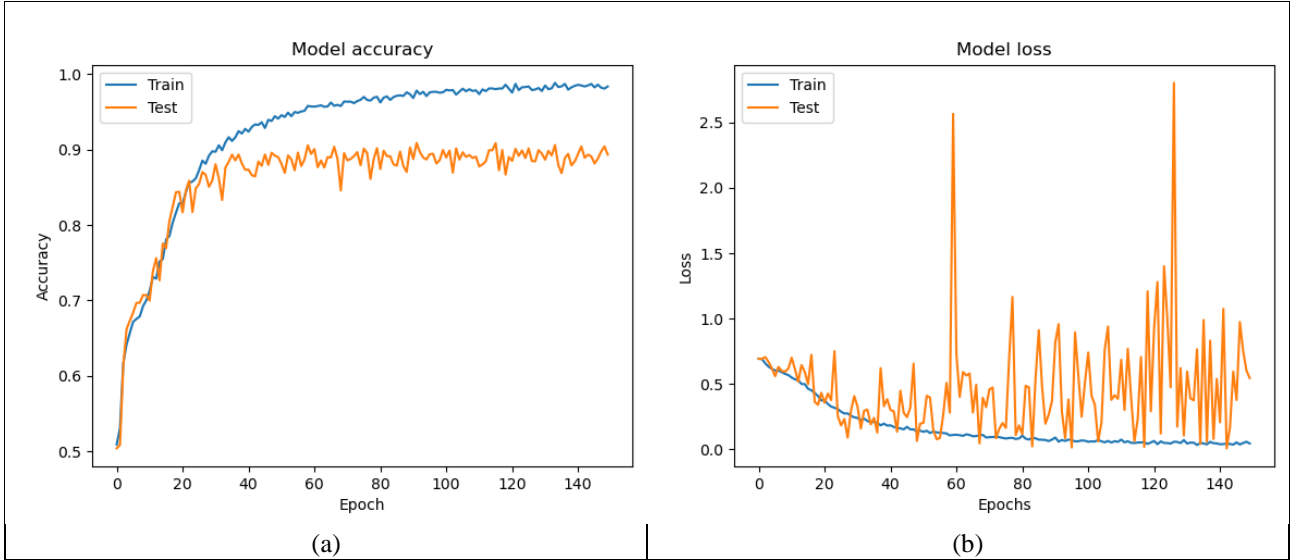
Derin öğrenme modeli eğitilirken verilerin hepsi aynı anda eğitime verilmez. Modeli tasarlayanların belirttiği oranda parçalara bölünür ve bu parçalar halinde eğitime verilir. Eğitime verilen ilk parça eğitilir ve modelin başarımlar oranı elde edilir. Bu başarımlar oranına göre ağırlık değerleri güncellenir. Belirtilen bu işlem her bir eğitim adımında uygulanır ve en uygun ağırlık değerleri bulunur. Ağırlık değerlerinin bulunması için yapılan eğitimin her adımına eğitim tur (Epoch) sayısı denilmektedir. Bu çalışmada modelin en iyi başarımlar oranı tur sayısı 250 seçilerek bulunmuştur. Bu çalışmada kullanılan hiper-parametrelerin değerlerinin bulunması için çeşitli test işlemleri gerçekleştirilmiştir. Yapılan bu testler sonucunda her bir hiper-parametre değeri ve

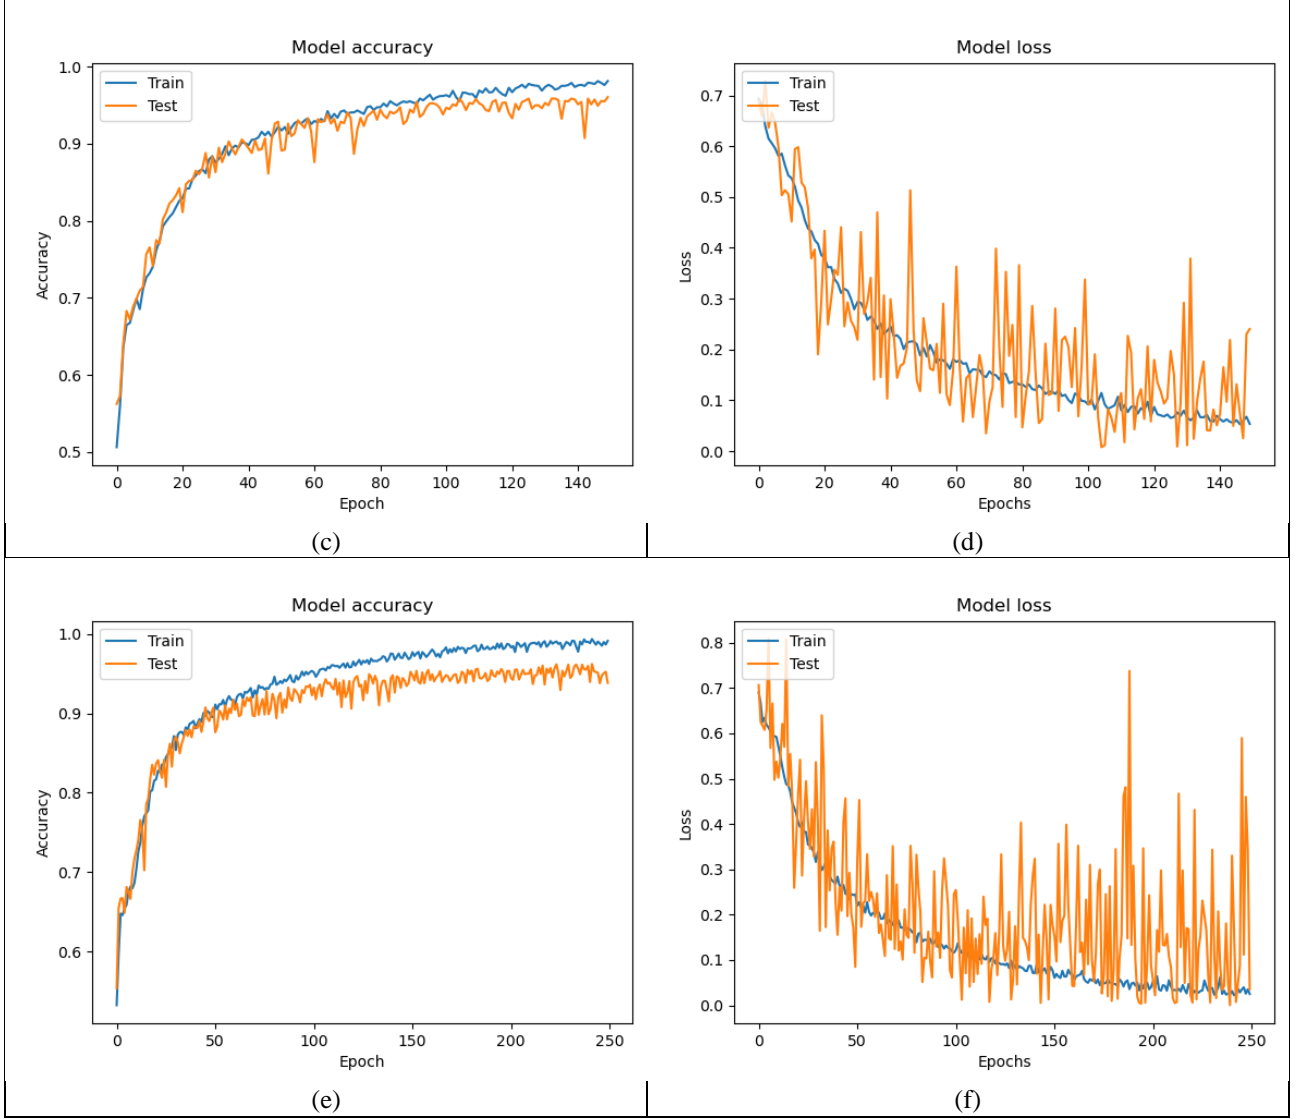
bu değere karşılık gelen doğruluk oranları Tablo 7 de özetlenmiştir.

Tablo 7. Hiper-parametrelerinin değişimine göre ESA modelinin test başarımları

Sınıflandırma	Tur	Küme Boyutu	Öğrenme Oranı	Veri Seti Boyutu	Eniyileştiriciler (Optimizers)	Test Doğruluk Oranı
ESA	150	16	10e-3	5000	Adam	%91,54
ESA	150	16	10e-3	5000	Adadelat	%81,88
ESA	150	16	10e-3	5000	SGD	%85,85
ESA	150	16	10e-3	5000	RMSprop	%86,86
ESA	150	16	10e-3	8000	Adam	%94,87
ESA	150	16	10e-3	8000	Adadelat	%83,74
ESA	150	16	10e-3	8000	SGD	%90,46
ESA	150	16	10e-3	8000	RMSprop	%91,44
ESA	250	32	10e-4	8000	Adam	%97,57
ESA	250	32	10e-4	8000	Adadelat	%88,74
ESA	250	32	10e-4	8000	SGD	%91,74
ESA	250	32	10e-4	8000	RMSprop	%93,42

Bu tabloda gösterilen en iyi modelin doğruluk (accuracy) ve kayıp (loss) oranlarının grafiksel gösterimleri Şekil 9'da gösterilmiştir.





Şekil 9. Farklı tur sayıları (Epochs) için ESA ile eğitim ve test sonuçları, (a) 5000 görüntü ve 150 tur sayısına ait doğruluk oranı, (b) 5000 görüntü ve 150 tur sayısına kayıp oranı (loss), (c) 8000 görüntü ve 150 tur sayısına ait doğruluk oranı, (d) 8000 görüntü ve 150 tur sayısına ait kayıp oranı, (e) 8000 görüntü ve 250 tur sayısına ait doğruluk oranı, (f) 8000 görüntü ve 250 tur sayısına ait kayıp oranı

Önerilen ESA modeline ait karmaşıklık matrisini bulmak için test veri setindeki görüntülerden 400 çeltik bitkisi yaprak görüntüsü (200 hastalıklı görüntü, 200 sağlıklı görüntü) kullanılarak test işlemi yapılmıştır. Yapılan test işleminden sonra elde edilen sonuçlara göre Tablo 8’de oluşturulan karmaşıklık matrisi gösterilmiştir. Test işleminden sonra elde edilen TN, FN, FP ve TP değerleri sırayla 197, 7, 3, 193 olarak bulunmuştur.

Tablo 8. Bitki hastalığının tespitinde kullanılan ESA ile çıkan sonuçların karmaşıklık matrisi

		Tahmin	
		Hastalıklı	Sağlıklı
Gerçek	Hastalıklı	197	3
	Sağlıklı	7	193

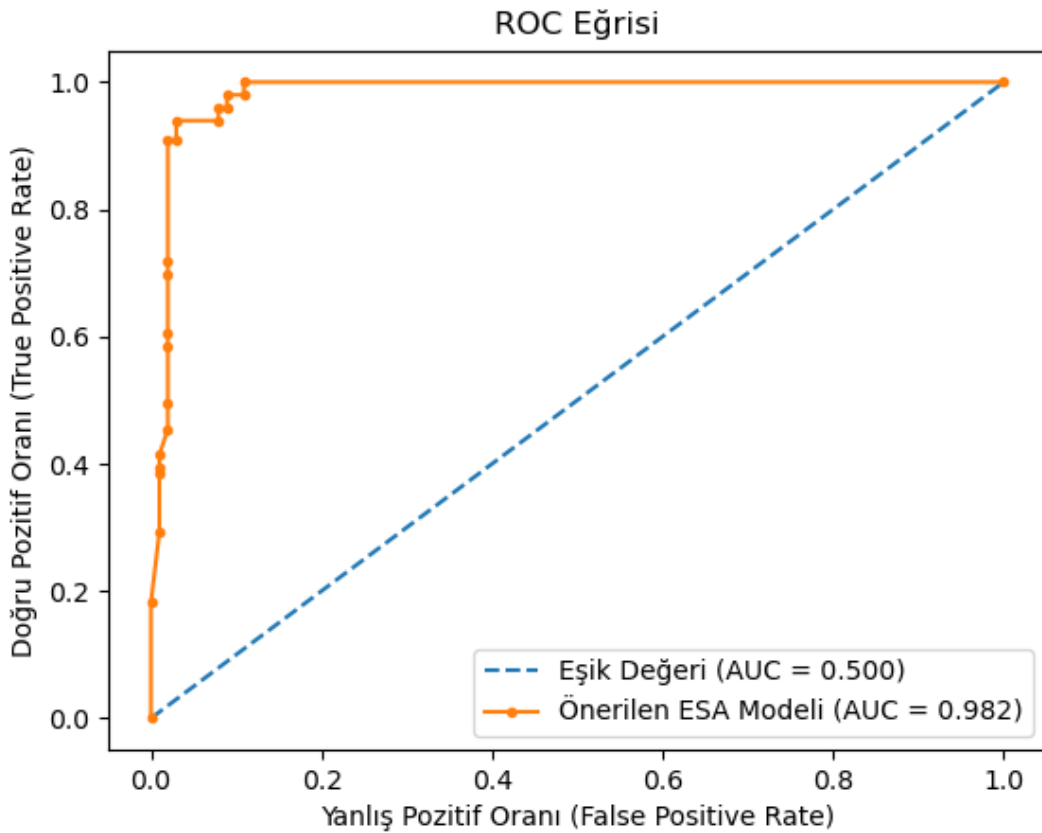
ESA ile YSA modellerin karmaşıklık matrisindeki sonuçlara göre başarı oranı, özgüllük (specificity), hatırlama (recall), hassas (precision) ve f1-score Tablo 9 da gösterilmiştir.

Tablo 9. ESA ve YSA model sonuçları

Sınıflandırma	Veri Seti Boyutu	Özgüllük	Başarım Oranı	Hatırlama	Hassas	F1-score
ESA	400	0,98	0,97	0,96	0,98	0,97
YSA	100	0,82	0,77	0,72	0,80	0,76

Hastalık tespiti yapan modellerin sonuçlarının daha net anlaşılabilmesi için performans ölçme metrikleri kullanılmaktadır. Bu çalışmada bu metriklerden karmaşıklık matrisi ve ROC (Receiver Operating Characteristic) eğrisi ile model performansları gösterilmiştir. Hastalıklı ve sağlıklı gibi sınıflandırma problemlerinin olasılık

değerlerinin sınıflandırılması için eşik (threshold) değeri kullanılır. ROC eğrisini elde etmek için eşik değeri 0.5 olarak seçilmiştir. Bitki hastalığını tespit etmek için önerilen ESA modeline ait ROC eğrisi ve AUC (Area under the ROC Curve) değeri Şekil 10 da gösterilmiştir.

**Şekil 10.** Önerilen ESA modeline ait ROC eğrisi ve AUC-ROC değeri.

ROC eğrisindeki y eksenini Doğru Pozitif Oranını, x eksenini Yanlış Pozitif Oranını temsil etmektedir. ROC eğrisinin hesaplanmasında bu eksenlerdeki (Doğru Pozitif Oranı, Yanlış Pozitif Oranı) değerlerin bilinmesi gerekmektedir. Bu değerleri bulmak için 200 çeltik bitkisi yaprak görüntüsü (100 hastalıklı, 100 sağlıklı) kullanılmıştır.

4. Sonuç ve Öneriler

Derin öğrenme denilince akla ilk gelen yapı olan ESA modeli yaygın bir şekilde tarım ürünlerindeki hastalıkların tespitinde kullanılmaktadır. Bu çalışma kapsamında ESA modelindeki en iyi hiperparametreler bulunarak hastalık tespitindeki başarımlarını arttırmaya çalışıldı. Daha sonra çeltik bitkisi görüntüleri üzerinden görüntü ön işleme yapılarak bu başarımlarını daha da ileriye

taşındı. Önerilen ESA tabanlı modelde çeltik bitkisinin hastalıklı/sağlıklı olup olmadığı tespit edildi. İlk olarak standart yapay sinir ağı ile yapılan eğitim işleminden sonra doğruluk oranı %77 olarak elde edildi. Derin öğrenme metodlarından biri olan ESA modeli ile yapılan test sonucunda ise %91,54 doğruluk oranına ulaşıldı. Hastalığın tespiti için görüntüdeki arka plan kaldırıldıktan sonra test işlemi uygulandığında sınıflandırma doğruluk oranı %97.57 olarak hesaplandı.

Evrişimli sinir ağı mimarisi ve sınıflandırma işleminde kullanılan hiper-parametrelerde değişiklik yapılarak daha iyi sonuçlara ulaşılabilir. Transfer öğrenme modellerinde kullanılan veri setlerine tarımdaki bitki hastalıklarının eklenmesi durumunda bu modellerin daha başarılı sonuçlara ulaşması beklenmektedir. Çeltik bitkisinin üretildiği bölgenin sulak olmasından dolayı geleneksel yöntemler ile veri setinin hazırlanması oldukça zordur. Bu görüntüleri elde etmek için çeltik ekili alanlarda İHA kullanılması gerekmektedir. Görüntülerin bu şekilde elde edilmesi ve İHA ile görüntü alınırken hastalığın tespit edilmesi ayrı bir araştırma konusu olarak ele alınacaktır.

Bu konu üzerinde gelecekte yapılabilecek çalışmalarda, hastalık sınıflandırmada daha iyi sonuçlar vermesi için diğer derin öğrenme mimarileri ve görüntünün sınıflandırmasını kolaylaştırma adına uygun görüntü ön işleme yöntemleri kullanılması planlanmaktadır.

References

- [1] S. Weizheng, W. Yachun, C. Zhanliang, and W. Hongda, "Grading method of leaf spot disease based on image processing," in 2008 International Conference on Computer Science and Software Engineering, 2008.
- [2] "Rice Production (Peace Corps): Chapter 14 – Diseases of rice,". [Online]. Available: <http://www.nzdl.org>. [Accessed: 19-Oct-2021].
- [3] B. ChandraKarmokar, M. Samawat Ullah, M. Kibria Siddiquee, and K. Md. Rokibul Alam, "Tea leaf diseases recognition using neural network ensemble," *Int. J. Comput. Appl.*, vol. 114, no. 17, pp. 27–30, 2015.
- [4] G. Wang, Y. Sun, and J. Wang, "Automatic image-based plant disease severity estimation using deep learning," *Comput. Intell. Neurosci.*, vol. 2017, pp. 1–8, 2017.
- [5] A. Fuentes, S. Yoon, S. Kim, and D. Park, "A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition," *Sensors (Basel)*, vol. 17, no. 9, p. 2022, 2017.
- [6] S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk, and D. Stefanovic, "Deep neural networks based recognition of plant diseases by leaf image classification," *Comput. Intell. Neurosci.*, vol. 2016, p. 3289801, 2016.
- [7] J. Lu, J. Hu, G. Zhao, F. Mei, and C. Zhang, "An in-field automatic wheat disease diagnosis system," *Comput. Electron. Agric.*, vol. 142, pp. 369–379, 2017.
- [8] R. Bhagawati, K. Bhagawati, A. Singh, R. Nongthombam, R. Sarmah, G. Bhagawati, "Artificial Neural Network Assisted Weather Based Plant Disease Forecasting System", *IJRITCC*, vol. 3, no. 6, pp. 4168–4173, Jun. 2015.

Bitkilerdeki hastalıkların erken teşhisi için RGB görüntü alan kameralar yerine multispektral kameralar kullanılması düşünülmektedir. Bu sayede bitkilerdeki hastalığın insan gözü ile tespiti anlaşılmayacak seviyede olduğunda erken tespiti yapılabilecektir. İHA ile konum bazlı multispektral görüntülerin elde edilmesi ve bu görüntüler üzerinde derin öğrenme mimarileri ile otomatik hastalık tespiti yapılması planlanmaktadır.

Yazarların Katkısı

Bu çalışma, Prof. Dr. Uğur YÜZGEÇ danışmanlığında İrfan ÖKTEN tarafından hazırlanan doktora tez çalışması kapsamında yapılmış olup, İrfan ÖKTEN bu çalışmada verilerin hazırlanması, çoğaltılması, modelin algoritma ve yazılımının hazırlanması, makalenin yazımı, Uğur YÜZGEÇ ise makalenin düzenlenmesi ve danışmanlık işlemlerinde katkıda bulunmuşlardır.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

- [9] S. P. Mohanty, D. P. Hughes, and M. Salathé, “Using deep learning for image-based plant disease detection,” *Front. Plant Sci.*, vol. 7, pp: 1419, 2016.
- [10] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Commun. ACM*, vol. 60, no. 6, pp. 84–90, 2017.
- [11] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” arXiv [cs.CV], 2014.
- [12] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [13] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [14] M. Kerkech, A. Hafiane, and R. Canals, “Deep learning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images,” *Comput. Electron. Agric.*, vol. 155, pp. 237–243, 2018.
- [15] J. Ma, K. Du, F. Zheng, L. Zhang, Z. Gong, and Z. Sun, “A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network,” *Comput. Electron. Agric.*, vol. 154, pp. 18–24, 2018.
- [16] Y. Lu, S. Yi, N. Zeng, Y. Liu, and Y. Zhang, “Identification of rice diseases using deep convolutional neural networks,” *Neurocomputing*, vol. 267, pp. 378–384, 2017.
- [17] H. B. Prajapati, J. P. Shah, and V. K. Dabhi, “Detection and classification of rice plant diseases,” *Intell. Decis. Technol.*, vol. 11, no. 3, pp. 357–373, 2017.
- [18] C. R. Rahman et al., “Identification and recognition of rice diseases and pests using convolutional neural networks,” *Biosyst. Eng.*, vol. 194, pp. 112–120, 2020.
- [19] C. DeChant et al., “Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning,” *Phytopathology*, vol. 107, no. 11, pp. 1426–1432, 2017.
- [20] B. Liu, Y. Zhang, D. He, and Y. Li, “Identification of apple leaf diseases based on deep convolutional neural networks,” *Symmetry (Basel)*, vol. 10, no. 1, pp: 11, 2017.
- [21] R. R. and D. Park, “A multiclass deep convolutional neural network classifier for detection of common rice plant anomalies,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 9, no. 1, 2018.
- [22] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [23] H. Durmus, E. O. Gunes, and M. Kirci, “Disease detection on the leaves of the tomato plants by using deep learning,” in *2017 6th International Conference on Agro-Geoinformatics*, 2017.
- [24] “Tf.Keras.Preprocessing.Image.ImageDataGenerator,” TensorFlow. [Online]. Available: https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator. [Accessed: 08-Jan-2022].