

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĐİ ANA BİLİM DALI

**DERİN ÖĐRENME YÖNTEMLERİ VE YAPAY SİNİR AĐI TABANLI NDVI
DEĐERLERİ İLE ÇELTİK BİTKİSİ HASTALIKLARIN TESPİTİ**

DOKTORA TEZİ

İR FAN ÖKTEN

TEZ DANIŐMANI
PROF. DR. UĐUR YÜZGEÇ

BİLECİK, 2022

10474125

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĐİ ANA BİLİM DALI

**DERİN ÖĐRENME YÖNTEMLERİ VE YAPAY SİNİR AĐI TABANLI NDVI
DEĐERLERİ İLE ÇELTİK BİTKİSİ HASTALIKLARIN TESPİTİ**

DOKTORA TEZİ

İR FAN ÖKTEN

TEZ DANIŐMANI
PROF. DR. UĐUR YÜZGEÇ

BİLECİK, 2022

10474125

BEYAN

Derin Öğrenme Yöntemleri ve Yapay Sinir Ağı Tabanlı NDVI Değerleri ile Çeltik Bitkisi Hastalıkların Tespiti adlı doktora tezi hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR		DESTEK ALINMAMIŞTIR	X
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:	/.....	

İrfan ÖKTEN

Tarih

.....

İmza

.....

ÖN SÖZ

Lisans ve Yüksek Lisans eğitimim boyunca vermiş olduğu dersler ve Doktora tez çalışmamın planlanmasında, araştırılmasında, oluşumunda ve yürütülmesinde ilgi ve desteğini hiçbir zaman esirgemeyen çok değerli hocam Prof. Dr. Uğur YÜZGEÇ'e;

Doktora sürecinde çok kıymetli tecrübelerini benimle paylaşan, tez izleme komitesi üyeleri hocalarım Sayın Doç. Dr. Devrim AKGÜN'ne ve Sayın Doç. Dr. Emre DANDIL'a;

Bu günlere kadar gelmemde en büyük emeğe sahip olan aileme;

Doktora süresince beni çalışmaya teşvik eden ve ders çalışabilmem için çocuklarımıza daha fazla ilgi gösteren eşime;

Sonsuz teşekkürlerimi sunarım.

İrfan Ökten

2022

ÖZET

DERİN ÖĞRENME YÖNTEMLERİ VE YAPAY SİNİR AĞI TABANLI NDVI DEĞERLERİ İLE ÇELTİK BİTKİSİ HASTALIKLARIN TESPİTİ

Dünya çapında gıda tüketimi göz önüne alındığında pirincin önemli bir yere sahip olduğu görülür. Çeltik bitkisi, buğdaygiller ailesinden mısır ve buğdaydan sonra en fazla ekimi yapılan bitkidir. Çeltik üretiminde çeşitli zararlılardan ve hastalıklardan dolayı üretim kaybı yaşanmaktadır. Genellikle yaşanan bu kayıplara neden olan üç temel hastalık bulunmaktadır: yaprak patlaması (Leaf Blast - *Pyricularia grisea*), kahverengi lekeler (Brown Spot - *Helminthosporium oryzae*) ve beyaz noktalar (Hispa - *Dicladispa armigera*). Tüm bu hastalık belirtileri bitkinin yaprağında bulunmaktadır.

Yaprak görüntülerinden bitki hastalığının otomatik bir şekilde teşhisi geliştirme aşamasında olan bir konudur. Bu tez kapsamında çeltik bitkisine ait bu üç hastalığı tespit etmek için derin öğrenme modellerinden Evrişimli Sinir Ağı (CNN: Convolution Neural Networks) kullanılmıştır. Çalışmada kullanılan 3341 adet çeltik bitkisi yaprağına ait RGB veri seti Kaggle sitesinden elde edilmiştir. Çeltik bitkisinin RGB yaprak görüntülerinden derin öğrenme modeli ile çeltik bitkisine ait üç önemli hastalık (Brown Spot, Leaf Blast ve Hispa) tespiti yüksek doğruluk oranlarıyla elde edilmiştir. Çeltik bitkisine ait hastalıkların erken tespiti için CNN modelinin deneyler sonucu bulunan en uygun hiper parametreler ile eğitimi gerçekleştirilmiştir. Ağın eğitimi için çeltik bitkisine ait RGB görüntüler kullanılarak %92,78 oranında doğruluk elde edilmiştir.

Tarım alanlarında ürünlerin sağlık durumlarının incelenmesinde genellikle multispektral kameralardan ve uydu görüntülerinden elde edilen Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI: Normalized Difference Vegetation Index) değerleri kullanılmaktadır. NDVI verilerinin elde edilmesinde kullanılan uzaktan algılama tekniklerinde yüksek maliyet ve hava durumunun uygunluğu öne çıkmaktadır. Diğer alternatif olan insansız hava araçlarına (İHA) entegre edilmiş multispektral kamera sistemlerinin maliyetlerinin yüksek olması ve uzman gereksinimine ihtiyaç duyulması bir başka sorundur. Bu tez çalışmasında ikinci olarak multispektral kameraların yerine standart RGB görüntü veren kamera sistemlerinden NDVI değerini tahmin etmek (nNDVI: Neural network-based Normalized Difference Vegetation Index) için yeni bir yapay sinir ağı modeli önerilmiştir. Önerilen ağın eğitim ve testlerinde kullanılan veri seti İsviçre'de bir tarım alanından ve Togo'da bir çiftlikten multispektral kamera ile alınan

görüntülerden elde edilmiştir. Bu model sayesinde %92,013 doğruluk oranı ile RGB görüntülerinden NDVI verileri elde edilmiştir.

Son olarak bu tez kapsamında çeltik bitkisinin standart RGB görüntülerinden nNDVI verileri elde edilerek, bu veriler ile derin öğrenme modelinin eğitimi yapılmış ve %96,97'lik bir doğruluk oranına ulaşılmıştır. Çeltik bitkisindeki yaprak görüntüleri ile hastalığının tespiti için elde edilen bu başarı oranı, yöntemin uygulanabilirliğini göstermektedir.

Anahtar kelimeler: Derin öğrenme, Evrişimli sinir ağı, Çeltik bitkisi, NDVI, Yapay zeka.

ABSTRACT

DETECTION OF DISEASES IN RICE PLANT WITH DEEP LEARNING METHODS AND ARTIFICIAL NETWORK BASED NDVI VALUES

Considering the worldwide food 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. Production loss is experienced in paddy production due to various pests and diseases. There are three main diseases that cause these losses: Leaf Blast (*Pyricularia grisea*), Brown Spot (*Helminthosporium oryzae*), and Hispa (*Dicladispa armigera*). All these disease symptoms are found in the leaves of the plant.

The automatic diagnosis of plant disease from leaf image is a topic under development. In this thesis, Convolutional Neural Network (CNN), one of the deep learning models, was used to detect these three diseases of the rice plant. The RGB data set of 3341 rice plant leaves used in the study was obtained from the Kaggle website. With the deep learning model from RGB leaf image of rice plant, three important diseases of rice plant (Brown Spot, Leaf Blast and Hispa) were detected with high accuracy rates. For the early detection of diseases of rice plant, the training of the CNN model was carried out with the most appropriate hyper parameters found as a result of the experiments. For the training of the network, an accuracy of 92.78% was obtained by using RGB image of the rice plant.

Normalized Difference Vegetation Index (NDVI) values obtained from multispectral cameras and satellite image are generally used to examine the health status of crops in agricultural areas. High cost and suitability of weather conditions come to the fore in remote sensing techniques used in obtaining NDVI data. Another problem is the high cost of multispectral camera systems integrated into unmanned aerial vehicles (UAV), which is another alternative, and the need for specialists. In this thesis, secondly, a new artificial neural network model is proposed to estimate the NDVI value (nNDVI: Neural network-based Normalized Difference Vegetation Index) from camera systems that provide standard RGB image instead of multispectral cameras. The data set used in the training and testing of the proposed network was obtained from image taken with a multispectral camera from an agricultural field in Switzerland and a farm in Togo. Thanks to this model, NDVI data was obtained from RGB image with an accuracy rate of 92,013%.

Finally, within the scope of this thesis, nNDVI data was obtained from standard RGB image of rice plant, and a deep learning model was trained with these data and an accuracy rate of 96.97%

was achieved. This success rate obtained for the detection of the disease with leaf image in the rice plant shows the applicability of the method.

Keywords: Deep learning, Convolutional neural network, Rice plant, NDVI, Artificial intelligence.

İÇİNDEKİLER

	Sayfa
ÖN SÖZ.....	i
ÖZET	ii
ABSTRACT	iv
İÇİNDEKİLER.....	vi
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	x
KISALTMALAR VE SİMGELER LİSTESİ.....	xiii
1. GİRİŞ	1
1.1. Çeltik bitkisi hastalığının tespiti.....	2
1.2. Tezin amacı	5
1.3. Tezin katkıları.....	6
2. LİTERATÜR TARAMASI	7
2.1. Çeltik bitkisine ait hastalıklar	7
2.2. Bitki hastalıklarının tespitinde kullanılan yöntemler.....	9
2.3. Tarım alanında kullanılan multispektral kamera sistemleri	12
2.4. Bitki indeksleri ve RGB görüntülerden NDVI değeri tahminine yönelik çalışmalar	16
3. EVRİŞİMLİ SİNİR AĞI İLE ÇELTİK BİTKİSİ HASTALIĞININ TESPİTİ.....	19
3.1. Görüntü işleme ve yapay sinir ağı ile çeltik bitkisi hastalığının tespiti	19
3.1.1. Görüntü ön işleme	20
3.1.2. Bölütleme (segmentasyon) işlemi	21
3.1.3. Özellik çıkarımı	22
3.1.4. Sınıflandırma	23
3.2. Veri seti	24
3.3. Veri artırımı	25

3.4.	Performans değerlendirme ölçütleri	27
3.5.	Donanım ve yazılım ortamı.....	30
3.6.	Evrışimli sinir ağları.....	31
3.7.	CNN ile çeltik bitkisinin hastalık tespiti (hastalıklı ve sağlıklı).....	34
3.8.	CNN ile çeltik bitkisinin hastalık tespiti (sağlıklı ve üç hastalık için).....	35
3.9.	Sonuçlar ve değerlendirme	36
3.9.1.	PNN modeli ile çeltik bitkisinin hastalık tespiti.....	37
3.9.2.	CNN modeli ile çeltik bitkisinin hastalık tespiti sonuçları (sağlıklı ve hastalıklı)	39
3.9.3.	CNN modeli ile çeltik bitkisinin hastalık tespiti sonuçları (sağlıklı ve üç hastalık için)	45
4.	STANDART RGB GÖRÜNTÜLERİNDEN NDVI DEĞERİ TAHMİNİ.....	51
4.1.	Normalize edilmiş fark bitki örtüsü indeksi (NDVI).....	51
4.2.	Çok katmanlı algılayıcılar (MLP)	52
4.3.	Veri seti.....	54
4.4.	Veri setinin hazırlanması	56
4.5.	Sinir ağ tabanlı bitki indeksi (nNDVI)	58
4.6.	Sonuçlar ve değerlendirme	59
5.	SİNİR AĞI TABANLI BİTKİ İNDEKSİ (nNDVI) İLE ÇELTİK BİTKİSİ HASTALIĞININ TESPİTİ	69
5.1.	Veri setinin hazırlanması	69
5.2.	Evrışimsel sinir ağı ile çeltik bitkisinin nNDVI değerinden hastalık tespiti (sağlıklı ve 3 hastalık için).....	70
5.3.	Sonuçlar ve değerlendirme	71
6.	SONUÇLAR VE TARTIŞMA	76
	KAYNAKÇA	79

TABLULAR LİSTESİ

	Sayfa
Tablo 1. 1. Çeltik bitkisinde en sık görülen hastalıklar ve temel belirtileri	2
Tablo 2. 1. Spektroskopik çalışmalarda hastalık tespitinde kullanılan bitkisel indeksler	16
Tablo 3. 1. Her bir görüntüden çıkarılan 20 adet özellik.....	23
Tablo 3. 2. Çeltik bitkisinin sınıf adları, veri sayısı ve veri artırımından sonraki veri sayısı..	26
Tablo 3. 3. İki sınıflı bir problemde kullanılan karmaşıklık matrisi.....	28
Tablo 3. 4. PNN modeli kullanarak elde edilen karışıklık matrisi	39
Tablo 3. 5. PNN modelinin performans ölçütleri	39
Tablo 3. 6. PNN ve CNN modellerinin çeltik bitkisi hastalığı sınıflandırma sonuçları.....	40
Tablo 3. 7. Sağlıklı ve Hastalıklı çeltik bitkisi sınıfları için sınıflandırma doğruluk sonuçları	40
Tablo 3. 8. Veri seti büyüklüğünün CNN modeli başarı oranı üzerindeki etkisi	41
Tablo 3. 9. Hiperparametrelerinin değişimine göre CNN modelinin test başarı oranları.....	42
Tablo 3. 10. Bitki hastalığının tespitinde kullanılan CNN ile çıkan sonuçların karmaşıklık matrisi.....	43
Tablo 3. 11. PNN ve CNN model sonuçları	44
Tablo 3. 12. Derin öğrenme modeli ile dörtlü sınıflandırma sonuçları	45
Tablo 3. 13. Veri seti boyutunun doğruluk oranı üzerindeki etkisi.....	46
Tablo 3. 14. Dörtlü sınıflandırma doğruluk oranları	46
Tablo 3. 15. Hiperparametrelerin değişimi ile CNN modelinin doğruluk oranının sonucu	47
Tablo 3. 16. CNN modeli kullanılarak elde edilen karışıklık matrisi, BS: Brown Spot, H: Healthy, His: Hispa, LB: Leaf Blast	49
Tablo 3. 17. Oluşturulan CNN modelinin sınıflandırma performansı.....	49
Tablo 4. 1. Önerilen model için giriş matris boyutu, çıkış matris boyutu ve belirtilen görüntü sayısına göre elde edilen veri seti boyutu.....	58
Tablo 4. 2. Literatürde kullanılan 9 eğitim fonksiyonu ile bulunan başarı oranları	60

Tablo 4. 3. Modelde kullanılan eğitim fonksiyonları ve tanımlamaları	60
Tablo 4. 4. Yapılan 10 test görüntüsü için ağın performansı	68
Tablo 5. 1. Derin öğrenme modelleri ile çeltik bitkisi hastalık tespiti uygulama sonuçları	73
Tablo 5. 2. CNN modeli kullanılarak elde edilen karışıklık matrisi (nNDVI görüntüler için), BS: Brown Spot, H: Healthy, His: Hispa, LB: Leaf Blast	73
Tablo 5. 3. Oluşturulan CNN modelinin sınıflandırma performansı (nNDVI görüntüleri için)	74
Tablo 6. 1. Çeltik bitkisi hastalıkların tespiti üzerine yapılan çalışmalar ile önerilen yöntemin karşılaştırılması.	77

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1. 1. Çeltik bitkisine ait farklı hastalıklar ve sağlıklı yaprak görüntüleri	3
Şekil 1. 2. Tezin genel yapısı	5
Şekil 2. 1. İHA görüntüleri ile soya fasulyesi yaprak hastalıklarını tanımlamak için önerilen bilgisayar görme sistemi. (a) Görüntü edinimi. (b) SLIC segmentasyonu. (c) Resim veri seti. (d) Özellik çıkarma. (e) Görüntü hastalığı sınıflandırması	10
Şekil 2. 2. Elma meyvesinden gelen ışık saçılma profillerini ölçmek için multispektral bir görüntüleme sisteminin şeması	14
Şekil 2. 3. 1064, 1150 ve 1572 band dalga boyundaki 3 resim sırayla gösterimi (A). Görüntünün histogram gerilmesi (histogram stretch), yumuşatılması (smoothing) ve NDVI değerinin hesaplanmasından sonraki hali (B). Histogram gerilmesini üst sınır eşliğinin uygulanmasından sonra (C). Otsu yöntemi kullanıldıktan sonraki hali (D). 8 boyutlu ‘disk’ ten sonraki nihai sonuç (E).....	15
Şekil 3. 1. Görüntü işleme ve PNN modeli ile çeltik bitkisi hastalığını tespit aşamaları	20
Şekil 3. 2. 3x3 medyan filtre uygulaması.....	21
Şekil 3. 3. Medyan filtre uygulanan çeltik bitkisi yaprağı	21
Şekil 3. 4. Çeltik bitkisi yaprak görüntüsüne OTSU metodu uygulanması	22
Şekil 3. 5. GLCM matrisinin hesaplanması örnekleri.....	23
Şekil 3. 6. Kullanılan Olasılıksal Sinir Ağı yapısı	24
Şekil 3. 7. Çeltik bitkisinin hastalıklı ve sağlıklı yaprak görüntüleri.....	25
Şekil 3. 8. Veri artırma yöntemi ile oluşturulan yeni çeltik bitkisi yaprak görüntüleri	27
Şekil 3. 9. CNN mimarisi.....	31
Şekil 3. 10. 4x4 giriş görüntüsüne 2x2 filtre ile evrişim işlemi	32
Şekil 3. 11. 2x2lik görüntüye maksimum havuzlama ve ortalama havuzlama işlemi	33
Şekil 3. 12. İkili sınıflandırma için oluşturulan CNN derin öğrenme modeli yapısı	34
Şekil 3. 13. Dörtlü sınıflandırma için oluşturulan CNN derin öğrenme modeli yapısı	36
Şekil 3. 14. Oluşturulan PNN modeli ile çeltik bitkisi hastalık tespiti program arayüzü	37

Şekil 3. 15. PNN modeli ile çeltik bitkisi hastalık tespit programı kullanımı	38
Şekil 3. 16. Farklı tur sayıları (Epochs) için CNN 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	43
Şekil 3. 17. Oluşturulan CNN modeline ait ROC eğrisi ve AUC-ROC değeri	44
Şekil 3. 18. Farklı eğitim tur (epoch) sayıları için CNN eğitim (training) ve doğrulama (validation) sonuçları, (a) 200 eğitim tur sayısı için doğruluk (accuracy) oranı, (b) 200 eğitim tur sayısı için kayıp (loss), (c) 500 eğitim tur sayısı için doğruluk (accuracy) oranı (d) 500 eğitim tur sayısı için kayıp (loss), (e) 750 eğitim tur sayısı için doğruluk (accuracy) oranı (f) 750 eğitim tur sayısı için kayıp (loss)	48
Şekil 4. 1. NDVI değerler aralıklarına göre bitki durumu gösterimi	52
Şekil 4. 2. Örnek bir MLP mimarisi.....	53
Şekil 4. 3. Multispektral kamera görüntüleri (İsviçre'deki tarım alanı); a (Mavi), b (Yeşil), c (Kırmızı), d (NIR), e (RE).....	54
Şekil 4. 4. Multispektral kamera görüntüleri (Togo'daki bir çiftlik); a (Mavi), b (Yeşil), c (Kırmızı), d (NIR), e (RE).....	55
Şekil 4. 5. RGB görüntüsü (a), ham NDVI görüntüsü (b) ve renkli NDVI görüntüsü (c).....	56
Şekil 4. 6. Giriş-Çıkış veri seti hazırlama şeması	57
Şekil 4. 7. 3 giriş (R, G ve B), 1 (nNDVI) çıkış ve 3 gizli katmandan oluşana MLP modeli .	58
Şekil 4. 8. RGB görüntülerden NDVI tahmini için kullanılan çok katmanlı yapay sinir ağ modeli	59
Şekil 4. 9. MLP ile eğitilen ağın doğrusal regresyon ile elde edilen başarımlar oranları (eğitim (R=92.017), doğrulama (R=91.999), test (R=92.013) ve hepsi (R=92.012))	61
Şekil 4. 10. Test için kullanılan bir görüntüden rastgele seçilen 44 piksel verisine göre nNDVI ile NDVI karşılaştırma gösterimi (a), kullanılan görüntüdeki 44 piksel verisine göre oluşturulan doğrusal regresyon ile nNDVI ile NDVI gösterimi (b).....	62
Şekil 4. 11. Eğitimi yapılmış ağın bulduğu nNDVI görüntü ile NDVI görüntüsü	68

Şekil 5. 1. RGB görüntülerden nNDVI görüntüsünü elde eden arayüz programı	69
Şekil 5. 2. Çeltik bitkisine ait hastalıkların erken tespit sisteminin genel gösterimi	71
Şekil 5. 3. Önerilen dönüştürme işleminden sonra elde edilen renklendirilmiş nNDVI görüntüleri	72

KISALTMALAR VE SİMGELER LİSTESİ

I: Fluorescence intensity (Floresan yoğunluğu)

R: Reflectance (Yansıtma).

b: Bant

d: Uzaklık

θ: Açı

ε: Hata

w: Ağırlık

F: Ara katman

CNN: Convolution Neural Network (Evrışimli Sinir Ağı)

CPU: Central Processing Unit (Merkezi İşlem Birimi)

GLCM: Gray Level Co-occurrence Matrix (Gri Düzey Eş Oluşum Matrisi)

GNDVI: Green NDVI

GPU: Graphics Processing Unit (Grafik İşlem Birimi)

GRVI: Green Ratio Vegetation Index

HSV: Hue, Saturation, Value (Ton, Doygunluk, Değer)

İHA: İnsansız Hava Aracı

IWB: Water Band Index (Su Bandı İndeksi)

k-NN: K-Nearest Neighbor (K En Yakın Komşu)

MAE: Mean Average Error (Ortalama Hata)

MCARI: Modified Chlorophyll Absorption in Reflectance Index (Yansımada Modifiye Edilmiş Klorofil Emilim İndeksi)

MDC: Minimum Distance Classifier (Minimum Mesafe Sınıflandırıcısı)

MLP: Multi Layer Perceptron (Çok Katmanlı Algılayıcılar)

MPE: Mean Percentage Error (Ortalama Hata Yüzdesi)

MSE: Mean Squared Error (Ortalama Karesel Hata)

NDRE: Normalized Difference Red Edge Index (Normalize Edilmiş Fark Kırmızı Kenar İndeksi)

NDVI: Normalized Difference Vegetation Index (Normalize Edilmiş Fark Bitki Örtüsü İndeksi)

NIR: Near-infrared (Yakın Kırmızı Ötesi)

nNDVI: Neural network based NDVI (Yapay Sinir Ağı Temelli NDVI)

PNN: Probabilistic Neural Network (Olasılıksal Sinir Ağı)

PRI: Photochemical reflectance index (Fotokimyasal Yansıma İndeksi)

ReLU: Rectifier Linear Unit (Doğrultucu Lineer Birim)

RMSE: Root Mean Squared Error (Karekök Ortalama Hata)

ROC: Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)

RVSI: Red-Edge Vegetation Stress Index (Kırmızı Kenarlı Bitki Stresi İndeksi)

SAVI: Soil-Adjusted Vegetation Index (Toprak Tabanlı Bitki İndeksi)

SGD: Stochastic Gradient Descent (Stokastik Gradyan İniş)

SLIC: Simple Linear Iterative Clustering (Basit Doğrusal Yinelemeli Kümeleme)

SMO: Sequential Minimal Optimization (sıralı minimal optimizasyon)

SVM: Support Vector Machine (Destek Vektör Makinesi)

VARI: Visible Atmospherically Resistance Index (Görünür Atmosferik Direnç İndeksi)

WI: Water Index (Su İndeksi)

YSA: Yapay Sinir Ağı

1. GİRİŞ

Dünyada ve ülkemizde canlılar için beslenme değeri açısından önemli bir yere sahip olan tahılların geniş bir ekim alanı vardır. Besin kaynağı olarak çeltik, tahıllar içinde dünya nüfusunun yarısından fazlası için buğdaydan sonra en önemli kültür bitkisidir. Dünyada ortalama olarak kişi başına düşen gerekli günlük enerjinin %25'i çeltik tüketimi ile karşılanmaktadır (Sürek, 2002). Kapladığı tarım alanı olarak dünyada üretimi yapılan tahıllar içerisinde buğday ve mısırdan sonra 3. sırada çeltik yer almaktadır (Özşahin, 2008; Turan, 2013).

Çeltik bitkisine Avrupa'da ortaçağlarda rastlanmış ve ilk olarak MÖ 3.000'li yıllarda Hindistan'da tarımına başlanmıştır. Çeltiğin ülkemize ise yaklaşık 500 yıl kadar önce geldiği ifade edilmektedir (Gül, 2003; Peng vd., 2009). Genellikle tropik ve ılıman bölgelerde tarımı yapılan çeltik, suyun içinde yetiştirilen tek tahıl bitkisidir. Çeltik dışındaki tahıl bitkileri suda bu kadar uzun süre canlılığını koruyamamaktadır. Çeltik sudaki oksijeni kullanabilir ve bundan kökleri de yararlanabilir (Chauhan vd., 2017; Van Nguyen ve Ferrero, 2006). Çeltik bitkisi, deniz seviyesinden 2500 metre rakıma kadar ve kuru toprak yapısı ile birlikte derin suya sahip su altındaki araziler gibi geniş bir değişim gösteren alanlarda ekilebilmektedir (Sürek, 2002).

Ülkemizde çeltik üretiminin yarısından fazlası Marmara bölgesinde yapılmaktadır. İllere göre ise en çok üretim Edirne, Samsun ve Balıkesir olarak sıralanmaktadır (TUİK, 2021). 2018 yılı toplam çeltik ekilen alanı 410.681 ton ile ülkemiz çeltik üretiminin yaklaşık %44'ü Edirne ilimizde gerçekleştirilmektedir. Edirne'deki çeltik alanlarının büyük bir kısmı monokültür şeklindedir (TUİK, 2020).

Diğer tarım ürünlerinde olduğu gibi çeltik üretiminde de çeşitli zararlılardan ve hastalıklardan dolayı üretim kaybı yaşanmaktadır. Çeltik üretiminde en sık rastlanan zararlılar yaprak pireleri, yaprak kurtları ve pirinç zararlıları olarak sayılabilir. Çeltik bitkisi üretiminde en sık rastlanan üç temel hastalık bulunmaktadır: bakteriyel yaprak lekesi, bakteriyel yanıklık ve kahverengi lekeler. Tüm bu hastalık ve/veya zararlılardan dolayı çeltik üretimindeki kayıp %30'lardan fazla olmaktadır. Çok büyük alanlardan oluşan Marmara bölgesi ve Edirne'de çeltik alanları hastalığın çıkış yaptığı ve kimyasal mücadele yapılması gereken Temmuz-Ağustos aylarında su altında bulunmaktadır. Ekili ürünlerin boyları ve arazi şartlarından dolayı çeltik alanlarına girilemeyen durumlarda özellikle hastalık erken teşhis edilememekte, epidemi ortaya çıkarak ürün ve verim kayıplarına neden olabilmektedir. Tüm bu sebeplerden dolayı hastalık çıkışı olan alanların kısa sürede tespit edilip o alanlarda mücadele yapılması gerekmektedir.

Çeltikte meydana gelen hastalıkların erken tespit edilememesinden dolayı verim düşmektedir. Oluşan hastalıklarla mücadele sırasında tüm alanlar ilaçlandığından sağlıklı bitkiler de ilaçlanabilmektedir. Ayrıca çeltik hastalıklarına ve zararlılara karşı aşırı kullanılan kimyasallar toprağı ve yer altı sularını kirletmektedir. Bunun yanısıra çeltik ekili alanlarda yaşamını sürdüren canlıları da yapılan ilaçlama ve kimyasallar olumsuz yönde etkilemektedir. Günümüzde, ekili alanlarda noktasal koordinat bazlı akıllı hastalık teşhis sistemlerinin geliştirilmesi ve uygulanması sayesinde hastalığa yakalanmamış bitkilerin gereksiz yere kimyasal maddelerle teması önlenmektedir.

1.1. Çeltik bitkisi hastalığının tespiti

Bitki hastalıkları, tarım ürünlerindeki verimi ve kaliteyi düşüren en önemli nedenlerden biridir (Weizheng vd., 2008). Bu hastalıkların önüne geçilmediği durumlarda toplam mahsul doğrudan etkilenmektedir. Bitkilerde oluşan hastalıklar iklim şartlarına göre değişkenlik gösterdiğinden sürekli olarak izlenmelidir.


Bitkilerde meydana gelen hastalıklara genellikle mantarlar, bakteriler veya virüsler neden olmaktadır. Çeltik bitkisinde en yaygın olarak bakteriyel yaprak yanığı (Bacterial leaf blight), kahverengi leke (Brown Spot), yaprak isi (Leaf Smut), hispa, yaprak patlaması (Leaf Blast) ve kovan yanığı (Sheath) görülmektedir (Rice Production, 2021). Bu hastalıklar yetiştirilen bölgeye göre farklılık göstermekte ve bazıları da belirli bölgelerde hiç görülmemektedir. Bu yüzden tüm hastalıkların sınıflandırılması için gerekli olan verinin elde edilmesi oldukça zorlaşmaktadır. Çeltik bitkisinde meydana gelen hastalıklar renk, boyut ve şekil olarak birbirinden ayrılmaktadır. Bu hastalıkların bitkinin hangi kısmını etkilediği, şekilsel belirtileri ve oluşan lezyonlardaki renkler Tablo 1.1’de en sık görülen üç çeltik bitkisi hastalığı için verilmektedir (Rahman vd., 2020).

Tablo 1. 1. Çeltik bitkisinde en sık görülen hastalıklar ve temel belirtileri

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

Kaynak: (Rahman vd., 2020)

Bu hastalıkların ortak noktası belirtilerin bitkinin yapraklarında görülmesidir. Yapraklar incelendiğinde hastalıkların şekilsel olarak birbirine benzediği görülmektedir. Çeltik bitkisine ait Brown Spot, Leaf Blast ve Hispa hastalıkları ile sağlıklı yaprağın görüntüleri Şekil 1.1’de gösterilmiştir.



Şekil 1. 1. Çeltik bitkisine ait farklı hastalıklar ve sağlıklı yaprak görüntüleri
Kaynak: (Kaggle, 2020)

Bu tez çalışmasında, çeltik bitkisi hastalıklarından Brown Spot, Hispa ve Leaf Blast ele alınmış ve sağlıklı çeltik bitkisi verileri ile birlikte dördü bir sınıflandırma işlemi gerçekleştirilmiştir. Ele alınan hastalıkların sınıflandırma başarımını arttırmak için, hastalığın tespitinde uygulanan yapay zekâ uygulamalarının yanı sıra görüntü ön işleme yöntemleri de kullanılmıştır.

Tez çalışması için ilk olarak Kaggle sitesinden çeltik bitkisine ait hastalıklı ve sağlıklı yaprakların bulunduğu 3341 adet görüntü elde edildi. Derin öğrenme tabanlı modellerin sınıflandırma başarımını yükseltmek için veri artırma yöntemi ile daha fazla hastalıklı ve sağlıklı görüntüler oluşturulmuştur. Çeltik bitkisinde görülen hastalıkların belirlenmesine yönelik olarak görüntüler farklı ön işleme tekniklerinden geçirilmiştir. Daha sonra derin öğrenme modelinin en uygun hiper parametreleri deneme yanılma metoduyla elde edilmiş ve bu derin öğrenme modeli ile eğitim yapılmıştır.

Tez başlangıcında, görüntü işleme yöntemleri ile temel bir yapay sinir ağı kullanılarak hastalığın tespiti yapıldığında model başarım oranının çok yüksek çıkmadığı tespit edilmiştir. Yapılan testler sonucu çeltik bitkisindeki hastalığın tespiti için %77 oranında bir başarı elde edilmiştir. Bu test işlemi yapılırken görüntü ön işleme ile medyan filtresi uygulandı. Görüntünün bölütleme (segmentasyon) işlemi için OTSU yöntemi kullanıldı. Görüntüdeki özellikleri çıkarmak için Gri Düzey Eş Oluşum Matrisi (GLCM: Gray Level Co-occurrence Matrix) algoritması kullanıldı. Daha sonra hastalığın sınıflandırılması için sınıflandırma ve

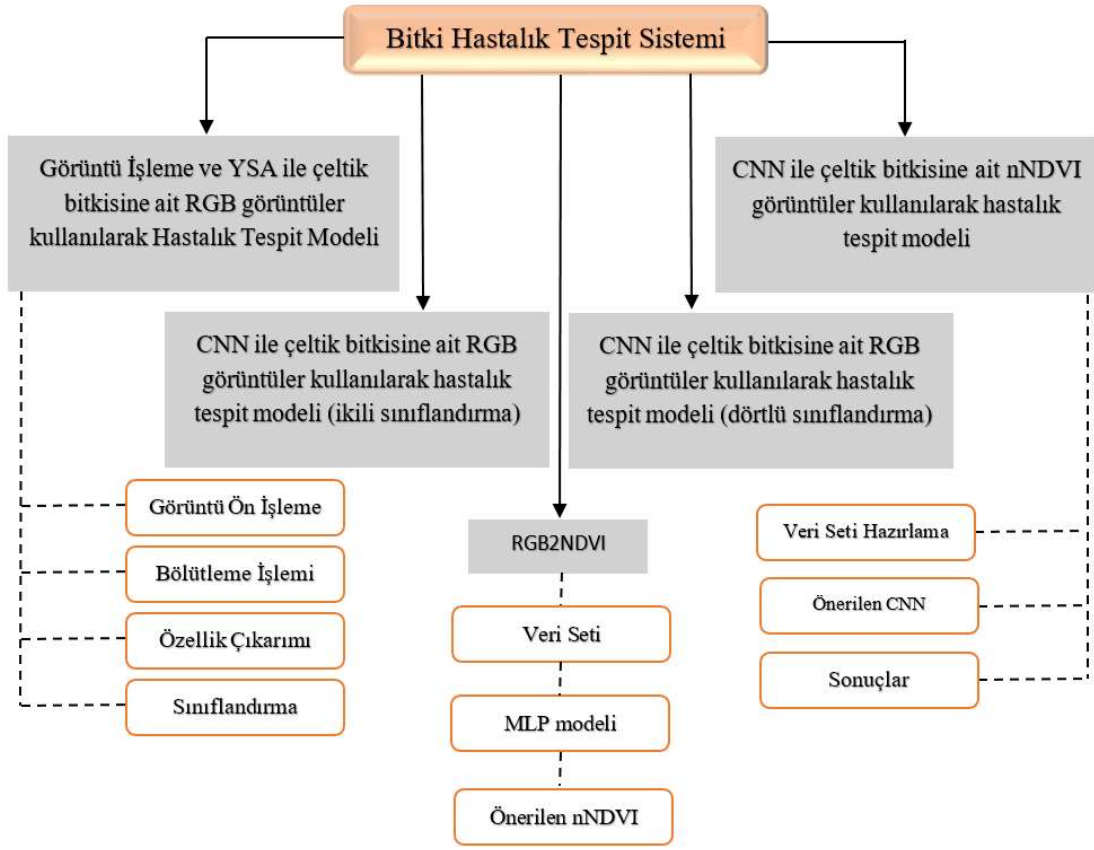
örüntü tanıma problemlerinde yaygın bir şekilde kullanılan ileri beslemeli bir sinir ağı olan Olasılıksal Sinir Ağı (PNN: Probabilistic Neural Network) kullanılmıştır.

İkinci olarak, çeltik bitkisi hastalığı tespitinde başarı oranını yükseltmek için derin öğrenme yöntemlerinden biri olan CNN yapısına göre bir başka model oluşturuldu. CNN modelindeki hiper parametrelerde değişiklikler yapılarak hastalığın tespiti için ağın eğitimi gerçekleştirildi. Eğitilen CNN modeline eğitimde kullanılmayan test görüntüleri modele verildiğinde %92,99 oranında bir doğruluk oranı elde edildi. Kullanılan veri setindeki tüm görüntüler üzerinde görüntü ön işleme (arka plan gürültü kaldırma) uygulandıktan sonra CNN modeli ile eğitim işlemi tekrar yapıldı. Eğitilen bu modelin test sonuçları incelendiğinde, %95,66'lık bir doğruluk oranına ulaşılmıştır.

Tarım alanlarındaki sebze, meyve veya bu alanda bulunan bitkilerin mahsul durumu, canlılığı veya hastalığının olup olmadığı NDVI verilerinin analizi ile tespit edilebilmektedir. Tarım alanlardaki NDVI haritalarını çıkarmak için Lansat-8 gibi uydu görüntülerinde bulunan yakın kızıl ötesi (NIR: Near-infrared) sensörlerin ya da multispektral kameralardan yararlanılmaktadır. Bu iki yöntemin yüksek maliyetleri, hava şartlarına bağımlı olmaları ve görüntülere erişim zorluğu gibi problemleri bulunmaktadır. Bu tez çalışmasında, bu problemlere çözüm ve alternatif olmak üzere ucuz maliyetli RGB kameralar ile NDVI değerini tahmin etmek için yeni bir bitki indeksi olarak sinir ağı temelli NDVI (Neural network based – NDVI: nNDVI) sunulmuştur. Önerilen bu yöntem için gerekli olan multispektral görüntü veri seti Wingtra web sayfasında bulunan İsviçre'deki bir tarım alanından ve Togo'daki bir çiftlikten alınmıştır. Bu veri seti kullanılarak eğitilen çok katmanlı algılayıcı (MLP: Multi Layer Perceptron) modelin test başarı oranı %92,013 olarak elde edilmiştir.

Bu tez çalışmasında son olarak MLP modeli ile RGB verileri NDVI değerlerine dönüştürülerek, derin öğrenme modeli (CNN) nNDVI değerleri ile tekrar eğitilmiş ve test edilmiştir. Bu işlem için çeltik bitkisine ait tüm RGB görüntüleri Matlab GUI ile geliştirilen arayüz ile nNDVI değerlerine dönüştürülmüştür. nNDVI verileri ile eğitim işlemi yapılan modelin test doğruluk oranı %96,97 olarak elde edilmiştir. Elde edilen bu doğruluk oranının RGB görüntüler ile elde edilen doğruluk oranından daha yüksek olduğu görülmüştür.

Bu tez çalışması kapsamında, çeltik bitkisi hastalık tespit sistemine ait yapılan çalışmaların genel yapısı Şekil 1.2'de gösterilmiştir.



Şekil 1. 2. Tezin genel yapısı

1.2. Tezin amacı

Bu tez çalışmasının amacı, ülkemiz çeltik alanlarında sorun oluşturan, arazi şartları (su içerisinde olması) ve çok geniş alanlarda ekimi sebebiyle erken teşhisi ve mücadelesinde zorluklar yaşanan çeltik hastalıklarının yapay zekâ ve hassas tarım yaklaşımlarıyla tespitidir.

Bu tez kapsamında ana hedef çeltik hastalıklarında oluşan semptomları, yapay zekâ uygulamaları ile multispektral görüntüler kullanılarak tespit etmektir. Tez çalışması sonucunda oluşacak bir ticarileşme modeli ile çeltik üretiminde verimliliğin artacağı ve böylece ülke ekonomisine katkıda bulunulacağı düşünülmektedir.

Bu çalışma hedefine ulaştığında, çeltik hastalıklarının ilk çıkış noktaları erkenden tespit edilerek o bölgelerde noktasal mücadele yapılabilir. Böylece çeltik ekili alanlarda çeltik hastalıklarına yönelik kullanılan pestisit miktarı konumsal bazlı ilaçlama yoluyla azaltılabilecektir. Böylece hastalığın yayılmasının önlenmesi ile doğal denge, insan ve çevreye daha az zarar verilmesi sağlanacaktır. Ayrıca, hedeflenen bu yöntem daha sonra ilgili alanlara göre değiştirilerek tarımda diğer kültür bitkileri ve hastalıklar içinde kullanılabilir. Bu hedeflerin çalışma sonunda bir prototip ile yapılabilir olduğunun belirlenmesi, bu konunun ticarileşebilir ve tüm Türkiye’de uygulanabilir olabileceğine dayanak olacaktır.

1.3. Tezin katkıları

Dünyada ve ülkemizde olduğu gibi çeltik önemli bir besin kaynağı olarak tüketilmektedir. Günümüzde bu besin kaynağının verimini düşürecek hastalıkların önüne geçmek için yapılan önemli çalışmalar mevcuttur. Bu tez kapsamında bu alandaki çalışmalara yenilik ve literatüre katkıda bulunulmuştur. Bu bağlamda tezin sunduğu katkılar aşağıda anlatılmıştır:

- Çeltik bitkisine ait hastalıklar ve belirtileri, en çok rastlanan hastalıkları ve veri setine ek kaynaklar sunulmuştur.
- Çeltik bitkisinde elde edilen görüntülerden daha başarılı sonuçlar elde etmek için veri artırımı yöntemleri ile mevcut veri seti daha da genişletilmiştir.
- Bir derin öğrenme modeli (CNN) ile çeltik bitkisine ait ikili (Hastalıklı, Sağlıklı) ve dörtlü (Sağlıklı, Brown Spot, Hispa ve Leaf Blast hastalıkları) sınıflandırma ile hastalık tespiti yapılmış ve sonuçları tartışılmıştır.
- NDVI görüntülerin elde edilmesinde kullanılan uzaktan algılama yöntemleri ve multispektral kamera sistemlerinin maliyetlerinin yüksek olmasından dolayı tez kapsamında daha ucuz ve alternatif bir yöntem geliştirilmiştir. Bu pahalı çözümlerin yerine standart RGB görüntü veren kamera sistemlerinden NDVI değerini bulmak için literatüre yeni bir yöntem eklenmiştir. Çok katmanlı algılayıcı (MLP) modele verilen RGB görüntülerinden NDVI tahmin değerleri (nNDVI) elde edilmiştir. Modelde kullanılan veri seti İsviçre ve Togo'dan alınan multispektral görüntüler ile oluşturulmuştur. Önerilen bu yöntem (nNDVI) değerleri ile gerçek NDVI değerleri kıyaslandığında %92,013 oranında başarı elde edilmiştir.
- Önerilen bu yöntem ile çeltik bitkisine ait hastalıkların erken tespiti için daha az maliyetli kamera sistemleri kullanılabileceği gösterilmiştir. Mevcut veri setindeki tüm görüntüler RGB'den NDVI verilerine dönüştürülmüştür. Bu veri seti ile CNN modeli eğitilmiş ve elde edilen sonuçlara göre başarı oranı %96,97 olarak elde edilmiştir. Aynı CNN modeline verilen nNDVI verilerinin RGB verilerine göre daha başarılı sınıflandırma sonuçlarına yol açtığı görülmüştür.

2. LİTERATÜR TARAMASI

Bu bölümde tez konusuna gerekçe olan çeltik bitkisi hastalığının tespitini sağlamak için yapılan çalışmalar incelenmiştir. Bu bağlamda yapılan literatür incelenmesi üç ana başlıkta ele alınmıştır. Birinci başlıkta çeltik bitkisine ait hastalıkların çeşitlerine ve ne gibi problemlere yol açtığına ait çalışma bilgileri verilmiştir. İkinci başlıkta bitki hastalıklarının tespiti için kullanılan yöntemlere ve bu yöntemlerin başarımlarına yer verilmiştir. Son başlıkta ise tarım alanında kullanılan multispektral kamera sistemleri ile elde edilen NDVI dönüşümleri ile hastalıkların tespitine yönelik literatür özeti sunulmuştur.

2.1. Çeltik bitkisine ait hastalıklar

Çeltik bitkisine ait hastalıklar arasında en yaygın olarak bakteriyel yaprak yanığı (Bacterial leaf blight), kahverengi leke (Brown Spot), yaprak isi (Leaf Smut), hispa, yaprak patlaması (Leaf Blast) ve kovan yanığı (Sheath) görülmekle birlikte bu tez kapsamında çeltik bitkisine ait bu hastalıklardan Brown Spot, Leaf Blast ve Hispa ele alınmıştır.

Brown Spot hastalığı *Sphaerulina oryzina* mantarı tarafından meydana gelmektedir. Yapraklarda ve üst yapraklarda yara şeklinde açık ile koyu kahverenginde, düz ve damara paralel şekilde ilerlemektedir. Genellikle 2–10 milimetre uzunluğunda ve 1-1.5 milimetre genişliğindedirler (Brown Spot, 2022). Leaf Blast hastalığı *Magnaporthe Oryza* mantarından kaynaklanan bir hastalıktır. Başlangıç aşamasında koyu yeşil sınırları olup daha sonra beyaz ile gri-yeşil lezyonlar veya lekeler şeklinde görünmektedirler (Blast, 2022). Çeltik Hispa hastalığı *Dicladispa armigera* böceğinin neden olduğu bir hastalık türüdür. Çeltik yaprağının üst yüzeyini aşındırıp orta damara paralel beyaz çizgiler meydana getirir. Yaprığın aşırı istilaya uğraması bitkinin yapraklarının kurummasına neden olmaktadır. (Crop Protection, 2022).

Bremer ve Özkan yaptıkları bir araştırmaya göre çeltik alanlarında rastlanılan hastalıklar içerisinde en yıkıcı olanının çeltik yanıklık hastalığı olduğunu bildirmişlerdir (Bremer ve Özkan, 1946). Fransa'da yapılan bir çalışmada ise; çeltik yanıklık hastalığının tohumla yayılmasının çok önemli olduğu vurgulanarak, *P. oryzae*'nin tohumun embriyosu dahil olmak üzere hem içinde hem de çeltiği saran başaklar arasında yoğun olarak bulunabildiği belirtilmiştir. Fransa'da sıcaklığın etkisi ile çeltik yanıklık hastalığının bir sonraki yıla geçişinde; tohum, bitki atıkları ve yabancı otların büyük önemi olduğu belirtilmiştir (Bernaux, 1966).

Dünya genelinde hastalıklara dayanıklı ve verimi yüksek 130 binden fazla çeltik çeşidinin olduğu bilinmektedir. Ülkemizde ise yoğun olarak ekimi yapılan Baldo ve Osmancık çeşitlerinin hastalıklara daha açık hale gelmesiyle birlikte verim ve kalitede ciddi düşüşler yaşandığından dolayı Cameo, Ronaldo, Efe ve Galileo gibi verimi yüksek çeltik çeşitlerinin ekiminin yoğunlaştığı bildirilmiştir. Çeltik tarımında sıcaklık ve yağışın önemli olduğu, özellikle erken ekimlerde ilkbahar mevsiminin geç donları ve ani sıcaklık düşüşlerinin tohum ve fidelerin bozulmasına yol açtığı belirtilmiştir. Ekimlerde geç vakite kalındığı zaman veya 2. ürün çeltik ekimlerinde ise hasadın gecikmesinden dolayı yağmurların yatan çeltiklerde çimlenmeye neden olması ve randıman değerlerinde ciddi düşüşler yaşandığı bildirilmiştir. Güney Marmara bölgesinde çeltik ekimleri, sıcaklığın 12°C'nin altına düşmediği zamanlarda yani mayıs ayı içerisinde yapılmaktadır (Sürek, 2002).

Güney Marmara bölgesinde *P. oryzae*'nin Osmancık ve Baldo çeltik çeşitlerinin fide, sapa kalkma ve olgunlaşma dönemlerinde hastalığa dayanıklılığı araştırılmıştır. Sonuç olarak, hastalık Baldo çeşidinde daha fazla görülmüş, fide döneminde hastalık her iki çeşitte de görülmemiş, sapa kalkma devresi ve olgunlaşma devrelerinde her iki çeşitte de hastalık görülmüştür. Ayrıca hastalığın çeltik ekimi yapılan her yerde görüldüğü ve önemli verim kaybına yol açtığı da belirtilmiştir (Elmacı, 2012).

Çukurova bölgesi çeltik ekim alanlarında sorun olan çeltik yanıklığı hastalığı etmeninin koloni gelişimi ve spor yoğunluğu üzerine sıcaklık ve yaprak ıslaklık süresinin etkisi araştırılmış. Etmenin uygun sıcaklık değeri 28°C de hastalık oluşumu için 4 saatlik yaprak ıslaklık süresini yeterli bulunmuştur (Akçalı, 2014).

Yapılan bir çalışmada; pirincin 3 milyardan fazla insanın beslenme kaynağı olduğu vurgulanmaktadır. Sürekli büyümekte olan küresel nüfusun beslenme ihtiyacını karşılamak için önümüzdeki yıllarda verimliliğin artırılması gerektiği belirtilmektedir. Buna karşın yıllık pirinç hasadının %10-30'unun *Magnaporthe oryzae*'nin enfeksiyonu nedeniyle kaybedildiği belirtilmektedir. Çeltikte yanıklığa sebep olan *M. oryzae* türüne özgü genetik yapının belirlenerek, dirençli türlere karşı, geniş spektrumlu fungus ilaçlarının bitki savunma aktivatörlerini tetikleyerek, yanıklık hastalığının kontrol edilebileceğini bildirilmiştir. Ayrıca yanıklık hastalığına karşı, genetiği değiştirilmiş çeltik çeşitlerinin hastalıkla mücadele konusunda önemli olduğu belirtilmiştir (Skamonti ve Gurr, 2009).

Yapılan bir çalışmada; *M. oryzae*'nin klonal (kendi genetiğini taşıyan başka hücreler üretmesi) yapısının çeşitli ülkelerde gözlemlendiği belirtilmiştir. Ayrıca bu bilginin yanıklık hastalığının dağılım stratejilerini saptamak, dünyada yeni ölümcül ırkların nasıl ortaya çıktığını

ve nasıl yayılabileceğini belirlemek için kullanılmaktadır. Yapılan çalışmalar neticesinde, üç büyük genetik grup gözlenmiştir. *M. oryzae*'nin doğal salgınlarında sporların 1-5 m gibi mesafelere yayıldığı belirtilerek, çeltik yanıklık etmeni sporların uzun mesafeli göçlerinde ise, enfekte olmuş tohumların taşınması sonucu ortaya çıktığı belirtilmiştir (Tharreau vd., 2009).

Kim ve Yoshino, çeltik yanıklık etmeni *Pyricularia oryzae* tarafından doğal olarak enfeksiyona uğramış yapraklardaki lezyon üzerinde gerçekleşen sporlasyon yoğunluğunun belirlenmesi konusunda bir çalışma yapmışlardır. Sonuçta, yaprakta ilk enfeksiyonun fark edilmesinden itibaren 9 gün boyunca yapraklardaki en büyük yaprak lezyon büyüklüğünün 14.8 mm ve en yüksek spor miktarının $1,2 \times 10^4$ konidi/ml olduğu kaydedilmiştir. Ayrıca yaprak yüzeyinin üstünde oluşan spor miktarının, çoğu zaman aynı lezyonun alt yüzeyinden on kat fazla olduğunu ve toplam spor miktarının %1-12'sinin etrafa salındığını belirtmişlerdir (Kim ve Yoshino, 1994).

Kato, çeltik bitkisinde dünya çapında çok önemli bir hastalık olarak kabul edilen yanıklık (*Magnaporthe grisea*) hastalığının, bitkinin kökü hariç yaprak, boğum, yaka sapı, başak sapı ve salkım gibi tüm organlarında enfeksiyon sonucu lezyonlara neden olabileceğini bildirmiştir. Aynı araştırmacı, hastalığın döngüsünün sporun enfeksiyonu ile başladığını ve tekrar spor verince sona erdiğini ve yaklaşık 20 gün içinde birçok yeni sporun etrafa yayıldığını ifade etmiştir. Bununla birlikte patojenin, yaprak yüzeyinde uzun süreli ıslaklık, yüksek oransal nem, 12/32°C arası gündüz ve gece sıcaklığındaki düşük rüzgar hızı veya rüzgarın olmayışı gibi uygun koşullarda enfeksiyon döngüsünü devam ettireceği ileri sürülmüştür (Kato, 2001).

Jiahao ve arkadaşları, Çin'in Jianou ve Pucheng bölgelerinde erken dönemde çeltik salkım yanıklığının meydana gelmesinde meteorolojik faktörlerin etkisini araştırmışlardır. Buna göre; Pucheng bölgesinde patojenin hastalık oluşumuna etkisinin, Mayıs ayının ortasındaki on günlük atmosferik basınç ve Mart ayının ortasındaki on günlük güneşlenmeden, Jianou Bölgesi'nde ise Mart ayının ortasındaki on günlük oransal nem ve Nisan'ın ortasındaki on günlük çişli günlerden kaynaklandığını belirlemişlerdir (Jiahao vd. 2005).


2.2. Bitki hastalıklarının tespitinde kullanılan yöntemler

Derin öğrenme teknikleri, günümüzde tarım alanlarındaki hastalıkların tespitinde umut vadetmektedir. Son yıllarda bu teknikler çay, elma, domates, asma, şeftali, armut ve buğday hastalıklarını analiz etmek için kullanılmıştır (ChandraKarmokar vd., 2015; Wang vd., 2017; Fuentes vd., 2017; Sladojevic vd., 2016; Lu vd., 2017). Literatürde bitki hastalıklarının tespitine

yönelik yapılmış olan çok fazla sayıda çalışmaya rastlamak mümkündür. Bunlardan bazılarında aşağıda yer verilmektedir:

Çeltik bitkisine ait dört hastalığı (Brown Spot, Leaf Blast, Rice Sheath ve Bacterial Blight) Minimum Mesafe Sınıflandırıcısı (MDC: Minimum Distance Classifier) ve k-En Yakın Komşu sınıflandırıcısı ile tespit edilip ve sırasıyla %87,02, %89,23 olarak başarımları elde edilmiştir (Joshi ve Jadhav, 2016).

Brodbeck ve arkadaşlarının çalışmasında, soya fasulyesi hastalık tanımada DJI Phantom 3 adında bir İHA modeli kullanılmıştır (Brodbeck vd., 2017). Kullandıkları kamera görüntü çözünürlüğü İHA'yı 1 ile 2 metre yükseklikte hastalığı tespit edebildikleri görülmüştür. Daha yüksek çözünürlüklü bir kamera kullanılması durumunda bu yüksekliğin artırılacağı gözlemlenmiştir. Soya fasulyesinin yapraklarının tespiti için Basit Doğrusal Yinelemeli Kümeleme (SLIC: Simple Linear Iterative Clustering) yöntemini kullanılmış. Bu yöntem çeltik bitkisinin yaprağının tespitinde de kullanılabilir.



Şekil 2. 1. İHA görüntüleri ile soya fasulyesi yaprak hastalıklarını tanımlamak için önerilen bilgisayar görme sistemi. (a) Görüntü edinimi. (b) SLIC segmentasyonu. (c) Resim veri seti. (d) Özellik çıkarma. (e) Görüntü hastalığı sınıflandırması

Kaynak: (Brodbeck vd., 2017)

Brodbeck ve arkadaşlarının önerdiği sistemin şeması Şekil 2.1’de verilmiştir. Beş adımdan oluşan bu sistemde, ilk olarak İHA ile görüntüler elde edilmiştir. Görüntüyü alan kameranın çözünürlüğüne göre İHA’nın yerden yüksekliği ayarlanmış ve soya yapraklarının tespiti için SLIC süper piksel yöntemi kullanılmıştır. Görüntünün SLIC süper piksel yöntemi ile bölümlendirilmesinden sonra, bu sistemin eğitilmesi ve test edilmesi için soya fasulyesine ait görüntü veri setinin oluşturulması gerekmiştir. Bu veri seti bir tarım uzmanı tarafından hedef nokta (target spot), külleme (powdery mildew) ve sağlıklı bitki olarak üç sınıfta etiketlenmiştir. Daha sonra, görüntülerin renk, gradyan, doku ve şekillerine ait özellikler çıkarılmıştır. Son adımda ise hastalığı sınıflandırmak için denetimli öğrenme yöntemlerinden sıralı minimal optimizasyon (SMO), Adaboost, J48 algoritmasını kullanan karar ağaçları, K-en yakın komşu (k-NN), rasgele orman (Random Forest) algoritmaları ve Naive Bayes sınıflandırıcısı kullanılmıştır.

Ramesh ve Vydeki çeltik bitkisine ait hastalıkların (Brown spot, Bacterial blight, Leaf blast ve Sheath rot) tespiti için optimize edilmiş derin sinir ağları ile Jaya algoritmasını kullanmışlar. Bu yöntemi uygulamadan önce görüntülerdeki arka planını kaldırmak ve hastalıklı ile hastaliksız bitki görüntüsünü ayırmak için RGB renk uzayını HSV (Hue, Saturation, Value) renk uzayına dönüştürülmüştür. Önerilen bu yöntemde toplam 650 çeltik bitkisi yaprak görüntü kullanılarak %94.25 oranında doğruluk elde edilmiştir (Ramesh ve Vydeki, 2020).

Bhagawati ve arkadaşları çeltik patlaması hastalığını tahmin etmek için sıcaklık, bağıl nem, yağış ve rüzgâr hızı gibi hava parametreleriyle bir sinir ağını eğitmişlerdir (Bhagawati vd., 2015). Mohanty ve arkadaşları 26 farklı hastalığı temsil eden 14 bitki türünün (elma, yaban mersini, kiraz, mısır, üzüm, şeftali, dolmalık biber, patates, ahududu, soya fasulyesi, narenciye, kabak, çilek ve domates) 54.306 tane görüntüsünü kullanarak yapraklardan hastalığı tespit etmek için derin CNN modeli kullanırken, Sladojevic ve arkadaşları da 5 bitki türünde (armut, kiraz, şeftali, elma ve asma) 13 farklı bitki hastalık türünü tanımak için CaffeNet modelini kullanmıştır (Mohanty vd., 2016; Sladojevic vd., 2016).

2011 yılından itibaren literatürde son teknoloji makine ve derin öğrenme tabanlı sınıflandırma yöntemleri etkisini göstermeye başlamıştır. Özellikle AlexNet ve daha sonrasında bu yönde benzer yaklaşımlarla geliştirilen VGGNet, GoogleNet- Inception, ResNet, vb. derin öğrenme bazlı modellerin sistem performansı bağlamında birçok farklı kullanım alanında diğer kullanılan klasik algoritmalara nazaran çok daha iyi sonuçlar verdiği gösterilmiştir (Krizhevsky vd., 2017; Simonyan ve Zisserman, 2014; Szegedy vd., 2016; He, 2016).

Kerkech ve arkadaşları çalışmasında üzüm bitkisi yaprakları üzerinde oluşan hastalıkların tespitinde CNN bazlı yöntemleri bazı bitki endekslerini kullanarak test etmişler (Kerkech vd., 2018). Benzer bir çalışmada salatalık bitkisi yaprakları üzerinde oluşan hastalıkların tespitinde yapılmıştır (Ma vd., 2018). Lu ve arkadaşları yayınladıkları çalışmada ise on çeşit çeltik bitkisi hastalığı (rice blast, false smut, Brown spot, rice bakanae, sheath blight, sheath rot, bacterial leaf blight, bacterial sheath rot, seeding blight ve bacterial wilt) üzerinde çalışmışlardır (Lu vd., 2017). Elde ettikleri sonuç geleneksel yöntemlere göre daha iyi olmakla beraber kullandıkları 500 çeltik görüntüsünün CNN tabanlı modellerin eğitimi için yeterli veri seti olmadığı düşünülmektedir. Bu bağlamda, Lu ve arkadaşlarının çalışmasının üzerine yapılabilecek araştırmaların ucunun açık olduğu söylenebilir. Prajapati ve arkadaşları, çeltik bitkisine ait üç farklı hastalığı tespit etmek için görüntü işleme yöntemi ve Destek Vektör Makinesi (SVM: Support Vector Machine) kullanarak %73,33 doğruluk oranı elde etti (Prajapati vd., 2017). Rahman ve arkadaşları CNN ile çeltik bitkisinin hastalığını %93,3 doğruluk oranında tespit etti (Rahman vd., 2020).

DeChant ve arkadaşları, mısır bitkisinde sıklıkla bulunan kuzey yaprak yanığı hastalığını otomatik olarak tanımlayan bir CNN modeli önermişlerdir. Önerdikleri bu model sayesinde mısır bitkisinde bulunan bu hastalığı %96,7 oranında bir doğruluk ile tespit etmişler (DeChant vd., 2017). Liu ve arkadaşları, elma meyvesine ait dört hastalığı tespit etmek için AlexNet ve GoogLeNet ağlarını birleştiren bir CNN modeli oluşturdu (Liu vd., 2017). Çeltik bitkisine ait on hastalığı sınıflandırmak için 500 çeltik bitkisi görüntüsü kullanarak LeNet-5 ve AlexNet gibi derin öğrenme modellerinden esinlenerek basit bir CNN modeli kullanarak %95,48 oranında bir doğruluk elde etmişlerdir (Lu vd., 2017). Atole ve Park ise, AlexNet ile 227 görüntü kullanarak normal çeltik bitkisi, hastalıklı çeltik bitkisi ve salyangoz istilasına uğramış çeltik bitkisi olmak üzere üç sınıf arasında bir sınıflandırma yapmıştır (Atole ve Park, 2018).

Çok güncel yayın tarihli bu çalışmalardan da anlaşılacağı üzere bitki hastalıklarının yapay zekâ uygulamaları ile tespiti aktif çalışma alanıdır.

2.3. Tarım alanında kullanılan multispektral kamera sistemleri


Bilgisayarlı görü, endüstride geniş çapta uygulanmaktadır. Endüstride otomatik muayene ve analiz, rehberlik, süreç kontrolü, miktar ölçümü ve kalite kontrolü gibi işlemlerde kullanılmaktadır. Hassas tarımda da, bilgisayarlı görü yaygın olarak kullanılmaktadır. Meyve tespiti, bitki teşhisi, beslenme ölçümü, varsayılan tespit, hastalık tespiti, gıda kalite kontrolü, zirai araç rehberliği ve verim haritalaması gibi işlemlerde bilgisayar görüşü konusu kapsamında

incelenmektedir. Dijital renkli görüntü işleme ve multispektral görüntüleme, bu işlemleri yerine getirmenin iki yaygın yoludur. Multispektral görüntüleme görünür bölge (VIS), kızıl ötesi (IR) ve ultraviyole (UV) bölgelerinden birden fazla dalga boyundan görüntü alabilir. Alınan bu görüntüler daha sonra uygun yazılımlar ile işlenerek görüntü elde edilir.

İnsan gözünün algılayabildiği spektral bölge aralığı 400-700 nm'dir. Bu aralık dışında kalan bölgeleride algılayan sistemlere multispektral görüntüleme olarak tanımlanmaktadır. Multispektral görüntüleme ile görünür bölge ve yakın kızılötesi spektral bölgelerin detaylı görüntülemesi sağlanmaktadır. Elde edilen multispektral görüntüler ile birçok farklı alanlara yönelik analizler gerçekleştirilmektedir. Multispektral görüntüleme ile çeşitli kimyasal maddelerin tespiti ve bitkilerin sağlıklı durumunun erken tespiti yapılabilmektedir. Multispektral görüntülemenin tarımsal ürünlerdeki kullanım alanları üzerine yapılan birçok çalışma bulunmaktadır. Bunlardan bazıları aşağıda verilmektedir:

Spektral aralığı 350 ila 2500 nm arasında değişen kolza tohumu çeşitlerinin VIS/NIR spektroskopisi ile elde edilmiş ve kümeleme analizini gerçekleştirmek için temel bileşen analizi (PCA) uygulanmıştır (Zou vd., 2011). Greyfurt kabuğundaki sınıflandırılmış narenciye kabı ve diğer hastalıklar, görünür ve NIR aralıkları ve tüm spektrumdan seçilen önemli 20 bant ile diskriminant analizi uygulayarak %100 doğruluk oranında sınıflandırma başarısı elde edilmiştir (Balasundaram vd., 2009). *B. oryzae* ile enfekte olmuş çeltik bitkisi kahverengi lekesinin 692 nm ile 732 nm arasında yansıma aralığında, duyarlık analizi ve türev tekniği kullanarak hastalık şiddetini değerlendirmiştir (Liu vd., 2008). Bu çalışmalardan da anlaşılacağı üzere spektral analizin bahsedilen görüntü tanıma tabanlı yapay zekâ algoritmaları kullanılarak hassas tarım uygulamalarında kullanılabilir olduğu anlamı çıkarılabilmektedir.

Wen ve Tao kurala dayalı kızılötesi makineye yakın görme yöntemi kullanarak elma için hata incelemesi gerçekleştirmiştir (Wen ve Tao, 1999). Lu, yakın kızılötesi multispektral görüntüleme ve spektral görüntüleme ile elma morluklarını ve çözülebilir katı içeriği tahminini araştırdı. Tahmin için kritik dalga boylarını elde ettiler (Lu, 2004). Şekil 2.2'de şematik olarak gösterilen bu araştırma için multispektral bir görüntüleme sistemi kurulmuştur.




Şekil 2. 2. Elma meyvesinden gelen ışık saçılma profillerini ölçmek için multispektral bir görüntüleme sisteminin şeması


Kaynak:(Lu, 2004).

Olgunlaşmamış yeşil turunçgil meyvesi ve Huanglongbing (HLB, aynı zamanda turunçgil yeşili olarak da bilinir) hastalığı, Kane ve Lee tarafından spektral görüntüleme kullanılarak tespit edildi (Kane ve Lee, 2007). Bu çalışmalarından (2.1) denkleminde gösterilen indeksi kullanmıştır. Denkleminde belirtilen indekste üç bant dalga boyu b_{1064} , b_{1150} ve b_{1572} olarak verilmiştir. Kullanılan indeksten sonra 2 boyutlu bir görüntü elde edilmiştir. Bu görüntü histogram gerilme ve yumuşatma işlemlerinden sonra Matlab programında bulunan Otsu fonksiyonu ile siyah beyaza dönüştürülmüş. Son olarak bu görüntü 8 piksel büyüklüğündeki bir disk (gürültü giderme yöntemi) kullanılarak gürültüler temizlenmiştir. Bu sürecin çıktıları Şekil 2.3’de gösterilmiştir.


$$B = \left(\frac{b_{1064}}{b_{1150}} \right) - \left(\frac{b_{1572}}{b_{1150}} \right) \quad (2.1)$$




A




B



C



D



E

Şekil 2. 3. 1064, 1150 ve 1572 band dalga boyundaki 3 resim sırayla gösterimi (A). Görüntünün histogram gerilmesi (histogram stretch), yumuşatılması (smoothing) ve NDVI değerinin hesaplanmasından sonraki hali (B). Histogram gerilmesini üst sınır eşiğinin uygulanmasından sonra (C). Otsu yöntemi kullanıldıktan sonraki hali (D). 8 boyutlu 'disk' ten sonraki nihai sonuç (E).

Kaynak: (Kane ve Lee, 2007).

Dash ve arkadaşlarının çalışmasında, İHA'lara entegre edilen multispektral kameralar ile; ormanda bulunan ağaçların fizyolojik stres durumlarının erken tespiti yapılmıştır (Dash vd., 2017). Ampatzidis ve Partel, multispektral kameraya sahip İHA'lar ile yapay zekâ ve makine öğrenmesi yöntemlerini kullanarak ağaçların türünü, ağaçlar arasındaki mesafeleri ve bireysel ağaç sağlık durumunu tespit edebilmişler (Ampatzidis ve Partel, 2019).

Mahdianpari ve arkadaşları multispektral görüntüler kullanarak Kanada'da bulunan sulak alanların sınıflandırmasında derin öğrenme modelleri ile tespit etmişler. Sulak alanların

sınıflandırmasında InceptionV3, DenseNet121, VGG19, VGG16, Xception, ResNet50 ve InceptionResNetV2 adlı iyi bilinen derin öğrenme mimarileri kullanılmıştır (Mahdianpari vd., 2018).

Multispektral kameralar insansız hava araçlarına (İHA) entegre edilerek tarım arazilerinden farklı bitki indeksleri elde edilebilmektedir. Ancak İHA'ların uçuşları sırasında hava şartlarının (sis bulutlanma ve güneş ışığının yetersiz kalması vb.) etkisi ve elde edilen görüntülerde titreşimden dolayı istenmeyen bozulmalar meydana gelmektedir. Bu amaçla belirtilen probleme yönelik, Histogram Eşitlemesi (Pizer vd., 1987), Retinex algoritması (Tang vd., 2011) ve Gauss filtrelemesi (Deng ve Cahill, 1993) kullanılabilir. Bunların dışında İHA üzerinden elde edilecek verilerin İHA'nın çalışma esnasında yaydığı titreşim sebebiyle görüntü bozulmasına karşı Gaussçu Noktasal Dağılım Fonksiyonu (Point Spread Function - PSF) algoritmasının uygulanması gerekebilmektedir (Gibbins vd., 2004).

2.4. Bitki indeksleri ve RGB görüntülerden NDVI değeri tahminine yönelik çalışmalar

Spektroskopi son 20 yılda hassas tarımda çalışılmış ve kullanılmıştır (Sankaran vd., 2010). Araştırmacılar meyve, sebze, tarla bitkileri ve ette kalite ve miktar analizi için spektroskopi kullanmaktadır. Hassas tarım için multispektral analiz, hastalık tespiti, beslenme seviyesi analizi, mekanik hasar tespiti, verim tahmini ve gıda kalitesi analizini içermektedir. Spektrum veya bitki örtüsü indekslerinin tamamı belirli görevler için uygulanmıştır.

Sınıflandırma için birçok spektroskopi tabanlı çalışma, farklı bitki koşullarında (hastalıklı veya sağlıklı bitki) spektral yansımadaki değişimi değerlendirmek için farklı bitkisel indeksler kullanır. Bazı bitkisel indeksler Tablo 2.1'de özetlenmiştir.

Tablo 2. 1. Spektroskopik çalışmalarda hastalık tespitinde kullanılan bitkisel indeksler

Bitkisel İndeksler	Formül	Kaynak
Disease index (f_D) (specific for individual study)	$f_D = \frac{I_{550\text{ nm}}}{I_{550\text{ nm}} + I_{690\text{ nm}}}$	Moshou vd., (2005)
Normalized difference vegetation index (NDVI)	$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}$	(Yang ve Cheng, 2001), (Bravo vd., 2004), (Yang vd., 2007), (Naidu vd., 2009)
Green normalized difference vegetation index (Green NDVI)	$Green\ NDVI = \frac{R_{GREEN} - R_{RED}}{R_{GREEN} + R_{RED}}$	(Gitelson ve Merzlyak, 1998)
Normalized difference red edge index (NDRE)	$NDRE = \frac{R_{NIR} - R_{RedEdge}}{R_{NIR} + R_{RedEdge}}$	(Novotná vd., 2013)

Green ratio vegetation index (GRVI)	$GRVI = \frac{NIR}{GREEN}$	(Wu, 2014)
Water Band Index (IWB)	$I_{WB} = \frac{R_{950\text{ nm}}}{R_{900\text{ nm}}}$	(Xu vd., 2007)
Soil-adjusted vegetation index (SAVI)	$SAVI = \frac{(R_{NIR} - R_{RED})(1 + L)}{R_{NIR} + R_{RED} + L}$	(Yang vd., 2007)
Other indices	$(R_{NIR} - R_{RED}), \frac{R_{RED}}{R_{NIR}}, \frac{R_{GREEN}}{R_{RED}}, \frac{R_{NIR}}{R_{RED}}$	(Yang vd., 2007)
Photochemical reflectance index (PRI)	$PRI = \frac{R_{531\text{ nm}} - R_{570\text{ nm}}}{R_{531\text{ nm}} + R_{570\text{ nm}}}$	Huang ve Lu 2007), (Naidu vd., 2009)
Red-edge vegetation stress index (RVSI)	$RVSI = \frac{R_{714\text{ nm}} + R_{752\text{ nm}}}{2 - R_{733\text{ nm}}}$	(Naidu vd., 2009)
Modified chlorophyll (a and b) absorption in reflectance index (MCARI)	$MCARI = [(R_{700\text{ nm}} - R_{670\text{ nm}}) - 0.2(R_{700\text{ nm}} - R_{550\text{ nm}})] \times \frac{R_{700\text{ nm}}}{R_{670\text{ nm}}}$	(Naidu vd., 2009)
Visible atmospherically resistance index (VARI)	$VARI = \frac{R_{GREEN} - R_{RED}}{R_{GREEN} + R_{RED} - R_{BLUE}}$	(Naidu vd., 2009)
Water Index (WI)	$WI = \frac{R_{900\text{ nm}}}{R_{970\text{ nm}}}$	(Naidu vd., 2009)

Kaynak: (Sankaran vd., 2010).

Tabloda verilen bitkisel indeks formüllerinde kullanılan I, floresan yoğunluğu (Fluorescence intensity), R yansıtma (Reflectance) ve L yeşil bitki örtüsü miktarını veren bir kat sayıdır.

Bitkiler kırmızı ışığı emer ve çoğunlukla yakın kızılötesi (NIR) ışığı yansıtır. Böylece bitkileri toprak, su ve nesne gibi diğer malzemelerden ayırır (Rabatel vd., 2014). Bu özelliğe dayanarak, bitki sağlığını izlemek için kırmızı ve NIR yansımadaki değerler ile normalleştirilmiş farklılık bitki indeksi (NDVI) hesaplanır. 1970'lerden beri NDVI, uydu görüntülerindeki bitki örtüsünü ve diğer malzemeleri ayırt etmek için uzaktan algılamada yaygın olarak kullanılmaktadır (Sannier vd., 2002; Kumar vd., 2012). Genellikle NDVI, bitkilerin doğru kırmızı ve NIR yansımalarını yakalayan bir multispektral kamera veya hiperspektral kamera tarafından alınan görüntülerden elde edilir (Deng vd., 2018; Thenkabail vd., 2000; Wang vd., 2020a). Ancak multispektral ve hipersepektral kameralar ağır, pahalı ve görüntüleri elde etmek için profesyonel işlemler gerektirir (Li vd., 2014). Bu tez kapsamında çeltik bitkisi hastalığının erken tespitinde NDVI bitki indeksi kullanılacağı için aşağıda RGB görüntülerden NDVI değerinin tahmini ile ilgili çalışmalara yer verilmiştir.

Costa ve arkadaşları üç farklı üründe (citrus, grapes and sugarcane) genetik algoritma kullanarak RGB görüntüler ile NDVI tahmininde bulunmuşlar. Kullandıkları bu yöntem ile ortalama hata (MAE: Mean Average Error) 0,052 ve ortalama hata yüzdesi (MPE: Mean Percentage Error) %6,89 olarak elde edilmiştir (Costa vd., 2020). Rabatel ve arkadaşları NDVI

hesaplamak için gerekli olan NIR ve Red bantların içindeki yakın kızılötesi engelleme filtresi (near-infrared blocking filter) yerine düşük geçişli bir filtreyle değiştirmişler. Bu değişim sonucunda RGB tabanlı kamera ile NDVI elde edebildiklerini göstermişlerdir (Rabatel vd., 2011).

Wang ve arkadaşları NIR'e duyarlı bir sensörü Raspberry Pi tabanlı bir RGB görüntü veren kameraya entegre etmişler. Entegre edilen bu sensör multispektral kamera fiyatlarına göre çok daha uygun olduğu belirtilmiştir. Gerçek NDVI değeri ile önerdikleri yöntem ile buldukları NDVI değerlerini tahmin etmede yüksek performanslara ($R^2 = 0,96$, $RMSE = 0,0079$) ulaşmışlardır (Wang vd., 2020b).

Houborg ve arkadaşları Lansat-8 uydu görüntülerden NDVI ile Planet Labs'tan RGB görüntüleri alıp veri madenciliği yöntemlerinden biri olan Cubist regreasyonu kullanarak dönüşüm işlemi yaptılar. Bu yöntem ile R^2 değeri 0,97 olarak elde edilmiştir (Houborg ve McCabe, 2016). Arai ve arkadaşları NIR yansıması ile yeşil renk yansıması arasındaki yüksek bir korelasyon olduğunu bulmuş. Bu nedenle, görünür kamera verileriyle NIR yansımasını tahmin etmenin mümkün olacağı öne sürülmüştür. NDVI değerini elde etmek için NIR yerine yeşil yansıması kullanılmıştır (Arai vd., 2016).

3. EVRİŞİMLİ SİNİR AĞI İLE ÇELTİK BİTKİSİ HASTALIĞININ TESPİTİ

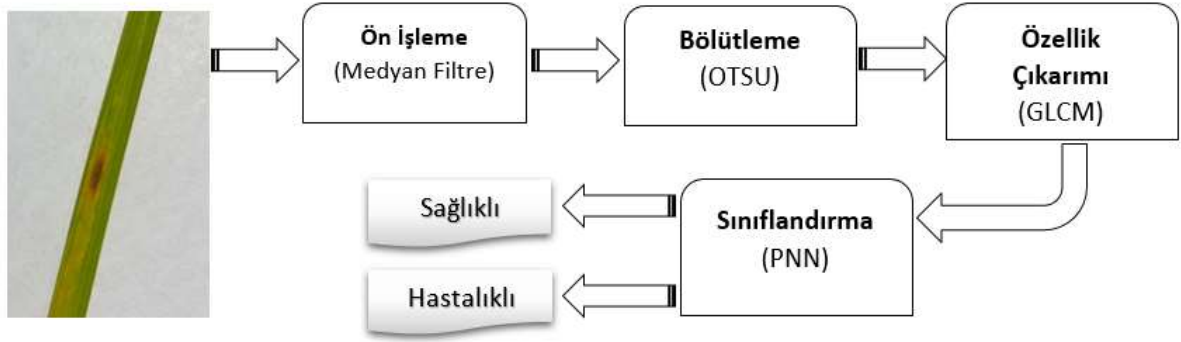
Bu tez kapsamında çeltik bitkisine ait hastalıkların tespiti için bu bölümde yöntemler, kullanılan derin öğrenme ve yapay sinir ağı modelleri, modellerdeki hiper-parametreler kullanılarak elde edilen sonuçlar ayrıntılı bir şekilde açıklanmıştır.

Tez çalışması kapsamında çeltik bitkisi hastalığının en uygun bir şekilde sınıflandırmak için farklı yöntemler denenmiştir. Bu denemelerden ilki geleneksel yöntemler ile görüntü ön işleme, bölütleme ve özellik çıkarımı işlemleri yapılmış. Daha sonra elde edilen özellikler Olasılıksal Sinir Ağına (PNN: Probabilistic Neural Network) verilip sınıflandırma işlemi gerçekleştirilmiştir. İkinci yöntem olarak bir evrişimli sinir ağı (CNN) modeli kullanılarak çeltik bitkisine ait hastalıklı ve sağlıklı olmak üzere ikili sınıflandırma işlemi yapılmıştır. Üçüncü yöntemde ise CNN modeli, parametreleri ve veri seti değiştirilerek dörtlü (Brown Spot, Hispa, Leaf Blast, Sağlıklı) bir sınıflandırma işlemi gerçekleştirilmiştir.

Çeltik bitkisine ait hastalıkların tespiti için görüntü işleme ve PNN kullanılmıştır. Görüntü işleme ve YSA tabanlı PNN modellerin ayrıntılı bir şekilde bu başlık altında verilmiştir. Daha sonra çeltik bitkisine ait hastalıkların tespitinde kullanılan derin öğrenme tabanlı CNN mimarisi ve kullanılan CNN modeli anlatılmıştır. Çeltik bitkisine ait görüntülerin elde edilmesi, görüntü verilerinin artırımı, modellerde kullanılan performans ölçütleri ve donanım-yazılım ortamlarından bahsedilmiştir.

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

Bu tez kapsamında görüntü işleme ve olasıksal yapay sinir ağı ile çeltik bitkisinin sağlık durumunu tespit edebilmek için önerilen sistem dört aşamadan oluşmaktadır. Birinci aşamada bitki görüntülerinin iyileştirmesi, yani gürültülerin (noise), bozukluklarının giderilmesi için görüntü üzerinde ön işleme yapılmaktadır. İkinci bölümde ise görüntü bölütleme (Otsu segmentasyon) yöntemi ile hastalıklı kısmın görüntüden çıkarılması sağlanmıştır. Üçüncü aşamada GLCM ile segmente edilmiş görüntüye ait özellikler çıkarılmıştır. Daha sonra son aşama olan sınıflandırmada Olasılıksal YSA modeli (PNN) kullanılmıştır. PNN modeline, çıkarılan özellikler verilerek çeltik bitkisinin hasta ya da sağlıklı olduğunu çıktı olarak kullanıcıya veren bitki hastalığını tespit eden bir sistem geliştirilmiştir (Ökten ve Yüzgeç, 2022a). Sisteme ait tüm aşamalar Şekil 3.1’de gösterilmiştir.



Şekil 3. 1. Görüntü işleme ve PNN modeli ile çeltik bitkisi hastalığını tespit aşamaları

3.1.1. Görüntü ön işleme

Yazılım ile kameradan alınan görüntülerin ilk haliyle yorumlanması zordur. Kamera ile alınan görüntülerde hava şartları, el titremesi, güneş açısı gibi durumlarda görüntü bozuklukları oluşmaktadır (Tan ve Jiang, 2019). Bu görüntülerdeki bozuklukları iyileştirmek veya azaltmak için çeşitli görüntü filtreleme yöntemleri kullanılmaktadır. Bu filtreleme yöntemlerinden genellikle medyan (median), keskinleştirme (unsharp), gürültü (imnoise), ortalama (average) veya düzleştirme (gaussian) filtreleri kullanılmaktadır.

Filtreleme işlemleri piksel değerlerinin değiştirilmesi sonucu elde edilen yeni piksel değerlerini temsil etmektedir. Görüntülerdeki gürültüleri (noise) temizlemek için uygulanan filtreler yardımıyla görüntülerin keskinleştirilmesi, renk düzeylerinin anlamlandırılması, bulanıklaştırılması ve parlaklığın artırılması gibi işlemler yapılır.

Bu aşamada bitki hastalığının tespiti için median filtreleme kullanılmıştır. Medyan filtreleme, seçilen piksellerin küçükten büyüğe doğru sıralamaya konulduğunda ortanca değerinin ortadaki değer ile değiştirme işlemidir. Şekil 3.2’de 3x3 piksel boyutunda bir medyan filtreleme örneği gösterilmiştir. Şekilde 3x3 boyutundaki matriste toplamda 9 piksel vardır. Bu pikseller küçükten büyüğe doğru sıralandığında ortanca değerin 160 olduğu görülmektedir. 3x3 boyutundaki matriste ise ortadaki değer olan 143’ün yerine ortanca değer olan 160 yazılmaktadır.


	120	150	178	201	141	
	183	140	123	175	101	
	215	180	143	160	134	
	210	201	170	104	133	
	113	109	103	120	197	

104
123
140
143
160
170
175
180
201

	120	150	178	201	141	
	183	140	123	175	101	
	215	180	160	160	134	
	210	201	170	104	133	
	113	109	103	120	197	

Şekil 3. 2. 3x3 medyan filtre uygulaması

Çeltik bitkisine ait tüm görüntüler öncelikle RGB den gri değerlere dönüştürülüp daha sonra 3x3 boyutunda Median filtre uygulanmıştır. Şekil 3.3'te çeltik görüntüsü ve median filtre uygulandıktan sonraki görüntü verilmiştir.



Şekil 3. 3. Medyan filtre uygulanan çeltik bitkisi yaprağı

3.1.2. Bölütleme (segmentasyon) işlemi

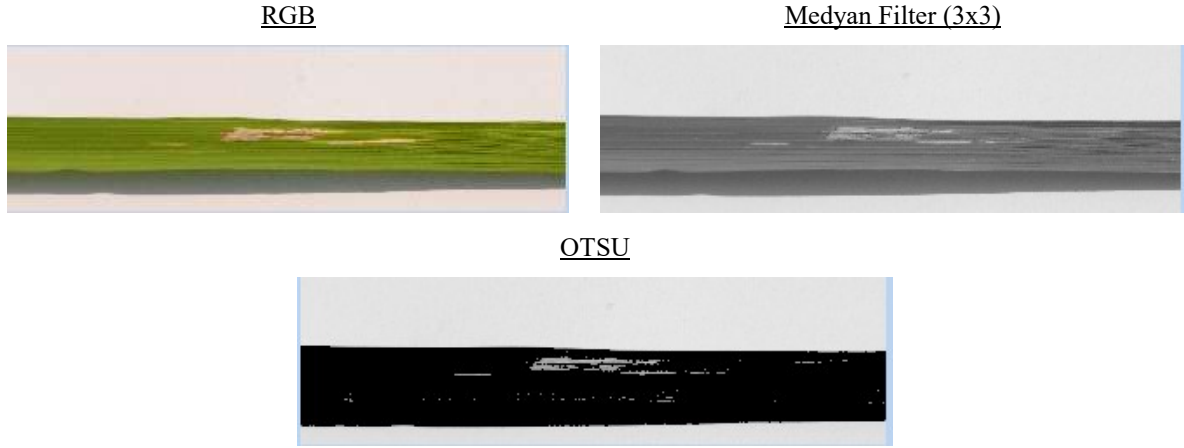
Bölütleme işlemi bitki yaprak görüntüleri içerisindeki hastalıklı kısımların belirginleştirilmesi için kullanılmaktadır. Görüntü işleme ve bilgisayarlı görmede otomatik bir şekilde görüntü eşiklemeyi yapmak için Nobuyuki OTSU tarafından bulunan OTSU metodu kullanılmaktadır (Sezgin ve Sankur, 2004). Bu aşamada görüntüleri bölütleme için OTSU metodu kullanılmıştır.

OTSU metodu, görüntülerdeki önemli kısımları daha anlaşılır bir şekilde ortaya çıkarmak için görüntüleri ikili görüntüye (binary image) (0 ya da 255) (siyah-beyaz) dönüştürmektedir. İkili görüntüyü elde etmek için gri seviyeli bir görüntü üzerinde 0-255 arasında seçilen bir eşik değeri seçilir. Aşağıdaki denklem 3.1'de belirtildiği gibi eşik (threshold) değerine göre ikili görüntüye dönüştürülür.

$$ikili_görüntü(x,y) = \begin{cases} eğer\ görüntü(x,y) < eşik_değeri & \rightarrow 0 \\ eğer\ görüntü(x,y) > eşik_değeri & \rightarrow 1 \end{cases} \quad (3.1)$$

Burada x ve y görüntü piksel koordinat değerlerini temsil etmektedir. Bu eşik değerini OTSU metodu, sınıf içi yoğunluk varyansını en aza indirerek veya sınıflar arası varyansı

maksimize ederek bulmaktadır (Otsu, 1979). Çeltik bitkisi yaprak görüntülerine görüntü ön işleme yapılırken görüntü gri seviyeye dönüştürülmüştür. Çeltik bitkisi görüntülerine görüntü ön işleme yöntemlerinden biri olan medyan filtresi uygulandıktan sonra OTSU bölütleme işlemi uygulanmıştır. Şekil 3.4’de bitkinin OTSU bölütleme işlemi uygulanmış hali gösterilmiştir.

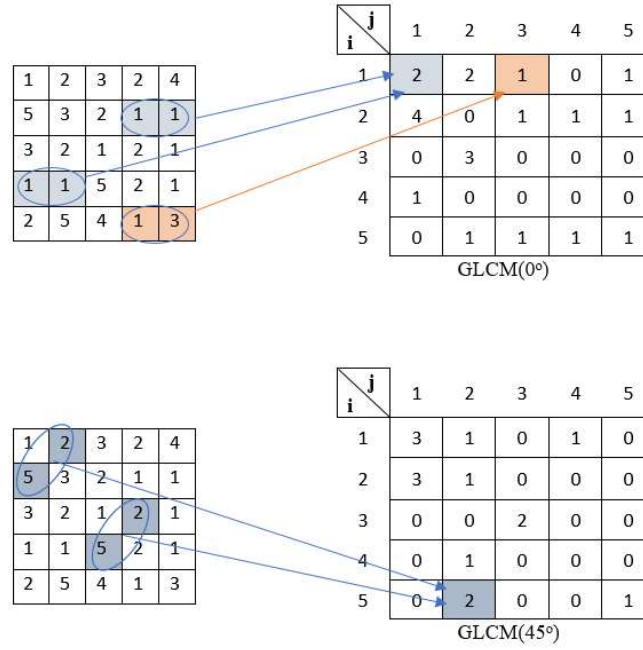


Şekil 3. 4. Çeltik bitkisi yaprak görüntüsüne OTSU metodu uygulanması

3.1.3. Özellik çıkarımı

GLCM, M. Haralick tarafından ortaya atılmış bir özellik çıkarma yöntemi olup, gri tonlu bir görüntünün özneliğini çıkarmaya yaramaktadır (Haralick, 1973). GLCM, iki komşu piksel arasındaki ilişkiyi tanımlar. Bu piksellerden birincisi referans pikseli, ikincisi de komşu piksel olarak bilinir. Matristeki dağılım, pikseller arasındaki mesafe ve açığa göre ayarlanır.

Pikseller arası uzaklığın yanı sıra, piksel çiftlerinin yönlerinin bilinmesine de gerek vardır. En çok ortak bilinen yönler $\theta=0, 45, 90, 135$ ve bunların simetrik benzerleridir. Şekil 3.5’te gri seviye sayısı 5, pikseller arası uzaklık $d=1$ ve yön açısı $\theta=0^\circ, 45^\circ$ olarak hesaplanmış bir eş-oluşum matrisinin örneği verilmiştir. Burada, görüntüdeki (1,1) ve (1,3) piksel çift sayıları yön açısı 0° olarak seçildiğinde GLCM matrisinde sırayla 2 ve 1 yazılmıştır. Görüntüdeki (5,2) piksel çift sayısı yön açısı 45° olarak seçildiğinde GLCM matrisinde sırasıyla 2 yazılmıştır. Bu işlemler diğer piksel çiftleri içinde hesaplanarak GLCM matrisi oluşturulur.



Şekil 3. 5. GLCM matrisinin hesaplanması örnekleri

Bitkinin yaprak dokusunu analiz etmek için doku analiz yöntemleri kullanılmaktadır. Bu yöntemler, piksel yoğunluğunun istatistiksel özniteliklerinin bir kümesini oluşturur. Farklı yerlerde bulunan iki farklı piksel arasındaki gri seviye farklılıkları karşılaştırılır. Farklı dokular, doku özellikleri ortaya çıkarılarak bulunabilir (Demirhan ve Güler, 2010). Bu çalışmadaki doku özellikleri GLCM kullanılarak çıkarılmıştır. Her bir görüntüye ait Korelasyon, Homojenlik, Enerji, Karşıtlık, Entropi gibi 20 adet doku özelliği çıkarılmıştır. Her bir görüntüden çıkarılan bu özellikler Tablo 3.1’de verilmiştir.

Tablo 3. 1. Her bir görüntüden çıkarılan 20 adet özellik

1. Enerji	6. Homojenlik	11. Toplam ortalama	16. Karelerin toplamı
2. Entropi	7. Korelasyon	12. Toplam varyans	17. Maksimum olasılık
3. Benzersizlik	8. Öz ilinti (Otomatik bağıntı)	13. Toplam Entropi	18. Maksimum korelasyon katsayısı
4. Kontrast	9. Küme gölgesi	14. Varyans farkı	19. Normalleştirilmiş ters farkı
5. Ters Farklılık	10. Küme Önemi	15. Entropi farkı	20. Normalleştirilmiş ters fark momenti


3.1.4. Sınıflandırma

PNN, Donald Specht tarafından geliştirilen olasılık yoğunluk tahmininin (probability density estimation-PDF) bir ağ formülasyonudur (Specht, 1990). Ayrıca PNN bir YSA modeli olup temel olarak Bayes yöntemini kullanmaktadır ve olasılıksal bir sınıflama işlemi

gerçekleştirmektedir. Sınıflara ait yoğunlukların hesaplaması için genellikle Parzen Yaklaşımı tercih edilmektedir. Denklem 3.2’de verilen formülde n eğitim için veri sayısını, m giriş uzayının boyutunu, i ise hangi örüntünün olduğunu göstermektedir. Denklemdeki σ , Gaussian fonksiyonunun hassasiyet kontrolünü sağlayan düzeltme parametresidir. x değeri, GLCM ile çıkarılan özelliklerdir.

$$F(x) = \frac{1}{2(\pi)^{\frac{m}{2}} \sigma^{mn}} \sum_{i=1}^n \exp \left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2} \right] \quad (3.2)$$

PNN yapısı giriş katmanı (Input layer), örüntü katmanı (Pattern layer), toplama katmanı (Summation layer) ve çıkış katmanından (Output layer) oluşmaktadır (Başçıl vd., 2012). Bu aşamada kullanılan modelin genel yapısı Şekil 3.6’da gösterilmektedir.



Şekil 3. 6. Kullanılan Olasılıksal Sinir Ağı yapısı

Bu PNN modeli için, GLCM ile özellik çıkarımı yapılmış olan çeltik bitkisi görüntüleri kullanılarak model eğitilerek çeltik bitki görüntülerinin sağlıklı mı yoksa hastalıklı mı olduğunu belirleyen iki çıkış alınmaktadır.

3.2. Veri seti

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 (Kaggle, 2020).

Kaggle internet sayfasında 1474 adet sağlıklı, 523 adet Brown Spot hastalığı, 565 adet Hispa hastalığı ve 779 adet Leaf Blast hastalığı olmak üzere toplamda 3341 çeltik bitkisi yaprak görüntüsü bulunmuştur. Bu veri setinde bulunan sınıflara ait örnek görüntüler Şekil 3.7’de gösterilmektedir.



Şekil 3. 7. Çeltik bitkisinin hastalıklı ve sağlıklı yaprak görüntüleri

Kaynak: (Kaggle, 2020)

3.3. Veri artırımı

Boyutu küçük olan veri setlerinde özellikle makine öğrenmesi modellerinin başarımını artırmak için verilerin çeşitli bozulma etkilerine maruz bırakılarak veri sayısı çoğaltılabilir. Bu şekilde modelin farklı koşulları öğrenmesi sağlanmaktadır.

- Görüntünün eksenlere göre simetriklerinin alınması,

- Rastgele görüntünün bir kısmının kesilip alınması,
- Eksenlerinin değiştirilmesi,
- Renk oranlarının değiştirilmesi,

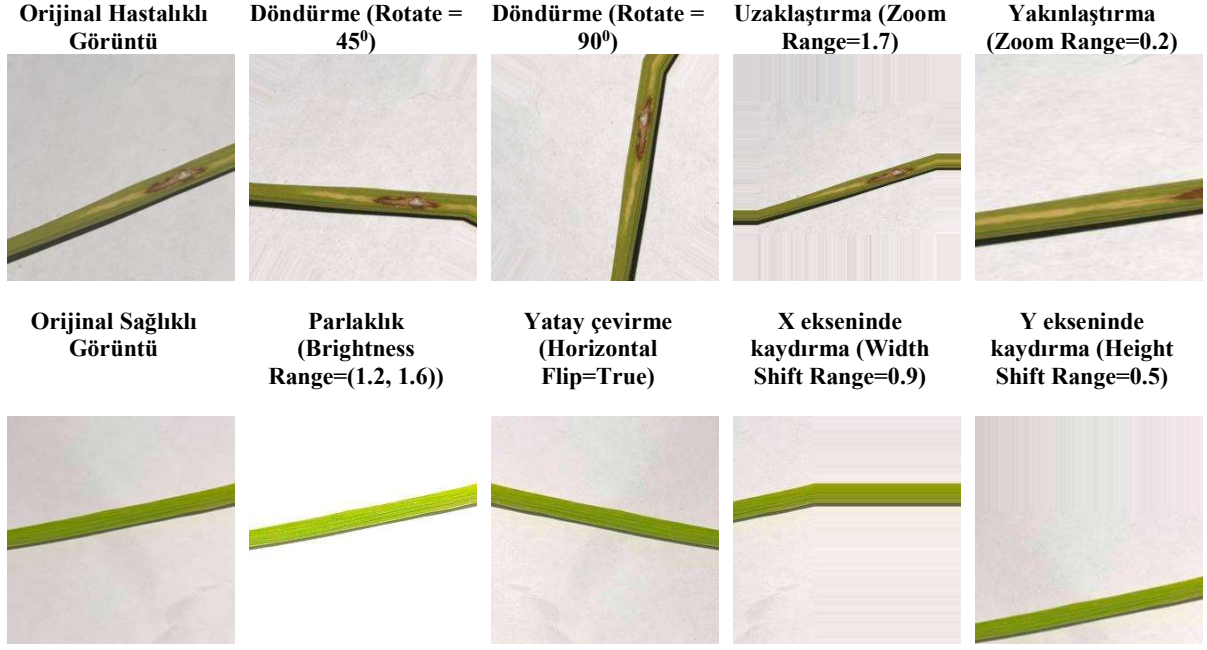
gibi birçok farklı şekilde veriden elde edilen yeni veri parçaları oluşturularak veri çoğaltma yapılabilir. Böylece model ezberleme (overfit) eğiliminden uzaklaşmaktadır. Bu çalışmada veri artırma yöntemi kullanılarak 3341 görüntüden 15000 görüntü oluşturulmuştur. Her sınıf için kullanılacak çeltik bitkisi yaprak görüntü sayısı, sınıflandırma adı ve veri artırımından sonraki görüntü sayısı Tablo 3.2'de özetlenmiştir.

Tablo 3. 2. Çeltik bitkisinin sınıf adları, veri sayısı ve veri artırımından sonraki veri sayısı

Sınıf adı	Veri sayısı	Veri artırımından sonraki veri sayısı
Brown Spot	523 (eğitim[418], test[105])	3750 (eğitim [3000], test[750])
Hispa	565 (eğitim [452], test[113])	3750 (eğitim [3000], test[750])
Leaf Blast	779 (eğitim [623], test[156])	3750 (eğitim [3000], test[750])
Sağlıklı	1474 (eğitim [1180], test[294])	3750 (eğitim [3000], test[750])
Toplam	3341 (eğitim [2673], test[668])	15000 (eğitim [12000], test[3000])

Veri setinde 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 işlemini gerçekleştirmek için *TensorFlow*'un apilerinden biri olan *Keras* kütüphanesinden *ImageDataGenerator* fonksiyondan yararlanılmıştır (TensorFlow, 2020).

Veri artırımından sonra elde edilen görüntüler ile ağız eğitimi ve test işlemi yapılmıştır. Şekil 3.8'de farklı veri artırma teknikleri ile elde edilen sağlıklı ve hastalıklı çeltik bitkisi yaprak görüntüleri gösterilmiştir.



Şekil 3. 8. Veri artırma yöntemi ile oluşturulan yeni çeltik bitkisi yaprak görüntüleri

3.4. Performans değerlendirme ölçütleri

Bu tez kapsamında çeltik bitkisi hastalığının tespiti için oluşturulan modellerden modellerin sınıflandırma başarımları, bu alandaki benzer çalışmalarla kıyaslamak ve bu yöntemlerin doğruluğunu göstermek için bazı ölçütler (Duyarlılık (Recall), Hassasiyet (Precision), Doğruluk (Accuracy) ve F1 ölçütü değerleri) kullanılmıştır. Makine öğrenimi alanında ve özellikle istatistiksel sınıflandırma probleminde, hata matrisi olarak da bilinen bir karmaşıklık matrisi, bir algoritmanın performansının görselleştirilmesine izin veren belirli bir tablo düzenidir (Stehman, 1997). Karmaşıklık matrisinden model başarımı için yukarıda verilen performans ölçütleri elde edilmektedir.

Tez kapsamında çeltik bitkisinin hastalığının tespitinde iki ayrı sınıflandırma yapılmıştır. İlk olarak iki sınıflı (hastalıklı ve sağlıklı) bir sınıflandırma yöntemi uygulanmıştır. Daha sonra dördü (Brown Spot, Hispa, Leaf Blast ve Sağlıklı) bir sınıflandırma ile çeltik bitkisine ait hastalıkların tespiti yapılmıştır. Bu kapsamda ikili sınıflandırma ile dördü sınıflandırma için kullanılan değerlendirme ölçütleri bu alt bölümde anlatılmıştır. İki sınıflı sınıflandırma için karmaşıklık matrisi Tablo 3.3'te verilmiştir. Tabloda gösterilen matriste TP (True Positive), FP (False Positive), FN (False Negative) ve TN (True Negatif) kısaltmalarının açıklamaları aşağıda verilmiştir:

- **TP:** Sınıflandırma sonucunun pozitif, gerçek sonucunda pozitif olanların sayısı
- **FP:** Sınıflandırma sonucunun pozitif, gerçek sonucun negatif olanların sayısı

- **FN:** Sınıflandırma sonucunun negatif, gerçek sonucun pozitif olanların sayısı
- **TN:** Sınıflandırma sonucunun negatif, gerçek sonucunda negatif olanların sayısı

Tablo 3. 3. İki sınıflı bir problemde kullanılan karmaşıklık matrisi

		Tahmin Edilen Değer	
		Pozitif	Negatif
Gerçek Değer	Pozitif	TP	FN
	Negatif	FP	TN

Tablo 3.3'te gösterilen karmaşıklık matrisindeki verilere göre hassasiyet, duyarlılık, doğruluk ve F1 ölçütü gibi metrik değerleri hesaplanmaktadır. Karmaşıklık matrisinde bulunan bu değerlerin birbirinden farklı hesaplamaları bulunmaktadır. Bu farklılığın nedeni incelenen her sistem için bu değerlendirme ölçütlerinin önemi değişmektedir. Örneğin hastalık tespitinde kullanılan bir sistemin doğruluk değeri hassasiyet değerinden daha önemli olmaktadır.

Hassasiyet, pozitif olarak tahminde bulunan durumların gerçekte ne oranda doğru olduğunu ifade etmektedir. Bu değer denklem 3.3'e göre hesaplanmaktadır.

$$Hassasiyet = \frac{TP}{TP+FP} \quad (3.3)$$

Doğruluk, doğru olarak tahmin edilen durumların tüm durumlara göre oranını ifade etmektedir. Doğruluk değeri denklem 3.4'de gösterilen formül ile hesaplanmaktadır.

$$Doğruluk = \frac{TP+TN}{TP+FN+FP+T} \quad (3.4)$$

Duyarlılık, gerçekte doğru olup ve doğru olarak tahmin edilen durumların ağırlıklı ortalamasını ifade etmektedir. Bu değer hesaplanması denklem 3.5'de gösterilmiştir.

$$Duyarlılık = \frac{TP}{TP+FN} \quad (3.5)$$

F1 ölçütünün hesaplanması için Hassasiyet ve Duyarlılık değerlerine ihtiyaç duyulmaktadır. F1 ölçütü ve diğer ölçütler 0 ile 1 arasında değerler almaktadırlar. Bu değerlerin 1'e yakın olması sistemin başarılı olduğunu göstermektedir. F1 ölçütü özellikle sınıflardaki veri eşitsizliği varsa doğruluk değerinden daha önemli olmaktadır. F1 ölçütü denklem 3.6'da belirtilen eşitlik ile hesaplanmaktadır.

$$F1\ Score = \frac{2*Hassasiyet*Duyarlilik}{Hassasiyet+Duyarlilik} \quad (3.6)$$

Model performansının oran olarak hesaplamak için TPR, TNR, PPV, NPV, FPR, FNR ve FDR gibi ölçütler kullanılmaktadır. TPR duyarlılık veya gerçek pozitif oranı olarak tanımlanmaktadır. TPR performans ölçütü denklem 3.7'de verilmiştir.

$$TPR = \frac{TP}{TP+FN} \quad (3.7)$$

TNR özgüllük veya gerçek negatif oranı olarak tanımlanmaktadır. TNR performans ölçütü denklem 3.8'de verilmiştir.

$$TNR = \frac{TN}{TN+FP} \quad (3.8)$$

PPV hassasiyet veya pozitif tahmin oranı olarak tanımlanmaktadır. PPV performans ölçütü denklem 3.9'de verilmiştir.

$$PPV = \frac{TP}{TP+F} \quad (3.9)$$

NPV negatif değer tahmini olarak tanımlanmaktadır. NPV performans ölçütü denklem 3.10'da verilmiştir.

$$NPV = \frac{TN}{TN+FN} \quad (3.10)$$

FPR yanlış pozitif oranı olarak tanımlanmaktadır. FPR performans ölçütü denklem 3.11'de verilmiştir.

$$FPR = \frac{FP}{FP+} \quad (3.11)$$

FNR yanlış negatif oranı olarak tanımlanmaktadır. FNR performans ölçütü denklem 3.12'de verilmiştir.

$$FNR = \frac{FN}{TP+FN} \quad (3.12)$$

FDR yanlış tespit oranı olarak tanımlanmaktadır. FDR performans ölçütü denklem 3.13’de verilmiştir.

$$FDR = \frac{FP}{TP+FP} \quad (3.13)$$

Bu tez kapsamında dörtlü (Sağlıklı, Leaf blast, Brown spot, Hispa) sınıflandırma işlemi için kullanılan karmaşıklık matrisi sonuçlar bölümünde ayrıntılı bir şekilde verilmiştir.

Tez çalışması kapsamında genellikle ikili sınıflandırma problemlerinde kullanılan Alıcı İşletim Karakteristiği (ROC: Receiver Operating Characteristic) eğrisi de değerlendirme ölçütü olarak kullanılmıştır. Bu eğrinin oluşturulması için bir eşik değerine ihtiyaç duyulmaktadır. ROC eğrisi verilen bu eşik değerine göre başarı oranını göstermektedir.

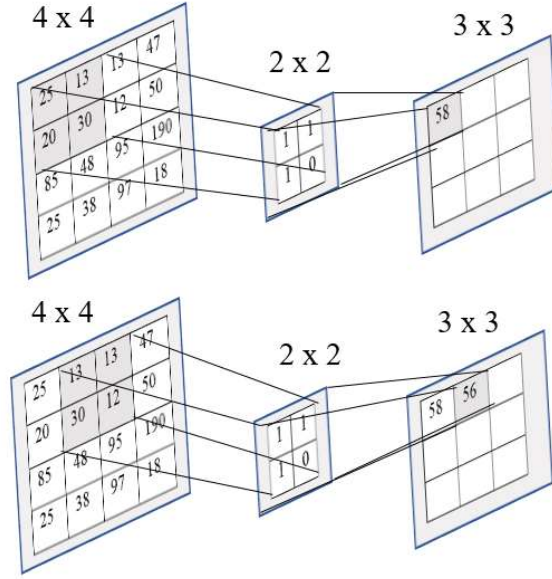
3.5. Donanım ve yazılım ortamı

Yapılan çalışmalar sonucu çeltik bitkisi hastalığının tespiti için Derin Öğrenme yöntemlerinden biri olan CNN kullanılmıştır. Bu çalışmada çeltik bitkisine ait hastalıkları ve sağlıklı olduğunu tespit etmek için *Python* programlama dili kullanılmıştır. CNN modeli kullanılarak özelliklerin çıkarılmasında *Tensorflow* ve *Theano* gibi derin öğrenme kütüphanelerini kullanan üst yüzey bir API olan *Keras* Kütüphanesi, veri artırımı için kullanılan görüntü işleme tekniği için *opencv (cv2)*, matematiksel işlemler için gerekli olan yapılar için *numpy*, verilerimizi görselleştirmek için kullanılan python kütüphanesi olan *matplotlib* kütüphanesi kullanılmıştır.

Bu çalışmada yapılan derin öğrenme uygulaması ilk olarak Google’un sunduğu Google Colaboratory üzerinde kullanıldı. Google Colaboratory üzerindeki Tesla K80 GPU kullanılarak birkaç uygulama gerçekleştirildi. Google’nın sunduğu bu hizmetin ücretsiz sürümü kapsamlı çalışmalar için kullanılan yeterli GPU ve CPU desteği vermemekteydi. Şimdilik Ücretli GPU desteği ülkemizde kullanılmaya açık olmadığı için satın alınamadı. Tüm bunlardan dolayı, derin öğrenme uygulamalarını geliştirebilmek için ekran kartı NVIDIA GeForce MX150, İşlemci Intel(R) Core(TM) i7-8550U ve yüklü bellek (RAM) 20GB özelliklere sahip bir kişisel bilgisayar bu çalışma kapsamında kullanılmıştır.

Derin öğrenme modellerinin GPU’yu kullanabilmesi için Tensorflow kütüphanesinin buna izin vermesi gerekmektedir. Bunun için bilgisayarda bir ekran kartına sahip olunması (NVIDIA) ve ekran kartının grafik işlem birimini kullanarak hesaplama performansında büyük ölçüde artışlara olanak veren paralel hesaplama mimarisi CUDA desteğine sahip olunması gerekir. Kullanılacak olan cihazın CUDA desteğinin yanında bir de NVIDIA’nın internet

görüntüsünden daha küçük boyutlu yeni bir matris oluşturulur. Şekil 3.10'da 4x4 boyuta sahip bir giriş görüntüsü ve bir 2x2 filtre için evrişim katmanındaki işlemin 2 adımı gösterilmektedir.




Şekil 3. 10. 4x4 giriş görüntüsüne 2x2 filtre ile evrişim işlemi


b-) Havuzlama Katmanı (Pooling Layer)

Bu katman, CNN modelinde görüntülerdeki piksel sayısını azaltmak için ardışık evrişim katmanları arasında sıklıkla eklenen bir katmandır. Bu katmanın görevi gösterimin kayma boyutunu, ağ içindeki parametreleri ve hesaplama sayısını azaltmak içindir. Bu sayede ağdaki uyumsuzluk kontrol edilmiş olur. Havuzlama katmanlarında maksimum havuzlama (max pooling), ortalama havuzlama (average pooling) ve L2-norm havuzlama yöntemleri kullanılmaktadır. Bu yöntemlerden genellikle maksimum havuzlama daha sıklıkla kullanılmaktadır. Bu çalışmada da evrişim katmanlar arasında maksimum havuzlama kullanılmıştır. Şekil 3.11'de örnek bir havuzlama işlemi gösterilmiştir.

Ortalama Havuzlama (Average Pooling)



Maksimum Havuzlama (Max Pooling)



Şekil 3. 11. 2x2lik görüntüye maksimum havuzlama ve ortalama havuzlama işlemi

c-) Aktivasyon Katmanı (Activation Layer)

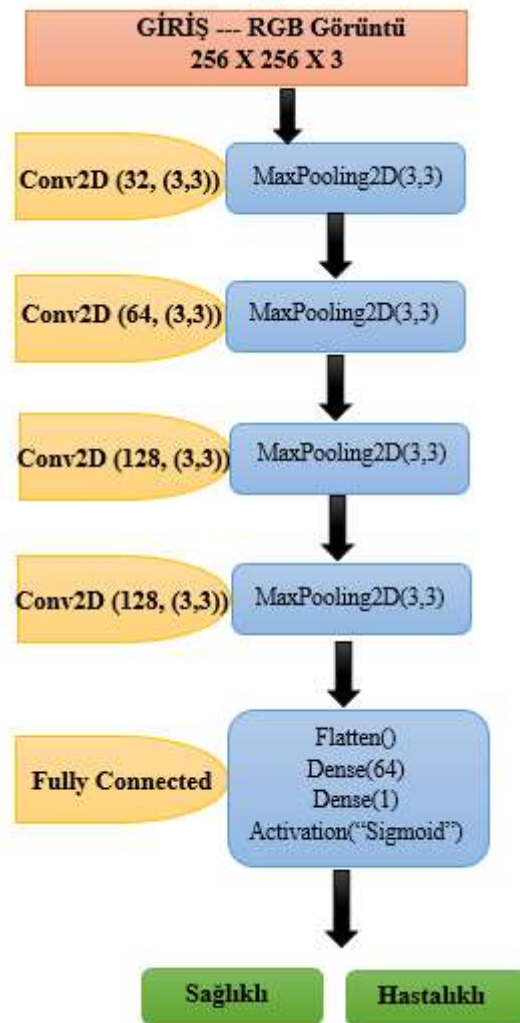
CNN modelinde genellikle tüm katmanlardan sonra doğrusal olmayan bir katman gelmektedir. Bu katmana aktivasyon katmanı adı verilir. Bu çalışmada aktivasyon katmanında ReLU (Rectifier Linear Unit) fonksiyonu kullanılmıştır. Önceki çalışmalarda genellikle doğrusal olmayan sigmoid, hiperbolik ve tanjant 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 (flattening) işlemi ile veriler düzeltilir. Düzleştirme işleminden sonra tam bağlantılı katmanı gelir. Bu katman CNN modelinin son ve en önemli katmanıdır. Bu katmanda sinir ağları ile sınıflandırma veya tanıma işlemi yapılmaktadır.

3.7. CNN ile çeltik bitkisinin hastalık tespiti (hastalıklı ve sağlıklı)

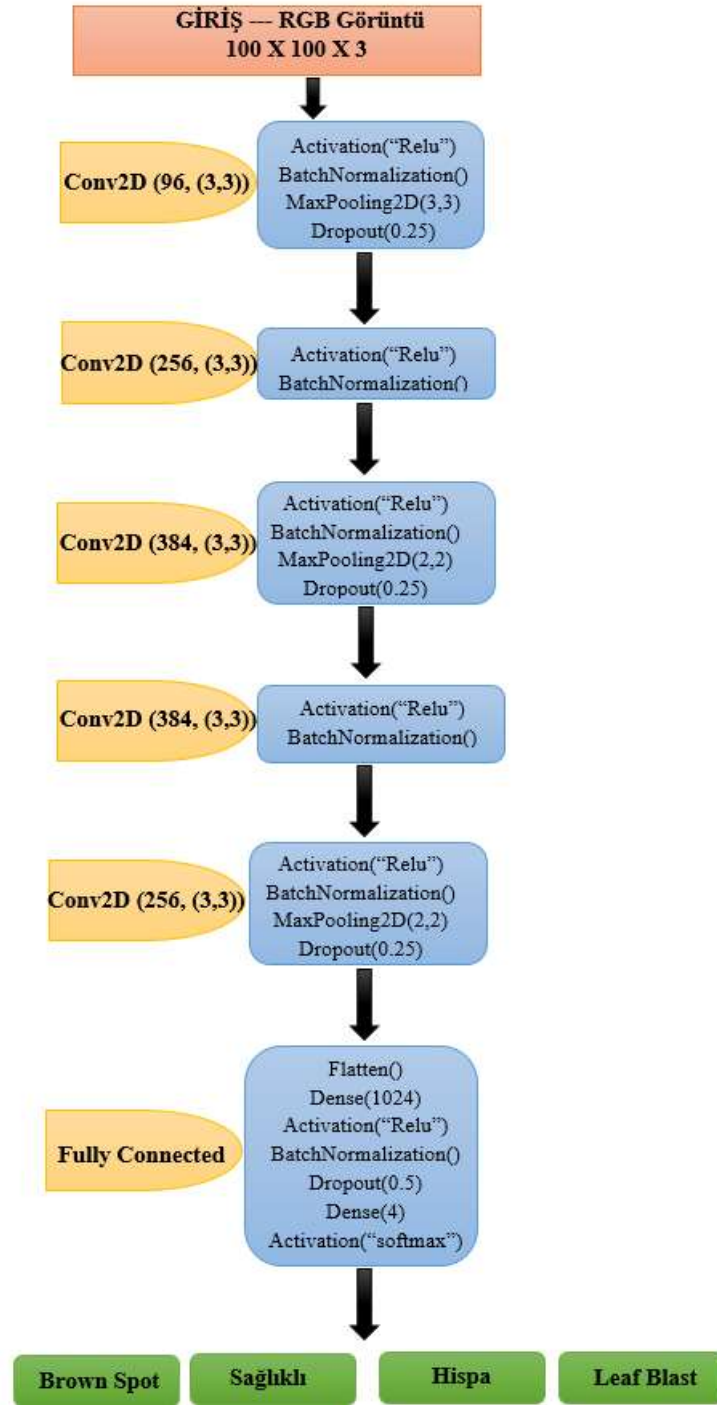
Çeltik bitkisi hastalıklarını tespit için görüntü işleme ile olasılıksal yapay sinir ağı kullanılarak elde edilen başarı oranı düşük çıkmıştır. Bu başarı oranının çeltik bitkisi hastalığının tespitinde kullanılması durumunda sağlıklı bitkilerde hastalıklı olarak etiketlenebilmektedir. Bu yüzden başarı oranını arttırmak için bir sonraki aşamada derin öğrenme yöntemlerinden birisi olan CNN modeli tercih edilmiştir. CNN ile bitki hastalığını tespit etmek için Şekil 3.12’de gösterilen model mimarisi oluşturulmuştur. Bu CNN modeli beş evrişimli katmandan oluşmaktadır. Aktivasyon fonksiyonu için ReLU fonksiyonu kullanılmıştır (Ökten ve Yüzgeç, 2022b). Kullanılan bu model hastalıklı ve sağlıklı olmak üzere ikili sınıflandırma yapmaktadır. Çeltik bitkisi görüntülerinin boyutu OpenCV Kütüphanesi kullanılarak 256x256 boyutuna dönüştürüldükten sonra CNN modeline giriş olarak verilmektedir.



Şekil 3. 12. İkili sınıflandırma için oluşturulan CNN derin öğrenme modeli yapısı

3.8. CNN ile eltik bitkisinin hastalık tespiti (saęlıklı ve üç hastalık için)

eltik bitkisi hastalığını tespiti için görüntü işleme ile yapay sinir aęı ve evrişimli sinir aęı kullanılmıştır. Bu iki yöntem ile iki sınıflı (hastalıklı, saęlıklı) sınıflandırma yapılmıştır. Elde edilen veri setinde ve eltik bitkisine ait genellikle rastlanan hastalıkları ayırt etmek için 1 saęlıklı ve 3 hastalıklı (Brown Spot, Hispa ve Leaf Blast) olmak üzere toplamda dörtlü bir sınıflandırma daha yapılmıştır. Bu sınıflandırmanın yapılması için yine CNN modeli tercih edilmiştir. CNN ile bitki hastalığını tespit etmek için Şekil 3.13’de gösterilen model yapısı oluşturulmuştur. Bu CNN modeli beş evrişimli katmandan oluşmaktadır. Aktivasyon fonksiyonu için ReLU kullanılmıştır. Oluşturulan bu model Brown Spot, Hispa, Leaf Blast ve Saęlıklı olmak üzere dörtlü sınıflandırma yapmaktadır. eltik bitkisi görüntülerinin boyutu OpenCV Kütüphanesi kullanılarak 100x100 boyutuna dönüştürüldükten sonra modele giriş olarak verilmektedir. Giriş olarak verilen görüntü boyutlarının 100x100 üzerinde olması durumunda kullanılan bilgisayarın *GPU birimi yetersiz* hatası alınmaktadır. Bu yüzden görüntü boyutu 256x256 yerine 100x100 olarak modelin girişine verilmiştir.



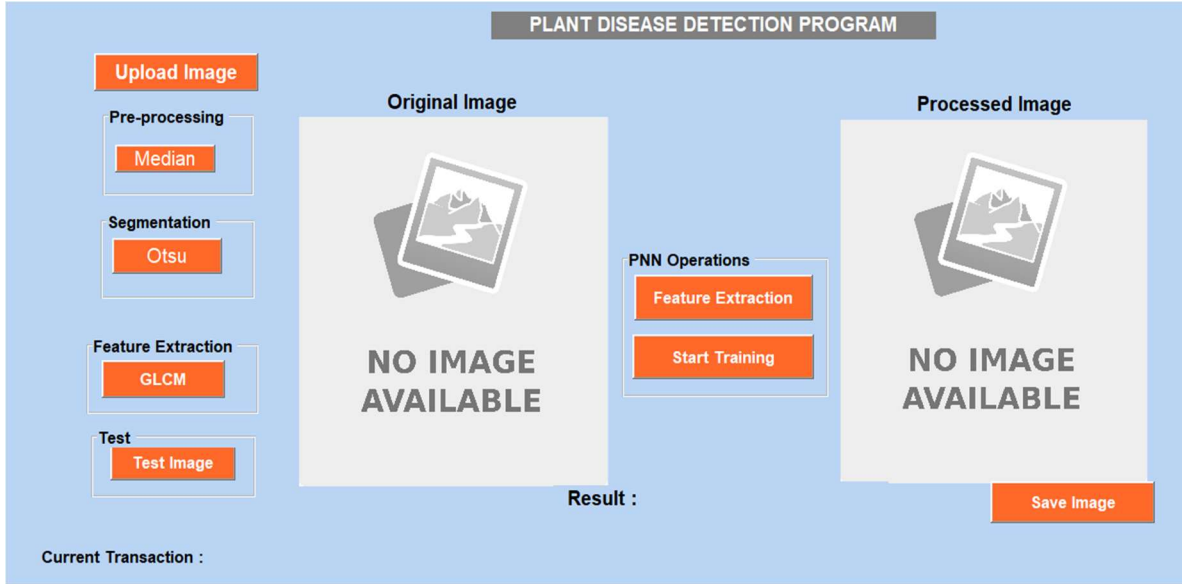
Şekil 3. 13. Dörtlü sınıflandırma için oluşturulan CNN derin öğrenme modeli yapısı

3.9. Sonuçlar ve değerlendirme

Çeltik bitkisine ait hastalık tespit sisteminin geliştirilmesinde kullanılan yöntemlerin ayrıntıları ve elde edilen sonuçlara ait performans ölçütleri bu başlık altında verilmiştir. Hastalığın sınıflandırması için kullanılan üç yöntem (PNN modeli, CNN (ikili sınıflandırma) ve CNN (dörtlü sınıflandırma)) ait sonuçlar ayrı ayrı başlıklar altında anlatılmıştır.

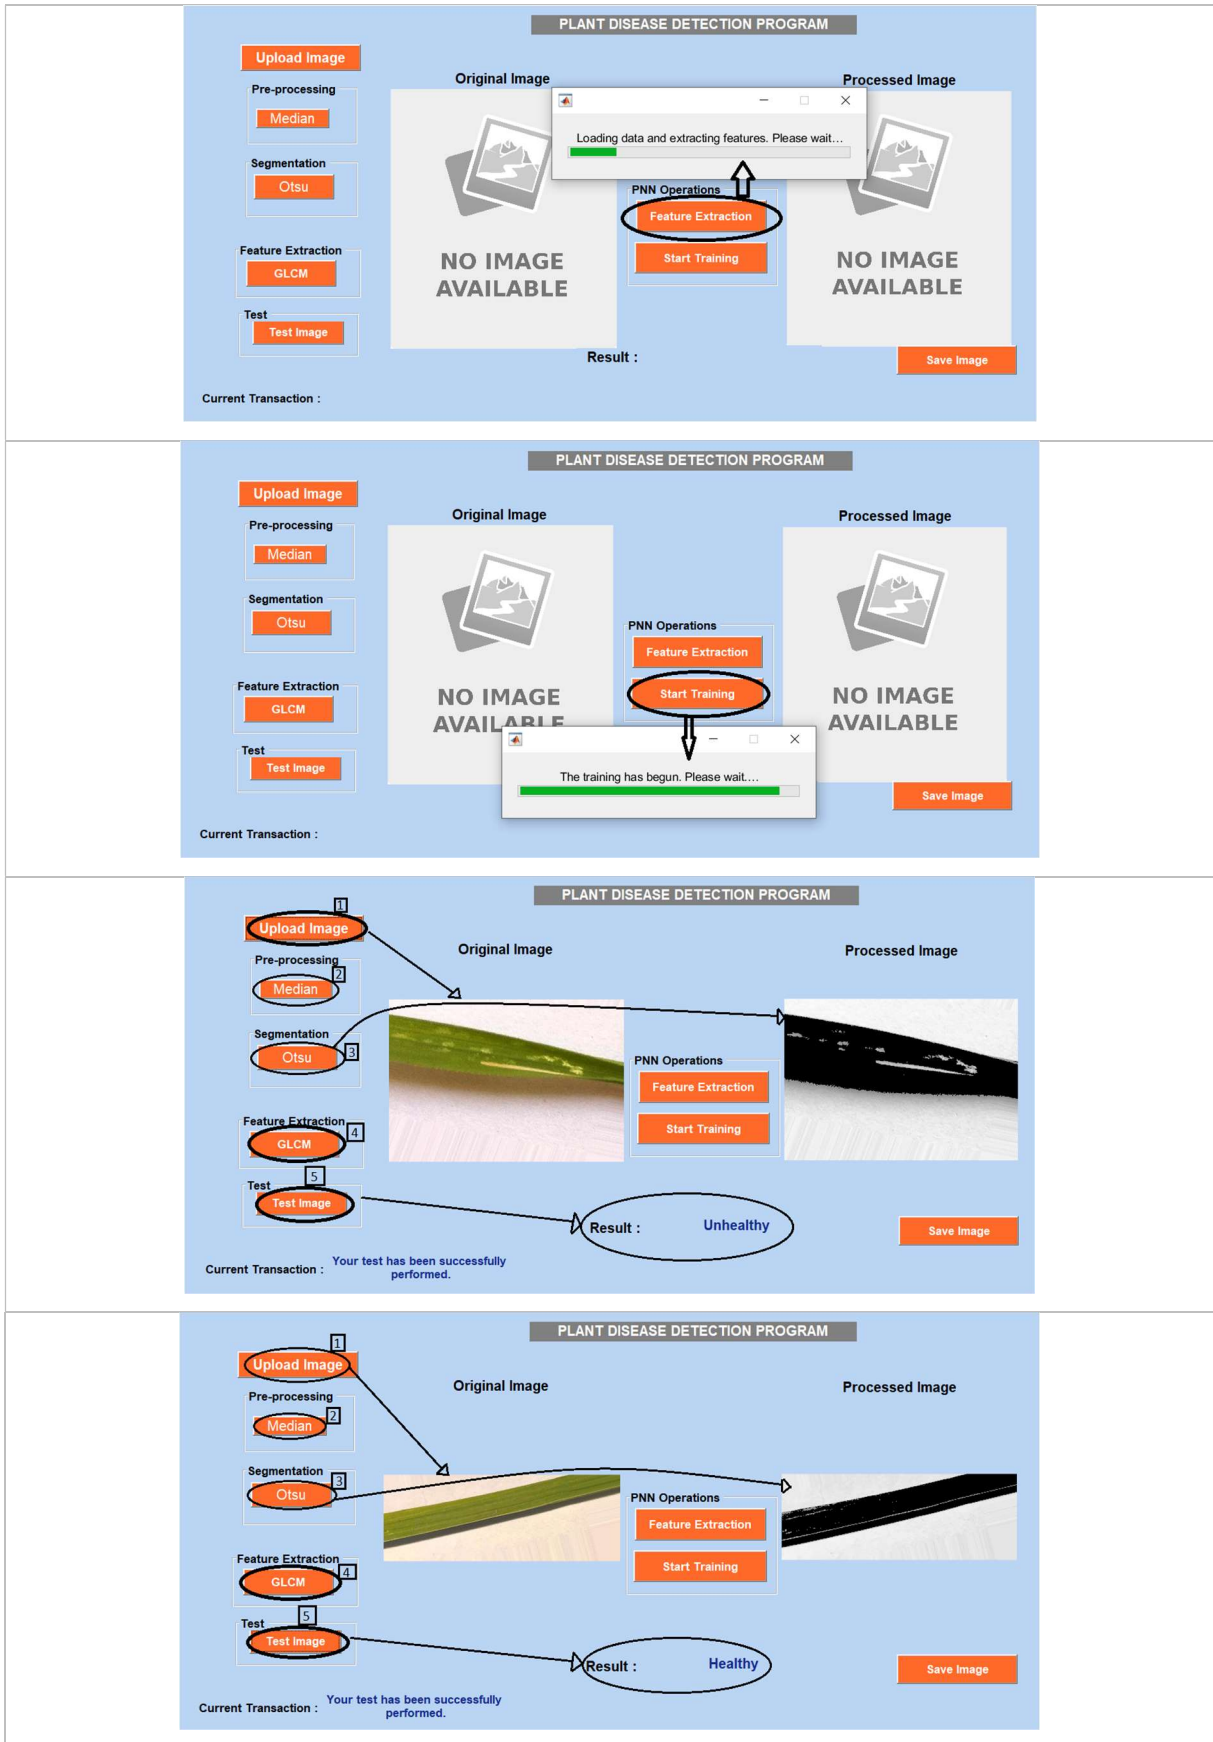
3.9.1. PNN modeli ile çeltik bitkisinin hastalık tespiti

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 3.14'te hastalık tespitini yapan programın arayüzü gösterilmiştir.



Şekil 3. 14. Oluşturulan PNN modeli ile çeltik bitkisi hastalık tespiti program arayüzü

Çeltik bitkisinin hastalıklarını tespit edecek olan arayüzde öncelikle görüntü ön işleme metotları çeltik bitkisi yaprak görüntülerine uygulandı. Görüntü ön işlemede medyan filtreleri, bölütleme (segmentasyon) işlemi için OTSU yöntemi, görüntülerin özelliklerini çıkarmak için GLCM algoritması kullanıldı. Çeltik bitkisine ait 534 görüntünün ön işleme, bölütleme ve sonra GLCM ile özellikleri çıkarıldı. Çeltik bitkisinin sağlıklı mı ya da hastalıklı mı olduğunu anlamak içinde PNN modeli oluşturulmuştur. Çeltik bitkisinin sınıflandırması için oluşturulan PNN modeli eğitimi için görüntülerin %75'i ve test için %25'i kullanmıştır. Eğitilmiş ağa test işlemi uygulandığında %77'lik bir doğruluk oranı elde edilmiştir. Şekil 3.15'de bu aşamaların kullanıcı arayüz programında nasıl yapıldığı aşama aşama gösterilmiştir.



Şekil 3. 15. PNN modeli ile çeltik bitkisi hastalık tespit programı kullanımı

PNN modelinde kullanılan test veri setindeki sonuçları kullanılarak elde edilen karışıklık matrisi Tablo 3.4’de verilmiştir. Karışıklık matrisin elde edilmesi için toplamda 134 çeltik bitkisi yaprak görüntüsü (67 hastalıklı görüntü, 67 sağlıklı görüntü) kullanılmıştır. Karışıklık matrisi Doğru Pozitif (TP – True Positive), Yanlış Pozitif (FP – False Positive), Doğru Negatif (TN - True Negative) ve Yanlış Negatif (FN – False Negative) değerlerinden oluşmaktadır.

Tablo 3. 4. PNN modeli kullanarak elde edilen karışıklık matrisi

		Tahmin		Toplam
		Hastalıklı	Sağlıklı	
Gerçek	Hastalıklı	55	12	67
	Sağlıklı	19	48	67
Toplam		74	60	

PNN ile yapılan çalışmanın test sonuçlarından karışıklık matrisindeki değerlere göre doğruluk oranı, özgüllük, duyarlılık, hassasiyet ve f1-skor Tablo 3.5’de gösterilmiştir.

Tablo 3. 5. PNN modelinin performans ölçütleri

Veri seti boyutu	Özgüllük	Doğruluk	Duyarlılık	Hassasiyet	f1-score
134	82%	76,8%	71,6%	80%	75,5%

3.9.2. CNN modeli ile çeltik bitkisinin hastalık tespiti sonuçları (sağlıklı ve hastalıklı)

Çeltik bitkisine ait hastalıkların bulunduğu görüntüler ile bitkinin sağlıklı olduğu görüntüler kullanılarak CNN modeli ile ikili sınıflandırma yapılmıştır. Görüntü ön işleme kısmında görüntülerin boyutu küçültülüp, daha sonra görüntülerdeki arka plan kaldırılmıştır. Ardından her bir sınıf için 3200 görüntü kullanılarak eğitim işlemi yapılmıştır. Eğitim işlemi sonunda CNN ağı eğitilmiş ve ağınlıklar kaydedilmiştir. Kaydedilmiş bu ağırlık ve model

ile her sınıf için 800 görüntü üzerinde test işlemi yapılmıştır. Yapılan test işlemleri sonucunda herhangi bir filtre kullanılmadığında elde edilen doğruluk oranı %91,54 olarak bulunmuştur. Tüm görüntülerin arka planındaki gürültülerin kaldırılması ile eğitilen ağda %97,57'lik bir başarı oranı elde edilmiştir. Elde edilen sonuçlar Tablo 3.6'da verilmiştir. Daha sonra test işlemleri sonucunda sınıf bazında çıkan başarı oranları Tablo 3.7'de özetlenmiştir. Bu sonuçlara göre hastalıklı sınıfa ait başarı oranı %98,45 ve sağlıklı sınıfa ait başarı oranı %96,68 olarak bulunmuştur.

Tablo 3. 6. PNN ve CNN modellerinin çeltik bitkisi hastalığı sınıflandırma sonuçları

Sınıflandırma	Ön İşleme	Bölütleme	Özellik Çıkarımı	Test Sonucu
PNN	Medyan filtre	OTSU	GLCM	%77
CNN	Filtresiz	-	-	%91,54
CNN	Arka planı temizleme	-	-	%97,57

Tablo 3. 7. 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

Derin öğrenmede kullanılan bazı hiperparametreler vardır. Hiperparametreler, derin öğrenme ağını tasarlayan kişiler tarafından belirlenir. Ağ oluşturulan kişi tarafından belirlenen hiperparametreler, probleme veya veri setine göre değişiklik gösterebilmektedir. Bu çalışma kapsamında hiperparametrelerde değişiklik yapıp ağı doğruluk oranının yükseltilmesi planlanmıştır. Derin öğrenme uygulamalarında sıklıkla kullanılan hiperparametreler ve bunların ağ üzerindeki sonuçları aşağıda belirtilmiştir.

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 3.8'de verilmiştir.

Tablo 3. 8. Veri seti büyüklüğünün CNN modeli başarı oranı üzerindeki etkisi

Sınıflandırma	Ön işleme	Veri seti boyutu	Başarı oranı
CNN	-	5000	%91,54
CNN	-	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 SGD (Stochastic Gradient Descent), Adalate, Adam, RMSprop yöntemleridir. Bu çalışmada bu dört yöntem için eğitim işlemi uygulanmıştır. Eğitim sonucunda elde edilen ağırlıklar ile CNN modelinin test işlemlerinde en yüksek başarı oranı Adam optimizasyon yöntemi ile elde edilmiştir. Bu yüzden çalışmada Adam optimizasyon yöntemi kullanılmıştır.


Bu çalışmada hiperparametrelerden olan küme boyutu (batch size) ve öğrenme oranı (learning rate) değerlerini seçmek için birkaç test işlemi yapıldı. Küme boyut değeri 32 olarak seçildi. Kullanılan verilerin çok olması ve modelin eğitildiği bilgisayarda çalışabilmesi için bu değer seçilmiştir. Genelde bu tarz çalışmalarda öğrenme oranı $1e-3$ ile $1e-4$ arasında bir değer alınarak kullanılmaktadır. Oluşturulan model için Öğrenme oranı $1e-4$ seçildiğinde daha başarılı sonuçlar elde edildiği görülmüştür.

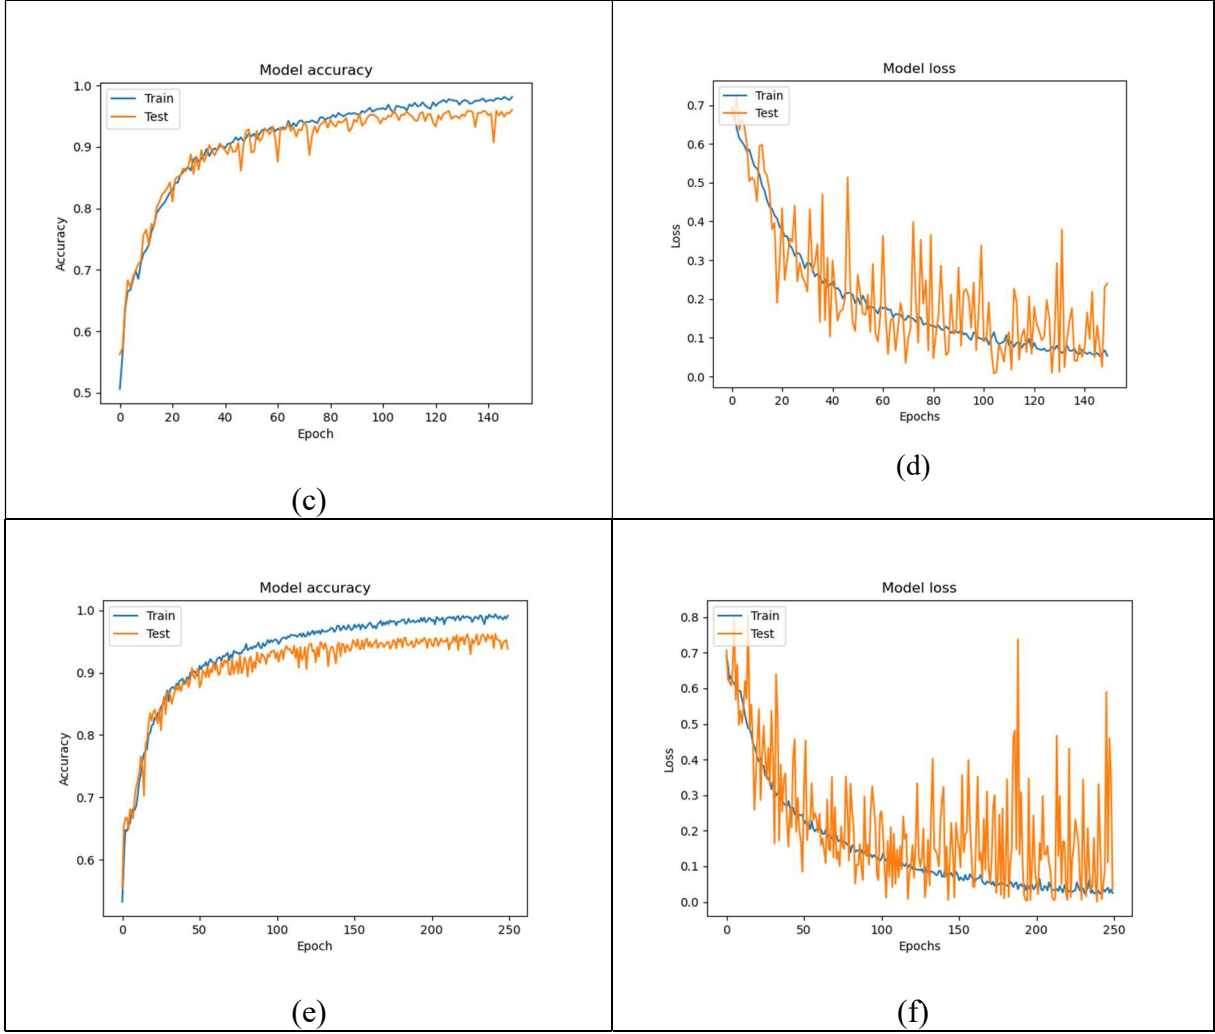
Derin öğrenme modeli eğitilirken verilerin hepsi aynı anda eğitime verilmez. Modeli tasarlayanların belirttiği oranda parçalara bölünür ve bu parçalar halinde eğitime verilir. Eğitime verilen ilk parça eğitilir ve modelin başarı oranı test edilir. Bu başarı oranına göre ağırlık değerleri güncellenir. 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 başarı oranı tur sayısı 250 seçilerek bulunmuştur.

Bu çalışmada kullanılan hiperparametrelerin değerlerinin bulunması için belirli test işlemleri gerçekleştirilmiştir. Yapılan bu testler sonucunda her bir hiperparametre değeri ve bu değerler ile elde edilen doğruluk oranları Tablo 3.9'da özetlenmiştir. Bu tabloda gösterilen iyi modelin doğruluk ve kayıp (loss) oranlarının grafiksel gösterimleri Şekil 3.16'da gösterilmiştir.

Tablo 3. 9. Hiperparametrelerinin deęişimine göre CNN modelinin test başarı oranları

Sınıflandırma	Tur	Küme Boyutu	Öğrenme Oranı	Veri Seti Boyutu	Eniyileştiriciler (Optimizers)	Test Doğruluk Oranı
CNN	150	16	1e-3	5000	Adam	%91,54
CNN	150	16	1e-3	5000	Adalate	%81,88
CNN	150	16	1e-3	5000	SGD	%85,85
CNN	150	16	1e-3	5000	RMSprop	%86,86
CNN	150	16	1e-3	8000	Adam	%94,87
CNN	150	16	1e-3	8000	Adalate	%83,74
CNN	150	16	1e-3	8000	SGD	%90,46
CNN	150	16	1e-3	8000	RMSprop	%91,44
CNN	250	32	1e-4	8000	Adam	%97,57
CNN	250	32	1e-4	8000	Adalate	%88,74
CNN	250	32	1e-4	8000	SGD	%91,74
CNN	250	32	1e-4	8000	RMSprop	%93,42





Şekil 3. 16. Farklı tur sayıları (Epochs) için CNN ile eğitim ve test sonuçları, (a) 5000 görüntü ve 150 tur sayısına ait doğruluk oranı, (b) 5000 görüntü ve 150 tur sayısına ait 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

Oluşturulan CNN modeline ait karmaşıklık matrisini bulmak için test veri setindeki görüntülerden 400 çeltik bitkisi yaprak görüntüsü (200 hastalıklı görüntü, 200 sağlıklı görüntü) kullanılmıştır. Yapılan test işleminden sonra elde edilen sonuçlara göre Tablo 3.10’da verilen karmaşıklık matrisi bulunmuştur.

Tablo 3. 10. Bitki hastalığının tespitinde kullanılan CNN ile çıkan sonuçların karmaşıklık matrisi

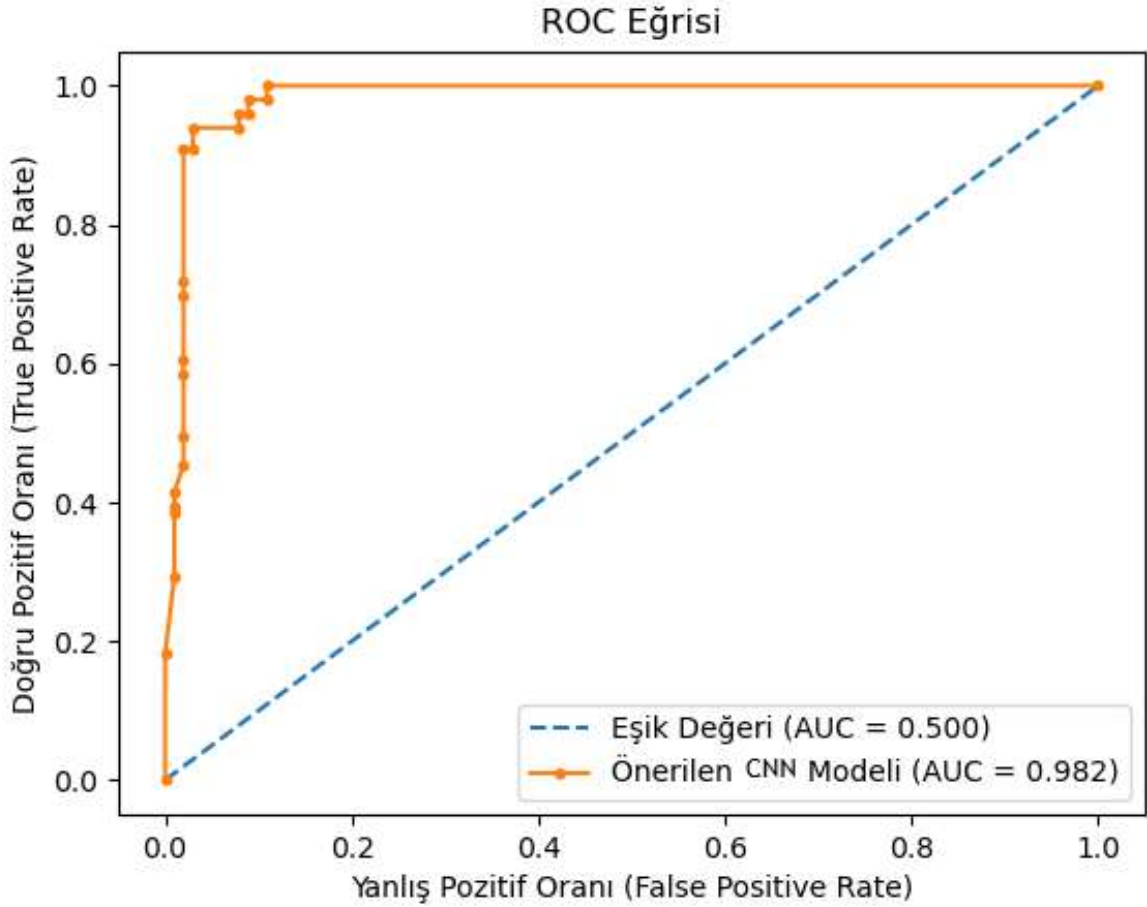
		Tahmin	
		Hastalıklı	Sağlıklı
Gerçek	Hastalıklı	197	3
	Sağlıklı	7	193

CNN ile PNN modellerin karmaşıklık matrisindeki sonuçlara göre başarı oranı, özgüllük, duyarlılık, hassasiyet ve f1-skor Tablo 3.11’de gösterilmiştir.

Tablo 3. 11. PNN ve CNN model sonuçları

Model	Veri Seti Boyutu	Özgüllük	Doğruluk	Duyarlılık	Hassasiyet	F1-skor
CNN	400	0,98	0,97	0,96	0,98	0,97
PNN	100	0,82	0,77	0,72	0,80	0,76

Hastalık tespiti yapan modellerin sonuçlarının daha net anlaşılabilmesi için performans ölçüm metrikleri kullanılmaktadır. Bu çalışmada bu metriklerden karmaşıklık matrisi ve ROC 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. Çeltik bitkisi hastalığını tespit etmek için kullanılan CNN modeline ait ROC eğrisi ve AUC (ROC eğrisi altında kalan alan) değeri Şekil 3.17’de gösterilmiştir.



Şekil 3. 17. Oluşturulan CNN 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) değerlerinin bilinmesi gerekmektedir. Bu değerleri bulmak için 200 çeltik bitkisi yaprak görüntüsü (100 hastalıklı, 100 sağlıklı) kullanılmıştır.

3.9.3. CNN modeli ile çeltik bitkisinin hastalık tespiti sonuçları (sağlıklı ve üç hastalık için)

Bu bölümde CNN modeli ile çeltik bitkisine ait üç hastalık ve sağlıklı olmak üzere toplamda dörtlü bir sınıflandırma yapılmıştır. Görüntü ön işleme kısmında görüntülerin boyutu küçültülüp daha sonra görüntülerdeki arka plan kaldırılmıştır. Veri artırma yönteminden sonra toplam 11200 (her sınıf için 2800) görüntü ile ağın eğitimi yapılmıştır. Veri setindeki görüntülerin %75'i eğitim %25'i test için kullanılmıştır. Eğitim işlemi ile ağ eğitilmiş ve ağın ağırlıkları kaydedilmiştir. Kaydedilmiş bu ağırlık ve model ile her sınıf için 700 görüntü üzerine test işlemi yapılmıştır. Yapılan test işlemleri sonucunda herhangi bir filtre kullanılmadığında elde edilen başarı oranı %85,48 olarak bulunmuştur. Tüm görüntülerin arka planındaki görüntülerin kaldırılması ile eğitilen ağda %92,78'lik bir başarı oranı elde edilmiştir. Bu yöntem ile daha önceki yöntemlerin karşılaştırılması Tablo 3.12'de verilmiştir.

Tablo 3. 12. Derin öğrenme modeli ile dörtlü sınıflandırma sonuçları

Sınıflandırma	Sınıf	Ön işleme	Bölütleme	Özellik Çıkarımı	Doğruluk oranı
CNN	4	-	-	-	%85,48
CNN	4	Arka Plan Kaldırma	-	-	%92,78

Bu çalışma kapsamında hiperparametrelerde değişiklik yapılarak ağın doğruluk oranı artırılmak istenmiştir. Derin öğrenme uygulamalarında sıklıkla kullanılan hiperparametreler ve bunların ağ üzerindeki sonuçları aşağıda belirtilmiştir.

Bu tez kapsamında dörtlü sınıflandırma problemini çözmek için kullanılan veri seti boyutunun yeterli olmadığı görülmüştür. Bu nedenle ikili sınıflandırmada yapıldığı gibi burada da veri artırımı yapılmıştır. 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 işlemini gerçekleştirmek için TensorFlow'un uygulamalarından biri olan Keras kütüphanesinden ImageDataGenerator fonksiyonundan yararlanılmıştır. Elde edilen 3341 çeltik bitkisi yaprak görüntüsünden veri

artırımı ile 15000 görüntü oluşturulmuştur. 3341 görüntü ile yapılan test işlemi ile 15000 görüntü ile yapılan test işleminin sonucu Tablo 3.13’de birlikte verilmiştir.

Tablo 3. 13. Veri seti boyutunun doğruluk oranı üzerindeki etkisi

Sınıflandırma	Sınıf	Ön işleme	Veri seti boyutu	Test doğruluk oranı
CNN	4	Arka Plan Kaldırma	3341	%92,78
CNN	4	Arka Plan Kaldırma	15000	%95,66

Daha sonra test işlemleri sonucunda sınıf bazında çıkan doğruluk oranları Tablo 3.14’te özetlenmiştir. Bu sonuçlara göre en başarılı sınıflandırma sonucu %98,44 ile Brown Spot hastalığı ve en kötü sınıflandırma başarısı %92,54 ile Leaf Blast hastalığı olmuştur.

Tablo 3. 14. Dörtlü sınıflandırma doğruluk oranları

Çeltik bitkisi hastalık ve sağlık durumları	Test edilmiş veri seti boyutu	Doğruluk Oranı
Brown Spot	700	98,44
Hispa	700	94,38
Leaf Blast	700	92,54
Sağlıklı	700	97,28
Toplam	2800	95,66

Tablo 3.15’de, eğitim tur sayısının, veri boyutunun, öğrenme oranının ve optimize edicilerin test doğruluk oranı üzerindeki etkileri özetlemektedir. Bu tabloda küme boyutu 16 olarak seçilmiştir. En iyi değerler tabloda kalın yazı tipi ile gösterilmiştir. Bu tür çalışmalarda genellikle öğrenme oranı $1e-3$ ve $1e-4$ olarak kullanıldığı için bu iki değer ile testler yapılmıştır. Bu tablo sonuçlarından CNN sınıflandırıcı modeli için öğrenme oranı $1e-4$ seçildiğinde daha başarılı sonuçlar elde edildiği görülmektedir.

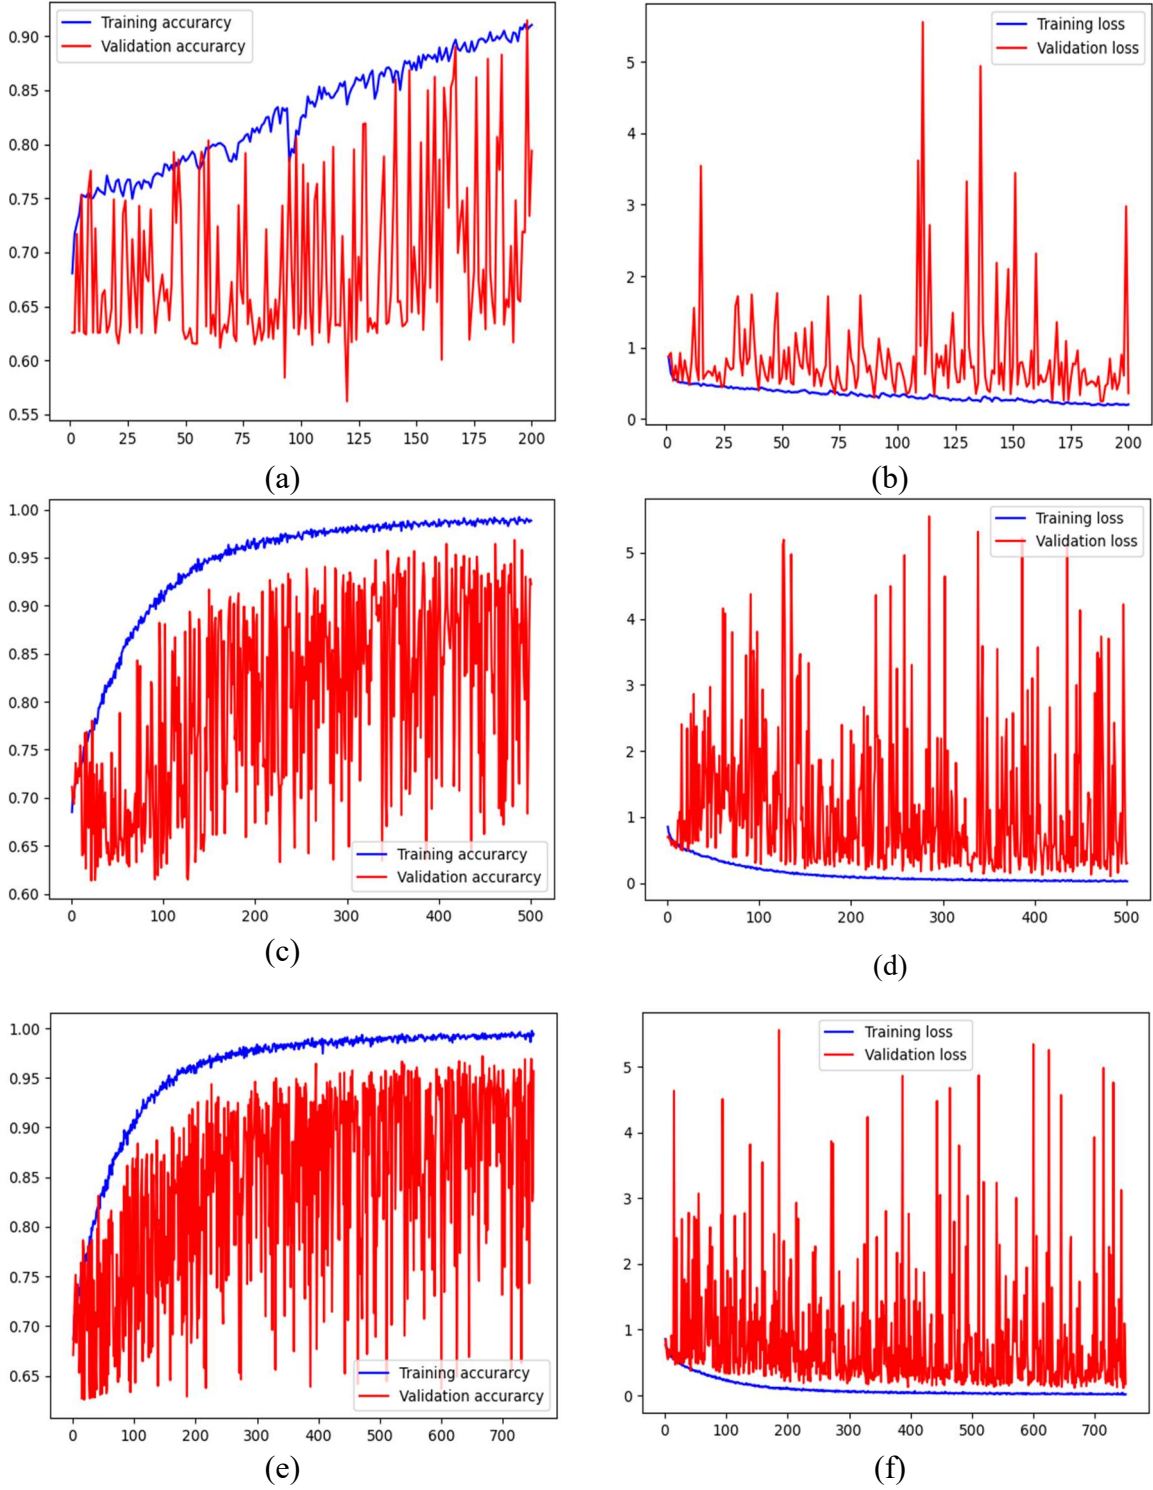
Derin öğrenmede doğrusal olmayan problemlerin çözümünde en uygun parametre değerini bulmak için optimizasyon yöntemleri kullanılmaktadır. Yapılan deneyler sonucunda çeltik bitkisi yapraklarındaki hastalığı tespit etmek için oluşturulan modelde Adam optimizasyon algoritması daha başarılı sonuçlar verdiği anlaşılmaktadır.

Derin öğrenme modeli eğitilirken verilerin tamamı eğitime aynı anda verilmemektedir. Ağı tasarlayanlar tarafından belirtildiği şekilde bölümlere ayrılarak bu bölümlerde eğitime verilir. Verilerin ilk kısmı eğitim süreci için kullanılır ve verilerin ikinci kısmı ile modelin doğruluğu test edilir. CNN modelinin ağırlık değerleri her adımda güncellenmektedir. Bu işlem her eğitim adımında uygulanarak en uygun ağırlık değerleri bulunur. Bu süreçlerin her adımına bir eğitim tur sayısı denir. Tablo 3.15’deki sonuçlardan eğitim tur sayısı 750 olarak en uygun değer olarak bulunmuştur. Veri seti boyutuna göre CNN modelinin doğruluk oranı, 14000 eğitim ve test verisi için daha iyi sonuçlar elde edilmiştir.

Tablo 3. 15. Hiperparametrelerin deęiřimi ile CNN modelinin doęruluk oranının sonucu

Sınıflandırma	Eđitim tur sayısı	Küme boyutu	Öđrenme oranı	Veri seti boyuru	Optimizasyonlar	Test doęruluk oranı
CNN	200	16	1e-3	2092	Adam	%78,64
CNN	200	16	1e-3	2092	Adalate	%67,48
CNN	200	16	1e-3	2092	SGD	%71,66
CNN	200	16	1e-3	2092	RMSprop	%70,55
CNN	200	16	1e-3	14000	Adam	%85,55
CNN	200	16	1e-3	14000	Adalate	%68,52
CNN	200	16	1e-3	14000	SGD	%75,56
CNN	200	16	1e-3	14000	RMSprop	%75,84
CNN	500	16	1e-4	14000	Adam	%92,24
CNN	500	16	1e-4	14000	Adalate	%69,65
CNN	500	16	1e-4	14000	SGD	%78,68
CNN	500	16	1e-4	14000	RMSprop	%80,45
CNN	750	16	1e-4	14000	Adam	%95,66
CNN	750	16	1e-4	14000	Adalate	%69,96
CNN	750	16	1e-4	14000	SGD	%80,46
CNN	750	16	1e-4	14000	RMSprop	%88,42

Çeltik bitkisi hastalığının sınıflandırılması için Tablo 3.15’de belirtilen hiper parametreler ile deneyler yapılmıştır. Şekil 3.18’de farklı eğitim tur (250, 500 ve 750) sayılarında eğitim ve doęrulama süreçleri için kullanılan CNN modelinin doęruluk ve kayıp eğrileri gösterilmektedir.



Şekil 3. 18. Farklı eğitim tur (epoch) sayıları için CNN eğitim (training) ve doğrulama (validation) sonuçları, (a) 200 eğitim tur sayısı için doğruluk (accuracy) oranı, (b) 200 eğitim tur sayısı için kayıp (loss), (c) 500 eğitim tur sayısı için doğruluk (accuracy) oranı (d) 500 eğitim tur sayısı için kayıp (loss), (e) 750 eğitim tur sayısı için doğruluk (accuracy) oranı (f) 750 eğitim tur sayısı için kayıp (loss)

CNN modelinin test veri setinin bir kısmına (tüm sınıflar için toplam 198 veri alınmıştır) uygulanmasıyla elde edilen karışıklık matrisi Tablo 3.16'da gösterilmiştir. Karışıklık matrisinde Doğru Pozitif (TP), Yanlış Pozitif (FP), Gerçek Negatif (TN) ve Yanlış Negatif (FN) değerleri vardır. Bu şekilde Brown Spot, Sağlıklı, Hispa, Leaf Blast sınıfları için TP değerleri sırasıyla

50, 50, 46 ve 42 olarak bulunmuştur. FN değerleri Brown Spot, Sağlıklı, Hispa, Leaf Blast sınıfları için sırasıyla 0, 0, 3 ve 7 olarak bulunmuştur. Brown Spot, Sağlıklı, Hispa, Leaf Blast sınıfları için TN değerleri sırasıyla 140, 147, 148 ve 149 olarak bulunmuştur. Brown Spot, Sağlıklı, Hispa, Leaf Blast sınıfları için FP değerleri sırasıyla 8, 1, 1 ve 0 olarak bulunmuştur.

Tablo 3. 16. CNN modeli kullanılarak elde edilen karışıklık matrisi, BS: Brown Spot, H: Healthy, His: Hispa, LB: Leaf Blast

BS	50	0	0	0
H	0	50	0	0
His	3	0	46	0
LB	5	1	1	42
	BS	H	His	LB

Tablo 3.17’de sağlıklı ve çeltik bitkisi hastalıkları için oluşturulan CNN sınıflandırıcısının performansı özetlenmektedir. Bu tabloda Doğruluk, F1 skor, Duyarlılık, Hassaslık, Yanlış Keşif Oranı (FDR), Yanlış Pozitif Oranı (FPR), Yanlış Negatif Oranı (FNR), Gerçek Pozitif Oranı (TPR), Gerçek Negatif Oran (TNR) ve Negatif Tahmin Değeri (NPV) gibi farklı performans metrikleri verilmektedir.

Tablo 3. 17. Oluşturulan CNN modelinin sınıflandırma performansı

Metrik	Brown Spot	Sağlıklı	Hispa	Leaf Blast
Doğruluk	98,4	97,2	94,3	92,5
F1-skor	93	99	96	92
Duyarlılık	100	100	93,9	85,7
Hassaslık	86	98	98	100
FDR	13,7	1,9	2,1	0
FPR	5,4	0,6	0,6	0
FNR	0	0	6,1	14,2
TPR	100	100	93,8	85,7
TNR	94,5	99,3	99,3	100
NPV	100	100	98	98,5

Bu tablodaki sonuçlara göre Brown Spot hastalığı %98,4 ile en yüksek doğruluk oranına sahiptir. Hassaslık metrik sonuçları, Leaf Blast hastalığının FP değerine sahip olmadığını, ancak Brown Spot hastalığının en yüksek FP değerine sahip olduğunu göstermektedir. Duyarlılık metriği açısından Brown Spot hastalığı ve sağlıklı sınıfları için FN değerlerinin sıfır olduğu ve bu sınıflar için CNN modelinin en yüksek duyarlılık değerlerine sahip olduğu görülmektedir. F1-skor değeri, hassaslık ve duyarlılık metrik değerlerinin harmonik ortalamasını gösterir.

F1-skor sonuçlarına göre CNN sınıflandırıcı, sağlıklı sınıf çeltik bitkisi için en iyi model tahminine sahiptir. FDR sonuçları, Brown Spot hastalığının çeltik bitkilerinde en yanlış tahmin edilen hastalık olduğunu göstermektedir. FPR metriği sonuçlarından Brown Spot hastalığının en yüksek FP değerine sahip olduğu ve Leaf Blast hastalığının en düşük FP değerine sahip olduğu anlaşılmaktadır. FNR sonuçları, en yüksek FN değerinin çeltik bitkilerinin Leaf Blast hastalığına ait olduğunu göstermektedir. TPR metriğinin sonuçlarına bakıldığında, CNN modeli Brown Spot hastalığı ve sağlıklı sınıflar için en yüksek TP değerlerine sahiptir. TNR metrik sonuçlarında TN değeri açısından Leaf Blast hastalığı en iyisi, Brown Spot hastalığı ise tüm sınıflar arasında en kötüsüdür. NPV sonuçlarına göre, Brown Spot hastalığı ve sağlıklı çeltik bitkisi sınıfları için bu sınıflara ait olmayanları tahmin etme olasılığı %100'dür.

4. STANDART RGB GÖRÜNTÜLERİNDEN NDVI DEĞERİ TAHMİNİ

Çeltik bitkisinin hastalıklarının tespitinin erken bir şekilde yapılması hastalığın çok yayılmadan önlem alınması için oldukça önemlidir. Tarım alanında hastalık erken teşhisi için NIR sensörüne sahip multispektral kamera sistemleri kullanılmaktadır. Bu kamera sistemlerinde standart RGB kameralarda bulunan 3 banttan (R, G ve B) daha fazla bant (NIR, RE vb.) bulunur. NIR ve kırmızı band değerlerinden NDVI değerleri bulunmaktadır. Ancak NDVI değerini bulmak için kullanılan bu kameraların maliyetli ve kurulum işlemlerinin zor olmasından dolayı standart kamera sistemlerinden bu görüntüleri tahmin etmek için yeni bir yöntem bu bölümde önerilmiştir.

Standart kameralardan elde edilen görüntülere ait kırmızı, yeşil ve mavi bantları kullanılarak NDVI değerlerini tahmin etmek için YSA türlerinden biri olan çok katmanlı algılayıcı (MLP) kullanılmıştır. Bu tez çalışmasında, RGB kameralar ile NDVI değerini tahmin etmek için yeni bir bitki indeksi olarak sinir ağı temelli NDVI (Neural network based – NDVI: nNDVI) sunulmuştur.

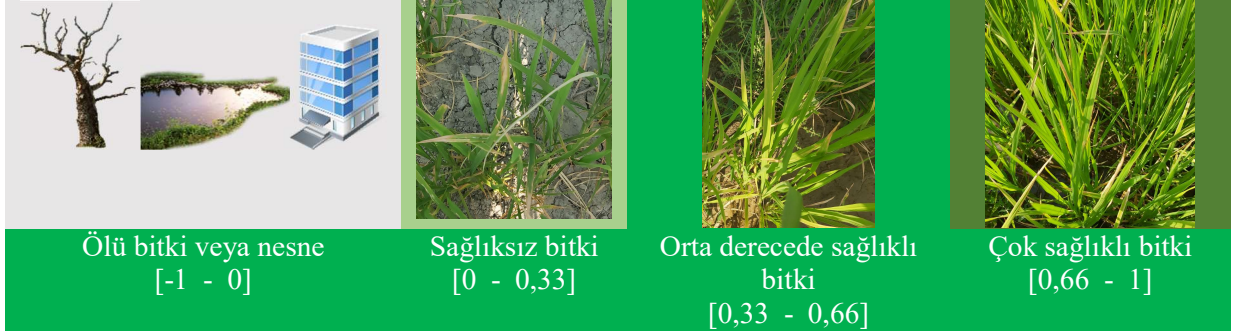
NDVI değerlerini tahmin eden MLP modelinin eğitimi için İsviçre ve Togo’da alınan beş bantlı (Red, Green, Blue, NIR ve RE) görüntüler kullanılarak veri seti oluşturulmuştur. Eğitimi ve testleri yapılan ağa ait sonuçlar ayrıntılı bir şekilde bu başlık altında anlatılmıştır.

4.1. Normalize edilmiş fark bitki örtüsü indeksi (NDVI)

Sağlıklı bir bitki kırmızı ve mavi ışığı emer ve yeşil ışığı yansıtır. Bu yüzden sağlıklı bir bitki yeşil görünmektedir. Bitkiler yeşil görünür ışığın yanında yakın kızılötesi (NIR) ışını da yansıtır ve bitki ne kadar sağlıklı olursa NIR ışını o kadar fazla yansıtır. Bir bitki susuz kaldığında veya strese girdiğinde bitkinin yaprakları NIR ışığı daha az yansıtmaktadır. Bir bitkinin ne kadar sağlıklı olduğunu anlamak için kırmızı ve NIR ışınlarının yansıma değerlerinin karşılaştırılması gerekir. NDVI analizi, uydu görüntülerinin veya multispektral kameralardaki NIR ve kırmızı bantları kullanılarak denklem 4.1’deki formül ile oluşturulmaktadır (Rouse vd., 1973).

$$NDVI = \frac{NIR - R}{NIR + Red} \quad (4.1)$$

Multispektral kameralardan elde edilen NDVI değerlerinin analizi sonucu NDVI haritaları oluşturulur. NDVI analiz sonucunda -1 ile 1 arasında değerler bulunmaktadır. Elde edilen bu analiz sonuçlarına göre bitki durumunu sınıflandırırken Şekil 4.1’de gösterilen aralıklar kullanılmaktadır.

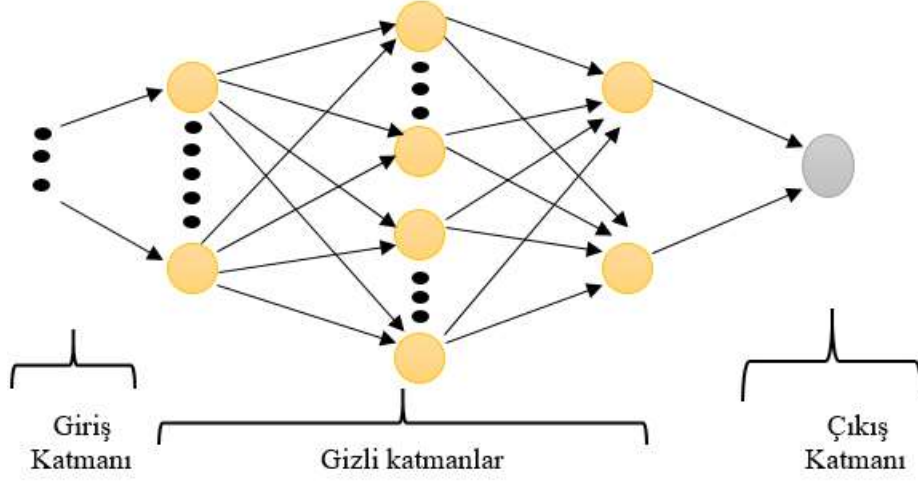


Şekil 4. 1. NDVI değerler aralıklarına göre bitki durumu gösterimi

4.2. Çok katmanlı algılayıcılar (MLP)

MLP, giriş ve çıkış katmanları arasında en az bir katman kullanan bir yapay sinir ağı türüdür. Tek katmanlı algılayıcının aksine, MLP'ler doğrusal olmayan sorunları çözebilir, bu nedenle yaygın kullanımda en popüler YSA türüdür (Kalteh ve Berndtsson, 2007; Arıkan Kargı, 2014). Bu MLP mimari yapısı, giriş katmanından, çıkış katmanından ve k adet gizli katman ve her gizli katmanda m adet nörondan oluşmaktadır (Dhamija ve Bhalla, 2011). Giriş katmanı her bir bağımsız değişkene karşılık gelen çok sayıda nörondan oluşmaktadır. Gizli katman, değişkenler arasındaki doğrusal olmayan ilişkilerin yakalanmasını sağlamaktadır. Çıkış katmanı da tahmin edilen sınıflandırmaya veya öneriye karşılık gelmektedir (Baranoff, 2000). MLP metodu ileri yönde bir yayılım gerçekleştirirken aynı zamanda hatayı en aza indirmek için geriye yayılım algoritması kullanmaktadır. İleri yayılım, ağa uygulanan girişin bir önceki katmandan bir sonraki katmana sırasıyla ilerleyerek çıkış katmanına ulaşmasıdır. Hata sinyali, giriş sinyalinin çıkış katmanına ulaşan değeri ile istenen değeri arasındaki farka denilmektedir. Hata sinyali, çıkış katmanından giriş katmanına doğru ilerler ve ağırlık değerleri güncellenerek hata değerinin en aza indirilmesi amaçlanmaktadır (Kumaşoğlu ve Bolat, 2011). Her gizli birimin, genel olarak doğrusal olmayan ve tüm gizli birimler için aynı olan bir etkinleştirme işlevi vardır. Gizli bir birimin çıktısı, aktivasyon fonksiyonunun, önceki katmandan gelen ağırlıklı sinyallerinin ve ayrı bir sapmanın toplamına uygulanmasıyla belirlenmektedir (Trenn, 2008).

Şekil 4.2'de üç giriş, üç gizli katman ve bir çıkış katmanından oluşan çok katmanlı algılayıcı ağı görülmektedir.



Şekil 4. 2. Örnek bir MLP mimarisi

Çok katmanlı algılayıcıların çalışma yapısı ağırlıkların hesaplandığı ileriye doğru hesaplama ve ağırlıkların güncellendiği geriye doğru hesaplama olmak üzere iki aşamadan oluşmaktadır. İleri doğru hesaplamanın temel amacı verilen giriş değerleri için çıkış değerinin tahmin edilmesi ve hedeflenen değer kullanılarak hatanın hesaplanmasıdır (Murtagh, 1991).

Giriş hücrelerindeki bilgiler ara katman hücrelerine aktarılırken ilgili ağırlıklar ile çarpılmakta ve ağırlıklı toplam fonksiyonuna göre her ara katman hücresinin NET girdisi hesaplanmaktadır:

$$NET_p = \sum_i w_{ip} x_i \quad (4.2)$$

Burada NET_p ara katmanın p. hücresine olan girdi; w_{ip} giriş katmanının i. hücresini, ara katmanın p. hücresine bağlayan ağırlık; x_i giriş katmanındaki i. hücresinin çıkışını temsil etmektedir. Bulunan NET girdi, bir aktivasyon fonksiyonundan geçirilerek, ara katman hücrelerinin çıkışı bulunmaktadır.

$$F_p = f(NET_p) \quad (4.3)$$

Burada F_p ara katmanın p. hücresinin aktivasyon fonksiyonunu göstermektedir. Kullanılacak aktivasyon fonksiyonunun türevlenebilir olması şarttır.

Bu aşamadan sonra hedef değer ile çıkış hücresinde bulunan değeri kullanarak hata hesaplaması yapılmaktadır. Hata hesaplaması:

$$\varepsilon_p = (T_p) - (F_p) \quad (4.4)$$


ε_p hata; T_p hedeflenen çıkış değeri; F_p p. hücrenin hesaplanan değerini göstermektedir. İkinci aşama olan geriye doğru hesaplamada ağırlıklar güncellenerek hata oranının en aza

indirgenmesi amaçlanır. Bunun için hata değerleri geriye doğru yayılır ve ağırlıklara ait güncelleme kuralları oluşturulur. Hata, öncelikli olarak çıkış katmanı ile ara katman arasındaki ağırlık değerleri; sonra ara katman ile giriş katmanı arasındaki ağırlık değerleri hesaplatılarak geriye doğru ilerler (Murtagh, 1991).

4.3. Veri seti


Çeltik bitkisi hastalığının erken dönemlerde tespiti için multispektral kameralar tarafından elde edilen NDVI görüntülere ihtiyaç duyulmaktadır. Bu kamera sistemlerinin maliyetli olması ve kurulumlarının zor olmasından dolayı RGB görüntülerinden NDVI görüntülere dönüştürmek için bir MLP modeli kullanılmıştır. Bu modelin eğitilmesi için aynı alanda çekilmiş RGB ve NIR bandında görüntü alan bir kameraya ihtiyaç duyulmaktadır. Bu bantlardaki verileri elde etmek için Wingtra internet sayfasında sunulan multispektral bir kamera olan MicaSense Altum verileri kullanılmıştır (Wingtra, 2022a).

Wingtra tarafından sunulan iki bölgeye ait veriler alınmıştır. Birinci bölge olan İsviçre'de 50 hektarlık tarım arazisi WingtraOne Micasense Altum sistemi ile haritalanmıştır. Bu haritalar, multispektral katmanlarda 4.0cm/px GSD ve termal LWIR katmanında 61cm/px (uçuş yüksekliği 90 m AGL) ile oluşturulmuştur. İsviçre'deki tarım arazisinden elde edilen örnek bir görüntüye ait bantlar Şekil 4.3'te gösterilmiştir.



Şekil 4. 3. Multispektral kamera görüntüleri (İsviçre'deki tarım alanı); a (Mavi), b (Yeşil), c (Kırmızı), d (NIR), e (RE)

İkinci bölge olan Togo'da 210 hektarlık bir çiftlikte WingtraOne Micasense Altum sistemi ile haritalanmıştır (Wingtra, 2022b). Bu haritalar, multispektral katmanlarda 9.0cm/px GSD ile oluşturulmuştur. Togo'daki çiftlik alanından elde edilen örnek bir görüntüye ait bantlar Şekil 4.4'de gösterilmiştir.




Şekil 4. 4. Multispektral kamera görüntüleri (Togo'daki bir çiftlik); a (Mavi), b (Yeşil), c (Kırmızı), d (NIR), e (RE)


Şekil 4.5'de multispektral kameradan alınan beş kanallı görüntülerden Kırmızı, Yeşil ve Mavi kanallarının Matlab programında yazılan bir betik ile birleştirilmesi sonucunda elde edilen RGB görüntüsü gösterilmiştir. Farklı bir betik ile NDVI hesaplama formülü (NIR ve Kırmızı kanalları kullanılarak) ile ham NDVI görüntüsü ve bitkinin sağlık durumunu net bir şekilde görmek için renklendirilmiş NDVI görüntüsü elde edilmiştir.



(a)



(b)



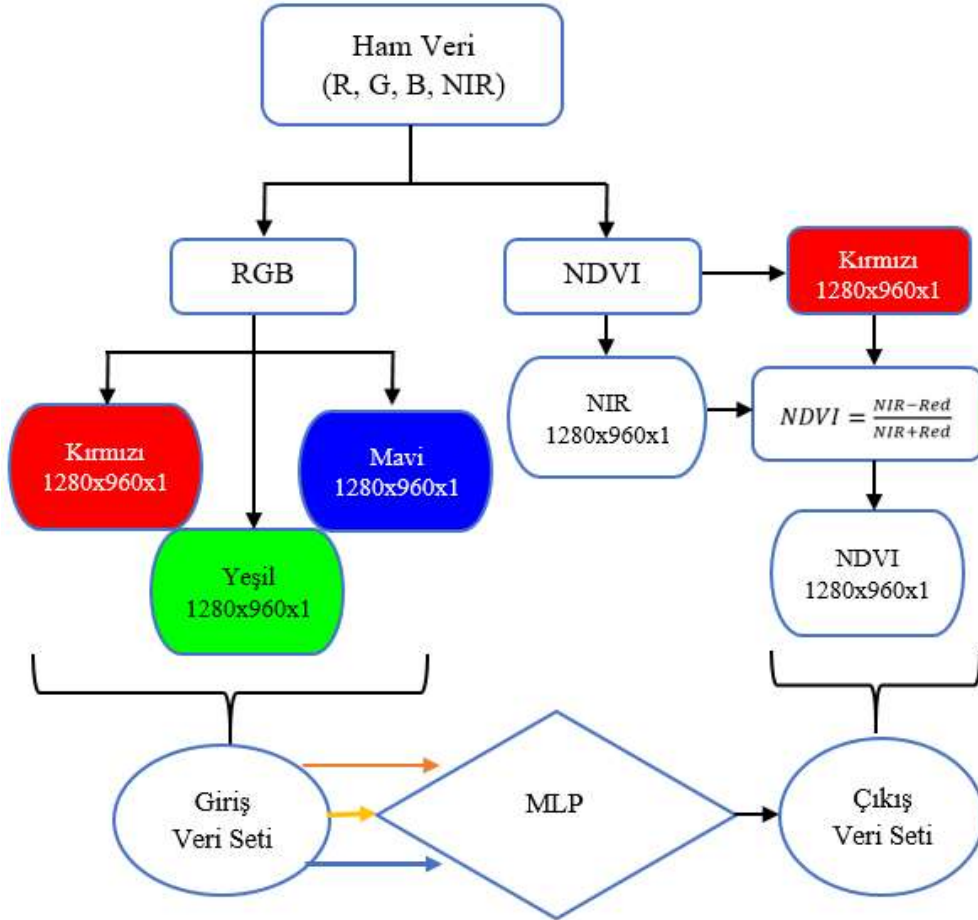
(c)

Şekil 4. 5. RGB görüntüsü (a), ham NDVI görüntüsü (b) ve renkli NDVI görüntüsü (c)

4.4. Veri setinin hazırlanması

Veri seti toplama bölümünde belirtilen veri setine ait görüntüler bu aşamada yapay sinir ağının kullanması için uygun hale getirilmiştir. nNDVI değerini bulmak için kullanılacak yapay

sinir ağının girişine Kırmızı, Yeşil ve Mavi değerleri verilmiştir. Ağın çıkışını hesaplamak için Denklem 4.1’de belirtilen formül sonucunda NDVI değerleri her görüntü için bulunmuştur. İsviçre’deki bir tarım alanından ve Togo’daki bir çiftlikten elde edilen görüntülerden veri setini oluşturmak için Şekil 4.6’da bir şematik gösterimi verilmiştir.



Şekil 4. 6. Giriş-Çıkış veri seti hazırlama şeması


RGB görüntü veren kamera sistemlerinden NDVI tahmin etmek için kullanılacak YSA modeline giriş ve çıkış veri seti oluşturuldu. Giriş veri setine eklenen her bir görüntünün boyutuna ait piksel değeri toplamda 1.228.800 (1280x960x1) boyutundadır. Bu piksel değeri ağa verilecek bir giriş verisini oluşturmaktadır. Oluşturulan ağa üç giriş (R, G ve B) verileceği için Matlab ortamında yazılan bir betik sayesinde 3 sütunlu bir matris oluşturuldu. Veri setine eklenen her bir görüntü oluşturulan bu matrise eklenmiştir. Çıkış veri setini elde etmek için girişte verilen Red bandı ile NIR bandı kullanılarak gerçek NDVI değeri bulunmuştur. YSA ile önerilen nNDVI değerini tahmin etmek için oluşturulan veri seti Tablo 4.1’de verilmiştir.

Tablo 4. 1. Önerilen model için giriş matris boyutu, çıkış matris boyutu ve belirtilen görüntü sayısına göre elde edilen veri seti boyutu

Görüntü sayısı	Giriş matris boyutu	Çıkış matris boyutu	Veri seti boyutu
1 görüntü	[RED; GREEN; BLUE] [1228800; 1228800; 1228800]	[NDVI] [1228800]	1280x960x1=1228800
40 görüntü	[RED; GREEN; BLUE] [49152000; 49152000; 49152000]	[NDVI] [49152000]	1280x960x40=49152000

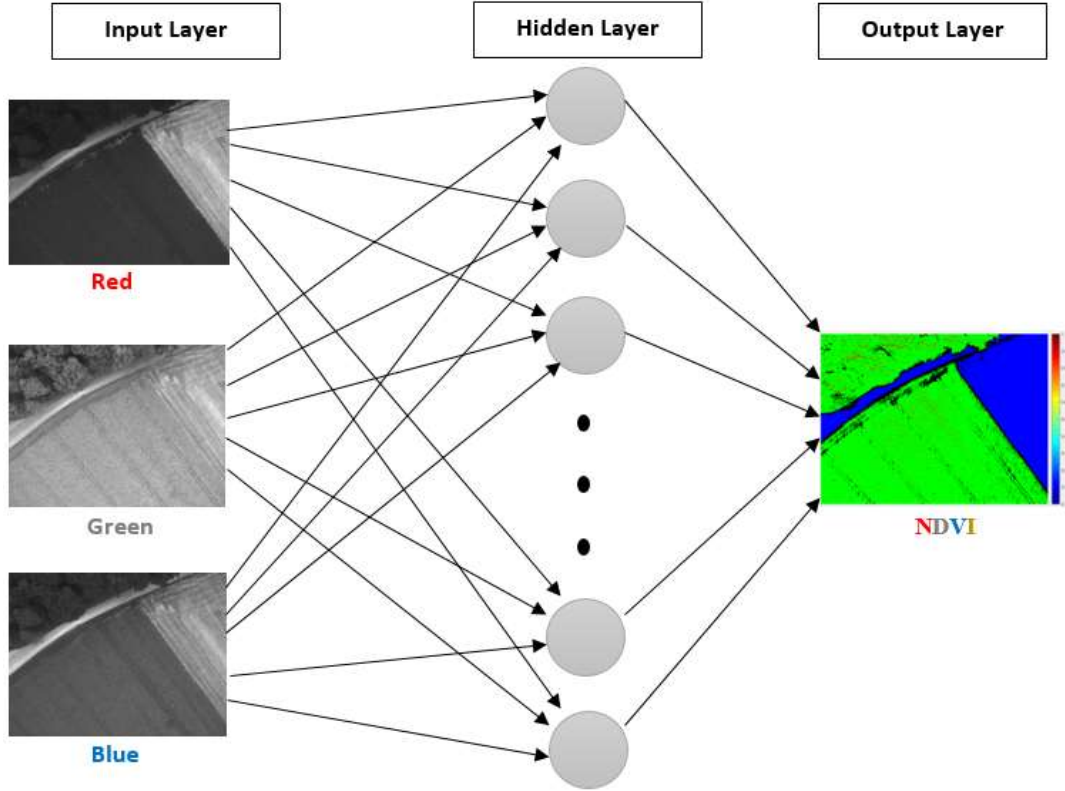
4.5. Sinir ağ tabanlı bitki indeksi (nNDVI)

MLP, giriş ve çıkış katmanları arasında bir veya daha fazla gizli katman bulunan bir YSA çeşididir. Bu çalışma kapsamında NDVI tahmini için YSA türlerinden biri olan MLP modeli kullanılmıştır. Kullanılan MLP modeli üç giriş, bir çıkış ve üç gizli katmandan oluşmaktadır. Modeli oluşturmak, eğitim ve test işlemlerini yapmak için Matlab programı kullanılmıştır. Oluşturulan model Şekil 4.7’de gösterilmiştir. Bu modelin en uygun yapısını oluşturmak için farklı sayıda deneme yanılma yapılmıştır.



Şekil 4. 7. 3 giriş (R, G ve B), 1 (nNDVI) çıkış ve 3 gizli katmandan oluşana MLP modeli

RGB görüntülerden NDVI’yı tahminde yeni bir indeks olan nNDVI elde edilmiştir. Sadece RGB görüntüye ait kamera görüntülerinden önerilen nNDVI değerlerini tahmin için Şekil 4.8’de çok katmanlı YSA modeli daha ayrıntılı bir şekilde gösterilmiştir.



Şekil 4. 8. RGB görüntülerden NDVI tahmini için kullanılan çok katmanlı yapay sinir ağı modeli

Bu modelin girişine kırmızı, yeşil ve mavi kanalları verilir ve çıkışta önerilen nNDVI değeri bulunmaya çalışılmıştır. Çıkışta önerilen nNDVI değerini bulmak için girişte her resimde bulunan kırmızı, yeşil ve mavi kanallardaki pikseller verilmiştir. Ağın eğitimi için hazırlanan veri seti 960×1280 boyutunda 40 görüntüden oluşmaktadır. Ağın çıkışı için her bir görüntünün kırmızı ve NIR bantlarından NDVI değerleri hesaplanarak kullanılmıştır.

4.6. Sonuçlar ve değerlendirme

Tarım alanlarındaki bitkilerin mahsul durumu, canlılığı veya hastalıkların tespitinde NDVI haritalarından faydalanılmaktadır. Tarım alanlarındaki NDVI haritalarını çıkarmak için Landsat-8 gibi uydu görüntülerinden veya multispektral kameralardan elde edilen görüntülerden yararlanılmaktadır. NDVI haritalarını oluşturan bu iki yöntemde yüksek maliyetleri ve görüntüye erişim zorluğu gibi problemleri mevcuttur. Günümüzde tarım alanlarına ait bitki durumları dronelar yardımıyla takip edilebilmektedir. Genellikle tarım alanında görüntü alan dronelarda standart RGB görüntü çeken kamera sistemleri kullanılmaktadır. RGB görüntü alan kameraların yerine multispektral kamera sistemlerinin kullanılması ek bir iş yükü ve aynı zamanda yüksek maliyetlere neden olmaktadır. Bu çalışma kapsamında dronelarda entegre olarak gelen veya manuel olarak kullanılan RGB görüntü alan kamera sistemleri kullanılarak

önerilen nNDVI haritaları oluşturulmuştur. Daha sonra önerilen nNDVI değerlerinin gerçek NDVI değerleri ile karşılaştırılması yapılmıştır.

Oluşturulan bu MLP modelinin en iyi sonuçları, gizli katman sayısı (8, 13, 9) ve her katmandaki nöron sayısı yapılan testler sonucunda bulunmuştur. Modeldeki diğer ağ parametreleri ve bu parametrelerde bulunan sonuçlar Tablo 4.2’de gösterilmiştir.

Tablo 4. 2. Literatürde kullanılan 9 eğitim fonksiyonu ile bulunan başarı oranları

Eğitim fonksiyonu	Test doğruluk oranı
Trainlm	%92,013
Trainbfg	%91,875
Trainrp	%91,122
Trainscg	%91,770
Traincgb	%91,870
Traincgf	%91,687
Traincgp	%91,215
Trainoss	%91,416
Traingdx	%87,515

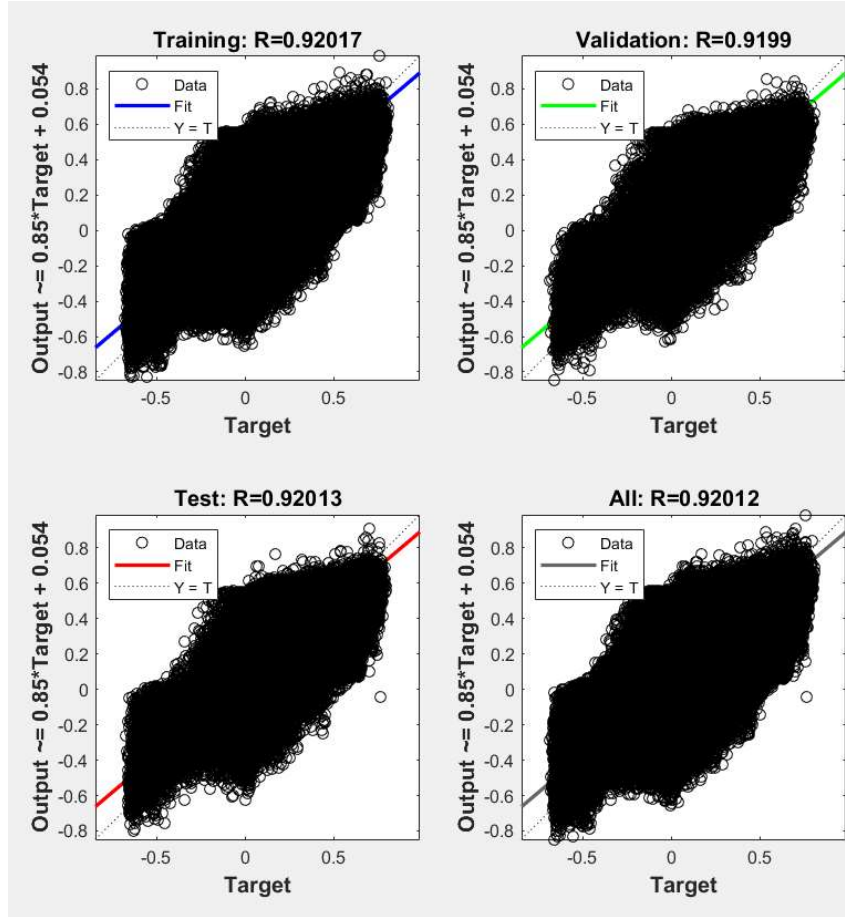
Tablo 4.2’de görüldüğü gibi en iyi başarı oranı trainlm (Levenberg-Marquardt) eğitim fonksiyonunda elde edilmiştir. Tablo 4.3’te test edilen diğer eğitim fonksiyonları ve tanımlamaları gösterilmiştir.

Tablo 4. 3. Modelde kullanılan eğitim fonksiyonları ve tanımlamaları

Eğitim Algoritmaları	Tanım
Trainlm	Levenberg-Marquardt
Trainbfg	BFGS Quasi-Newton
Trainrp	Resilient Backpropagation
Trainscg	Scaled Conjugate Gradient
Traincgb	Conjugate Gradient with Powell/Beale Restarts
Traincgf	Fletcher-Powell Conjugate Gradient
Traincgp	Polak-Ribière Conjugate Gradient
Trainoss	One Step Secant
Traingdx	Variable Learning Rate Backpropagation

Yapılan deney sonuçlarında başarı oranı en yüksek %92,013 ile trainlm (Levenberg-Marquardt) yöntemi, gizli katman sayısı (8, 13, 9) ve performans ölçümü için MSE (Mean Squared Error) kullanılarak elde edilmiştir. Eğitim için veri setinin %70'i, doğrulama (validation) için veri setinin %15'i ve test için veri setinin %15'i alınarak eğitim gerçekleştirilmiştir. Eğitimin tamamlanması 450 tur (epoch) sonunda olmuştur.


Doğrusal regresyon (Linear Regression) iki veri arasındaki doğrusal ilişkiyi inceleyen istatistiksel bir yöntemdir (Su, 2012). MLP ile yapılan deney sonuçları doğrusal regresyon yöntemi ile gösterilmiştir. Ayrıca bu çalışmada bulunan nNDVI değeri ile NDVI değerlerinin sonuçlarının daha kolay yorumlanabilmeleri için Doğrusal regresyon kullanılmıştır. MLP ile eğitim bittikten sonra eğitim, doğrulama ve test başarı sonuçları Şekil 4.9'da gösterilmiştir. Bu doğrusal regresyon değerleri için 34.406.400 piksel eğitim, 7.372.800 piksel doğrulama ve 7.372.800 piksel test veri seti olarak kullanılmıştır.




Şekil 4. 9. MLP ile eğitilen ağın doğrusal regresyon ile elde edilen başarı oranları (eğitim (R=92.017), doğrulama (R=91.999), test (R=92.013) ve hepsi (R=92.012))

Bu çalışma kapsamında MLP ile kullanılan tüm veri setine ait eğitim, doğrulama ve test sonuçları gösterildi. Fakat kullanılan veri seti boyutunun çok olmasından dolayı regresyon

grafiklerinin yorumlanması zorlaşmıştır. Bu yüzden nNDVI ile NDVI değerlerini karşılaştırmak için kullanılan veri setine ait rastgele seçilen 44 piksel değerine ait grafiksel sonuçlar Şekil 4.10'da gösterilmiştir.



(a)




(b)


Şekil 4. 10. Test için kullanılan bir görüntüden rastgele seçilen 44 piksel verisine göre nNDVI ile NDVI karşılaştırma gösterimi (a), kullanılan görüntüdeki 44 piksel verisine göre oluşturulan doğrusal regresyon ile nNDVI ile NDVI gösterimi (b)

Sadece RGB görüntü kullanarak NDVI değerini bulmak için MLP modeli kullanılarak eğitim yapılmıştır. Bu eğitim sonucunda ağın test görüntüleri üzerindeki doğruluk oranı


%92,013 olarak elde edilmiştir. Daha sonra eğitimi yapılan ağa eğitim ve test veri setinde bulunmayan 10 tane RGB görüntüsü verildiğinde Şekil 4.11'deki gibi nNDVI görüntüleri elde edilmiştir. Şekilde gerçek ham NDVI görüntüleriyle önerilen ham nNDVI görüntüleri, gerçek renkli NDVI görüntüleri ile önerilen renkli nNDVI görüntüleri verilmiştir. Yapılan test sonuçlarında ağın performansını ölçmek için her bir test görüntüsü için Ortalama Kareysel Hata (MSE: Mean Squared Error) ile Karekök Ortalama Hata (RMSE: Root Mean Squared Error) değerleri Tablo 4.4'de verilmiştir.




Ham NDVI (Test #1)




Ham nNDVI (Test #1)




Renkli NDVI (Test #1)




Renkli nNDVI (Test #1)




Ham NDVI (Test #2)




Ham nNDVI (Test #2)




Renkli NDVI (Test #2)




Renkli nNDVI (Test #2)




Ham NDVI (Test #3)




Ham nNDVI (Test #3)




Renkli NDVI (Test #3)




Renkli nNDVI (Test #3)




Ham NDVI (Test #4)




Ham nNDVI (Test #4)



Renkli NDVI (Test #4)




Renkli nNDVI (Test #4)




Ham NDVI (Test #5)




Ham nNDVI (Test #5)




Renkli NDVI (Test #5)




Renkli nNDVI (Test #5)




Ham NDVI (Test #6)




Ham nNDVI (Test #6)




Renkli NDVI (Test #6)




Renkli nNDVI (Test #6)




Ham NDVI (Test #7)




Ham nNDVI (Test #7)




Renkli NDVI (Test #7)




Renkli nNDVI (Test #7)




Ham NDVI (Test #8)



Ham nNDVI (Test #8)




Renkli NDVI (Test #8)




Renkli nNDVI (Test #8)




Ham NDVI (Test #9)




Ham nNDVI (Test #9)



Renkli NDVI (Test #9)



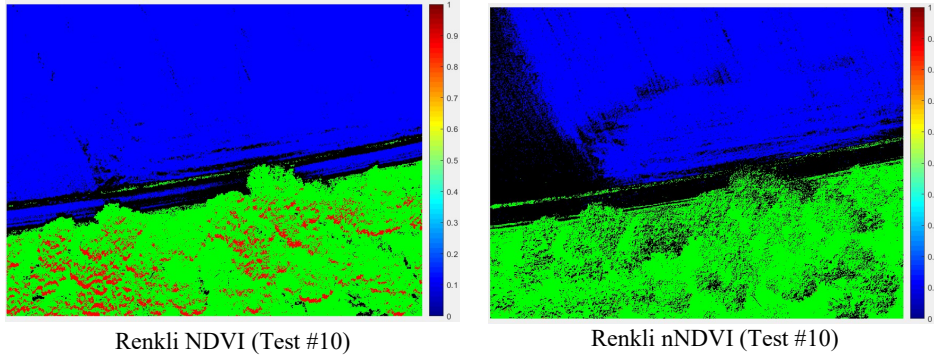
Renkli nNDVI (Test #9)



Ham NDVI (Test #10)



Ham nNDVI (Test #10)



Şekil 4. 11. Eğitimi yapılmış ağıın bulduğu nNDVI görüntü ile NDVI görüntüsü

Tablo 4. 4. Yapılan 10 test görüntüsü için ağıın performansı

Test No	MSE	RMSE
Test #1	0.0532	0.2307
Test #2	0.0356	0.1888
Test #3	0.0258	0.1607
Test #4	0.0260	0.1611
Test #5	0.0347	0.1862
Test #6	0.0180	0.1342
Test #7	0.0359	0.1895
Test #8	0.0277	0.1664
Test #9	0.0794	0.2817
Test #10	0.0236	0.1537

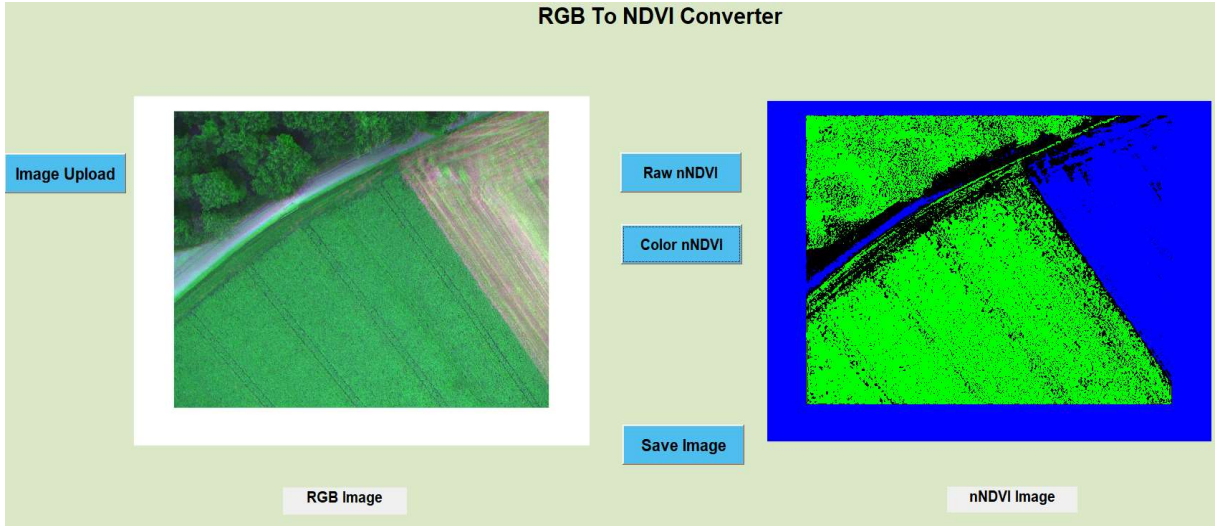
MLP modeli ile RGB görüntülerden NDVI tahmini için geliştirilen ağıın başarıım oranı test verileri üzerinden %92,013 olarak elde edilmiştir. Önerilen nNDVI modelinin başarıımını farklı görüntüler üzerinden test etmek için eğitim ve test aşamasında ağıa verilmeyen 10 görüntü kullanılmıştır. Bu 10 görüntüye ait sonuçlar Şekil 4.11’de ve Tablo 4.4’de verilmiştir. Yapılan testlerin performanslarının ölçümü için her bir görüntüdeki tüm piksellerin gerçek NDVI değerleri bulunmuş ve önerilen modelden alınan nNDVI sonuçları ile aralarındaki hata değerleri (MSE ve RMSE) hesaplanmıştır. Sonuçlar incelendiğinde hata oranlarını düşük çıkan testlerdeki görüntülerin renklendirilmiş gerçek NDVI ile önerilen nNDVI görüntülerin daha çok benzerlik göstermiştir.

5. SİNİR AĞI TABANLI BİTKİ İNDEKSİ (nNDVI) İLE ÇELTİK BİTKİSİ HASTALIĞININ TESPİTİ

Bu bölümde bir önceki bölümde standart RGB görüntülerinden NDVI verilerine dönüştürme işlemi (nNDVI elde etme) kullanılarak öncelikle Kaggle veri setindeki çeltik bitkisine ait RGB yaprak görüntüleri nNDVI verilerine dönüştürülmüştür. Ardından bu yeni nNDVI veri seti ile 3. bölümde kullanılan CNN modeli tekrar eğitilerek test edilmiştir. Sonuçlar nNDVI verileri ile elde edilen CNN başarımlarının RGB verileri ile yapılan başarımlarından daha üstün olduğunu ortaya koymaktadır.

5.1. Veri setinin hazırlanması

Bir önceki bölümde yapılan deneyler sonucunda NIR sensörüne sahip olmayan RGB görüntüler ile bulunan NDVI tahminlerinde başarılı sonuçlara ulaşılmıştı. NDVI değerini tahmin etmek için kullanılan MLP modelinin eğitim sonucunda en iyi model parametreleri kaydedilmiştir. Eğitilen bu model ile çeltik bitkisine ait görüntülerin nNDVI değerlerine dönüştürme işlemi gerçekleştirilmiştir. Bu işlemi gerçekleştirmek için Matlab GUI ile bir arayüz hazırlanmıştır. Şekil 5.1’de RGB görüntüler kullanılarak NDVI değerinin tahmin işlemini yapan GUI arayüzü gösterilmiştir.



Şekil 5. 1. RGB görüntülerden nNDVI görüntüsünü elde eden arayüz programı

Bu dönüşüm için yapılan programda “Image Upload” butonu tıklanarak RGB görüntüler eklenilir, “Raw nNDVI” veya “Color nNDVI” butonları tıklanarak önerilen nNDVI görüntüler elde edilir. Dönüştürme işlemi için “Raw nNDVI” veya “Color nNDVI” butonu tıkladığı anda program arka planda daha önce MLP ile eğitilmiş olan ağı çalışma alanına ekler ve yüklenen RGB görüntüsünün tüm pikselleri ağı verilip nNDVI verisine dönüştürülür. İşlem bittikten

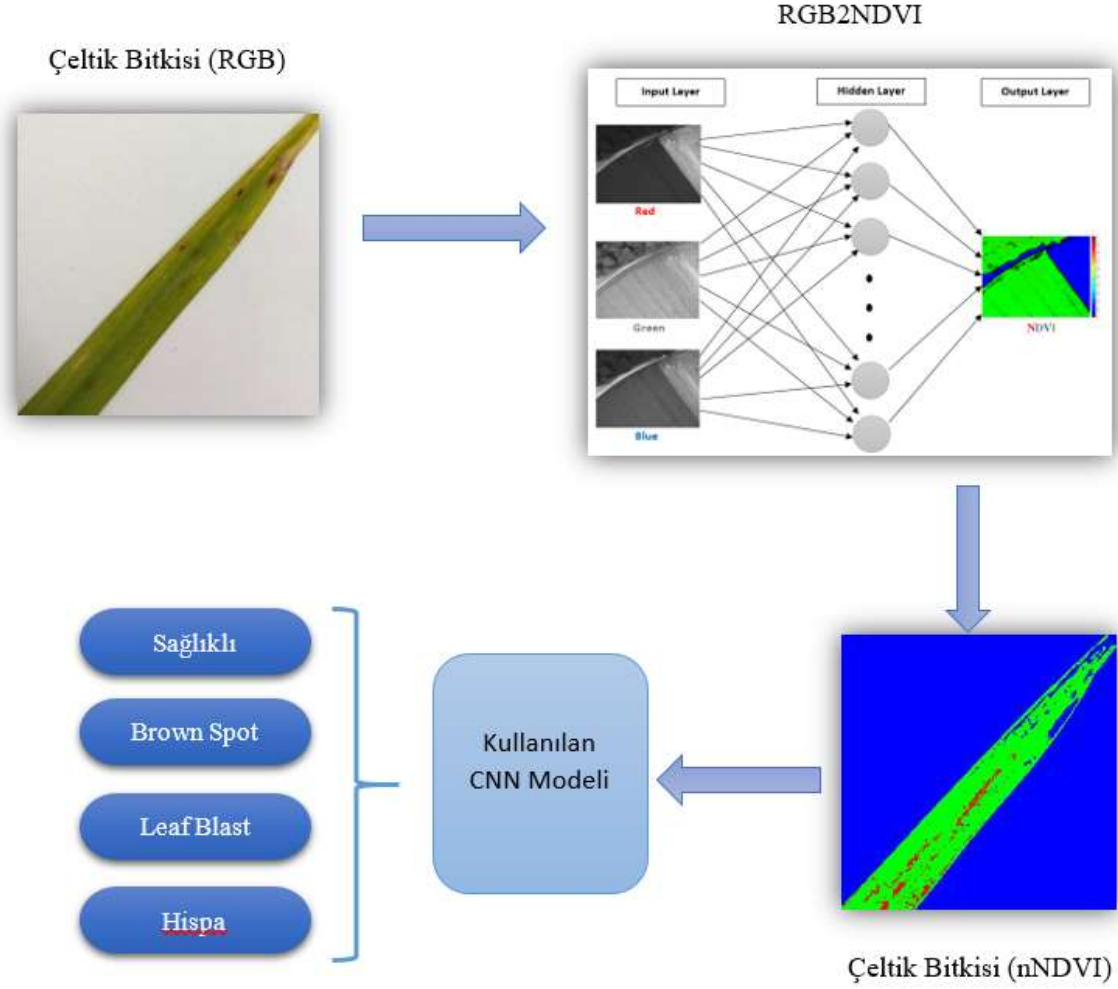
sonra istenildiği takdirde elde edinilen nNDVI verisinden oluşan görüntü “Save Image” butonu ile kaydedilebilir.

RGB'den NDVI verisine dönüştürme işlemi için hazırlanan bu arayüz ilk başta teker teker görüntü dönüşümüne izin vermekteydi. CNN modelinin eğitimi için verilen 3341 çeltik bitkisi görüntüsünün bu arayüz ile dönüştürme işlemi uzun sürmektedir. Bu nedenle geliştirilen arayüze daha sonra toplu görüntü verme ve toplu dönüştürme işlemi için bir modül geliştirilip eklendi. Bu modül ile çeltik bitkisine ait tüm görüntüler kısa bir süre içerisinde dönüştürme işlemi yapıp yeni nNDVI değerleri elde edilmiştir.

5.2. Evrişimsel sinir ağı ile çeltik bitkisinin nNDVI değerinden hastalık tespiti (sağlıklı ve 3 hastalık için)

Çeltik bitkisine ait hastalıkların erken tespiti için önerilen yöntem ile RGB görüntüler NDVI görüntülere dönüştürüldü. Daha önce elde edilen veri setinde ve çeltik bitkisine ait sıklıkla rastlanan hastalıkları ayırt etmek için sağlıklı ve üç hastalıklı (Brown Spot, Leaf Blast ve Hispa) olmak üzere dördü sınıflandırma yapılmıştı. Bu sınıflandırmada kullanılan görüntüler NDVI değerlere dönüştürüldü ve daha önce RGB görüntülerin dördü sınıflandırması için CNN modeli (bkz. Şekil 3.13) ile tekrardan eğitilmiştir. Çeltik bitkisi görüntülerinin boyutu OpenCV Kütüphanesi kullanılarak 100x100 boyutuna indirgenmiş ve nNDVI değerlere dönüştürüldükten sonra CNN modeline giriş olarak verilmiştir.


Bu tez kapsamında çeltik bitkisine ait hastalıkların erken tespitinin yapılması için önerilen sistemin genel gösterimi Şekil 5.2’de gösterilmiştir.




Şekil 5. 2. Çeltik bitkisine ait hastalıkların erken tespit sisteminin genel gösterimi

5.3. Sonuçlar ve değerlendirme


Çeltik bitkisine ait RGB görüntülerin NDVI görüntülere dönüştürme işlemi için geliştirilen sisteme tüm görüntülerin verilir NDVI değerlerinin bulunması gerekmektedir. Bu işlemi için önerilen sisteme 3341 çeltik görüntüsünün teker teker verilmesi gerekmektedir. Bu görüntülerin bu şekilde verilmesi zaman kaybına neden olacağı için görüntülerin toplu bir şekilde verilmesine imkân sağlayan bir betik yazıldı. Bu işlem sonucu çeltik bitkisine ait tüm RGB görüntüleri NDVI görüntülere dönüştürülmüştür. Dönüştürme işlemi sonucunda elde edilen bazı NDVI görüntüleri Şekil 5.3'te gösterilmiştir.




Brown Spot



Hispa



Leaf Blast



Sağlıklı

Şekil 5. 3. Önerilen dönüştürme işleminden sonra elde edilen renklendirilmiş nNDVI görüntüleri

Çeltik bitkisine ait hastalıkların erken tespiti için oluşturulan CNN modelinde kullanılmak üzere nNDVI görüntüleri oluşturulmuştur. Elde edilen bu görüntülerin %75'i eğitim, %25'i test için kullanılmıştır. Bu veriler kullanılarak oluşturulan CNN modeli bir kez daha eğitilmiştir. Eğitilen ağa test görüntüleri verildiğinde %96,97 oranında bir başarı elde edilmiştir. Oluşturulan bu yöntem ile daha önceki yöntemlerin karşılaştırılması Tablo 5.1'de verilmiştir.

Tablo 5. 1. Derin öğrenme modelleri ile çeltik bitkisi hastalık tespiti uygulama sonuçları

Sınıflandırma	Ön işleme	Bölütleme	Özellik Çıkarımı	Doğruluk oranı
CNN	-	-	-	%85,48
CNN	Arka Plan Kaldırma	-	-	%92,78
CNN	nNDVI	-	-	%96,97

CNN modeline RGB görüntüler ile eğitim işlemi yapılırken en uygun hiper parametreler (eğitim tur sayısı, veri boyutu, öğrenme oranı, küme boyutu, optimize ediciler vb.) bulunmuştu. Modelin en yüksek doğruluk oranı verdiği hiperparametreler nNDVI görüntüler ile eğitimi yapılan modelde de kullanılmıştır. Bu hiperparametrelerden küme boyutu 16 olarak seçilmiştir. Öğrenme oranı değeri için $1e-4$ ve eğitim tur sayısı da 750 seçilmiştir. Bu model ile çeltik bitkisine ait hastalık tespiti için Adam optimizasyon algoritması kullanılmıştır.

CNN modelinin test veri setinin bir kısmına (tüm sınıflar için 198 veri alınmıştır) uygulanmasıyla elde edilen karışıklık matrisi Tablo 5.2'de gösterilmiştir. Karışıklık matrisinde Doğru Pozitif (TP), Yanlış Pozitif (FP), Gerçek Negatif (TN) ve Yanlış Negatif (FN) değerleri vardır. Bu matriste Brown Spot, Sağlıklı, Hispa, Leaf Blast sınıfları için TP değerleri sırasıyla 49, 49, 48 ve 46'dır. FN değerleri Brown Spot, Healthy, Hispa, Leaf Blast sınıfları için sırasıyla 0, 1, 2 ve 3'dir. Brown Spot, Sağlıklı, Hispa, Leaf Blast sınıfları için TN değerleri sırasıyla 149, 143, 148 ve 148'dur. Brown Spot, Sağlıklı, Hispa, Leaf Blast sınıfları için FP değerleri sırasıyla 0, 5, 0 ve 1'dir.

Tablo 5. 2. CNN modeli kullanılarak elde edilen karışıklık matrisi (nNDVI görüntüler için), BS: Brown Spot, H: Healthy, His: Hispa, LB: Leaf Blast

BS	49	0	0	0
H	0	49	0	1
His	0	2	48	0
LB	0	3	0	46
	BS	H	His	LB

Tablo 5.3'te sağlıklı ve çeltik bitkisi hastalıkları için kullanılan CNN tabanlı dörtlü sınıflandırıcının nNDVI görüntüler üzerindeki performansı özetlenmektedir. Bu tabloda Doğruluk, F1 skor, Duyarlılık, Hassaslık, Yanlış Keşif Oranı (FDR), Yanlış Pozitif Oranı (FPR), Yanlış Negatif Oranı (FNR), Gerçek Pozitif Oranı (TPR), Gerçek Negatif Oran (TNR) ve Negatif Tahmin Değeri (NPV) gibi farklı performans metrikleri gösterilmiştir.

Tablo 5. 3. Oluşturulan CNN modelinin sınıflandırma performansı (nNDVI görüntüleri için)

Metrik	Brown Spot	Sağlıklı	Hispa	Leaf Blast
Doğruluk	100	98	96	93,8
F1-skor	100	94	98	96
Duyarlılık	100	98	96	94
Hassaslık	100	90,7	100	97,8
FDR	0	0,09	0	0,02
FPR	0	0,03	0	0,006
FNR	0	0,02	0,04	0,06
TPR	100	98	96	93,8
TNR	100	96,6	100	99,3
NPV	100	99,3	98,6	98

Bu tablodaki sonuçlara göre Brown Spot hastalığı %100 ile en yüksek doğruluk oranına sahiptir. Hassaslık metrik sonuçları, Brown Spot ile Hispa hastalığının FP değerine sahip olmadığını, ancak sağlıklı çeltik bitkilerinde en yüksek FP değerine sahip olduğunu göstermektedir. Duyarlılık metriği açısından Brown Spot hastalığı için FN değerlerinin sıfır olduğu ve bu sınıf için CNN modelinin en yüksek duyarlılık değerlerine sahip olduğu görülmektedir.

F1-skor sonuçlarına göre CNN sınıflandırıcısı, Brown Spot sınıfı için en iyi model tahminine sahiptir. FDR sonuçları, Leaf Blast hastalığının çeltik bitkilerinde en yanlış tahmin edilen hastalık olduğunu göstermektedir. FPR metriği sonuçlarından Leaf Blast hastalığının en yüksek FP değerine sahip olduğu ve sağlıklı çeltik bitkisi ile Brown Spot hastalığının en düşük FP değerine sahip olduğu anlaşılmaktadır. FNR sonuçları, en yüksek FN değerinin çeltik bitkilerinin Leaf Blast hastalığına ait olduğunu göstermektedir. TPR metriğinin sonuçlarına

bakıldığında, CNN modeli Brown Spot hastalığı ve sağlıklı sınıflar için en yüksek TP değerlerine sahiptir. TNR metrik sonuçları incelendiğinde Brown Spot ile Hispa hastalıklarının en doğru sınıflandırma sonucunu verdiği görülmektedir. NPV sonuçlarına göre, Brown Spot hastalığı ve sağlıklı çeltik bitkisi sınıfları için bu sınıflara ait olmayanları tahmin etme olasılığı %100'dür.

Bu tez çalışması kapsamında çeltik bitkisine ait hastalıkların erken tespiti için ihtiyaç duyulan NDVI görüntülerinin elde edilmesinin maliyetli olmasından dolayı RGB görüntülerin NDVI görüntülere dönüştürmek için bir yöntem geliştirildi. Geliştirilen bu yöntem ile çeltik bitkisine ait görüntülerin hepsi NDVI değerlere (nNDVI) dönüştürüldü. Bu işlemde sonra CNN modeline elde edilen bu yeni görüntüler verildi. CNN modelinden alınan sonuçlara göre çeltik bitkisine ait hastalıkların tespiti için nNDVI görüntüler ile elde edilen doğruluk oranı (%96,97), RGB görüntülerden elde edilen doğruluk oranında (%92,78) daha yüksek çıktığı görülmüştür.

6. SONUÇLAR VE TARTIŞMA

Bu tez çalışması kapsamında çeltik alanlarında önemli bir sorun oluşturan çeltik bitkisi hastalıklarının yapay zeka modelleriyle erken tespiti ele alınmıştır. Ekili alanlar üzerinden çeltik bitkilerinin görüntülenmesi ve analiz edilmesi ile belirlenen farklı çeltik hastalıklarının tespitlerini yapmak, çalışmanın ana konuları arasındadır. Çalışma temel olarak üç kısımdan oluşmaktadır. İlk olarak, çeltik bitkisi yapraklarının RGB görüntüleri kullanılarak bir derin öğrenme modeli (CNN) ile çeltik bitkisinde yaygın bir şekilde çıkan hastalıkların (Brown spot, Hispa ve Leaf Blast) ve sağlıklı görüntülerin tespiti yapıldı. İkinci olarak tarımsal analizlerde kullanılan NDVI değerlerini tahmin etmek için bir MLP modeli önerilerek yeni bir sinir ağı tabanlı bitki indeksi (nNDVI) sunuldu. Son olarak çeltik bitkisinin nNDVI öngörü değerleri kullanılarak bir derin öğrenme modeli ile çeltik bitkisi hastalıklarının tespiti gerçekleştirildi.

Bu tez kapsamında çeltik bitkisi hastalığının tespiti için ilk önce YSA modellerinden olasılıksal bir sinir ağı (PNN) ile yapılan eğitim işleminden sonra doğruluk oranı %77 olarak elde edildi. Yapılan araştırmalar ve deneyler sonucu derin öğrenme yöntemlerinden biri olan CNN modeli ile çeltik bitkisinin yapraklarının RGB görüntülerinden çeltik bitkisi hastalıkları tespit edilmiştir. Elde edilen veri setindeki görüntüler kullanılarak CNN modeli eğitildikten sonra yapılan test sonucunda %85,48 doğruluk oranı elde edildi. Hastalığın tespiti için veri setindeki tüm görüntülerdeki arka plandaki gürültüler kaldırıldıktan sonra test işlemi sonucunda %92,78'lik bir doğruluk oranına ulaşılmıştır.

Tarım alanlarında bitki hastalıklarının erken tespiti için genellikle multispektral kamera sistemleri kullanılmaktadır. Bu kamera sistemlerinin maliyetlerinin yüksek olmasından dolayı birçok çiftçi tarım alanlarında bu sistemleri kullanamamaktadır. Multispektral kamera sistemlerinde bulunan NIR sensörü ve kırmızı bant değeri sayesinde NDVI değerleri elde edilmektedir. Bu çalışma kapsamında daha ucuz ve alternatif bir yöntem olarak NDVI değerlerini standart RGB görüntü veren kamera sistemleri kullanılarak elde etmek için bir MLP modeli önerildi. Önerilen bu model ile RGB görüntülerinden NDVI verileri %92,013 oranında doğru bir şekilde tahmin edilmiştir. Çeltik bitkisine ait elde edilen RGB görüntüler bu yöntem ile NDVI görüntülere dönüştürülüp CNN modeli ile eğitim işlemi yapıldı. Bu işlem sonucunda ise çeltik bitkisi hastalıkları tespitinde %96,97 oranında bir doğruluk oranı elde edilmiştir.

Bugüne kadar çeltik bitkisi hastalıklarına yönelik yapılan çalışmalar incelenmiştir. Yapılan bu incelemeler sonucunda hastalık tespitinde güncel çalışmalarda derin öğrenme modelleri kullanıldığı görülmüştür. Derin öğrenme yöntemleri ile elde edilen başarımların sonuçları yapılan ön işleme ve kullanılan transfer öğrenme yöntemlerinden dolayı her çalışmada farklı

çıkılmaktadır. Önerdiğimiz dönüşüm sonra elde edilen görüntüler ile derin öğrenme ağı eğitildiğinde elde ettiğimiz sonuçlar yapılan çalışmalara göre iyi sonuçlar elde edildiği görülmüştür. Önerilen modelin çeltik bitkisi hastalıkların tespitine yönelik yapılan diğer çalışmalar ile karşılaştırılması Tablo 6.1’de gösterilmektedir.

Tablo 6. 1. Çeltik bitkisi hastalıkların tespiti üzerine yapılan çalışmalar ile önerilen yöntemin karşılaştırılması.

Araştırmacılar	Yöntemler	Veri Seti	Kullanılan kameralar (veri seti için)	Doğruluk
(Zhou vd., 2019)	FCM-KM ve Faster-RCNN birleşimi	Hunan Piriñç Araştırma Enstitüsü'nün piriñç tarlası. Çin	Canon EOS R (piksel: 2,400 X 1,600)	%97.5
(Phadikar, 2012)	Bayes ve SVM sınıflandırıcısı	Doğu Midnapur, Hindistan'ın piriñç tarlası görüntüleri	Nikon COOLPIX P4 dijital fotoğraf makinesi	Bayes Sınıflandırıcısı: %79.5 SVM: %68.1
(Ramesh ve Vydeki, 2020)	Jaya Optimizasyon Algoritması (DNN_JOA) ile Optimize Edilmiş Derin Sinir Ağı	Çiftlik alanı	Yüksek çözünürlüklü dijital kamera	%94.25
(Li vd., 2020)	Faster-RCNN	Anhui, Jiangxi ve Hunan Eyaletindeki piriñç tarlası. Çin	Cep telefonu kamerası (iPhone7 ve HUAWEI P10) ve Sony DSC-QX10 kamera	%84.1
(Prajapati vd., 2017)	SVM	Çiftlik alanı	NIKON D90 dijital SLR (12.3 megapiksel)	5 kat çapraz doğrulama: %83.80 10 kat çapraz doğrulama: %88.57
(Rathore ve Prasad, 2020)	CNN (ikili sınıflandırma)	Kaggle veri seti	-	%99.61
(Rahman vd., 2020)	Basit CNN	Bangladeş Piriñç Araştırma Enstitüsü'nün (BRRI) piriñç tarlaları	Dört farklı kamera türü	%94.33
(Bari vd., 2021)	Faster-RCNN	Hem saha verileri hem de Kaggle veri kümesi	Akıllı telefon kamerası (Xiaomi Redmi 8)	%98.84
(Zhou vd., 2013)	Bulanık C-ortalamalar (FCM)	Dafeng çiftliği. Çin	Canon SX110 IS Dijital kamera	%87
(Sabri Elmitwally vd., 2022)	Alex-Net	-	Dijital Kamera	%99
(Natarajan vd., 2021)	CNN+ InceptionResNet42	Kaggle veri seti	-	%95.67
(Ghosal ve Sarkar, 2020)	CNN+ VGG-16	International Rice Research Institute (IRRI)	Motorola E4 Plus ve Redmi 5A telefon kamerası	%92.46
Önerilen model	nNDVI+CNN	Kaggle veri seti	-	İkili sınıflandırma: %97.57 Dörtlü sınıflandırma: %96.97

Çeltik bitkisine ait hastalıkların tespitinde önerilen 12 yöntem tabloda gösterilmiştir. Önerdiğimiz yöntem ile çeltik bitkisine ait hastalıkların tespitinde elde ettiğimiz başarı oranı incelenen bu 12 çalışmadan 9 tanesinden daha yüksek çıkmıştır. Yapılan bazı çalışmalarda CNN modelinin yanında VGG-16 ile InceptionResNet42 gibi transfer öğrenme yöntemleride kullanılmıştır. Tez kapsamında transfer öğrenme kullanmadan önerilen yöntem, transfer öğrenme ile eğitilen ağlardan daha yüksek başarı oranı elde edilmiştir. Çeltik bitkisi hastalıkların tespiti için yapılan çalışmalarda RGB görüntüler kullanıldığı görülmüştür. Önerilen yöntemde RGB görüntülerin nNDVI değerleri hesaplanmıştır. Elde edilen nNDVI değerler kullanıldığında çeltik bitkisi hastalıkların tespitinde daha başarılı sonuçlar elde edilmiştir.

Çeltik bitkisinin üretildiği bölgenin sulak olmasından dolayı geleneksel yöntemler ile veri setinin hazırlanması oldukça zordur. Bu görüntüleri elde etmek için pirinç ekili alanlarda İHA kullanılması gerekmektedir. Görüntülerin bu şekilde elde edilmesi ve İHA ile görüntü alınırken hastalığın tespit edilmesi ayrı bir araştırma konusu olabilmektedir.

İlerleyen çalışmalarda RGB görüntüleri NDVI görüntülere dönüştürmek için farklı yapay zekâ yöntemleri denenebilir. Bu yöntemlerin denenmesi ile daha başarılı dönüşümler yapılabilir. Önerilen yöntemle dönüştürme işlemi farklı tarım alanlarındaki ürünlere uygulanabilir. RGB den NDVI verileri elde eden yazılımı standart kamera sistemleri ile birleştirilip gerçek zamanlı dönüşüm yapılabilir. Bu sayede tarım alanlarında kullanılan İHA'lara entegre olarak gelen kamera sistemlerine bu yazılım yüklenebilir.

Derin öğrenme yöntemlerinden biri olan CNN ile gerçekleştirilen eğitim sonuçlarında başarılı sonuçlar elde edilmiştir. Fakat sonraki çalışmalarda başarı oranını veya hastalığı tespit hızını daha da artırmak için CNN yerine farklı bir yapay zekâ yöntemi araştırılabilir. Önerilen bu sistem, farklı ürünlere ait hastalıkların veya zararlı otların tespitinde de kullanılabilirliği test edilebilir.

KAYNAKÇA

- Akçalı, E.** (2014). *Çukurova'da Çeltik Yanıklığı Hastalığı (Pyricularia Oryzae Cav.)'nın Epidemiyolojisi ve Mücadelesi Üzerine Çalışmalar.* (Yayınlanmış Doktora Lisans Tezi). Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Hatay.
- Ampatzidis, Y., & Partel, V.** (2019). UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. *Remote Sensing*, 11(4), 410. <https://doi.org/10.3390/rs11040410>.
- Arai, K., Gondoh, K., Shigetomi, O., & Yuko.** (2016). Method for NIR reflectance estimation with visible camera data based on regression for NDVI estimation and its application for insect damage detection of rice paddy fields. *International Journal of Advanced Research in Artificial Intelligence*, 5(11). <https://doi.org/10.14569/ijarai.2016.051103>.
- Arıkan Kargı, V. S.** (2014). A comparison of artificial neural networks and multiple linear regression models as in predictors of fabric weft defects . *Textile and Apparel* , 24 (3) , 309-316 . Retrieved from <https://dergipark.org.tr/en/pub/tekstilvekonfeksiyon/issue/23645/251871>.
- Atole, R. R., & 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 : IJACSA*, 9(1). <https://doi.org/10.14569/ijacsa.2018.090109>.
- Balasundaram, D., Burks, T. F., Bulanon, D. M., Schubert, T., & Lee, W. S.** (2009). Spectral reflectance characteristics of citrus canker and other peel conditions of grapefruit. *Postharvest Biology and Technology*, 51(2), 220–226. <https://doi.org/10.1016/j.postharvbio.2008.07.014>
- Baranoff, E. G., Sager, T. W., & Shively, T. S.** (2000). A semiparametric stochastic spline model as a managerial tool for potential insolvency. *The Journal of Risk and Insurance*, 67(3), 369. <https://doi.org/10.2307/253834>.
- Bari, B. S., Islam, M. N., Rashid, M., Hasan, M. J., Razman, M. A. M., Musa, R. M., ... & Majeed, A. P. A.** (2021). A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework. *PeerJ Computer Science*, 7, e432.
- Başçıl, M. S. , Çetin, O. , Er, O. & Temurtaş, F.** (2012). A study on Parkinson's Disease Diagnosis Using Probabilistic Neural Network . *Electronic Letters on Science and Engineering* , 8 (1) , 1-10 . Retrieved from <https://dergipark.org.tr/en/pub/else/issue/29312/313742>.
- Bernaux, P.** (1966). *L'epidemie de Pyriculariose du Riz en France en 1966.* Bull. Inf. Rizic. Fr., 63: 11-15.

Bhagawati, R., Bhagawati, K., Singh, A. K. K., Nongthombam, R., Sarmah, R., & 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.

Blast (leaf and collar). (2022). (*n.d.*). *Org.* [Erişim: 15.05.2022, <http://www.knowledgebank.irri.org/training/fact-sheets/pestmanagement/diseases/item/blast-leaf-collar>].

Bravo, C., Moshou, D., Oberti, R., West, J., McCartney, A., Bodria, L., & Ramon, H. (2004). Foliar disease detection in the field using optical sensor fusion. *International Commission of Agricultural Engineering*, Vol. *VI Manuscript FP*, 4(008).

Bremer, H., ve Özkan, H. (1946). *Türkiye’de Çeltik Hastalıkları*. *Ziraat Dergisi*, 73-74: 41-53.

Brodbeck, C., Sikora, E., Delaney, D., Pate, G., & Johnson, J. (2017). Using unmanned aircraft systems for early detection of soybean diseases. *Advances in Animal Biosciences*, 8(2), 802–806. <https://doi.org/10.1017/s2040470017001315>.

Brown Spot. (2022). (*n.d.*). *Org.* [Erişim: 15.05.2022, <http://www.knowledgebank.irri.org/training/factsheets/pestmanagement/diseases/item/brown-spot>].

ChandraKarmokar, B., Samawat Ullah, M., Kibria Siddiquee, M., & Md. Rokibul Alam, K. (2015). Tea leaf diseases recognition using neural network ensemble. *International Journal of Computer Applications*, 114(17), 27–30. <https://doi.org/10.5120/20071-1993>.

Chauhan, B. S., Jabran, K., & Mahajan, G. (Eds.). (2017). *Rice production worldwide* (Vol. 247). Cham, Switzerland: Springer International Publishing.

Costa, L., Nunes, L., & Ampatzidis, Y. (2020). A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. *Computers and Electronics in Agriculture*, 172(105334), 105334. <https://doi.org/10.1016/j.compag.2020.105334>

Crop Protection. (2022). (*n.d.*). *Tnau.Ac.In.* [Erişim: 15.05.2022, https://agritech.tnau.ac.in/expert_system/paddy/cppests_ricehispa.html].

Dash, J. P., Watt, M. S., Pearse, G. D., Heaphy, M., & Dungey, H. S. (2017). Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease

outbreak. *ISPRS Journal of Photogrammetry and Remote Sensing: Official Publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)*, 131, 1–14. <https://doi.org/10.1016/j.isprsjprs.2017.07.007>.

DeChant, C., Wiesner-Hanks, T., Chen, S., Stewart, E. L., Yosinski, J., Gore, M. A., Nelson, R. J., & Lipson, H. (2017). Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning. *Phytopathology*, 107(11), 1426–1432. <https://doi.org/10.1094/PHYTO-11-16-0417-R>.

Demirhan, A., & Güler, İ. (2010). Özörgütlemeli Harita Ağları Ve Gri Düzey Eş Oluşum Matrisleri İle Görüntü Bölütleme. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 25(2).

Deng, G., & Cahill, L. W. (2005). An adaptive Gaussian filter for noise reduction and edge detection. *1993 IEEE Conference Record Nuclear Science Symposium and Medical Imaging Conference*.

Deng, L., Mao, Z., Li, X., Hu, Z., Duan, F., & Yan, Y. (2018). UAV-based multispectral remote sensing for precision agriculture: A comparison between different cameras. *ISPRS Journal of Photogrammetry and Remote Sensing: Official Publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)*, 146, 124–136. <https://doi.org/10.1016/j.isprsjprs.2018.09.008>

Dhamija, A. K., & Bhalla, V. K. (2011). Exchange rate forecasting: comparison of various architectures of neural networks. *Neural Computing & Applications*, 20(3), 355–363. <https://doi.org/10.1007/s00521-010-0385-5>.

Durmus, H., Gunes, E. O., & Kirci, M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. 2017 6th International Conference on Agro-Geoinformatics.

Elmacı, A. (2012). Güney Marmara Çeltik Alanlarında Çeltik Yanıklık Hastalığının (*Pyricularia Oryzae* Cavara) Yaygınlık Ve Yakalanma Oranları İle Hastalık Şiddetinin Belirlenmesi. (Yayınlanmış Yüksek Lisans Tezi). Ege Üniversitesi, Fen Bilimler Enstitüsü, İzmir.

Fuentes, A., Yoon, S., Kim, S., & Park, D. (2017). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors (Basel, Switzerland)*, 17(9), 2022. <https://doi.org/10.3390/s17092022>.

Ghosal, S., & Sarkar, K. (2020). Rice leaf diseases classification using CNN with transfer learning. *2020 IEEE Calcutta Conference (CALCON)*.

- Gibbins, D., Roberts, P., & Swierkowski, L.** (2005). A video Geo-location and image enhancement tool for small unmanned air vehicles (UAVs). Proceedings of the 2004 Intelligent Sensors, Sensor Networks and Information Processing Conference, 2004.
- Gitelson, A. A., & Merzlyak, M. N.** (1998). Remote sensing of chlorophyll concentration in higher plant leaves. *Advances in Space Research: The Official Journal of the Committee on Space Research (COSPAR)*, 22(5), 689–692. [https://doi.org/10.1016/s0273-1177\(97\)01133-2](https://doi.org/10.1016/s0273-1177(97)01133-2).
- Gül, U.** (2003). Çeltik. Tarımsal Ekonomi Araştırma Enstitüsü – Bakış, Sayı: 3, Nüsha: 15, Ankara.
- Haralick, R. M., Shanmugam, K., & Dinstein, I.** (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics, SMC-3*(6), 610–621. <https://doi.org/10.1109/tsmc.1973.4309314>.
- He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Houborg, R., & McCabe, M.** (2016). High-resolution NDVI from planet’s constellation of earth observing nano-satellites: A new data source for precision agriculture. *Remote Sensing*, 8(9), 768. <https://doi.org/10.3390/rs8090768>.
- Jiahao, C., Ruifeng, G., Zonghuan, X., Liping, K., Renye, W., Yanjin, L., & Chunlai, Z.** (2005). Meteorological forecast model for early-season rice panicle blast in the northwest of Fujian province and its application. *Acta Agriculturae Universitatis Jiangxiensis*, 27(2), 205-209.
- Joshi, A. A., & Jadhav, B. D.** (2016). Monitoring and controlling rice diseases using Image processing techniques. *2016 International Conference on Computing, Analytics and Security Trends (CAST)*.
- Kaggle.** (2020). *Rice Diseases Image Dataset*. [Erişim: 01.23.2019, <https://www.kaggle.com/datasets/minhhuy2810/rice-diseases-image-dataset>].
- Kalteh, A. M., & Berndtsson, R.** (2007). Interpolating monthly precipitation by self-organizing map (SOM) and multilayer perceptron (MLP). *Journal Des Sciences Hydrologiques [Hydrological Sciences Journal]*, 52(2), 305–317. <https://doi.org/10.1623/hysj.52.2.305>.
- Kane, K. E., & Lee, W. S.** (2007). Multispectral imaging for in-field green citrus identification. In *2007 ASAE Annual Meeting* (p. 1). American Society of Agricultural and Biological Engineers.
- Kato, H.** (2001). *Rice blast disease. Rice blast control*. The Royal Society of Chemistry Japan. s. 23-25. DOI :10.1039/b100803j.

- Kerkech, M., Hafiane, A., & Canals, R.** (2018). Deep learning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Computers and Electronics in Agriculture*, *155*, 237–243. <https://doi.org/10.1016/j.compag.2018.10.006>
- Kim, K.K., ve Yoshino, R.** (1994). *Epidemiological studies of rice blast disease caused by Pyricularia oryzae*. *Ann. Phytopathol. Soc. Jpn.* 61:89-92.7.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, *60*(6), 84–90. <https://doi.org/10.1145/3065386>.
- Kumar, A., Bhandari, A. K., & Padhy, P.** (2012). Improved normalised difference vegetation index method based on discrete cosine transform and singular value decomposition for satellite image processing. *IET Signal Processing*, *6*(7), 617. <https://doi.org/10.1049/iet-spr.2011.0298>.
- Kumaşođlu, G., & Bolat, B.** (2011). Yapay sinir ađlarıyla mőzikal tőr tanıma. *Elektrik-Elektronik Bilgisayar Sempozyumu (FEEB), Elazıđ, Tőrkiye*, *5*(7).
- LeCun, Y., Bengio, Y., & Hinton, G.** (2015). Deep learning. *Nature*, *521*(7553), 436–444. <https://doi.org/10.1038/nature14539>.
- Li, D., Wang, R., Xie, C., Liu, L., Zhang, J., Li, R., Wang, F., Zhou, M., & Liu, W.** (2020). A recognition method for rice plant diseases and pests video detection based on deep convolutional neural network. *Sensors (Basel, Switzerland)*, *20*(3), 578. <https://doi.org/10.3390/s20030578>.
- Li, L., Zhang, Q., & Huang, D.** (2014). A review of imaging techniques for plant phenotyping. *Sensors (Basel, Switzerland)*, *14*(11), 20078–20111. <https://doi.org/10.3390/s141120078>
- Liu, B., Zhang, Y., He, D., & Li, Y.** (2017). Identification of apple leaf diseases based on deep convolutional neural networks. *Symmetry*, *10*(1), 11. <https://doi.org/10.3390/sym10010011>.
- Liu, Z.-Y., Huang, J.-F., & Tao, R.-X.** (2008). Characterizing and estimating fungal disease severity of rice brown spot with hyperspectral reflectance data. *Rice Science*, *15*(3), 232–242. [https://doi.org/10.1016/s1672-6308\(08\)60047-5](https://doi.org/10.1016/s1672-6308(08)60047-5).
- Lu, J., Hu, J., Zhao, G., Mei, F., & Zhang, C.** (2017). An in-field automatic wheat disease diagnosis system. *Computers and Electronics in Agriculture*, *142*, 369–379. <https://doi.org/10.1016/j.compag.2017.09.012>.
- Lu, R.** (2004). Multispectral imaging for predicting firmness and soluble solids content of apple fruit. *Postharvest Biology and Technology*, *31*(2), 147–157. <https://doi.org/10.1016/j.postharvbio.2003.08.006>.

- Lu, Y., Yi, S., Zeng, N., Liu, Y., & Zhang, Y.** (2017). Identification of rice diseases using deep convolutional neural networks. *Neurocomputing*, *267*, 378–384. <https://doi.org/10.1016/j.neucom.2017.06.023>.
- Ma, J., Du, K., Zheng, F., Zhang, L., Gong, Z., & Sun, Z.** (2018). A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network. *Computers and Electronics in Agriculture*, *154*, 18–24. <https://doi.org/10.1016/j.compag.2018.08.048>.
- Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F., & Zhang, Y.** (2018). Very deep Convolutional Neural Networks for complex land cover mapping using multispectral remote sensing imagery. *Remote Sensing*, *10*(7), 1119. <https://doi.org/10.3390/rs10071119>.
- Mohanty, S. P., Hughes, D. P., & Salathé, M.** (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, *7*, 1419. <https://doi.org/10.3389/fpls.2016.01419>.
- Moshou, D., Bravo, C., Oberti, R., West, J., Bodria, L., McCartney, A., & Ramon, H.** (2005). Plant disease detection based on data fusion of hyper-spectral and multi-spectral fluorescence imaging using Kohonen maps. *Real-Time Imaging*, *11*(2), 75–83. <https://doi.org/10.1016/j.rti.2005.03.003>.
- Murtagh, F.** (1991). Multilayer perceptrons for classification and regression. *Neurocomputing*, *2*(5–6), 183–197. [https://doi.org/10.1016/0925-2312\(91\)90023-5](https://doi.org/10.1016/0925-2312(91)90023-5).
- Naidu, R. A., Perry, E. M., Pierce, F. J., & Mekuria, T.** (2009). The potential of spectral reflectance technique for the detection of Grapevine leafroll-associated virus-3 in two red-berried wine grape cultivars. *Computers and Electronics in Agriculture*, *66*(1), 38–45. <https://doi.org/10.1016/j.compag.2008.11.007>.
- Natarajan, K., Narasimha Prasad, L. V., Pavan Kumar, C. S., Subedi, B., Abraha, H. B., & E, S., V.** (2021). Rice leaf diseases prediction using deep neural networks with transfer learning. *Environmental Research*, *198*(111275), 111275. <https://doi.org/10.1016/j.envres.2021.111275>.
- Novotná, K., Rajsnerová, P., Miša, P., & Klem, M. M. K.** (2013). Normalized red-edge index–new reflectance index for diagnostics of nitrogen status in barley. *Mendel Net*, 120–126.
- Otsu, N.** (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, *9*(1), 62–66. <https://doi.org/10.1109/tsmc.1979.4310076>.

- Ökten, İ., Yüzgeç, U.** (2022a). Rice Plant Disease Detection Using Image Processing and Probabilistic Neural Network. In: Seyman, M.N. (eds) Electrical and Computer Engineering. ICECENG 2022. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol 436. Springer, Cham. https://doi.org/10.1007/978-3-031-01984-5_7.
- Ökten, İ. & Yüzgeç, U.** (2022b). Evrişimli Sinir Ağı ile Çeltik Bitkisi Hastalığının Tespiti . Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 11 (1), 203-217. DOI: 10.17798/bitlisfen.1014393.
- Özşahin, E.** (2008). *Gönen Ovasında Pirinç Tarımı*. Fırat Üniversitesi Sosyal Bilimler Dergisi, 18, 49-70.
- Peng, S., Tang, Q., & Zou, Y.** (2009). Current status and challenges of rice production in China. *Plant Production Science*, 12(1), 3-8.
- Phadikar, S.** (2012). Classification of rice leaf diseases based on Morphological changes. *International Journal of Information and Electronics Engineering*. <https://doi.org/10.7763/ijiee.2012.v2.137>.
- Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ter Haar Romeny, B., Zimmerman, J. B., & Zuiderveld, K.** (1987). Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3), 355–368. [https://doi.org/10.1016/s0734-189x\(87\)80186-x](https://doi.org/10.1016/s0734-189x(87)80186-x).
- Prajapati, H. B., Shah, J. P., & Dabhi, V. K.** (2017). Detection and classification of rice plant diseases. *Intelligent Decision Technologies*, 11(3), 357–373. <https://doi.org/10.3233/idt-170301>.
- Rabatel, G., Gorretta, N., & Labbé, S.** (2011). Getting NDVI spectral bands from a single standard RGB digital camera: A methodological approach. In *Advances in Artificial Intelligence* (pp. 333–342). Springer Berlin Heidelberg.
- Rabatel, G., Gorretta, N., & Labbé, S.** (2014). Getting simultaneous red and near-infrared band data from a single digital camera for plant monitoring applications: Theoretical and practical study. *Biosystems Engineering*, 117, 2–14. <https://doi.org/10.1016/j.biosystemseng.2013.06.008>.
- Rahman, C. R., Arko, P. S., Ali, M. E., Iqbal Khan, M. A., Apon, S. H., Nowrin, F., & Wasif, A.** (2020). Identification and recognition of rice diseases and pests using convolutional neural networks. *Biosystems Engineering*, 194, 112–120. <https://doi.org/10.1016/j.biosystemseng.2020.03.020>.

- Ramesh, S., & 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/10.1016/j.inpa.2019.09.002>.
- Rathore, N. P. S., & Prasad, L.** (2020). Automatic rice plant disease recognition and identification using convolutional neural network. *Journal of critical reviews*, 7(15), 6076–6086.
- Rice Production.** (2021). (Peace Corps): Chapter 14. Diseases of rice. [Erişim: 19.10.2021, <http://www.nzdl>].
- Rouse Jr, J. W., Haas, R. H., Schell, J. A., & Deering, D. W.** (1973). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation* (No. NASA-CR-132982).
- Sabri Elmitwally, N., Tariq, M., Adnan Khan, M., Ahmad, M., Abbas, S., & Mazaed Alotaibi, F.** (2022). Rice leaves disease diagnose empowered with transfer learning. *Computer Systems Science and Engineering*, 42(3), 1001–1014. <https://doi.org/10.32604/csse.2022.022017>
- Sankaran, S., Mishra, A., Ehsani, R., & Davis, C.** (2010). A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture*, 72(1), 1–13. <https://doi.org/10.1016/j.compag.2010.02.007>.
- Sannier, C. A. D., Taylor, J. C., & Plessis, W. D.** (2002). Real-time monitoring of vegetation biomass with NOAA-AVHRR in Etosha National Park, Namibia, for fire risk assessment. *International Journal of Remote Sensing*, 23(1), 71–89. <https://doi.org/10.1080/01431160010006863>
- Sezgin, M., & Sankur, B.** (2004). Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic imaging*, 13(1), 146–165.
- Simonyan, K., & Zisserman, A.** (2014). Very deep convolutional networks for large-scale image recognition. In *arXiv [cs.CV]*. <http://arxiv.org/abs/1409.1556>.
- Skamonti, P., ve Gurr S.J.** (2009). *Against the grain: safeguarding rice from rice blast disease*. View Journal Information. 27(3): 141-150. DOI:10.1016/j.tibtech.2008.12.002.
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D.** (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 2016, 3289801. <https://doi.org/10.1155/2016/3289801>.

- Stehman, S. V.** (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*, 62(1), 77–89. [https://doi.org/10.1016/s0034-4257\(97\)00083-7](https://doi.org/10.1016/s0034-4257(97)00083-7).
- Specht, D. F.** (1990). Probabilistic neural networks. *Neural Networks: The Official Journal of the International Neural Network Society*, 3(1), 109–118. [https://doi.org/10.1016/0893-6080\(90\)90049-q](https://doi.org/10.1016/0893-6080(90)90049-q).
- Su, X., Yan, X., & Tsai, C.-L.** (2012). Linear regression: Linear regression. *Wiley Interdisciplinary Reviews. Computational Statistics*, 4(3), 275–294. <https://doi.org/10.1002/wics.1198>.
- Sürek, H.** (2002). *Çeltik Tarımı*. Hasat Yayıncılık, İstanbul, s. 66-70.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z.** (2016). Rethinking the inception architecture for computer vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Tan, L., & Jiang, J.** (2019). Image Processing Basics. In *Digital Signal Processing* (pp. 649–726). Elsevier.
- Tang, L., Chen, S., Liu, W., & Li, Y.** (2011). Improved retinex image enhancement algorithm. *Procedia Environmental Sciences*, 11, 208–212. <https://doi.org/10.1016/j.proenv.2011.12.032>.
- TensorFlow.** (2020). *Tf.Keras.Preprocessing.Image.ImageDataGenerator*, [Erişim: 09.01.2020, https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator]].
- Tharreau, D., Fudal, I., Andriantsimalona, D., Santoso., Utumi, D., Fournier, E., Lebrun, M.H., ve Notteghem J.L. Edited by: Wang, G.L., Valent, B.** (2009). *World Population Structure and Migration of the Rice Blast Fungus, Magnaporthe oryzae*. Conference: 4th International Rice Blast Conference. Changsha, China. Date: OCT 09.14, 2007. s. 209, DOI: 10.1007/978-1-4020-9500-9_21.
- Thenkabail, P. S., Smith, R. B., & De Pauw, E.** (2000). Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. *Remote Sensing of Environment*, 71(2), 158–182. [https://doi.org/10.1016/s0034-4257\(99\)00067-x](https://doi.org/10.1016/s0034-4257(99)00067-x)
- Trenn, S.** (2008). Multilayer perceptrons: approximation order and necessary number of hidden units. *IEEE Transactions on Neural Networks*, 19(5), 836–844. <https://doi.org/10.1109/TNN.2007.912306>.

TÜİK (Türkiye İstatistik Kurumu). (2021). [Erişim: 19.05.2021, [URL:https://biruni.tuik.gov.tr/medas/?kn=92&locale=tr](https://biruni.tuik.gov.tr/medas/?kn=92&locale=tr)].

TÜİK (Türkiye İstatistik Kurumu). (2020). *2018 Yılına Ait Veriler*. [Erişim: 25.09.2020, <http://www.tuik.gov.tr/>].

Turan, A. (2013). *Çimlendirilmiş Esmer Pirinç Keki Üretiminin Biyoaktif Bileşenlere Etkisi*. (Yayınlanmış Yüksek Lisans Tezi). Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.

Van Nguyen, N., & Ferrero, A. (2006). Meeting the challenges of global rice production. *Paddy and Water Environment*, 4(1), 1-9.

Wang, G., Sun, Y., & Wang, J. (2017). Automatic image-based plant disease severity estimation using deep learning. *Computational Intelligence and Neuroscience*, 2017, 1–8. <https://doi.org/10.1155/2017/2917536>

Wang, L., Jin, J., Song, Z., Wang, J., Zhang, L., Rehman, T. U., Ma, D., Carpenter, N. R., & Tuinstra, M. R. (2020a). LeafSpec: An accurate and portable hyperspectral corn leaf imager. *Computers and Electronics in Agriculture*, 169(105209), 105209. <https://doi.org/10.1016/j.compag.2019.105209>

Wang, L., Duan, Y., Zhang, L., Rehman, T., Ma, D., & Jin, J. (2020b). Precise estimation of NDVI with a simple NIR sensitive RGB camera and machine learning methods for corn plants. *Sensors (Basel, Switzerland)*, 20(11), 3208. <https://doi.org/10.3390/s20113208>

Weizheng, S., Yachun, W., Zhanliang, C., ve Hongda, W. (2008). Grading method of leaf spot disease based on image processing. *2008 International Conference on Computer Science and Software Engineering*, 491-494.

Wen, Z., & Tao, Y. (1999). Building a rule-based machine-vision system for defect inspection on apple sorting and packing lines. *Expert Systems with Applications*, 16(3), 307–313. [https://doi.org/10.1016/s0957-4174\(98\)00079-7](https://doi.org/10.1016/s0957-4174(98)00079-7).

Wingtra. (2020a). *Agricultural field in Switzerland. MicaSense Altum, 48ha, 4cm/px*. [Erişim: 21.04.2020, <https://drive.google.com/drive/folders/1HsM6NoFMtJlhh-SmxjnYHyRcVuAx3535>].

Wingtra. (2020b). *Model Farm in Togo, MicaSense RedEdge-M, 210 ha, 9 cm/px*. [Erişim: 21.04.2020, https://drive.google.com/drive/folders/1qtMXZCDk_rRglrACGO-V9WOWxZJI3bxS].

Wu, W. (2014). The generalized difference vegetation index (GDVI) for dryland characterization. *Remote Sensing*, 6(2), 1211–1233. <https://doi.org/10.3390/rs6021211>.

- Xu, H. R., Ying, Y. B., Fu, X. P., & Zhu, S. P.** (2007). Near-infrared spectroscopy in detecting leaf miner damage on tomato leaf. *Biosystems Engineering*, 96(4), 447–454. <https://doi.org/10.1016/j.biosystemseng.2007.01.008>.
- Yang, C. M., & Cheng, C. H.** (2001). Spectral characteristics of rice plants infested by brown planthoppers. *Proceedings of the National Science Council, Republic of China. Part B, Life Sciences*, 25(3), 180–186.
- Yang, C.-M., Cheng, C.-H., & Chen, R.-K.** (2007). Changes in spectral characteristics of rice canopy infested with brown planthopper and leafhopper. *Crop Science*, 47(1), 329–335. <https://doi.org/10.2135/cropsci2006.05.0335>.
- Zhou, G., Zhang, W., Chen, A., He, M., & Ma, X.** (2019). Rapid detection of rice disease based on FCM-KM and faster R-CNN fusion. *IEEE Access: Practical Innovations, Open Solutions*, 7, 143190–143206. <https://doi.org/10.1109/access.2019.2943454>.
- Zhou, Z., Zang, Y., Li, Y., Zhang, Y., Wang, P., & Luo, X.** (2013). Rice plant-hopper infestation detection and classification algorithms based on fractal dimension values and fuzzy C-means. *Mathematical and Computer Modelling*, 58(3-4), 701-709.
- Zou, Q., Fang, H., Liu, F., Kong, W., & He, Y.** (2011). Comparative study of distance discriminant analysis and BP neural network for identification of rapeseed cultivars using visible/near infrared spectra. In *Computer and Computing Technologies in Agriculture IV* (pp. 124–133). Springer Berlin Heidelberg.