MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİTKİ GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ İÇİN DERİN ÖĞRENME MODELİ

TÜLİN BOYAR

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Yüksek Lisans Programı

DANIŞMAN

Doç. Dr. Kazım YILDIZ

EŞ-DANIŞMAN

Doç. Dr. Önder Demir

İSTANBUL, 2024

MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİTKİ GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ İÇİN DERİN ÖĞRENME MODELİ

TÜLİN BOYAR

(523621006)

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Yüksek Lisans Programı

DANIŞMAN

Doç. Dr. Kazım YILDIZ

EŞ-DANIŞMAN

Doç. Dr. Önder Demir

İSTANBUL, 2024

ÖNSÖZ

Tez çalışmamın araştırılmasında ve yürütülmesinde her daim destek olan, her fırsatta yardımını esirgemeyen değerli danışmanım Doç.Dr. Kazım YILDIZ'a, eşdanışmanım Doç.Dr. Önder Demir'e ve FYL-2022-10761 numaralı proje desteğinden dolayı Marmara Üniversitesi Bilimsel Araştırma Projeleri birimine,

Tez çalışmam boyunca desteği ve sabrı için kıymetli arkadaşlarıma ve bugünlere gelmemde büyük pay sahibi olan değerli anneme ve babama

Teşekkürlerimi sunarım.

HAZİRAN,2024 **TÜLİN BOYAR**

İÇİNDEKİLER

ÖNSÖZ ..... **I**

İÇİNDEKİLER ..... **II**

ÖZET ..... **IV**

ABSTRACT ..... **V**

SEMBOLLER ..... **VI**

KISALTMALAR ..... **VII**

TABLO LİSTESİ ..... **VIII**

ŞEKİL LİSTESİ ..... **IX**

1. GİRİŞ **1**

1.1. GENEL BAKIŞ **1**

1.1.1. Problemin Tanımı **2**

1.1.2. Amaç ve Hedef **3**

1.1.3. Ana Katkılar **5**

1.1.4. Tez Organizasyonu **6**

1.2. LITERATÜR TARAMASI **6**

2. MATERYAL VE YÖNTEM **14**

2.1. VERI SETI **14**

2.2. DERİN ÖĞRENME MİMARİSİ **16**

2.2.1. Yapay Sinir Ağları (YSA) **16**

2.2.1.1. Toplama Fonksiyonu 18

2.2.1.2. Aktivasyon Fonksiyonu 18

2.2.2. Evrişimsel Sinir Ağları **19**

2.2.3. U-Net Derin Öğrenme Modeli ve Çeşitleri **20**

2.2.3.1. Base U-Net 20

2.2.3.2. Attention U-Net 21

2.2.3.3. Inception U-Net 22

2.2.3.4. Residual U-Net 24

2.2.3.5. U-Net+ RCN 26
2.2.3.6. Dense U-Net 27
2.2.3.7. U-Net++ 27
2.3. METODOLOJİ 28
2.3.1. Performans Metrikleri 30
3. SONUÇLAR VE TARTIŞMA 33
3.1. FARKLI MODELLERIN KARŞILAŞTIRMALI ANALIZI 33
3.2. MEVCUT ARAŞTIRMALARIN ÖTESINDE U-NET DERIN ÖĞRENME MODELLERINI KULLANAN ÇEŞITLI BITKI YAPRAK HASTALIKLARI TESPIT YAKLAŞIMLARININ DEĞERLENDIRILMESI 35
4. SONUÇLAR 38
KAYNAKÇA 40
ÖZGEÇMİŞ

ÖZET

BİTKİ GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ İÇİN DERİN ÖĞRENME MODELİ

Günümüzde tarımda karşılaşılan en büyük sorunlardan bir tanesi bitki hastalıklarıdır. Farklı tarım ürünlerinde meydana gelen bitki hastalıkları o yılki mahsulü etkilemekte, verimi düşürmekte üretici ekonomisine ve ülke ekonomisine zarar vermektedir. Bitki hastalıklarının geneli bulaşıcı olup hızla yayılmaktadır. Bu nedenle erken tespit edilerek, hastalıklı kısımlara zirai ilaçlama ile müdahale edilemezse; hastalık yayılarak ürün bahçesini, serasını veya tarlasını sarabilmektedir. Yılda bir veya birkaç defa mahsul alabilmek için göz ardı edilemez bir emek ortaya konulmaktadır ve oldukça fazla zaman alan, maliyetli bir hazırlık sürecinden geçilmektedir. Burada harcanan emek, zaman ve maliyetin nihai amacına ulaşması yani tarım ürünlerinin veriminin artması ve karşılaşılan bitki hastalıklarının çözülmesi oldukça önemlidir.

Bu tez çalışmasının amacı bahçe ve örtülü alanların insansız hava aracı ile gerçek zamanlı taranarak bitki yapraklarında oluşan hastalıkları tespit eden bir derin öğrenme modeli önermektir. U-Net tabanlı derin öğrenme modelleri özellik çıkarma, veri arttırma ve veri segmantasyon teknkiklerini kullanan çok katmanlı mimarisiyle bitki hastalıkları tespitinde avantajlıdır. Çalışma kapsamında fındık bahçelerinden insansız hava aracı ile elde edilen görüntülerle özgün bir veri seti oluşturulmuş ve U-Net tabanlı Base U-Net, Attention U-Net, Inception U-Net, Residual U-Net, RCN+ U-Net, Dense U-Net ve U-Net++ modelleriyle eğitim için tercih edilmiştir. U-Net++ modeli 1.68 çalışma süresiyle; piksel doğruluğu %88.06, mDice değeri %64.49 olarak sonuç elde edilmiştir.

ABSTRACT

DEEP LEARNING MODEL FOR DISEASE DETECTION FROM PLANT IMAGES

One of the biggest problems encountered in agriculture today is plant diseases. Plant diseases occurring in different agricultural products affect that year's crop, reduce yield and harm the producer's economy and the country's economy. Most plant diseases are contagious and spread rapidly. Therefore, if they are not detected early and the diseased parts cannot be treated with agricultural pesticides; the disease can spread and invade the product garden, greenhouse or field. In order to be able to harvest once or several times a year, an undeniable effort is put forth and a very time-consuming and costly preparation process is passed. It is very important that the labor, time and cost spent here reach their ultimate goal, namely increasing the yield of agricultural products and resolving the encountered plant diseases.

The aim of this thesis is to propose a deep learning model that detects diseases on plant leaves by scanning gardens and covered areas in real time with an unmanned aerial vehicle. U-Net-based deep learning models are advantageous in plant disease detection with their multi-layered architecture that uses feature extraction, data augmentation and data segmentation techniques. Within the scope of the study, an original data set was created with images obtained from hazelnut gardens by unmanned aerial vehicles and U-Net based Base U-Net, Attention U-Net, Inception U-Net, Residual U-Net, RCN+ U-Net, Dense U-Net and U-Net++ models were preferred for training. UNet++ model has a pixel accuracy of 88.06% and a meDice value of 64.49% with a running time of 1.68.

SEMBOLLER

f () : Aktivasyon fonksiyonu

F (.) : Kalıntı fonksiyonu

h (.) : Kimlik eşleme fonksiyonu

İ **:** Eğitim sırası

K : Bir yinelemede eğitim sırası

max(.) : Maksimum fonksiyonu

N **:** Derin öğrenme modeli eğitim sayısı

$\mathbf{N_b}$: Bir eğitimde kullanılan örnek sayı

relu(.) : Relu fonksiyonu

$\sum$ **:** Toplam

$\mathbf{x_l}$: Kalıntı birimi girişidir.

$\mathbf{y_l}$: Kalıntı birimi çıkışıdır.

KISALTMALAR

AP : Average Precision

CNN : Convolutional Neural Network

DCGAN : Deep Convolutional Generative Adversarial Network

DCNN : Deep Convolutional Neural Network

FCN : Fully Convolutional Network

FN : False Negatif

FP : False Pozitif

IoU : Intersection over Union

İHA : İnsansız hava arac

KNN : K- Nearest Neighbors

mAP : Mean Average Precision

mDice : Mean Dice

mluO : Mean Intersection over Union

NN : Neural Network

R-CNN : Region Based Convolutional Neural Network

ResNet-50 : Residual Network

RGB : Red-Green-Blue

ROC : Receiver Operating Characteristic

SVM : Support Vector Machine

TP : True Pozitif

TN : True Negatif

VGG-16 : Very Deep Convolutional Networks 16

VGG-19 : Very Deep Convolutional Networks 19

YOLO : You Only Look Once.

TABLO LİSTESİ

Tablo 1: Dünya fındık üretimi[29] 3

Tablo 2: Karmaşıklık matrisi 31

Tablo 3: Farklı modellerin performans karşılaştırması 35

Tablo 4: Diğer bitkiler için değiştirilmiş U-Net modelleri İle yaprak hastalıklarının tespiti hakkında literatür araştırması 36

ŞEKİL LİSTESİ

Şekil 1: Çay yaprağı hastalıklarının görüntüleri: (a) kırmızı örümcek, (b) çay sivrisinek böceği, (c) siyah çürüme, (d) kahverengi yanıklık, (e) yaprak pası [20]. 7

Şekil 2: Çalışmaya ait oluşturulan veri setinden örnek hastalıklı asma yaprağı görüntüleri 8

Şekil 3: Altı çeşit üzüm hastalığının örnekleri (a) külleme, (b) antraknoz, (c) kahverengi leke, (d) botrytis, (e) kara çiçek, (f) tüylü küf [10] 10

Şekil 4: Label-Img aracını kullanarak pamuk yaprağının hastalıklı parçaları üzerindeki kutuların sınırlandırılması [2] 11

Şekil 5: Deneysel bahçe ve 0.99 mAP değeri ile noktasal hastalık tespiti[36] 12

Şekil 6: (a) Sağlıklı yaprakların etiketlenmesi, (b) Hastalıklı parçaların etiketlenmesi [37] 13

Şekil 7: Tez çalışması kapsamında hazırlanan veri setinden seçilmiş örnek İHA ile elde edilen görüntüler 16

Şekil 8: Yapay sinir ağları genel yapısı ve nöronlar [40] 17

Şekil 9: Toplama fonksiyonu [43] 18

Şekil 10: Aktivasyon Fonksiyonu [43] 19

Şekil 11: Attention U-Net segmentasyon modelinin blok diyagramı. Giriş görüntüsü: kodlama kısmında her ölçekte aşamalı olarak filtrelenir. Dikkat kapıları filtreler Atlama bağlantıları aracılığıyla yayılan özellikler[60]. 22

Şekil 12: Inception U-Net Mimarisi 23

Şekil 13: Başlangıç modeli iki yapılandırması [40] 24

Şekil 14: Tekrarlayan katman[47] 25

Şekil 15: İnsansız hava aracı görüntülerine uygulanan ileri görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanılarak fındık yaprağı hastalıklarının segmentasyonu için kapsamlı bir çerçeve geliştirilmiştir. Çerçeve, hastalıklı alanları doğru bir şekilde tanımlamayı amaçlamaktadır. 30

Şekil 16: Farklı U-Net modellerine ait semantik segmantasyon sonuçları 35

1. GİRİŞ

Teknolojinin gelişmesi birçok alana da yansıyarak teknoloji destekli kullanımlar yaygınlaşmıştır. Tarım alanında da yeni teknoloji teknikleri kullanılarak birçok soruna çözüm getirilerek, maliyet ve zaman ziyanı önlenmektedir ve verim arttırılmaktadır. Uygulanabilir birçok modern tarım tekniği üretici iş birliği ile yerinde denenerek ülkemizde de faaliyete geçirilmeli, birçok ürünün yetişmesine elverişli olan ülkemizin tarım faaliyetleri teknolojinin katkısıyla modernleşerek arttırılmalıdır.

Bu tez çalışmasında bitki yapraklarında görülen hastalıkların erken ve hızlıca tespiti için bir derin öğrenme modeli geliştirilmesi ve geliştirilen modelin gömülü sistem yazılımı ile insansız hava aracına entegre edilmesi amaçlanmaktadır[1].

Bitki hastalıkları genellikle bulaşıcıdır ve yapraklar arasında hızla yayılmaktadır, hastalığın erken tespit edilmesi ve ilaçlanarak hastalıklı alanların temizlenmesi oldukça önemlidir. İnsan gözüyle büyük bahçe veya tarlaların taranması, kontrol edilmesi oldukça zor ve zaman alıcıdır ayrıca hastalık başlangıcında oluşan küçük lekelerin tespit edilmesi de neredeyse imkansızdır. Kontrol ve tarama işleminin insansız hava aracı görüntüleri üzerinden yapılması modern tarım gereğine uygun olarak üreticinin işini kolaylaştıracak, zaman kaybını önleyecektir.

Literatürde yapılan çalışmalar incelendiğinde derin öğrenme modeli ile bitki yapraklarında meydana gelen hastalıklar görüntüler üzerinden tespit edilebilmesi denenmiş ve çok sayıda çalışma yüksek doğruluk oranıyla başarıya ulaşmıştır[2-28]. Başarıya ulaşan bilimsel çalışmaların ülkemizde yetişen bitkilerde de uygulanarak, üreticiye ve ülke ekonomisine zarar veren hastalıkların önlenmesi de bu tez çalışmasının hedefleri arasında yer almaktadır.

1.1. Genel Bakış

Bu tez çalışmasında, mevcut literatürdeki dikkate değer bir boşluğu ele alarak, yaprak hastalıklarının tanımlanmasına yönelik öncü bir metodoloji sunmaktadır. Çalışma, geleneksel yaprak merkezli yöntemlere kıyasla ağaç tabanlı tanımlama tekniklerinin etkinliğinin değerlendirilmesine odaklanmaktadır. Bu değerlendirme, drone olarak da adlandırılan insansız hava araçlarının (İHA) doğal ortamlarda makul yüksekliklerde yakaladığı video görüntüleri kullanılarak gerçekleştirilir. Bu yeni yaklaşım, erken yaprak hastalığı tespitinin hassasiyetini

ve verimliliğini artırma konusunda umut vaat ediyor. Ayrıca yaprak hastalıklarının tanımlanmasına odaklanan çalışma, tarımsal üretim kayıplarının azaltılmasında potansiyel uygulamalarla yenilikçi teknolojilerin geliştirilmesine katkıda bulunuyor. Ek olarak, meyve bahçelerinde görüntü yakalamak için İHA kullanmak farklı zorluklar ortaya çıkarıyor:

- Rüzgar, sis ve yağmur gibi olumsuz hava koşulları, İHA'nın uçuş yeteneklerini ve stabilitesini engelleyebilir ve bu da optimal olmayan sonuçlara yol açabilir.
- Yüksek binalar, ağaçlar ve teller gibi fiziksel engeller, İHA operasyonları için güvenlik riskleri oluşturarak bahçe gözetimindeki etkinliğini sınırlamaktadır.
- İHA'ların sınırlı pil ömrü, geniş mesafeleri kat etme yeteneklerini kısıtlayarak kapsamlı görüntü yakalama kapasitelerini etkiler.
- Harekete bağlı bulanıklık veya rüzgarlı koşullarda titreme gibi görüntü stabilitesi sorunları, toplanan verilerin kalitesini tehlikeye atabilir.

Önemli bir şekilde, çalışmada:

- İnsansız hava aracı video kayıtlarından türetilen benzersiz bir görüntü veri seti oluşturulması hedeflenmiştir.
- Görüntülerden veri seti oluşturulması, veri setinin çoğaltılması ve görüntülerin bitki hastalıkları tespitinde kullanılması için görüntü işleme tekniklerinden yararlanarak derin öğrenme modelleri kullanılması hedeflenmiştir.
- Derin öğrenme modelinin etkililiğinin detaylı bir şekilde karşılaştırılması hedeflenmiştir.
- Hızlı bir tarama ile; açık ve örtülü alanlarda bitki yapraklarında oluşan hastalık temelli anormalliklerinin tespit edilmesine yönelik bilgilerin sunulması amaçlanmıştır.

1.1.1. Problemin Tanımı

Tez çalışmasında bitki yapraklarında meydana gelen hastalıkların tespit edilmesi üzerine çalışma yapılırken, ülkemizin üretimde dünya sıralamasında birinci olduğu fındık bitkisi örnek bitki kümesi olarak belirlenmiştir. Ülkemiz verimli toprakları ve uygun iklim koşulları ile Karadeniz kıyı şehirlerinde fındık üretimi yoğun olarak yapılmaktadır. Dünya fındık üretimi ve ihracatında Türkiye ilk sırada yer almaktadır. Dünya fındık üretiminin yaklaşık %70'ini Türkiye'yi sırasıyla İtalya, Kafkas ülkeleri (Azerbaycan+Gürcistan), İran, ABD ve İspanya takip

etmektedir. Türkiye'de fındık, tarım ürünleri arasında en fazla ihracat geliri sağlayan üründür ve bu konumunu uzun süre koruyacağı öngörülmektedir[29].

Tablo 1: Dünya fındık üretimi[29]

Ülkeler	2017	2018	2019	2020	2021	2022
Türkiye	675000	515000	776046	665000	684000	775000
İtalya	131281	132700	98530	140560	84670	98670
Azerbaycan	29030	46270	44452	64410	67630	72104
İran	45530	52067	53793	49465	13609	13406
Gürcistan	21400	17000	24000	32700	46000	33400
ABD	24210	24406	24174	24263	70310	70310
İspanya	12790	13688	13745	13407	7780	-----
Şili	16800	20330	40000	33939	35185	62557
Çin	10487	8030	12370	5450	24814	24695
Diğer Ülkeler	59625	84695	77442	100835	12340	19460
Dünya Toplam	1001319	873344	1125049	1072308	1077393	1195732

Olumsuz hava şartları, hastalık ve zararlılardan kaynaklanan kayıplar üreticiyi ve ülke ekonomisini olumsuz etkilemektedir. Özellikle çeşitli bitki hastalıkları nedeniyle bitki yapraklarında meydana gelen anomaliler bulaşıcı olabilmekte ve hızlıca yayılabilmektedir. Fındık yetiştiriciliği, xanthomonas arboricola kaynaklı bakteriyel yanıklık ve anisogramma anomolanın neden olduğu diaporthe amygdali ve doğu fındık yanıklığı gibi mantar enfeksiyonları dahil olmak üzere çeşitli bakteriyel ve fungal hastalıklardan kaynaklanan önemli tehditlerle karşı karşıyadır. Bu zorluklarla mücadele etmek için entegre zararlı yönetimi stratejileri gereklidir [30-33]. Bitki yapraklarında hastalığın erken tespit edilmesi kritik önem taşımaktadır, hastalık sağlıklı bitki yapraklarına bulaşmadan ve daha geniş bir alana yayılmadan tespit edilmeli ve ilaçlama yapılarak müdahale edilmelidir.

1.1.2. Amaç ve Hedef

Teknoloji destekli araçların bahçe ve örtülü alanlarda kullanımı yaygınlaşmıştır. Yeni teknolojilerle tarım alanında çeşitli problemlere çözüm getirilmiş ve verim arttırılmıştır; zaman ve

maliyetten kazanç sağlanmıştır. Çeşitli ürünlerin yetiştirilmesi için elverişli toprakların bulunduğu ülkemizde de uygulanabilir birçok modern tarım yöntemi üretici ile iş birliği içerisinde yerinde denenerek faaliyete geçirilmelidir.

Tez çalışmasında bitki yapraklarında meydana gelen hastalıkların ilk safhalarda kolay ve hızlı bir şekilde tespit etmek amacıyla derin öğrenme modellerinin geliştirilmesi ve geliştirilen modelin insansız hava aracına gömülü sistem yazılımı ile entegre edilmesi amaçlanmaktadır.

Bulaşıcı bitki hastalıkları yapraklarında hızlıca yayılabilmektedir, bitki yapraklarında oluşan hastalığın erken tespit edilmesi ve zirai ilaçlarla müdahale edilmesi oldukça önemlidir. İnsan gözüyle büyük tarım alanlarının ve büyük bahçelerin taranarak hastalığın tespit edilmesi bir hayli zor ve zaman alıcıdır. Üstelik bitki hastalıkları başlangıçta küçük lekeler olarak gözlemlenmektedir ve sağlıklı yapraklar arasına gizlenebilmektedir. Büyük bahçe ve tarım alanlarının insansız hava araçları ile taranarak hastalıklı yaprakların tespit edilmesi modern tarıma uygun olarak üreticinin işini kolaylaştıracaktır ve daha hızlı sonuçlar sunacaktır.

Derin öğrenme modeli üzerine yapılan bilimsel çalışmalarda bitki yapraklarında oluşan hastalıklar, görüntüler üzerinden tespit edilebilmiştir ve yüksek doğruluk oranıyla sonuç veren modeller önerilmiştir. Başarıya ulaşan bilimsel çalışmaların ülkemizde yetişen bitkilerde de uygulanarak, üreticiye ve ülke ekonomisine zarar veren hastalıkların önlenmesi de bu tez çalışmasının hedefleri arasında yer almaktadır.

Yapılan bilimsel çalışmalardan başarılı sonuçlara ulaşan modeller, ülkemiz tarım alanlarında da uygulanarak gerçek sonuçların değerlendirilmesi ve bir tarım diyarı olan ülkemizin tarım ürünlerinde ihracatını arttırması uzak hedefler arasındadır.

Tez çalışmasıyla gerçekleştirilecek olan;

Bilimsel hedefler:

- Yapay zekanın ülkemizde karşılaşılan bir soruna nasıl çözüm getirebileceği ve bu çözümün uyarlanmasının somutlaştırılması,
- Bilgisayarla görme teknikleri kullanmak amacıyla görüntülerin toplanması, toplanan görüntülerin işlenerek derin öğrenme modeli altında yer alan; görüntü üzerinde nesne tespiti için gerekli model eğitim verilerinin oluşturulması, ağın eğitilmesi, sonuçların anlık izlenmesi gibi tüm alanlarda literatüre geniş çaplı bir katkı sunulması,

- Oluşturulan veri setini paylaşıma açılması ile bu alanda yapılan çalışmalara katkıda bulunulması,
- Görüntülerle eğitilmiş ağdan kararlı ve başarılı sonuçlar alındığı taktirde yazılımın gömülü sistemler uygulaması olarak insansız hava aracına entegre edilmesi ve özgün bir ürün ortaya koyulması.

Ülkesel hedefler:

- Tarım cenneti olan ülkemizde üreticinin ve dolayısıyla ülke ekonomisini olumsuz yönde etkileyen bitki hastalıklarına modern, teknoloji gereklerine uygun ve yenilikçi bir çözüm getirilmesi,
- Tarım alanında yaşanan bir probleme yapay zekâ ile çözüm getirerek, disiplinler arası çalışmaların önemini ve gücünü ortaya koyulması,
- Tarım ürünlerinde büyük tehdit oluşturan bitki hastalıkları için alınan önlemlerle olası zararları engelleyerek, ülke ekonomisinin korunması.

1.1.3. Ana Katkılar

Tez çalışmasında görüntüler üzerinden nesne tespiti yapılacaktır. İnsan beynini taklit eden yapay zekâ, makine öğrenmesi ile makinelerin yeteneklerini genişletecek çeşitli derin öğrenme teknikleri kullanır. Derin öğrenme modellerinde veriler çeşitli algoritmalarla beslenerek; ağın eğitilmesi ve tespit edilecek nesnenin öğrenilmesi gerçekleşmektedir. Yapay sinir ağlarıyla oluşturulan derin öğrenme modellerinde öğrenme gerçekleşir ve ağa giriş olarak verilen görüntü üzerinden öğrenilmiş nesneler tespit edilir. Geliştirilecek olan model bir derin öğrenme tekniğidir ve makine öğrenmesinde kullanılır, çalışmanın başarıya ulaşmasıyla geliştirilecek olan insansız hava aracına modelin gömülü sistem yazılımı ile entegre edilmesiyle hastalıkları tanır hale gelecektir. Çalışma, yapay zekâ ve makina öğrenmesinin, problem ve ihtiyaç doğrultusunda kullanımını örnekleyecek; gerçek zamanlı bir uyarlamasını ortaya koyacak ve disiplinler arası çalışmalara etkisini gösterecek; literatüre bu alanda özgün bir çalışma kazandıracaktır. Bu çalışmayla; Avrupa yeşil mutabakatına uyum kapsamındaki öncelikli Ar-Ge ve yenilik konuları metninde, yeşil ve sürdürülebilir tarım kapsamında yer alan tarım tekniklerinin yaygınlaştırılmasına yönelik yenilikçi uygulamalara katkıda bulunulacaktır. Yapay zekâ ve derin öğrenme modelleri ile yapılacak olan çalışmada, model eğitimi insansız hava aracı görüntüleriyle gerçekleşecektir. Ağın eğitilmesi için gerekli olan yüksek çözünürlükteki, fazlaca sayıda görüntünün toplanması ve işlenmesi; büyük veri ve veri analitiği çalışmasıdır ve bu

alanda yapılacak olan çalışmalar için büyük bir veri seti sunacaktır. Modelin başarıya ulaşmasıyla tasarlanacak olan özel yazılımlı insansız hava aracı robotik, mekanik ve otomasyon alanında yapılan çalışmalara bir yenisini ekleyecektir.

1.1.4. Tez Organizasyonu

Tez dört bölümden oluşmaktadır: 'Giriş' bölümünde bitki hastalıklarla ilgili genel bilgilere, bitki yapraklarında görülen hastalıklara ve literatür çalışmalarına yer verilmiştir. İkinci bölüm olan 'Materyal ve Yöntem' bölümünde kullanılan veri setine, veri setinin model eğitimi için hazırlık işlemlerinde, derin öğrenme modelleri ile ilgili genel bilgilerine yer verilmiştir ve kullanılan yöntem mimarisi detaylandırılmıştır. Üçüncü bölümde ise 'Sonuçlar ve Tartışma' adı altında elde edilen deneysel sonuçların performansı değerlendirilmiş ve ölçme metrikleriyle karşılaştırmalı olarak ortaya koyulmuştur.

1.2. Literatür Taraması

Son yıllarda bitki yapraklarında meydana gelen hastalıklar tespit etmek amacıyla birçok çalışma yapılmıştır. Bitki yaprağı görüntülerini sınıflandırmak veya hastalık görüntülerini bölümlendirmek için çoğunlukla derin öğrenme modelleri kullanılırken; görüntü iyileştirme, özellik çıkarımı ve nesne tespiti gibi işlemlerde de görüntü işleme teknikleri kullanılmıştır. Bu tekniklerin bir arada kullanılması bitki hastalıklarının erken tespiti ve müdahalesinde etkili bir araç olabilir[13].

Mahum, R. ve arkadaşları, patates yaprağı hastalıklarının tespiti için etkili bir derin öğrenme modeli kullanılarak yeni bir çerçeve sunuldu. DenseNet-201'de ekstra bir geçiş katmanı kullanılarak önceden eğitilmiş Efficient DenseNet modeli kullanıldı. Önerilen model, patates yapraklarında dört farklı hastalığı %97,2 doğrulukla tespit etmiştir [14].

Soeb ve arkadaşları [20], You Only Look Once(YOLO) v7 yaklaşımıyla çay yapraklarında hastalık tespiti için Bangladeş'teki 4 çay bahçesinden 4000 dijital görüntü toplanmış ve veri artırma yöntemiyle örneklem artırmıştır. Büyük bir veri kümesiyle eğitilen model, Evrişimli Sinir Ağları, (Convolutional Neural Network), resim, Deep CNN, DNN, AX-Retina Net, geliştirilmiş Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network), YOLOv5 ve çok amaçlı görüntü segmentasyonu dahil olmak üzere diğer hedef tespit ve tanımlama ağlarıyla karşılaştırılmaktadır. YOLOv7 modelinin elde ettiği nesne tespiti ve tanımlama için elde edilen

sonuçlar mAP değeri, F1 puanı, geri çağırma değeri, hassasiyet, tespit etme doğruluğu gibi ölçme metrikleri ile doğruluğu sağlanmıştır. Şekil 1'de veri setinden örnekler gösterilmektedir.

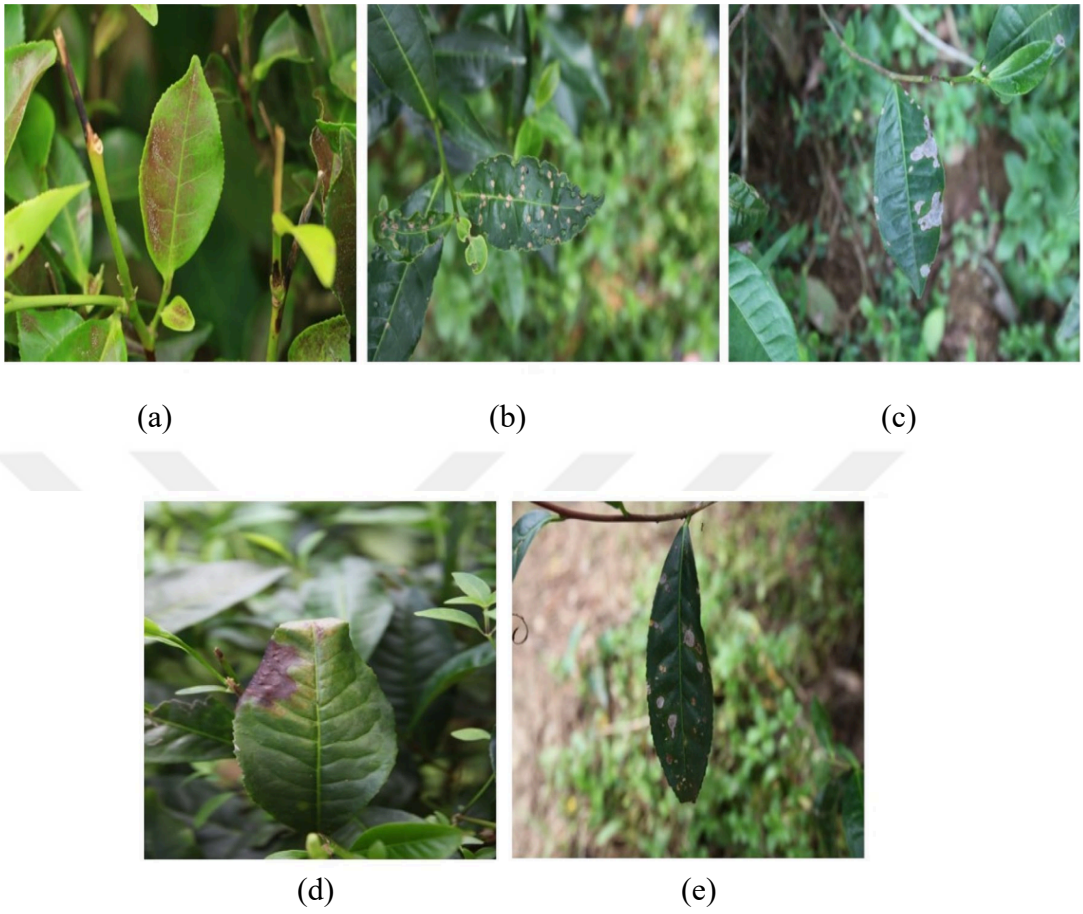

Şekil 1: Çay yaprağı hastalıklarının görüntüleri: (a) kırmızı örümcek, (b) çay sivrisinek böceği, (c) siyah çürüme, (d) kahverengi yanıklık, (e) yaprak pası [20].

Yaprak hastalıklarının tespitini geliştirmek için CNN'leri kullanan bir sistem öneren çalışmada [2], CNN mimarisi sağlam olacak şekilde tasarlanmış olup, bir ağ görselleştirme modülü ve model kontrolü sağlayan etkileşimli bir modül içermektedir. Önerilen model, PlantVillage veri kümesinde %99'un üzerinde sınıflandırma doğruluğuyla hastalıkları tespit edebildi.

Pirinç yapraklarında hastalık tespiti için DenseNet201, DenseNet121, DenseNet169, Inception-V3, Mobilenetv2, Very Deep Convolutional Networks 16 (VGG-16), Very Deep Convolutional Networks 19 (VGG-19), InceoptionResnetV2, Xception, Residual Network (ResNet-50) ve NasNetMobile CNN modelleri kullanılmış ve sonuçlar karşılaştırılmıştır. Deney sonuçlarına göre pirinç yaprağı hastalıklarının tespitinde en başarılı model %99,99 doğruluk oranıyla DenseNet169 modeli olmuştur[9].

Mustafa H. Ve arkadaşları tarafından yapılan çalışmada biber yapraklarındaki hastalıkları otomatik olarak tespit etmek için beş katmanlı bir CNN modeli önerilmektedir. Model eğitimi için 20.000 artırılmış görüntü kullanılmıştır. Elde edilen sonuçlara göre çalışmada sunulan CNN modeli biber hastalıklarını %99,99 doğrulukla tespit etmektedir [16].

Praveen, S.P. ve arkadaşları tarafından yapılan çalışmada üzüm yaprağı hastalıklarının gerçek zamanlı tespiti üzerine yapılan çalışmada [17] daha hızlı Bölge Tabanlı Evrişimsel Sinir Ağı (Region Based Convolutional Neural Network), YOLO-X ve Tek Atışlı Çoklu Kutu Dedektörü (Single Shot Multibox Detector) yöntemleri kullanılmıştır. Gerçek zamanlı hastalık tespitinde performansı artırmak için dikkat stratejisi modülü kullanılmıştır. Deneysel sonuçlara göre farklı dikkat stratejileri kullanan SSD Faster, CNN ve YOLO'ya göre daha yüksek hassasiyet göstermiştir. Şekil 2'de veri setinde yer alan hastalıklı üzüm yaprakları gösterilmektedir.

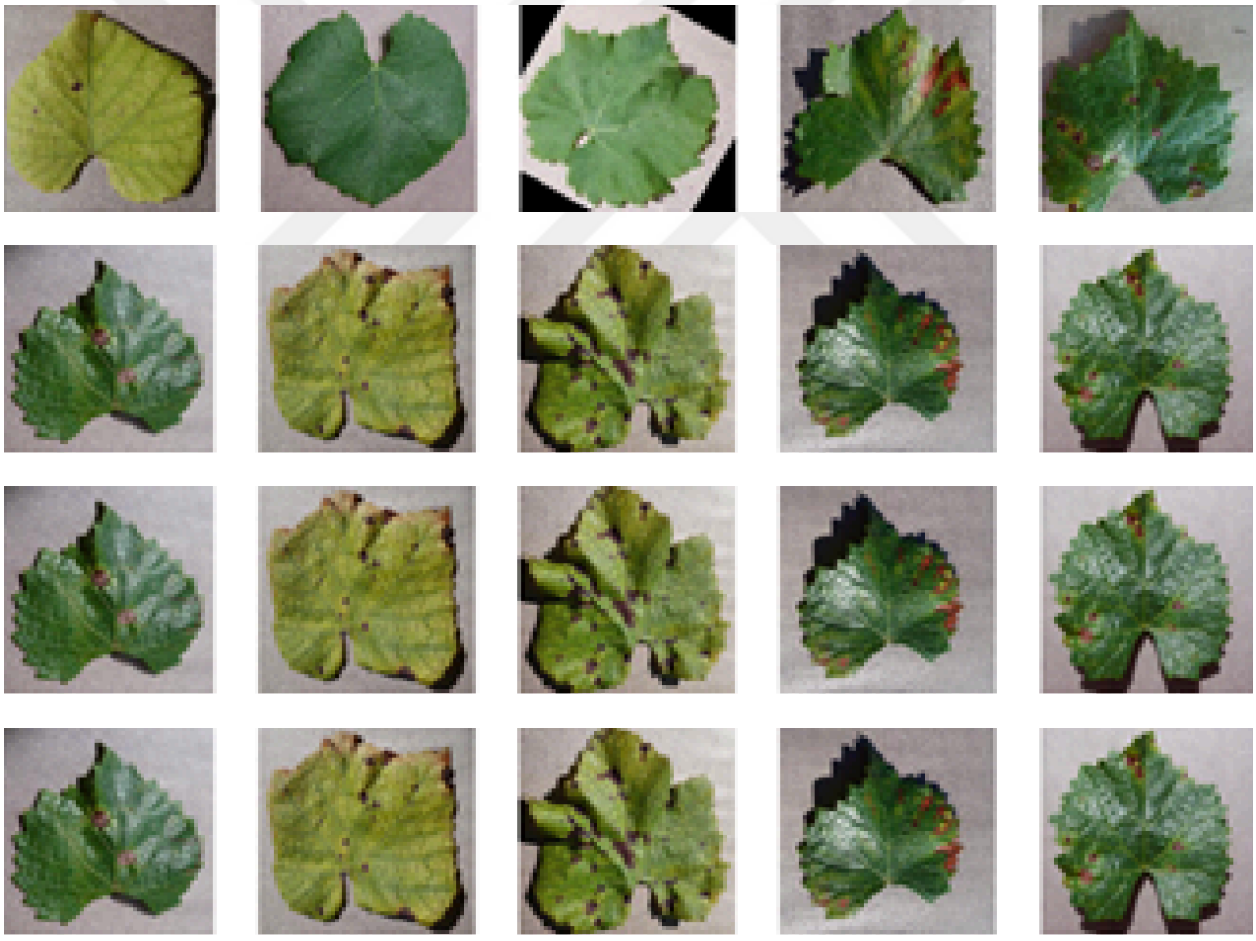

Şekil 2: Çalışmaya ait oluşturulan veri setinden örnek hastalıklı asma yaprağı görüntüleri

Mango yapraklarında hastalık tespiti için hibrit bir sistem öneren çalışmada [18] çok sınıflı bir Karar Destek Sistemi (Support Vector Machine) önerilmiştir. Spatial Fuzzy C-Means modeli

ile veriler arasındaki benzerliklere göre kümeleme yöntemi kullanılmıştır. Önerilen yöntem benzer yöntemlere göre yüksek doğruluk elde etmiştir.

Yu ve arkadaşları [34] bitki yapraklarındaki hastalıkların sınıflandırılmasında kullanılan derin öğrenme modeli olan FormLeaf modeli kullanmış ve yeni bir transformatör bloğu tasarlanmıştır. Modeli dört ayrı veri seti üzerinde test etmişlerdir ve VillagePlant veri seti için model %99,94; PlantDoc veri seti için %77,54; Ilbean veri seti için %99,22; AI 2018 için %86,89 doğruluk oranıyla sonuç almışlardır.

Bilgisayarla görme ve derin öğrenme yaklaşımlarını kullanan araştırma, şeker kamışı yaprağı hastalığının hassas tespiti ve sınıflandırılması için akuantum davranışlı parçacık sürüsü optimizasyonuna dayalı derin transfer öğrenme (QBPSO-DTL) modeli tanıtmıştır. Hastalık tahmininde yüksek doğruluk elde etmek için önerilen QBPSO-DTL modeli, optimal bölge büyüyen segmentasyonu, özellik çıkarıcı olarak SqueezeNet'i ve sınıflandırma modeli olarak derin yığınlı otomatik kodlayıcıyı (DSAE) birleştirmiştir. Daha iyi sonuçlar, 200 dönemi altında maksimum 99.5952 Alıcı Çalışma Karakteristiği (Eceiver Operating Characteristic) 'ne sahip olan QBPSO-DTL yöntemiyle gösterilmiştir [28].

Üzüm yapraklarında hastalık tespiti, FasterRCNN, YOLOx ve SSD dahil olmak üzere çeşitli nesne tespit modellerinden yararlanan dikkat mekanizmaları kullanılarak incelenmiştir. Sonuçlar, çeşitli dikkat süreçlerine dayanan modellerin, çalışma hızını ve algılama hassasiyetini başarılı bir şekilde arttırdığını, YOLOx+ECA'nın en az parametreyle en iyi algılama hassasiyetini elde ettiğini göstermektedir [10].

Şekil 3’de altı çeşit üzüm hastalığının örneklendiği veri seti görülmektedir. Şekil 3-a külleme, Şekil 3-b antraknoz, Şekil 3-c kahverengi leke, Şekil 3-d botrytis, Şekil 3-e kara çiçek, Şekil 3-f tüylü küf hastalıklarına ait örnek verileri göstermektedir.

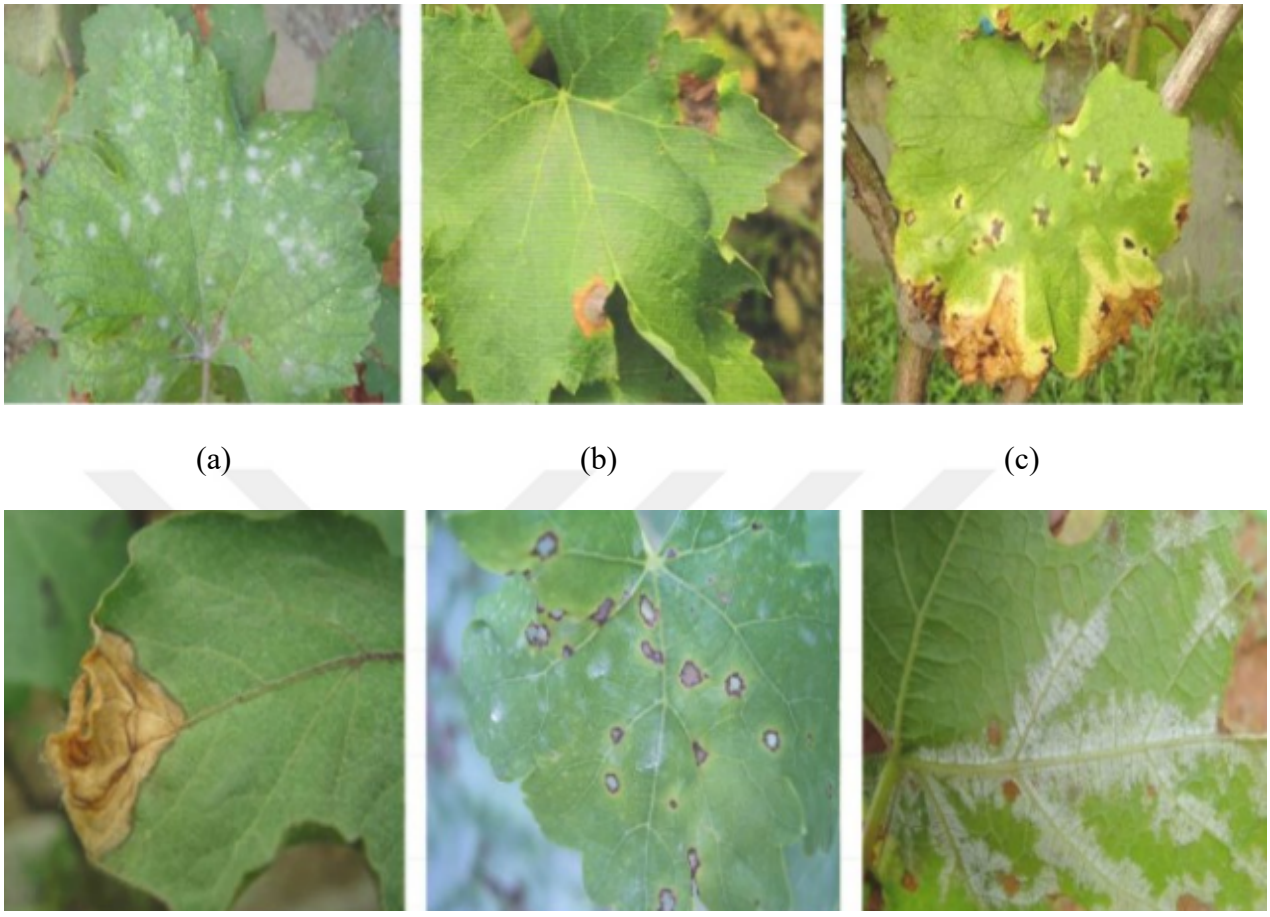

(a) (b) (c)

(d) (e) (f)

Şekil 3: Altı çeşit üzüm hastalığının örnekleri (a) külleme, (b) antraknoz, (c) kahverengi leke, (d) botrytis, (e) kara çiçek, (f) tüylü küf [10]

Joshi ve arkadaşları [11], görüntü işleme teknikleri kullanılarak bitki hastalıklarının tespiti konusunda detaylı bir literatür taraması yapmışlardır ve çeşitli algoritma ve metodolojiler kullanmışlardır. Doğru hastalık tespiti ve sınıflandırması için CNN'ler, SVM'ler ve derin öğrenme ilkeleri gibi farklı yaklaşımların araştırıldığı çalışmada sonuçlar %94 - %99 aralığındadır.

Hastalıkların ürün kalitesi ve verimi üzerindeki etkisini azaltmak amacıyla pirinç mahsullerindeki yaprak hastalıklarını değerlendirmek için yapılan çalışmada [8] transfer öğrenmeye dayalı bir derin öğrenme modeli önerilmiştir. Model, CNN, InceptionV3, VGG16, ResNet, SqueezeNet ve VGG19 dahil olmak üzere çeşitli transfer öğrenme mimarilerini kullanarak pirinç

bitkilerindeki yaprak hastalıklarını tespit etmiştir ve sınıflandırmıştır. Semantik segmentasyon gerçekleştirerek, yaprak görüntüleri ön işleme tabi tutulmuştur ve TL yapıları, segmentlere ayrılmış resimler kullanılarak ayarlanmıştır. Önerilen model, %96,4'lük doğruluk oranıyla en yeni modellerden daha iyi performans göstermiştir. Çalışmada, önerilen modelin çeltik bitkilerindeki yaprak hastalıklarını doğru bir şekilde tanımlayabildiği ve kategorize edebildiği için tarımsal araştırmalar için yararlı olduğu sonucuna varılmıştır.

Albattah ve arkadaşları [35], insansız hava aracı ve geliştirilmiş bir EfficientNetV2-B4 modeline dayalı çok sınıflı bitki hastalığı teşhisi için güçlü bir derin öğrenme yöntemi önermektedir. Yöntem, zayıf kontrast bilgisi, giriş görüntülerindeki gürültü, bulanıklık ve hastalıklı bölümlerin boyutu ve yapısındaki farklılıklar gibi sorunlara çözüm getirmektedir. Sırasıyla %99,63, %99,93 ve %99,99'luk mükemmel hassasiyet, geri çağırma ve doğruluk değerleriyle özelleştirilmiş EfficientNetV2-B4 modeli başarılı sonuç vermiştir. Optimize edilmiş yinelemelerin sayısı arttıkça modelin toplam kayıp değeri düşüş göstermiştir; modelin pamuk yapraklarındaki hastalıkları tespit etmedeki başarılı olduğunu kanıtlamıştır.

Udawant, P. Ver arkadaşı tarafından yapılan çalışmada; gerçek dünya senaryolarında pamuk yaprağı hastalıklarını tanımlamak için Mask R-CNN nesne tanımlama yöntemine transfer öğrenmeyi uygulamıştır ve %94'lük bir eğitim doğruluğuna ulaşılmıştır[22]. Şekil 4'de etiketleme aracı kullanılarak hastalıklı alanların sınırlandırmasına ait örnekler gösterilmektedir.

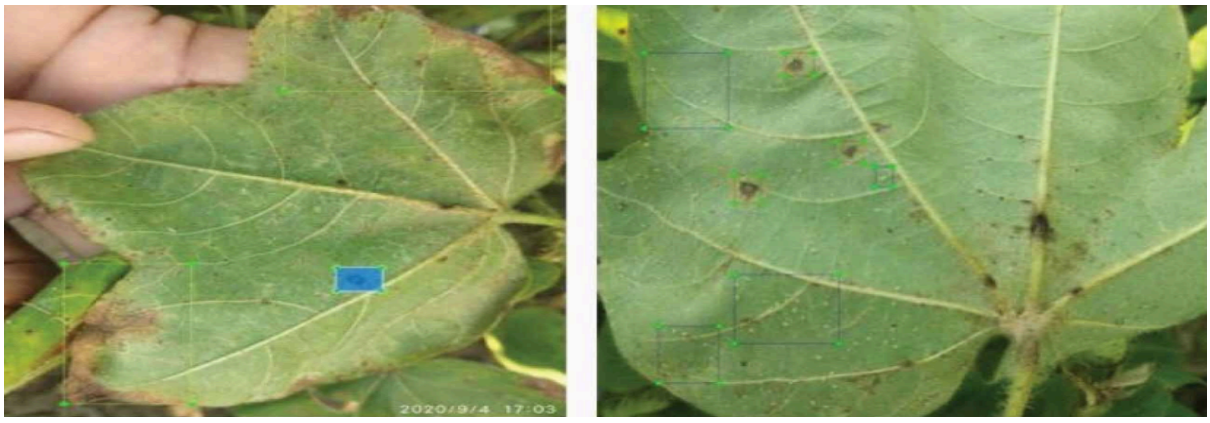

Şekil 4: Label-Img aracını kullanarak pamuk yaprağının hastalıklı parçaları üzerindeki kutuların sınırlandırılması [2]

Mohapatra, M. Ve arkadaşları tarafından botanik bitkilerde hastalık tespiti üzerine yapılan çalışmada [15], CNN tarafından geliştirilen derin öğrenme modeli kullanılarak mango yapraklarında hastalık tespiti yapılmıştır.

Vasavi, P. Ve arkadaşı tarafından geliştirilen model CSO, BWO, WOA, EHO, SVM, Sinir Ağı (Neural Network), NB ve RF gibi mevcut modellerle karşılaştırılmış ve daha başarılı sonuçlar elde edilmiştir. Elde edilen sonuçlara göre hastalık 0,912 doğruluk oranıyla tespit edilmiştir. Bitki hastalığı tespitinde kullanılan değiştirilmiş CNN'leri ve optimize edilmiş derin öğrenme modellerini geleneksel makine öğrenme teknikleriyle karşılaştıran bir inceleme çalışması yapılmıştır. Elde edilen sonuçlara göre, değiştirilmiş CNN'lerin çok kanallı modeli, derin öğrenmede %99,5 ile en yüksek doğruluğu elde ederken, doğrusal çekirdekli SVM, makine öğrenme tekniklerinde %99 doğruluk elde etmiştir[23].

AI tabanlı derin öğrenme modeli Dolmalık biber yapraklarında hastalık tespiti için Faster R-CNN ve FPN yöntemi kullanıldı. Önerilen model, 0,5 IoU oranında ortalama %100 hassasiyet ve ortalama %99,7 geri çağırma skoru ile çalışmıştır; 0,5-0,95 IoU aralığı için ortalama kesinlik ve ortalama geri çağırma sırasıyla %99,5 ve %99,1 idi [36]. Şekil 5'te noktasal hastalık tespiti için örnek sonuç kümesi gösterilmektedir.



Şekil 5: Deneysel bahçe ve 0.99 mAP değeri ile noktasal hastalık tespiti[36]

Elma yaprağı hastalığı tespit ve sınıflandırmasına yönelik bir CNN modeli olan VGG16 ile yapılan çalışmada %93,3 doğruluk oranı ile başarılı olunmuştur. Çalışmanın amacı elma yaprağı hastalıklarının erken tespit ve sınıflandırma sürecini basitleştirmektedir[19].

Pirinç yaprağı hastalıklarını tespit etmek için 5.368 görüntüden oluşan bir veri seti kullanılarak yapılan çalışmada, önceden eğitilmiş SqueezeNet derin öğrenme modeli kullanılmıştır. Önerilen model deneysel sonuçlara göre %98,3 doğruluğa ulaşmıştır. Önerilen model sonuçları

SVM, Random Forest, K- Nearest Neighbors(KNN), Naive Bayes ve AdaBoost gibi sınıflandırıcılarla karşılaştırılmıştır [12].

Fındık yaprağı hastalıklarının tespitinin amaçlandığı çalışmada YOLOV5 modeli kullanılmıştır. Yeterli örneklemin elde edilemediği çalışmalarda ise görüntü iyileştirmeye yönelik çalışmalara ağırlık verilmiştir [37]. Şekil 6-a'da sağlıklı fındık yaprakları; Şekil 6-b'de fındık yapraklarında hastalıklı alanların etiketlendiği örnekler gösterilmektedir.



(a) (b)

Şekil 6: (a) Sağlıklı yaprakların etiketlenmesi, (b) Hastalıklı parçaların etiketlenmesi [37]

Wang, Y. Ve arkadaşları tarafından mobil cihazlar aracılığıyla elma yapraklarındaki hastalıkları gerçek zamanlı tespit etmek için bir model önerilmiştir. Önerilen MGA-YOLO modelinde Evrişimsel Blok Dikkat Modülü (CBAM) YOLO ağına entegre edilerek özellik çıkarma performansı artırılmıştır. Deneysel sonuçlara göre yöntemin mAP'si %94'e ulaşmıştır[25].

Liu ve arkadaşları, bitki yapraklarında hastalık tespiti için Gizli Anlamsal Maskeleme Otomatik Kodlayıcı (Latent Semantic Masking Auto Encoder) kullanan, kendi kendini denetleyen, transformatör tabanlı bir ön eğitim yöntemi önermiştir. Yapılan çalışmalarda genellikle tercih edilen CNN modellerinin performansının, küresel bilgi etkileşimi ve ayırt edici özellik temsilinin olmayışı nedeniyle sınırlı olduğu vurgulanmıştır. Önerilen model IP02i CPB ve Plant Village veri setleri üzerinde test edildi ve %74,69-%7699-%99,93 doğruluk elde etmişlerdir [38].

Tarek, H. Ve arkadaşları tarafından yapılan çalışmada ResNet50, InceptionV3, AlexNet, MobileNetV1, MobileNetV2 ve MobileNetV3 teknikleri optimize edilerek kullanılmıştır.

Performansları, gerçek zamanlı hastalık tespiti için Raspberry Pi 4 üzerinde değerlendirilmiştir. MobileNetV3 Small için %98,99 doğruluk ve MobileNetV3 Large için %99,81 doğruluk elde edilmiştir [21].

Dwivedi, R. Ve arkadaşları bitki hastalıklarının tespiti için benzersiz bir model sunan çalışmada Extreme Learning Machine Algoritması ve L1-norm minimizasyonu kullanılmıştır. Çeşitli bitkiler üzerinde yapılan deney sonuçlarına göre şeftali yapraklarında %98,5 doğruluk oranıyla, çilek yapraklarında ise %97,7 doğruluk oranıyla hastalık tespit edilmiştir[6].

Selvanarayanan, R., ve arkadaşları tarafından yapılan çalışmada araştırmacılar, otomatik yöntemler ve doğru sınıflandırmalar kullanarak kahve kirazlarındaki hastalığın erken teşhisine yönelik bir strateji sunmuşlarıdır. Kahve meyvesi veri kümeleri üzerinde bir model eğitmek için XGBoost'u kullanmışlardır ve %98,56'lık bir doğruluk elde etmişlerdir [39].

Yu ve aradaşları, elma hastalığının tanınması için hafif bir LW-ResNet modeli önerilmiştir ve bir test setinde yüksek hassasiyet, hatırlama ve F1 puanı (her biri için %97'nin üzerinde) elde edilmiştir [27].

2. MATERYAL VE YÖNTEM

Bu bölümde fındık yaprağı hastalığının tespiti için kullanılan veri seti ve metodoloji ayrıntılı olarak açıklanmaktadır.

2.1. Veri Seti

Görüntüler üzerinden hastalık tespiti yapılan çalışmalarda kullanılan veri setleri tek bir hastalıklı yaprak örneklerinden oluşmaktadır. Araştırmada kullanılan veri seti ise kullanım amacına uygun olarak insansız hava aracı ile çekilmiş videolardan elde edilmiştir. Videolar fındık bahçelerinin yoğun olduğu özellikle fındık yetiştiriciliği yapılan bölgelerden toplanmıştır. Fındık yaprak hastalıklarından külleme hastalığının hangi fındık bahçelerinde hangi dönemlerde gözlemlenebileceği araştırılmıştır ve çekimler hastalık ve anomalilerin tespit edilebileceği dönemlerde gerçekleştirilmiştir. Fındık video verileri İHA kullanılarak 3 ila 10 metre arasındaki irtifalarda çekilmiştir. Videolar piksel çözünürlüğü 1920x1080 ve kare hızı ise 25 kare (fps) olarak elde edilmiştir. Bu kayıtlar fındık ağaçlarının yetiştiği zorlu arazilerde yapılmıştır. Araştırmanın bu aşamasında görüntüler, sınırlı bir zaman dilimi içerisinde de olsa, güneşli hava koşulları

altında doğal ortamlarda elde edilmiştir. Araştırmayı kolaylaştırmak için, insansız hava aracı görüntülerinden farklı aralıklarla 80 kareden oluşan özel bir veri seti oluşturulmuştur.

Şekil 7'de bir fındık bahçesinin insansız hava aracı ile farklı açılarda ve farklı ışıklarda çeşitli irtifalardan taranmış, veri kümesinden örnek görüntüler gösterilmektedir.

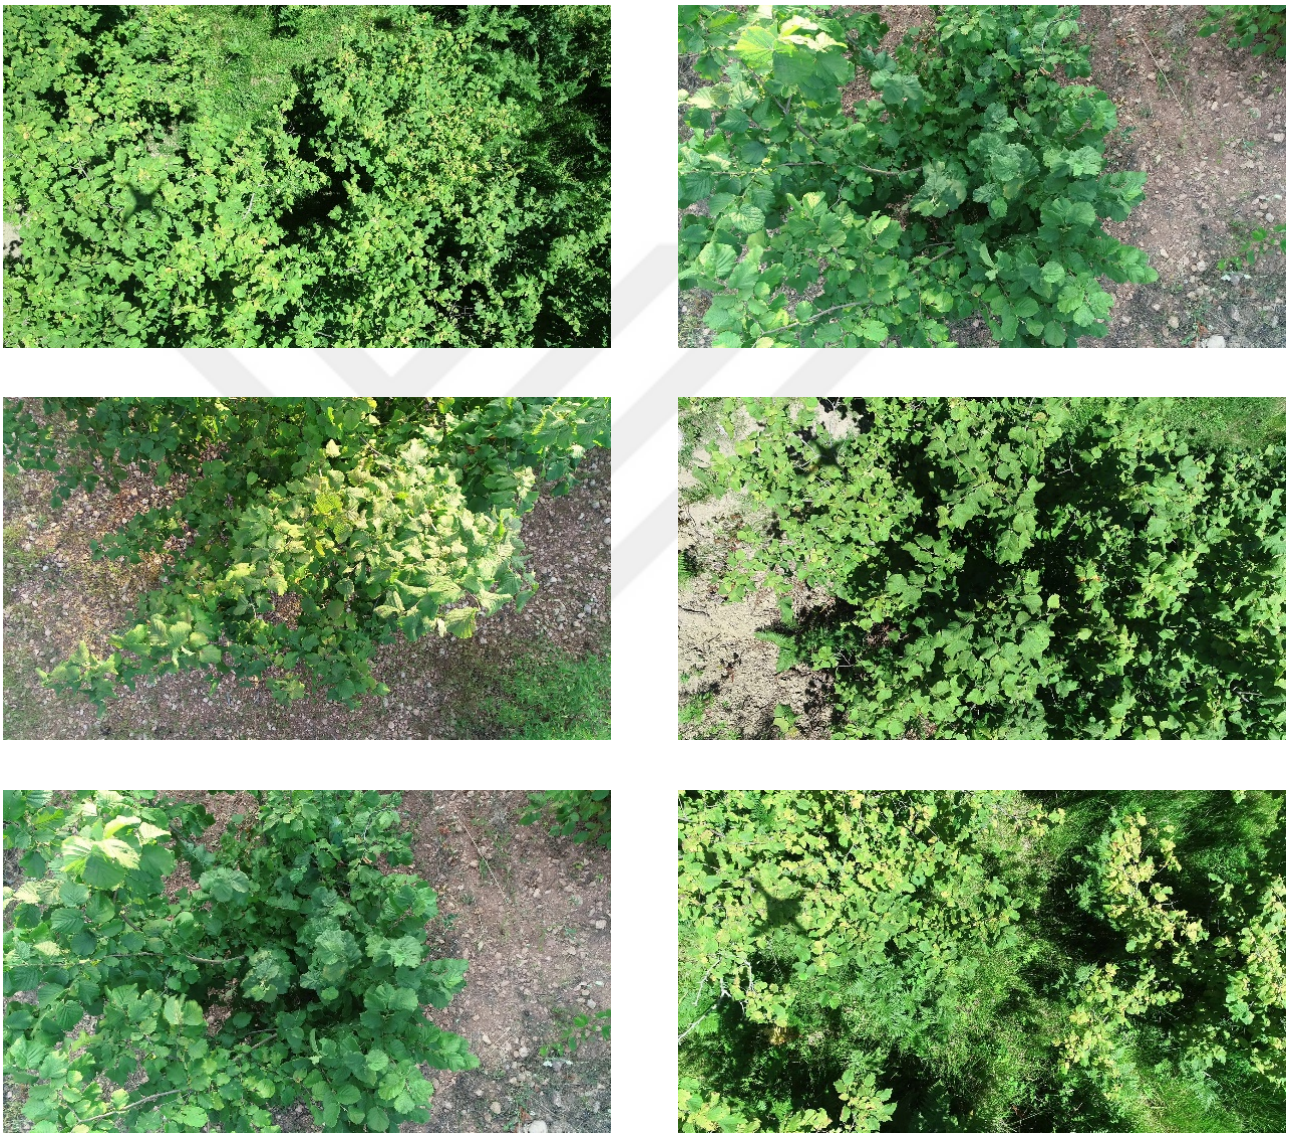




Şekil 7: Tez çalışması kapsamında hazırlanan veri setinden seçilmiş örnek İHA ile elde edilen görüntüler

2.2. Derin Öğrenme Mimarisi

Bu bölümde uygulanan model için altyapı sağlamak amacıyla ilgili modelde kullanılan matematiksel arka plan, özellikler ve derin öğrenme modeline dair genel yapı anlatılmaktadır.

2.2.1. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, insan beynini araştırmış ve beynin bilgileri işlerken kullandığı teknikleri ele almış, buradan esinlenerek geliştirilmiş bir bilgi işlem teknolojisidir. Basit biyolojik sinir sisteminin çalışma şeklinde yer alan biyolojik nöron hücreleri ve bu nöron hücrelerinin birbirleriyle aralarında kurdukları ve sinaptik bağlantı adı verilen yapıyı dijital olarak modellemesidir [40]. İnsan beyninin öğrenme yeteneği araştırılarak, mevcut bilgiler ile yeni öğrenme arasında gerçekleşen bağlantılar yapay sinir ağlarında kullanılarak yapay nöronlar oluşturulur. Temel bir YSA modeli üç katman olarak elde edilmektedir. Verilerin işleme sokulduğu ilk katman girdi katmanıdır; ikinci katman ise girdi katmanından gelen verileri işleyerek işlem birimlerinde hesaplamalar yapan gizli katmandır; üçüncü katman ise gizli katmandan gelen verileri işleyerek çıktı üreten çıktı katmanıdır.

Şekil 8'de bir yapay sinir ağlarına dair genel yapı ve yapay sinir ağlarını oluşturan katmanlar sunulmaktadır. Yapay sinir ağına bilgi girişi girdi katmanı aracılığı ile iletilir. Bilgileri işleyen katman gizli katmandır ve gizli katmana bilgi girişi giriş katmanından iletilmektedir. Gizli katmanda işlenen veriler ise çıktı katmanına iletilir.

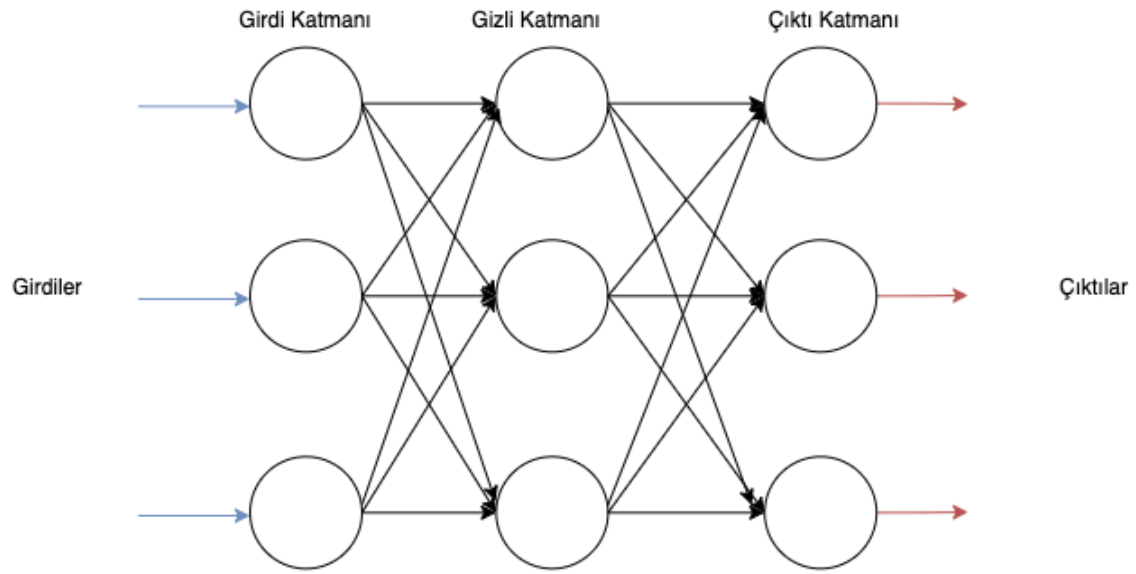

Şekil 8: Yapay sinir ağları genel yapısı ve nöronlar [40]

Gizli katmanlarda bilgilerin işlenmesi ise ağa gelen bilgilerin ağın ağırlık değerleri ile çıktıların üretilmesidir. Girdilerle doğru çıktıların üretilmesi ağın ağırlık değerlerinin doğruluğuna bağlıdır. Yapay sinir ağlarında bir nöron için ağırlıklar optimum ayarlanarak spesifik girdiler için istenilen çıktılara ulaşılabilir; ancak sayıca çok fazla nörondan olan bir yapay sinir ağı söz konusu olduğunda tüm ağırlıkların tek tek elle belirlenmesi karmaşık hale gelmektedir. Ağdan beklenilen çıktının üretilmesi için ağırlıkların ayarlanması yardımcı fonksiyonlar ile yapılabilmektedir. Ağ için doğru ağırlık değerlerinin bulunmasına ağın eğitilmesi denilmektedir. İlk olarak rastgele belirlenen ağırlık değerleri her eğitim sonrası belirlenen öğrenme kuralına göre iyileştirilir. Eğitim esnasında ağın öğrenme kuralına bağlı olarak ağırlıklar değişir. Eğitim tekrarlayarak ağırlıklar yenilenir ve en doğru değerlerin bulunması hedeflenir. Ağırlıkların en doğru değerlere ulaşması eğitim setinde yer alan her bir veri örneği için doğru çıktının üretilmesidir. Veri setinde test için ayrılan örneklere doğru çıktı üretilirse ağ eğitilmiş sayılmaktadır. Ağ eğitiminden sonra ağırlıklar belirlenmiş olur ancak her bir ağırlığın anlamı bilinmediği için gizli katmanlar olarak isimlendirilmektedir. Ağırlıkların tek tek ne anlama geldiği bilinmez ancak girdiler için çıktılar gizli katmanlarda üretilir. Bir yapay sinir ağ modelini oluşturan özellikler ağ topolojisi, toplama fonksiyonu, ağın öğrenme stratejisi, aktivasyon fonksiyonu, öğrenme kuralı olarak nitelendirilmektedir [41].

2.2.1.1. Toplama Fonksiyonu

Şekil 8'de girdiler X ile temsil edilen değerlerle gösterilmektedir. Bir nörondan girdiler aracılığı ile iletilen bilginin önemi ve etkisi w ile gösterilen ağırlıklardır. Girdi değerlerinin etkisi ağırlık değerlerine bağlıdır; bu değerler ne kadar yüksek olursa etki o kadar fazla olacaktır. Giriş nöronları için girdinin ağırlık ile çarpımı çıktıyı verecektir. Her bir nöron ağırlıkları ile girdiler çarpılır her katmanda bulunan Şekil 9'da z ile gösterilen ön yargılar eklenir ve toplama fonksiyonu ile net girdi değeri hesaplanır[42].

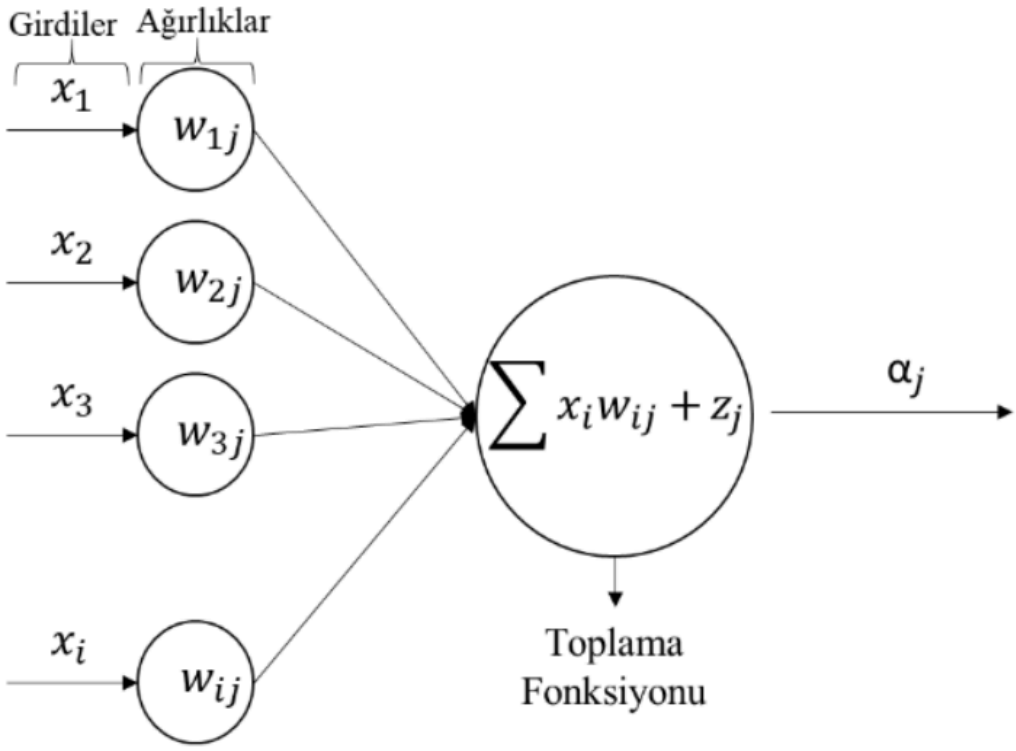

Şekil 9: Toplama fonksiyonu [43]

2.2.1.2. Aktivasyon Fonksiyonu

Yapay sinir ağlarında bir nöronda çıktı elde etmek amacıyla kullanılan fonksiyona aktivasyon fonksiyonu veya transfer fonksiyonu denilmektedir." Var" ya da "Yok" olarak ikili sonuç üretmek üzere oluşturulmuş sinir ağlarının çıktılarının belirlenmesinde kullanılmaktadır. Sinir

ağları ile çözülmek istenilen probleme bağlı olarak farklı aktivasyon fonksiyonları seçilebilmektedir. Seçilen aktivasyon fonksiyonuna göre elde edilen değerler "-1,1" ya da "0 ,1" arasında olabilir. Şekil 10'da yaygın olarak kullanılan aktivasyon fonksiyonları Tanh, Sigmond ve Relu gösterilmektedir. [41]

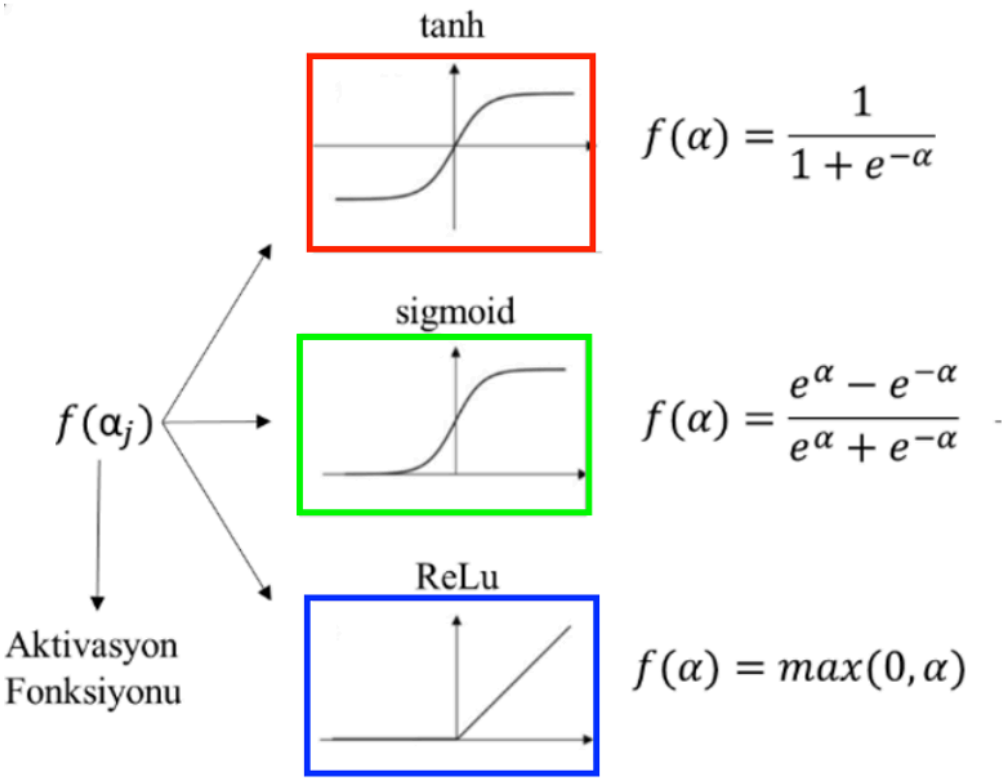

Şekil 10: Aktivasyon Fonksiyonu [43]

Tez çalışmasında uygulanan U-NET modellerinde aktivasyon fonksiyonu olarak yaygın olarak kullanılan RELU fonksiyonu kullanılmıştır.

relu(x)=max(0,x) (2.1)

2.2.2. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (Convolutional Neural Networks), resim niteliklerini tanıyarak sınıflandırma yapabilen bilgisayarlı görüş derin öğrenme ağıdır. CNN mimarisi, görsel korteksin organizasyonu ve işlevlerinden etkilenmiştir. İnsanların beyin yapılarında bulunan nöron bağlantıları ile benzerlik gösteren yapıda tasarlanmıştır[43].

Bir ileri beslemeli sinir ağı çeşidi olan CNN, çekirdek (ya da filtre) iyileştirmesi yöntemi ile kendi kendine öğrenebilir olarak düzenlenmiştir. Öncesinde sinir ağları için geri yayılım esnasında patlayan ve kaybolan gradyanlar görülmekte iken; CNN'de daha az bağlantıya yönelik ağırlıklar kullanılarak bu sorun önlenmektedir [44, 45].

İleri beslemeli sinir ağları çoğunlukla tam bağlı olan ağlardır, tam olarak bağlı ağlar için her bir katmanda bulunan tüm nöronlar bir sonraki katmanda bulunan diğer nöronlara bağlı olmaktadır. Böyle birbirine tam bağlı olan ağlarda veri uyumuna yatkınlık yüksek seviyededir. Eğitim esnasında parametreler için ağırlık azalması yani ceza ya da bağlantı kesintisi gibi yöntemlerle aşırı veri uyumuna tedbir alınmaktadır. CNN'ler için güçlü olmayan bir veri kümesinde önyargı ihtimali artarken; sağlam bir veri kümesi ile spesifik bir veri kümesi karakterini analiz eden genelleştirilmiş ilkelerden oluşan öğrenme ihtimali artmaktadır [46].

2.2.3. U-Net Derin Öğrenme Modeli ve Çeşitleri

U-Net tabanlı model çeşitleri, belirli bir soruna özel bir çözüm sağlamak üzere tasarlanmıştır. U-Net ve çeşitleri [47] birçok görüntü işleme görevinde, özellikle tıbbi görüntü bölümlemede tercih edilmiştir. U-Net modeli temelinde, performansı iyileştirmek amacıyla hızlı bir şekilde ve çok çeşitli olarak tıbbı görüntüler için segmentasyon metotları geliştirilmiştir. Özellikle U-Net modellerinin geliştirildiği alanlar; özellik çıkarma, ağ eğitiminde hız iyileştirmeleri, eğitim doğruluğu, uygulama aralığı, eğitim için veri setinin küçük olduğu durumlar, genelleme, özellik füzyonu gibi alanlardır. Çeşitli segmentasyon sorunlarının çözümüne uygun olarak farklı yapılarda ağ tasarımı için çeşitli stratejiler kullanılır.

2.2.3.1. Base U-Net

Base U-Net modeli 2015 yılında tıbbı görüntülere yönelik segmentasyon amacı ile tasarlanan bir derin öğrenme modelidir. Tıbbi görüntü segmentasyonu için geliştirilmiş bir derin öğrenme modelidir [48]. Bu mimari, bir giriş görüntüsünden anlamlı özellikler çıkarmak için tasarlanmış simetrik bir yapıya sahiptir [49]. Bu yapı iki ana bölümden oluşmaktadır. İlk ana bölüme daralma yolu; ikinci ana bölüme ise genişleme yolu denir. U-Net'in "U" şeklini almasının nedeni daralma ve genişleme yollarının simetrik olmasıdır. İndirgeme yolu, özellik çıkarımı için birden fazla evrişim katmanı ve havuzlama katmanı içerir. Her evrişim sürecini, görüntüdeki önemli özellikleri yakalamak için aktivasyon fonksiyonları takip eder. Havuzlama, özellik haritasının boyutunu azaltır ve modelin daha genel özellikleri öğrenmesine

yardımcı olur. Genişletme yolu, indirgeme yolundan elde edilen özellik haritalarını kullanarak bölümleme haritasını yeniden oluşturur. Transpoze evrişim katmanları ile karakterize edilir ve özellik haritalarının boyutunu arttırır. Ek olarak, azaltma yolundan gelen yüksek çözünürlüklü özellikler, kırpma ve birleştirme işlemleriyle genişletme yoluna aktarılır ve bu, modelin daha ayrıntılı bilgileri korumasına olanak tanır. Base U-Net modeli az sayıda eğitim örneğiyle bile iyi performans gösterebilir. Böyle bir özellik, örnek sayısının sınırlı olduğu çalışmalarda U-net'i avantajlı kılmaktadır.

Base U-Net için ağ mimarisi iki boyuttan oluşmaktadır. Tam Evrişimli Ağ (Fully Convolutional Network) yapısını değiştirip ve genişletip kullanan U-Net az miktarda veri eğitim görüntüsü içeren veri seti ile çalışarak doğru segmentasyon üretimini sağlamaktadır. Buradaki ana fikir; daralma ağının sıralı katman yapıları ile değiştirilmesi ve havuzlama operasyonu üst örnekleme işleminin alt örnekleme işlemini desteklemesini sağlamaktadır. Böylece katmanlar çıktı çözünürlüğünü arttırılır. Yukarı doğru elde edilen çıktı ile kısaltılmış yoldan elde edilen yüksek çözünürlük ile birleştirilir ve ince nitelikleri çıkarabilen ve daha doğru bir segmentasyon sonucu veren sıralı evrişimli katmanlar oluşturulur.

Klasik bir CNN çoğunlukla evrişim sonrası birkaç tamamıyla bağlı katmana bağlanmış olur ve evrişim katmanı tarafından çıkarılan özellik haritası ile görüntü boyutunda sınıflandırma amacıyla uzunluğu sabit olan bir özellik vektörü ile eşlenmektedir. Fakat geliştirilen FCN yapısı, görüntü tanımlamasını piksel boyutunda gerçekleştirir ve bu sayede semantik boyutta görüntüleme için segmentasyon görevini basitleştirir [50]. U-Net, tıbbi görüntülerin ölçüm boyutunun büyük olması nedeniyle bölümlemeye uygulanabilir. Büyük medikal görüntülerin segmentlere ayrılarak küçük parçalara ayrılması gerektiğinde ağa girişi mümkün değildir. Ağ yapısı nedeniyle U-Net kullanılarak küçük parçaların kesilmesi için üst üste bindirme-işleme stratejileri uygundur. Her boyuttaki görselleri giriş olarak kabul edebilir [51].

2.2.3.2. Attention U-Net

Attention yani dikkat katmanları eklenerek U-Net mimarisinin geliştirilmesidir [52]. Base U-Net'in evrişim ve havuzlama katmanlarını korur. Ancak uzatma yolu sırasında özellik birleştirme noktalarına dikkat katmanları ekler. Dikkat katmanları, modelin kritik özelliklere odaklanmasına ve önemsiz arka plan ayrıntılarını göz ardı etmesine olanak tanır [53]. Bu yetenek, tıbbi görüntü segmentasyonu gibi ayrıntıların kritik olduğu uygulamalarda özellikle avantajlıdır. Dikkat mekanizması genellikle modelin bir sonraki katmanda hangi özelliklerin

daha önemli olduğunu öğrenmesine yardımcı olan bir bileşendir [54]. Veri kümesindeki karmaşık modeller arasındaki ilişkileri modellemenin ve önemli bilgilere odaklanmanın bir yoludur. Bu mimarideki dikkat mekanizmaları, azaltma yolundaki özellik haritalarıyla birleştirilmeden önce genişletme yolu sırasında kullanılır [55]. Dikkat U-Net birçok hastalığın tespitinde başarıyla uygulanmıştır [56-58].

Şekil 11'de gösterildiği üzere Attention U-Net mimarisi iki aşamadan oluşan U-Net temelline dayanmaktadır: İlk aşamada kodlama yapılır; ikinci aşamada bu kodlama çözülür. Önce yapının genel hatları haritalama bilgileri elde ediliyor ve ön planda yer alan objelerin çeşidi ve lokasyonu belirleniyor. Sonrasında ise fazlaca sayıda ölçek ile elde edilen nitelik haritaları, çıkarılan genel hatları ve ince özellik tahminleri atlama bağlantıları sayesinde birleştirilir [59].

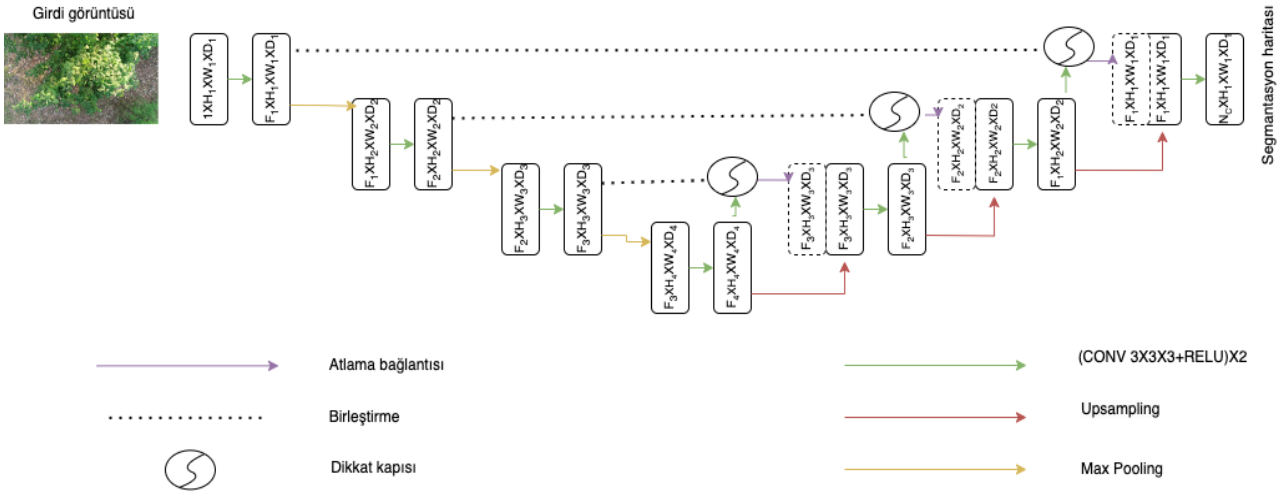

Şekil 11: Attention U-Net segmentasyon modelinin blok diyagramı. Giriş görüntüsü: kodlama kısmında her ölçekte aşamalı olarak filtrelenir. Dikkat kapıları filtreler Atlama bağlantıları aracılığıyla yayılan özellikler [60].

2.2.3.3. Inception U-Net

Inception U-Net mimarisi, U-Net mimarisinin başlangıç modülleri ile desteklenmesiyle ve güçlendirilmesiyle oluşturulan bir derin öğrenme modelidir [60, 61]. Bu model, başlangıç yapısının farklı ölçeklerdeki filtreleri kullanma yeteneğini U-Net çerçevesine başarıyla dahil

eder [62]. Inception U-Net, farklı ölçeklerdeki özellikleri etkili bir şekilde tespit edip işleyebilmektedir. Aynı katmanda farklı boyutlardaki filtrelerin kullanılması, modelin daha az parametreyle daha zengin özellik kümelerini öğrenmesine olanak tanır. Örneğin, küçük, orta ve büyük boyutlu evrişim filtreleri kullanılarak model hem ince ayrıntıları hem de daha genel özellikleri aynı anda yakalayabilir. Esnek bir modeldir ve çeşitli boyutlardaki özellikleri işleyebilir. Bu, onu farklı görev ve veri kümeleri için uygun hale getirir. Şekil 13'de Inception U-Net modeli mimarisi gösterilmektedir.

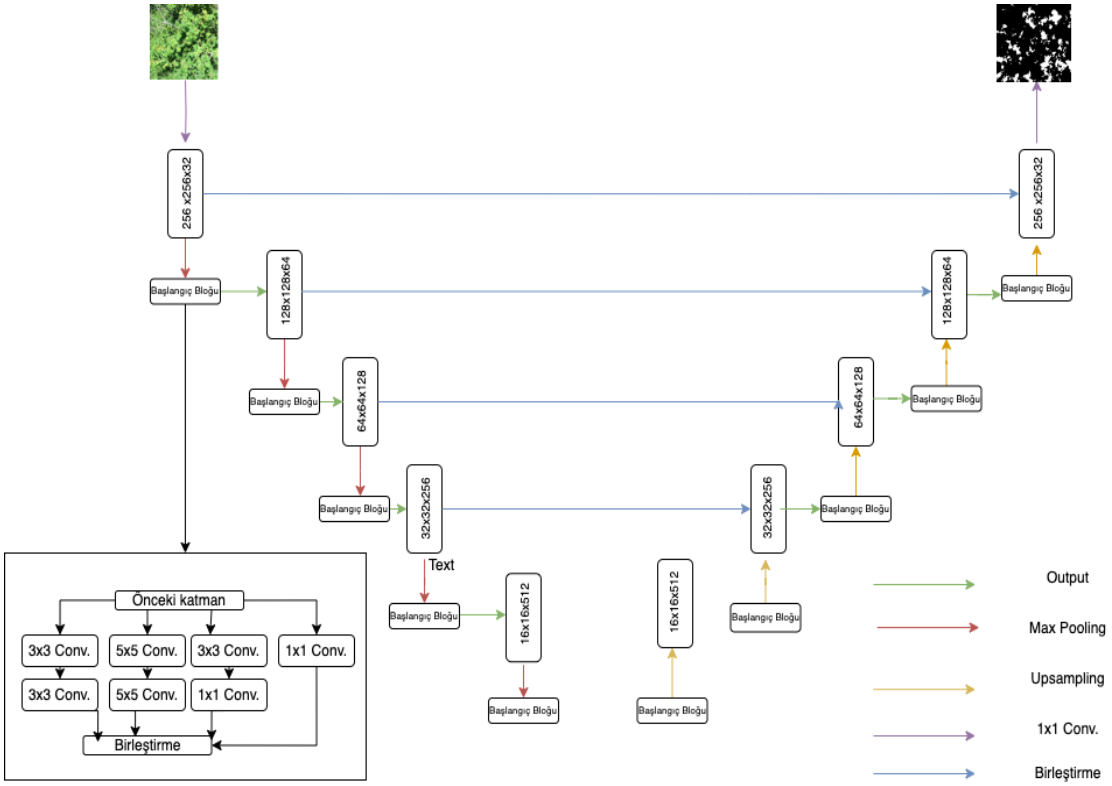

Şekil 12: Inception U-Net Mimarisi

Genellikle görüntü işleme için kullanılan algoritmalar evrişimler için sabit boyutta filtreler kullanırlar; ancak doğru filtre boyutunu belirlemek için modelin konfigürasyonu genellikle zahmetlidir. Üstelik boyutu sabit olan filtreler yalnızca benzer boyutta parçalar içeren görüntüler açısından uygundur. Birçok uygulamada ve analizde belirgin bölgedeki şekil ve boyut farkı olan görüntüler ele alınmaktadır. Bu soruna çözüm ise şekil ve boyut açısından geniş yelpazeye sahip örnek kümeler için yüksek seviyeli ayrıntıları okuyabilen daha derin ağlar kullanmaktır;ancak bu tür derin ağların da hesaplama maliyetleri yüksek olmaktadır.

Başlangıç ağı ağdaki aynı katmanda farklı boyutlarda filtre kullanarak bu soruna alternatif bir çözüm sunmaktadır. Çeşitli filtrelerden elde edilen çıktılar birleştirilerek sonraki diğer katmana iletilir. Başlangıç ağı, farklı filtre boyutları nedeniyle farklı belirgin bölgelere sahip görüntüleri oldukça etkili bir şekilde analiz edebilir. Hesaplama karmaşıklığını azaltmak için, başlangıç ağı boyut azaltma için her 3 × 3 veya daha büyük filtreden önce 1 × 1 evrişim ekler. Ek olarak, her başlangıç modülüne paralel olarak havuzlama katmanları da eklenebilir [61].

Şekil 13'de atlama bağlantıları olan üç ardışık ResNet bloğu gösterilmiştir. Atlanılan sinyal tüm nesneler için ekleme yolu aracılığı ile kanaldan elde edilen çıktı ile birleştirilir. Yaygın olarak kullanılan ResNet uygulamaları çift katmanlı veya üç katmanlı atlamalardır[47].

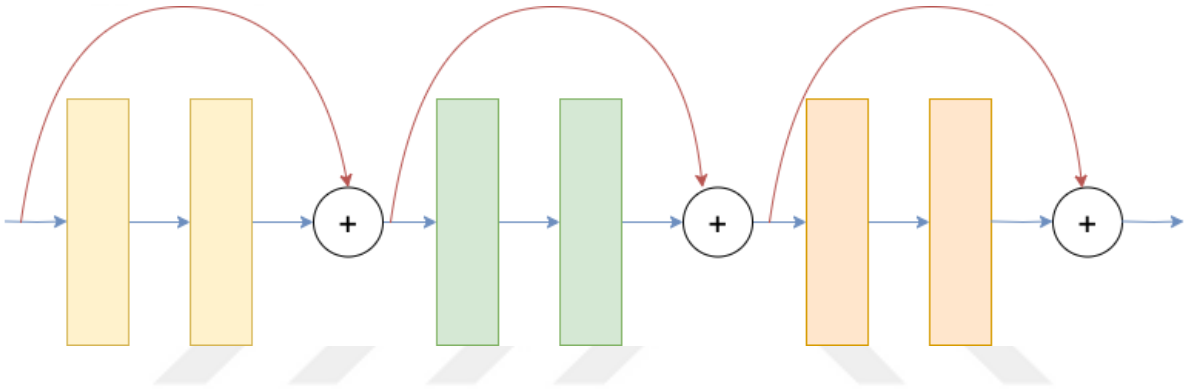

Şekil 13: Başlangıç modeli iki yapılandırması [40]

2.2.3.4. Residual U-Net

Base U-Net mimarisine artık blokların eklenmesiyle geliştirilmiş bir modeldir [63-65]. Bu yapısal iyileştirme, daha derin olmasına rağmen modelin eğitilmesini kolaylaştırır ve daha karmaşık özellikleri öğrenmesini sağlar. Artık bloklar, atlama bağlantıları kullanılarak giriş bilgilerinin bir veya daha fazla katmanın çıkışına eklenmesine olanak tanır. Yani artık bloklar, girişin bir kopyasını doğrudan çıkışa ekleyerek çalışır. Bu, eğitim sırasında bilginin derin katmanlara daha verimli aktarılmasını sağlar. Böylece model, kimlik fonksiyonunu öğrenebilir ve iyileştirme sağlamadığı takdirde ek katmanları atlayabilir. Doğrudan bağlantılar, geri yayılım sırasında degradelerin daha verimli şekilde akmasına olanak tanır ve bu da eğitim sürecinin hızlandırılmasına yardımcı olur. Bu şekilde ağın daha derin katmanları giriş sinyalinin daha saf bir formunu alır ve gradyanlar daha verimli bir şekilde yayılır. Bu, derin

ağların eğitiminde sıklıkla karşılaşılan kaybolan gradyan problemine bir çözüm sağlar[66]. Artık blokların kullanılması genellikle daha iyi segmentasyon performansına yol açar. Çünkü model daha zengin özellik hiyerarşilerini öğrenebilir. Beyin yapısının haritalanmasından meme kanserine kadar pek çok alanda kalıntı U-Net yapısı ile başarılı çalışmalar yapılmıştır; kemik yapısı analizinden prostat kanserine kadar [67-71].

Şekil 14'te tekrarlayan bir katman gösterilmektedir. Tekrarlayan bir katmanda her nöron farklı zaman aralıklarında çıktısından geri bildirim alır ve bir önceki katmandan da yeni bilgi alır. Aldığı bu bilgilerle yeni çıktısını üretir. Bu tekrarlayan yapı ağın ardışık bilgileri işlemesine imkan sağlar[47].

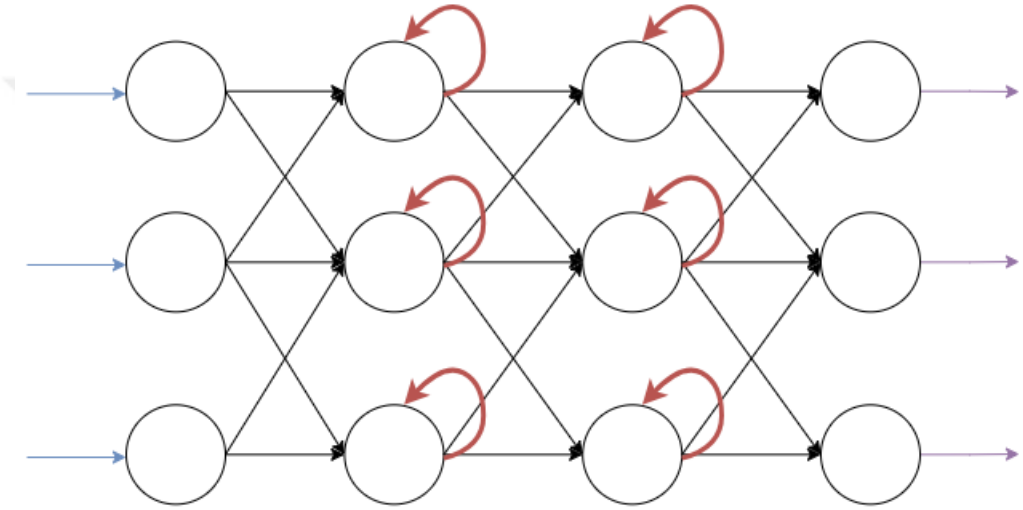

Şekil 14: Tekrarlayan katman[47]

Her bir kalıntı birimi şu şekilde gösterilebilir:

$$y_l = \mathrm{h}(x_l) + \mathrm{F}((x_l, (w_l) \quad (2.2)$$

$$x_{l+1} = \mathrm{f}(y_l) \quad (2.3)$$

Formül 2.2'de;

x_l: Kalıntı birimi girişidir.

$\mathrm{h}(x_l)$: Kimlik eşleme fonksiyonudur.

$\mathrm{F}((x_l, (w_l)$:Kalıntı fonksiyonuna karşılık gelir.

y_l: Kalıntı birimi çıkışıdır.

Formül 2.3'de;

x_{l+1}: Kalıntı birimi girişine denk gelir.

f (y_l): Aktivasyon fonksiyonudur.

2.2.3.5. U-Net+ RCN

Yinelenen Evrişimsel Ağ (Recurrent Neural Networks-)'ları ve U-Net, derin öğrenme tabanlı görüntü bölütleme görevlerinde birlikte kullanılabilecek veya birbirlerinin özelliklerinden yararlanabilecek şekilde tasarlanmıştır [72]. Özellikle, RCN'lerin tekrarlayan doğası, segmentasyon sırasında daha ayrıntılı ve doğru sonuçlar sağlamak için U-Net mimarisine entegre edilebilir [73]. Özellikle, RCN'ler mekansal bağlamı veya zamansal değişimleri ele almak için kullanılır. Bu, yinelenen yapıların her yinelemede girdi hakkında daha fazla bilgi toplamasına ve modelin sonraki katmanlarında daha zengin temsiller üretmesine olanak tanır. U-net ile birleştirildiğinde bu yaklaşım, segmentasyonun daha doğru ve ayrıntılı hale getirilmesine yardımcı olabilir [74].

Tekrarlayan veya yinelenen sinir ağları ses ve metin gibi sıralı olan verilerin incelenmesi amacıyla geliştirilmiş bir sinir ağı çeşidir. Ağ, bir düğümün çıktısının, Şekil 6'da gösterildiği gibi, geleneksel bir ileri beslemeli ağın aksine, aynı düğümlerden gelen önceki çıktıya göre değişeceği şekilde tasarlanmıştır. Sürekli bir geri bildirim tekrarından dolayı tekrarlayan veya yinelenen bağlantı olarak ifade edilir. Düğüm için çıktının farklı adımlarda değiştirilmesini sağlayan zamansal nitelikler sunan dahili bir bellek oluşturmaktadır. Bu özellik diğer tüm katmanlara entegre edildiğinde önceki verilerden elde edilne bağlamsal verilerin işlenebilmesi için imkan sunar. Tekrarlayan U-Net modeli geri bildirim içeren döngülerini evrişimsel bir katmana dahit etmesiyle yinelenen evrişimsel sinir ağlarını kullanmaktadır. Geri bildirim kullanımı ise hem evrişim sonrası hem de aktivasyon fonksiyonu sonrasında olmaktadır ve bir filtrenin çıkardığı özellik haritasını ilgili ikatmana iletmesiyle geri besleme gerçekleşir. Her bir birim geri bildirim özelliği sayesinde kendi özellik haritasını yan birimlerinden aldıkları bağlama göre güncelleyerek elde ettikleri bilgilerin doğruluğunu arttırarak daha iyi bir performans elde ederler [47].

2.2.3.6. Dense U-Net

DenseNet'in özelliklerini entegre ederek U-Net mimarisini geliştiren derin bir öğrenme modelidir [75, 76]. Bu model DenseNet'ten alınan yoğun bağlantı yapısını kullanır. Yoğun bağlantılar, her katmanın çıktısının sonraki tüm katmanlara doğrudan bağlı olduğu anlamına gelir [77]. Yoğun bağlantılar sayesinde, Yoğun U-Net modelinde özellikler maksimum düzeyde yeniden kullanılır [78]. Bu, modelin daha az parametreyle daha fazla bilgi edinmesine olanak tanır. Yoğun bağlantılar, ağın daha derin katmanlarına verimli bir gradyan akışı sağlar ve bu da, yok olan gradyan problemine bir çözüm sağlar [79]. Yoğun bağlantıların sağladığı özellik entegrasyonu, modelin daha detaylı ve hassas segmentasyon haritaları üretmesine yardımcı olur. Beyin tümörü analizi, akciğer ve karaciğer kanseri tanısı, serebral kan damarı segmentasyonu gibi birçok çalışmada kullanılmış ve başarılı sonuçlar elde edilmiştir [80-83].

2.2.3.7. U-Net++

Kodlayıcı ve kod çözücü olara iki aşamalı mimarı kullanan görüntü işleme modellerinin görüntü bölütleme modelleri arasında en gelişmiş olduğu kabul edilmektedir.[84] Mimariyi kullanan segmantasyon ağlarının yapısı kodlayıcı, kod çözüçü, alt aşındaki derinlik, anlam bilim, kaba taneli özellik haritaları ve bağlantı atlatmalarından oluşmaktadır. Tıbbı görüntülerdeki lezyonların ya da anomali görüntülerde keskinliğe daha çok ihtiyaç duyulmaktadır. Tıbbı görüntüleme üzerine yapılan çalışmalarda kenar bölütlemede meydana gelen yanlışlıklar klinkte sonuçları ciddi olan sorunlara neden olabilmektedir. Bu nedenle, bu sorunu çözmek için özellik füzyonunu iyileştirmeye yönelik çeşitli yöntemler önerilmiştir ve bu yöntemlerden biri de derin izleme iç içe yoğun atlama bağlantı yolu ile UNet++ modelidir.

U-Net mimarisinin daha gelişmiş bir versiyonudur. Orijinal U-Net mimarisine ek olarak, bu model bir dizi iç içe geçmiş U-Net yapısından oluşur [85]. Bu yapılar, farklı derinlik seviyelerindeki özellikleri daha etkili bir şekilde birleştirmeyi ve böylece segmentasyon performansını iyileştirmeyi amaçlamaktadır [86]. Özelliklerin farklı derinlik seviyelerindeki etkili kombinasyonu, modelin hem yerel ayrıntıları hem de genel bağlamı daha iyi anlamasına yardımcı olur. Bu mimari diğer U-Net varyanslarından daha esnek ve uyarlanabilirdir. Farklı segmentasyon görevlerine ve çeşitli görüntü boyutlarına kolaylıkla uyum sağlayabilir [87]. Ayrıca, farklı görevler için özelleştirmeye olanak tanıyan modelin parçalarını eğitim sürecine dahil etme veya hariç tutma olanağı da sunar. U-Net++'ın geliştirilmesi, derin öğrenme tabanlı

görüntü bölütleme alanında önemli bir yenilik olarak kabul edilmektedir ve bu mimari üzerinde yapılan çalışmalar [68-71], bölütleme tekniklerinin geliştirilmesine önemli katkılar sağlamıştır[88-91].

U-Net'te ise kodlayıcının özellik haritası kod çözücü tarafından alınır. Fakat U-Net++ modelinin kullandığı evrişim bölümü yoğundur ve evrişim katmanlarının adedi mimarideki U'nun yapısına göre değişiklik göstermektedir. Kodlayıcı ile kod çözücü nitelik haritalarında oluşan anlamsal boğluğun birbirine bağlanması yoğun evrişim bölümü ile sağlanır. Burada kodlayıcıdan elde edilen özellik haritası ve ilgili kod çözücü özellik haritasının bir anlam ifade edecek düzeyde benzerlik göstermesi optimize edicinin karşı karşıya kaldığı sorunları basit bir şekilde çözebileceğini kabul etmektedir. Bilinmeyen ağ derinliklerinin hafifleştirilmesi amacıyla çeşitli derinliklere sahip U ağlarının etkin entegrasyonu kullanılmaktadır. Bu U-Net'ler bir kodlayıcıyı kısmen paylaşabilir ve aynı anda derin denetim yoluyla birlikte öğrenebilir, bu da modelin budanmasına ve geliştirilmesine olanak tanıyacaktır. Tasarımı yeniden yapılan bu atlama bağlantısı, kod çözücü alt ağında çeşitli ölçeklerdeki anlamsal nitelikleri yan yana getirebilir ve otomatik olarak esnek bir nitelik birleşim haritası ortaya çıkarabilir [59].

2.3. Metodoloji

Bölüm 2.3, özel veri kümesinin kökenine ilişkin kapsamlı bir genel bakış sunmaktadır. Özellikle bu bölümdeki söylem, Bölüm 2.2'de tanıtılan derin öğrenme mimarilerini kullanarak eğitim, doğrulama ve test için kullanılan metodolojileri açıklamaya odaklanmaktadır. Fındık yaprağı hastalıklarını, insansız hava aracı görüntüleri üzerinde gelişmiş görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanarak segmentlere ayırmak için kapsamlı bir çerçeve geliştirildi ve Şekil 6'de gösterildiği gibi, fındık ağacı bahçeleri üzerinden çekilen yüksek çözünürlüklü hava görüntüleri kullanılarak fındık yaprakları üzerindeki hastalıklı alanların doğru bir şekilde tanımlanması amaçlanmıştır.

Çalışmanın deneysel kurulumuna ilişkin olarak, derin öğrenme modellerinin verimli bir şekilde uygulanmasını kolaylaştırmak için yüksek çözünürlüklü Red-Green-Blue (RGB) görüntüleri başlangıçta 256x256 kare boyutunda parçalara bölündü. Aşırı uyumu önlemek amacıyla, belirli sınırlar dahilinde rastgele ayarlanmış parametrelere dayalı olarak eğitim veri setini genişletmek için çeşitli veri büyütme teknikleri uygulandı. Daha sonra, insan gözlemciler tarafından algılanan hastalıklı yaprak alanlarının çokgen etiketlenmesi yoluyla temel gerçek maskeleri

üretildi. Amaç, hastalık türleri arasında ayrım yapmadan yalnızca hastalıklı ve sağlıklı bölgelere odaklanan ikili sınıflandırma ve semantik segmentasyon olduğundan, hastalıklı alanları gösteren maskeler, karşılık gelen gerçek görüntülerin yanı sıra model eğitimi için girdi verileri olarak kullanıldı. Her model, bu eğitim aşamasında aynı eğitim verilerini kullandı ve çıktı verileri olarak segmentasyon haritaları üretti. Test aşamasında, eğitim veri setinin parçası olmayan görüntü verileri ilk kez eğitilmiş modeller tarafından değerlendirildi. Benzer boyutlarda (256x256 çerçeve boyutları) parçalara bölündükten sonra değerlendirme (tahmin) işlemi gerçekleştirildi. Daha sonra, hastalıklı bölgeleri orijinal boyutlarında elde etmek için bölümlenmiş çıktı haritaları yeniden birleştirildi.

Tüm modeller için Adam optimizer, 0,001 öğrenme oranı ve 16 parti büyüklüğü ile kullanıldı ve 30 dönemlik bir eğitim oturumuna tabi tutuldu.

Şekil 15'de tez çalışmasında gerçekleştirilen iş akışına ait özet gösterilmektedir.

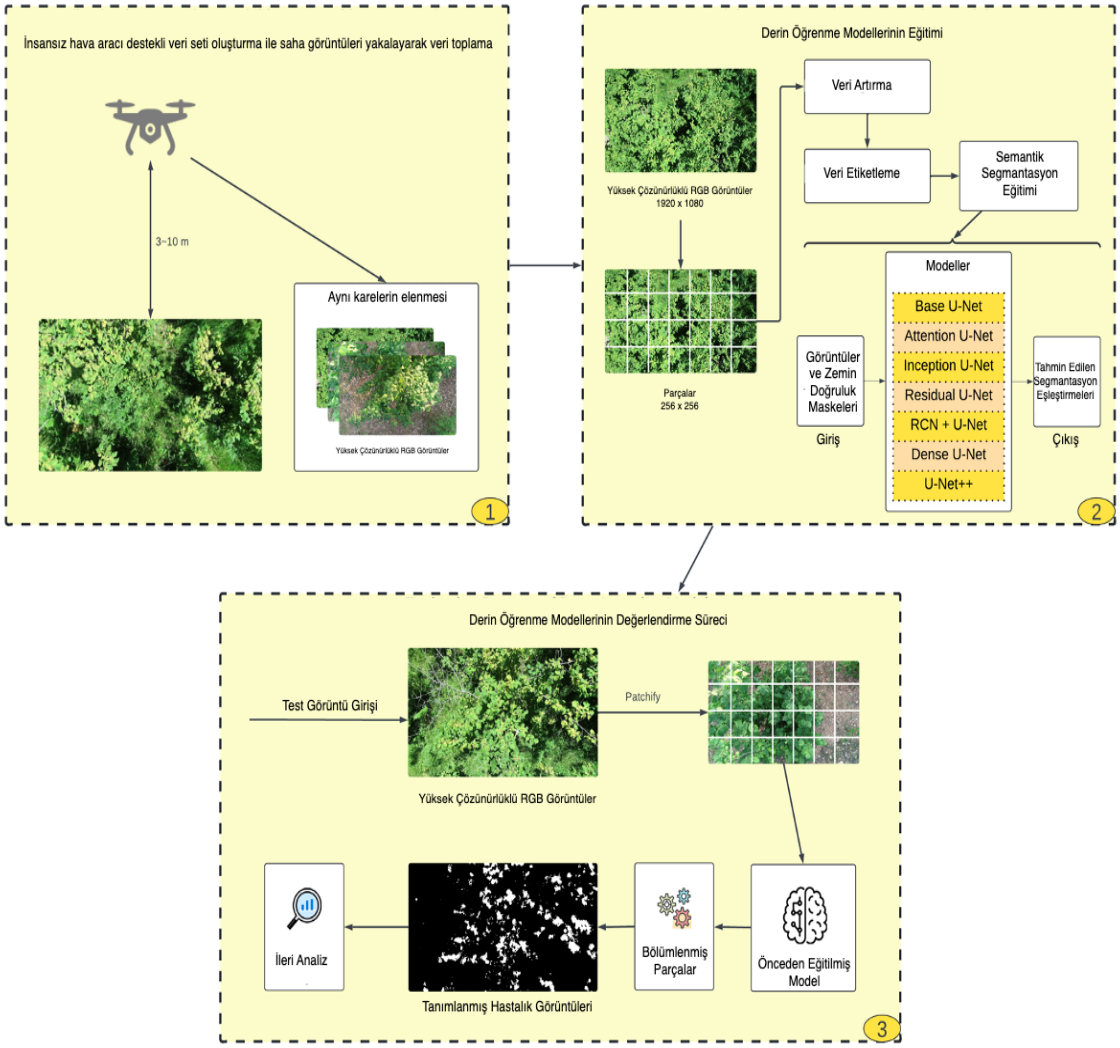

Şekil 15: İnsansız hava aracı görüntülerine uygulanan ileri görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanılarak fındık yaprağı hastalıklarının segmentasyonu için kapsamlı bir çerçeve geliştirilmiştir. Çerçeve, hastalıklı alanları doğru bir şekilde tanımlamayı amaçlamaktadır.

2.3.1. Performans Metrikleri

Model etkililiğinin değerlendirilmesi, oluşturulan görüntüler ile referans şablonları arasındaki anlaşmanın kapsamlı bir analizine dayanır. Model performansı ölçmek amacıyla karşılaştırma matrisinden elde edilen Doğruluk, Kesinlik, F ölçümü, Duyarlılık değerleri ve bu değerler

kullanılarak yapılan hesaplamalarla elde edilen Ortalama Piksel Doğruluğu, Benzerlik Skoru, Ortalama Hassasiyet değerleri kullanılmıştır.

Tablo 2: Karmaşıklık matrisi

	Pozitif Tahmin	Negatif Tahmin
Gerçek Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
Gerçek Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

$$\textbf{mean pixel Accuracy} = \frac{1}{N}\sum_{i=1}^{N}\frac{TP(i)+TN(i)}{2\times TP(i)+FP(i)+FN(i)} \quad (2.4)$$

Formül 2.4 ortalama piksel doğruluğunu vermektedir, hesaplamada kullanılan:

N: Eğitim sayısı,

TP: True Pozitif yani doğru pozitif tahmin sayısını,

TN: True Negatif yani doğru negatif tahmin sayısını,

FP: False Pozitif yani yanlış pozitif tahmin sayısını,

FN: False Negatif yani yanlış negative tahmin sayısını

Ifade etmektedir.

Doğruluk metriği, doğru tahminde bulunulan örneklem sayısının toplam tahminde bulunulan örneklem sayısına oranıdır. Görüntü işleme çalışmalarında ise örnekler çoğunlukla vokseller ya da piksellerdir.Ancak doğruluk, görüntü işlemede ortaya çıkabilecek dengesiz veri dağılımlarında yardımcı olmaz ve nadiren kendi başına dikkate alınır [92].

$$\textbf{precision} = \frac{TP}{TP+FP} \quad (2.5)$$

Formül 2.5 hassasiyet değerini vermektedir. Doğru pozitif sayısının doğru pozitif ve yanlış pozitif sayısına oranı ile elde edilir. Hassasiyet değeri pozitif olarak tahmin edilen tüm değerler

arasında doğru tahmin edilen pozitifleri ölçer. Hassasiyet görüntüde yer alan yanlış pozitif piksel sayısını ölçmek için kullanılır [92].

$$\boxed{\textbf{recall} = \frac{TP}{TP + FN}} \tag{2.6}$$

Formül 2.6 geri çağırma formülünü göstermektedir,Doğru pozitif sayısının doğru pozitif ve yanlış negatif sayılarının toplamına oranıdır.

Geri çağırma ya da duyarlılık, doğru pozitif olarak tahmin edilen örneklerin oranını ölçmektedir ayrıca bir görüntüde tahmin edilen yanlış negatif piksel sayısının ölçümü için de kullanılır [92]. Bir modelin veya algoritmanın çok daha geniş bir değerlendirmesini elde etmek için hassasiyeti geri çağırmayla veya özgüllüğü duyarlılıkla eşleştirmek yaygın bir uygulamadır

$$\boxed{\boldsymbol{mIoU} = \frac{1}{N}\sum_{i=1}^{N}\frac{TP(i)}{TP(i) + FP(i) + FN(i)}} \tag{2.7}$$

Formül 2.7 Tahmin edilen ile hedef alanlarının kesişimlerinin birleşimlerine oran ortalamasını vermektedir. Her bir yamada TP sayısının; TP, FP ve FN sayılarının toplamına oranıdır.

$$\boxed{\boldsymbol{AP} = \frac{1}{N_b}\sum_{k=0}^{N_b-1}(recall(k) + recall(k+1)) \times precision(k)} \tag{2.8}$$

Formül 2ç8 Hassasiyeti vermektedir:

$\boldsymbol{N_b}$: Bir yinelemede kullanılan örnek sayısnı göstermektedir. (batch size)

$$\boxed{\boldsymbol{mAP} = \frac{1}{N}\sum_{i=1}^{N} AP(i)} \tag{2.9}$$

Formul 2.9 ortalama hassasiyet değerini vermektedir.

$$\boxed{\boldsymbol{mDice} = \frac{1}{N}\sum_{i=1}^{N}\frac{2\times TP(i)}{2\times TP(i) + FP(i) + FN(i)}} \tag{2.10}$$

Formul 2.10 tahmin edilen segmentasyon maskesiyle gerçek segmentasyon maskesi benzerlik skorunu vermektedir, iki örnek arasındaki benzerliği karşılaştırır.

3. SONUÇLAR VE TARTIŞMA

3.1. Farklı Modellerin Karşılaştırmalı Analizi

Şekil 16, tüm model çıktılarının segmentasyon haritalarını, orijinal görüntülerle ve test veri kümesinden rastgele seçilen 5 görüntünün temel gerçek maskeleriyle birlikte gösterir. Ayrıca performans metriklerinin sonuçları, çeşitli model performanslarını karşılaştırmak için yararlı bir kıyaslama olan Tablo 3'te verilmektedir. Bu bulgular ışığında U-Net++ modelinin özel veri seti üzerinde değerlendirmede en etkili performansa sahip olduğu sonucuna varabiliriz. Bu durum modelin segmentasyon görevindeki başarısını destekleyen önemli bir bulgu olarak değerlendirilebilir.

Giriş Görüntüleri

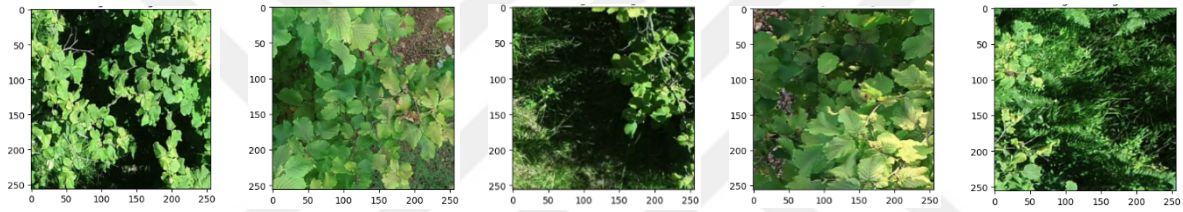

Maske

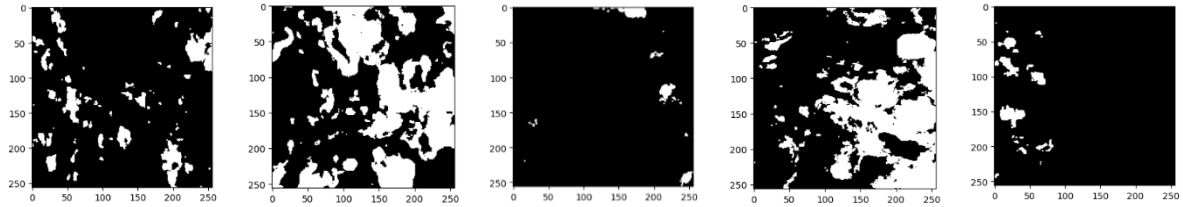

Base U-Net

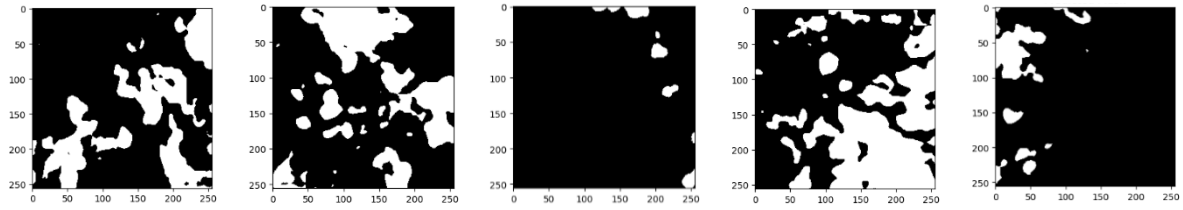

Attention U-Net

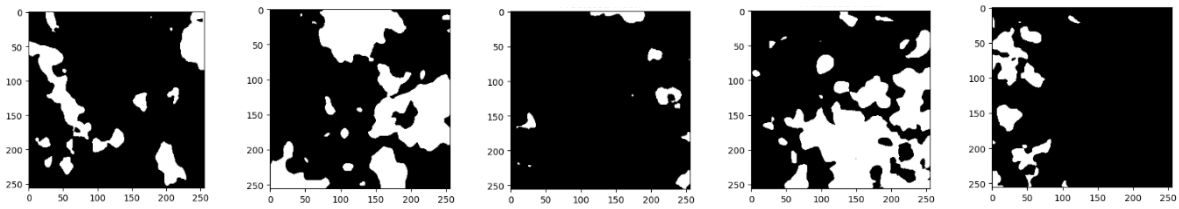

Inception U-Net

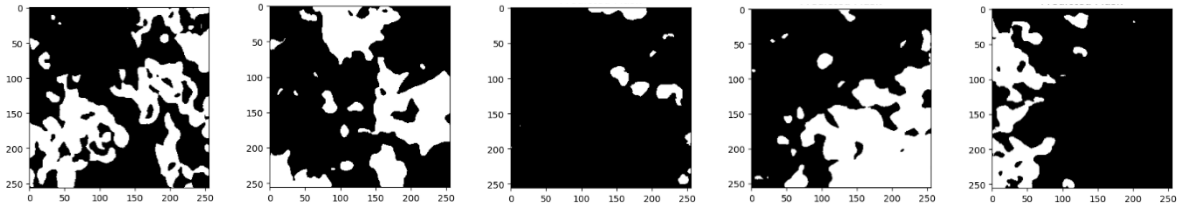

Residual U-Net

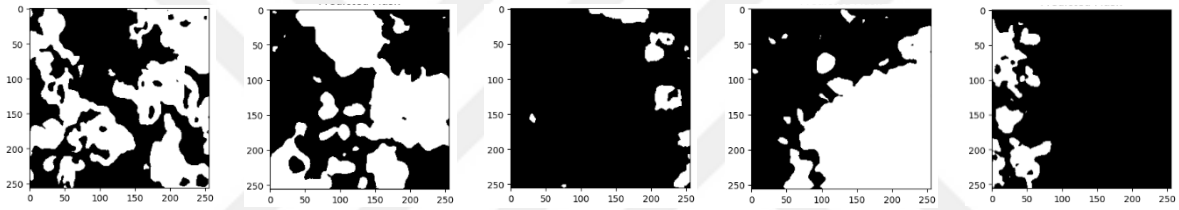

RCN + U-Net

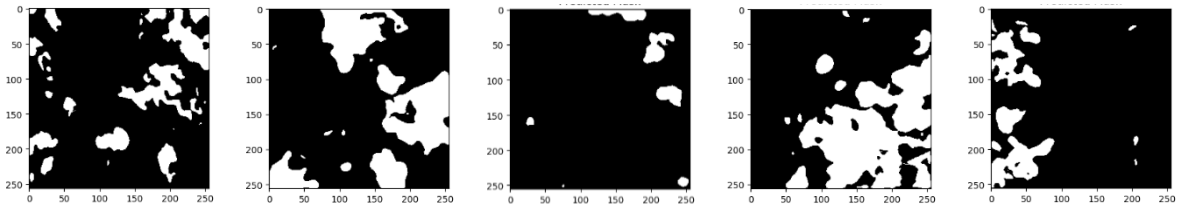

Dense U-Net

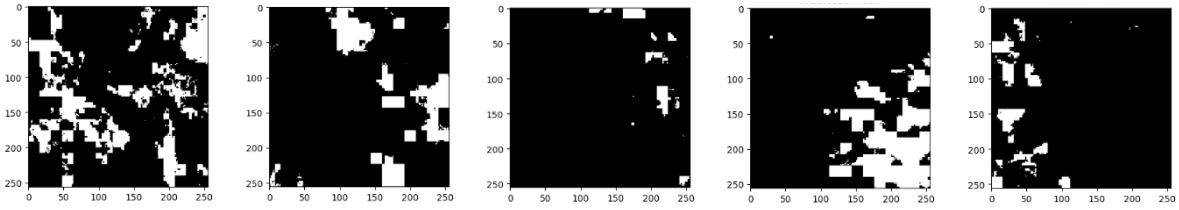

U-Net++

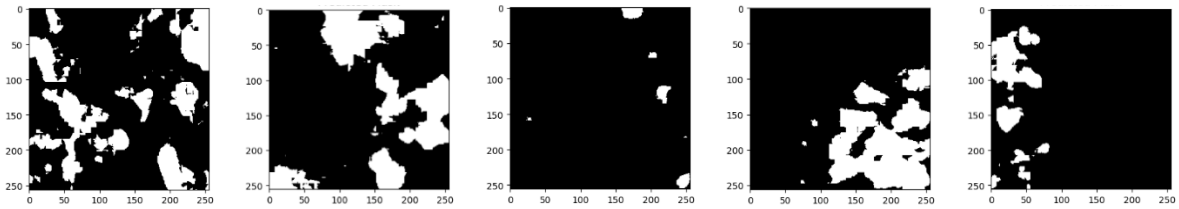

Şekil 16: Farklı U-Net modellerine ait semantik segmantasyon sonuçları

Tablo 3'de Hazırlanan veri seti kümesinin Base U-Net, Attention U-Net, Inception U-Net, Residual U-Net, RCN + U-Net, Dense U-Net, U-Net++ modellerine uygulanmasıyla elde edilen sonuçlar sunulmaktadır.

Tablo 3: Farklı modellerin performans karşılaştırması

Model Adı	mIoU	mAP	mDice (%)	Piksel Doğruluğu (%)	Running Time (s/batch)
Base U-Net	0.39	0.65	56.26	87.50	1.71
Attention U-Net	0.45	0.59	62.34	87.00	1.76
Inception U-Net	0.46	0.56	62.39	86.56	1.77
Residual U-Net	0.46	0.51	62.52	83.24	1.73
RCN + U-Net	0.46	0.61	63.29	87.24	1.72
Dense U-Net	0.41	**0.68**	58.15	87.95	1.73
U-Net++	**0.48**	0.64	**64.49**	**88.06**	**1.68**

3.2. Mevcut Araştırmaların Ötesinde U-Net Derin Öğrenme Modellerini Kullanan Çeşitli Bitki Yaprak Hastalıkları Tespit Yaklaşımlarının Değerlendirilmesi

Literatürde diğer mahsuller için değiştirilmiş U-Net modelleriyle yaprak hastalıklarını tespit eden çalışmaların genel bulguları Tablo 4'te sunulmaktadır. Yukarıda bahsedilen çalışmaların karşılaştırması şu şekilde özetlenebilir: Görüntü oluşturmayla ilgili olarak, çalışma sentetik teknolojiden yararlanmıştır [4]. Derin Evrişimli Üretken Çekişmeli Ağı (Deep Convolutional Generative Adversarial Network) tarafından oluşturulan görüntüler, çalışmalarda ise artırılmış

gerçek görüntüler kullanıldı [3, 5, 7, 24, 26]. Buna karşılık, çalışmada segmentasyon sonrası görüntüler kullanıldı[5]. Görüntü yakalama ortamına ilişkin çalışmalar doğal ortamda yürütülürken, diğer çalışmalar laboratuvar ortamında yürütülmüştür [4, 24, 26]. Yapılan çalışmaların her birinde, U-Net tabanlı modellerin, kullanılan veri kümeleri genelinde üstün performans gösterdiği tutarlı bir şekilde gözlemlendi. Bu fenomen, doğal ortamda mı yoksa laboratuvar ortamında mı yakalandıklarına bakılmaksızın, veri kümelerinde yer alan yaprak görüntülerinin yakın plan ve yüksek çözünürlüklü doğasına atfedilebilir. U-Net tabanlı modellerin bu tür görüntüleri doğru bir şekilde segmentlere ayırmadaki etkinliği, bunların çeşitli çevresel koşullardaki sağlamlığını ve uyarlanabilirliğini vurguluyor ve böylece görüntü analizi görevlerindeki önemini doğruluyor.

Tablo 4: Diğer bitkiler için değiştirilmiş U-Net modelleri İle yaprak hastalıklarının tespiti hakkında literatür araştırması

Ref.	Argüman	Detay
[3]	Data	20,000 augmented pepper leaf images, 120x120 pixels RGB
	Image Generation	Augmented from real images
	Image Capturing Env.	Laboratory environment
	Model	InceptionV3, UNet
	Scores	F1 Score: 0.99
[4]	Data	10,000 synthetic jasmine leaf images, 256x256 pixels RGB
	Image Generation	Created using DCGAN
	Image Capturing Env.	Natural environment
	Model	Custom Backbone ResUNet
	Scores	mIoU: 0.91, Dice Score: 0.96
[5]	Data	18,161 tomato leaf images, various conditions
	Image Generation	Used after segmentation

	Image Capturing Env.	Laboratory environment
	Model	EfficientNet, Modified U-net
	Scores	IoU: 0.99, Dice Score: 0.99
[7]	Data	2,000 potato leaf images, 256x256 pixels RGB
	Image Generation	Augmented from real images
	Image Capturing Env.	Laboratory environment
	Model	RS-UNet (Enhanced with ResNet50 and SE)
	Scores	IoU: 0.80, Dice Score: 0.89
[24]	Data	Diseased pear leaf images from Dangshan fruit orchard, 512x512 pixels
	Image Generation	Augmented from real images
	Image Capturing Env.	Natural environment
	Model	MFBP-UNet.
	Scores	mIoU: 0.86, Dice Score: 0.92
[26]	Data	Various crop leaf images, segmented into sections, 512x512 pixels RGB
	Image Generation	Augmented from real images
	Image Capturing Env.	Image Environment: Natural environment
	Model	LWMSDU-Net (Lightweight Multi-Scale Dilated U-Net)
	Scores	F1 Score: 91.57

4. SONUÇLAR

Bu tez çalışmasında, modern tarımda kullanılmak üzere insansız hava aracı ile taranan tarım alanlarında bitki hastalıklarını tespit etmek üzere bir derin öğrenme modeli önerilmiştir. Literatürde bitki hastalıklarını tespit etmek üzere yapılan çalışmalar incelendiğinde gerçek ortamda elde edilen görüntüler ile sentetik teknolojilerin kullanıldığı çalışmalarda U-Net tabanlı derin öğrenme modellerinin başarılı sonuçlar elde ettiği görülmüştür. Bu sebeple tez çalışmasında bitki hastalıklarını tespit etmek üzere derin öğrenme yaklaşımı benimsenmiş ve U-Net modelleri kullanılmıştır. 7 ayrı U-Net deneysel modeli oluşturulmuş ve veri setine ayrı ayrı uygulanmıştır ve elde edilen sonuçlar ışığında U-Net++ derin öğrenme modeli insasnsız hava aracı görüntülerinden bitki hastalıkları tespitinde daha başarılı olduğu gözlemlenmiştir.

Çalışma kapsamında fındık üretiminin yapıldığı bölgelerden, fındık bitkisinde meydana gelen hastalıkları örnekleyen görüntüler elde edilerek veri seti oluşturulmuştur. Bitki hastalık tespiti için yapılan çalışmaların aksine görüntüler tek bir yaprağın yakın görüntüsünü değil; uzaktan çekilmiş fındık ağaçları üzerinde sık yaprak görüntülerinden oluşmaktadır. Karmaşık görüntüler üzerinden bitki hastalıklarını tespit etmek üzere çekilen video görüntülerinden kareler elde edilerek ve elde edilen görüntülere veri arttırma, veri etiketleme, semantik segmantasyon,görüntü ve zemin ayrıştırılması için maskeleme gibi görüntü işleme teknikleri uygulanarak özgün bir veri seti elde edilmiştir

Tez çalışmasına ön araştırma nitelğinde yayınlanan makalede hastalıklı fındık bitkisi yaprak görüntülerinden oluşan veri seti oluşturulmuş ve nesne tespiti üzerine YOLOv5 modeli önerilmiştir[37]. Çalışma yakından çekilmiş görüntüleri içerirken tez çalışmasında insansız hava aracı ile uzaktan taranan bahçe alanlarında hastalık tespiti amacına uygun olarak karmaşık görseller üzerinde etkile olan sentetik segmentasyon ve görüntü zemin ayırt edici maskeleme teknikleri uygulanmıştır. Tez çalışmasında görüntü segmantasyonuyla görüntü piksellerine etiketler atayarak görüntünün daha çok işlenmesine olanak sağlar ve karmaşıklığı azaltan U-Net modelleri üzerine odaklanılmıştır.

Elde edilen veri seti; Base U-Net, Attention U-Net, Inception U-Net, Residual U-Net, RCN + U-Net, Dense U-Net ve U-Net++ olmak üzere 7 ayrı U-Net modeli ile test edilerek deneysel sonuçlar elde edilmiştir. Uygulanan modeller arasında U-Net++ modeli diğer modellere göre 1.68(s/batch) çalışma zamanıyla diğer modeller arasında en hızlı sonucu vermektedir. U-Net++ modeli %88.06 piksel doğruluğu ile en yüksek doğruluk sonucunu vermiştir; ayrıca tahmin

edilen segmentasyon maskesiyle gerçek segmentasyon maskesi benzerlik skoru (mDice) %64.49 değeri ile diğer modellerden daha yüksektir. Ortalama hassasiyet mAP skor değerlerinde U-Net++ modeli 0.64 ile 0.68 mAP skoruna sahip Dense U-Net modelinden daha düşük; ancak diğer modellerden daha yüksek sonuç vermiştir. Tahmin edilen ile hedef alanlarının kesişimlerinin birleşimlerine oran ortalamasını veren mloU skorunda ise U-Net++ modeli 0.48 ile en yüksek sonucu vermiştir.

Sonuç olarak bulgular, beklenenden biraz daha düşük performans metrik puanlarına rağmen, U-Net++ modelinin hastalıklı yaprak bölgelerini segmentlere ayırmadaki etkinliğinin altını çiziyor. Yapraklar dışındaki nesnelerin dikkate alınması, yanlış pozitiflerin, yanlış negatiflerin ve gerçek negatiflerin artmasına katkıda bulunur ve daha iyi sonuçlar için eğitim veri setinin genişletilmesi ve modele özgü hiperparametrelerin ayarlanması gerekliliğini ortaya koyar. Özellikle, ağaç tabanlı hastalık tespiti için yüksek uçan insansız hava araçlarının kullanılması, dikkatli görüntü yakalama ve belirli açılardan analiz gerektirir. Gelecekteki çalışmalar bu faktörleri daha derinlemesine incelemeli ve erken yaprak hastalığı tespit tekniklerinin etkinliğini daha da artırmak için metodolojik ilerlemeler sağlamaya çalışmalıdır. Bu araştırma, tarımsal üretim kayıplarının azaltılmasında potansiyel uygulamalarla yenilikçi teknolojilerin ilerlemesine önemli ölçüde katkıda bulunarak, daha verimli ve hassas meyve bahçesi gözetim yöntemlerinin önünü açmaktadır.

Gelecekte görüntülerle eğitilmiş ağdan kararlı ve başarılı sonuçlar elde etmek üzere çalışmaların geliştirilmesi; elde edilen eğitimli modelin gömülü sistem yazılımı olarak insansız hava aracına yüklenerek bitki hastalıkları tespitinde kullanılmak üzere ürünleştirilmesi hedeflenmektedir.

KAYNAKÇA

1. Yaman, O. and T. Tuncer, *Bitkilerdeki Yaprak Hastalığı Tespiti için Derin Özellik Çıkarma ve Makine Öğrenmesi Yöntemi.* Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 2022. **34**(1): p. 123-132.
2. Aabidi, M.H., et al., *A Model Proposal for Enhancing Leaf Disease Detection Using Convolutional Neural Networks (CNN): Case Study.* International Journal of Online & Biomedical Engineering, 2023. **19**(12).
3. AlArfaj, A.A., et al., *Multi-Step Preprocessing With UNet Segmentation and Transfer Learning Model for Pepper Bell Leaf Disease Detection.* IEEE Access, 2023. **11**: p. 132254-132267.
4. Bhagwat, A., V. Laxmi, and S. Shrivastava, *A Custom Backbone UNet Framework with DCGAN Augmentation for Efficient Segmentation of Leaf Spot Diseases in Jasmine Plant.* Journal of Computer Networks & Communications, 2024. **2024**.
5. Chowdhury, M.E., et al., *Automatic and reliable leaf disease detection using deep learning techniques.* AgriEngineering, 2021. **3**(2): p. 294-312.
6. Dwivedi, R., T. Dutta, and Y.-C. Hu, *A leaf disease detection mechanism based on L1-norm minimization extreme learning machine.* IEEE geoscience and remote sensing letters, 2021. **19**: p. 1-5.
7. Fu, J., Y. Zhao, and G. Wu, *Potato leaf disease segmentation method based on improved unet.* Applied Sciences, 2023. **13**(20): p. 11179.
8. Gautam, V., et al., *A transfer learning-based artificial intelligence model for leaf disease assessment.* Sustainability, 2022. **14**(20): p. 13610.
9. Gopi, S.C. and H.K. Kondaveeti. *Transfer Learning for Rice Leaf Disease Detection*. in *2023 Third International Conference on Artificial Intelligence and Smart Energy (ICAIS)*. 2023. IEEE.
10. Guo, W., et al., *Grape leaf disease detection based on attention mechanisms.* International Journal of Agricultural and Biological Engineering, 2022. **15**(5): p. 205-212.
11. Joshi, K., et al. *Plant leaf disease detection using computer vision techniques and machine learning*. in *ITM Web of Conferences*. 2022. EDP Sciences.
12. Kaur, A., K. Guleria, and N.K. Trivedi. *A Deep Learning Based Model for Rice Leaf Disease Detection*. in *2022 10th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions)(ICRITO)*. 2022. IEEE.
13. Kini, A.S., P.K. Reddy, and S.N. Pai, *Techniques of deep learning and image processing in plant leaf disease detection: a review.* International Journal of Electrical and Computer Engineering, 2023. **13**(3): p. 3029-3040.
14. Mahum, R., et al., *A novel framework for potato leaf disease detection using an efficient deep learning model.* Human and Ecological Risk Assessment: An International Journal, 2023. **29**(2): p. 303-326.

15. Mohapatra, M., et al., *Botanical leaf disease detection and classification using convolutional neural network: a hybrid metaheuristic enabled approach.* Computers, 2022. **11**(5): p. 82.

16. Mustafa, H., et al., *Pepper bell leaf disease detection and classification using optimized convolutional neural network.* Multimedia Tools and Applications, 2023. **82**(8): p. 12065-12080.

17. Praveen, S.P., et al., *A Novel Classification Approach for Grape Leaf Disease Detection Based on Different Attention Deep Learning Techniques.* International Journal of Advanced Computer Science and Applications (IJACSA), 2023. **14**(6).

18. Sahu, S.K. and M. Pandey, *An optimal hybrid multiclass SVM for plant leaf disease detection using spatial Fuzzy C-Means model.* Expert Systems with Applications, 2023. **214**: p. 118989.

19. Sangeetha, K., et al. *Apple leaf disease detection using deep learning*. in *2022 6th International Conference on Computing Methodologies and Communication (ICCMC)*. 2022. IEEE.

20. Soeb, M.J.A., et al., *Tea leaf disease detection and identification based on YOLOv7 (YOLO-T).* Scientific reports, 2023. **13**(1): p. 6078.

21. Tarek, H., et al., *Optimized deep learning algorithms for tomato leaf disease detection with hardware deployment.* Electronics, 2022. **11**(1): p. 140.

22. Udawant, P. and P. Srinath, *Cotton leaf disease detection using instance segmentation.* Journal of Cases on Information Technology (JCIT), 2022. **24**(4): p. 1-10.

23. Vasavi, P., A. Punitha, and T.V.N. Rao, *Crop leaf disease detection and classification using machine learning and deep learning algorithms by visual symptoms: A review.* International Journal of Electrical and Computer Engineering, 2022. **12**(2): p. 2079.

24. Wang, H., et al., *MFBP-UNet: A network for pear leaf disease segmentation in natural agricultural environments.* Plants, 2023. **12**(18): p. 3209.

25. Wang, Y., Y. Wang, and J. Zhao, *MGA-YOLO: A lightweight one-stage network for apple leaf disease detection.* Frontiers in Plant Science, 2022. **13**: p. 927424.

26. Xu, C., C. Yu, and S. Zhang, *Lightweight multi-scale dilated U-Net for crop disease leaf image segmentation.* Electronics, 2022. **11**(23): p. 3947.

27. Yu, H., et al., *Disease Recognition of Apple Leaf Using Lightweight Multi-Scale Network with ECANet.* CMES-Computer Modeling in Engineering & Sciences, 2022. **132**(3).

28. Zamani, A.S., et al., *Performance of machine learning and image processing in plant leaf disease detection.* Journal of Food Quality, 2022. **2022**: p. 1-7.

29. *Food and Agriculture Organization of the United Nations.* 2024.

30. Nicoletti, R., et al., *Hazelnut-associated bacteria and their implications in crop management.* Horticulturae, 2022. **8**(12): p. 1195.

31. Lamichhane, J. and L. Varvaro, *X anthomonas arboricola disease of hazelnut: Current status and future perspectives for its management.* Plant Pathology, 2014. **63**(2): p. 243-254.

32. Wiman, N.G., et al., *Identity and pathogenicity of some fungi associated with hazelnut (Corylus avellana L.) trunk cankers in Oregon.* PLoS One, 2019. **14**(10): p. e0223500.

33. Ghasemi-Doodaran, S. and M. Davari, *Fungal diseases of hazelnut in Iran.* University of Yasouj Plant Pathology Science, 2020. **9**(2): p. 85-94.

34. Yu, S., L. Xie, and Q. Huang, *Inception convolutional vision transformers for plant disease identification.* Internet of Things, 2023. **21**: p. 100650.

35. Albattah, W., et al., *Artificial intelligence-based drone system for multiclass plant disease detection using an improved efficient convolutional neural network.* Frontiers in Plant Science, 2022. **13**: p. 808380.

36. Biswal, B. and S. Chestnut. *DeepTrac: Applying Artificial Intelligence in Plant Disease Detection*. in *SoutheastCon 2022*. 2022. IEEE.

37. BOYAR, T. and K. YILDIZ, *Powdery mildew detection in hazelnut with deep learning.* Hittite Journal of Science and Engineering, 2022. **9**(3): p. 159-166.

38. Liu, H., et al., *Self-supervised transformer-based pre-training method using latent semantic masking auto-encoder for pest and disease classification.* Computers and Electronics in Agriculture, 2022. **203**: p. 107448.

39. Selvanarayanan, R., S. Rajendran, and Y. Alotaibi, *Early Detection of Colletotrichum Kahawae Disease in Coffee Cherry Based on Computer Vision Techniques.* CMES-Computer Modeling in Engineering & Sciences, 2024. **139**(1).

40. Aydın, Ş., *Yapay zekâ teknolojisi (yapay zekâların dünü bugünü yarını).* Adana: Çukurova Üniversitesi. Erişim adresi: https://www. academia. edu/35714946/YAPAY_ZEK% C3% 82_TEKNOLOJ% C, 2017. **4**: p. B0S.

41. Pabuçcu, H. and T. Bayramoğlu, *Yapay sinir ağlari ile CO2 emisyonu tahmini: Türkiye örneği.* Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 2016. **18**(3): p. 762-778.

42. Gupta, N., N. VAYA, and B. MISHRA, *Artificial Neural Network.* Eastern pharmacist, 1997. **40**(475): p. 39-41.

43. Bhatt, D., et al., *CNN variants for computer vision: History, architecture, application, challenges and future scope.* Electronics, 2021. **10**(20): p. 2470.

44. Venkatesan, R. and B. Li, *Convolutional neural networks in visual computing: a concise guide*. 2017: CRC Press.

45. Balas, V.E., R. Kumar, and R. Srivastava, *Recent trends and advances in artificial intelligence and internet of things*. 2020: Springer.

46. Chen, L., et al., *Hidden bias in the DUD-E dataset leads to misleading performance of deep learning in structure-based virtual screening.* PloS one, 2019. **14**(8): p. e0220113.

47. Siddique, N., et al., *U-net and its variants for medical image segmentation: A review of theory and applications.* Ieee Access, 2021. **9**: p. 82031-82057.

48. Ronneberger, O., P. Fischer, and T. Brox. *U-net: Convolutional networks for biomedical image segmentation*. in *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18*. 2015. Springer.

49. Ibtehaz, N. and M.S. Rahman, *MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation.* Neural networks, 2020. **121**: p. 74-87.

50. Zheng, S., et al., *MDCC-Net: multiscale double-channel convolution U-Net framework for colorectal tumor segmentation.* Computers in Biology and Medicine, 2021. **130**: p. 104183.

51. Liu, X., et al., *A review of deep-learning-based medical image segmentation methods.* Sustainability, 2021. **13**(3): p. 1224.

52. Oktay, O., et al., *Attention u-net: Learning where to look for the pancreas.* arXiv preprint arXiv:1804.03999, 2018.

53. Schlemper, J., et al., *Attention gated networks: Learning to leverage salient regions in medical images.* Medical image analysis, 2019. **53**: p. 197-207.

54. Petit, O., et al. *U-net transformer: Self and cross attention for medical image segmentation*. in *Machine Learning in Medical Imaging: 12th International Workshop, MLMI 2021, Held in Conjunction with MICCAI 2021, Strasbourg, France, September 27, 2021, Proceedings 12*. 2021. Springer.

55. Wang, H., et al. *Mixed transformer u-net for medical image segmentation*. in *ICASSP 2022-2022 IEEE international conference on acoustics, speech and signal processing (ICASSP)*. 2022. IEEE.

56. Abraham, N. and N.M. Khan. *A novel focal tversky loss function with improved attention u-net for lesion segmentation*. in *2019 IEEE 16th international symposium on biomedical imaging (ISBI 2019)*. 2019. IEEE.

57. Zhang, Z., et al. *Et-net: A generic edge-attention guidance network for medical image segmentation*. in *Medical Image Computing and Computer Assisted Intervention–MICCAI 2019: 22nd International Conference, Shenzhen, China, October 13–17, 2019, Proceedings, Part I 22*. 2019. Springer.

58. Zhang, H., H. Zhu, and X. Ling, *Polar coordinate sampling-based segmentation of overlapping cervical cells using attention U-Net and random walk.* Neurocomputing, 2020. **383**: p. 212-223.

59. Yin, X.-X., et al., *[Retracted] U-Net-Based Medical Image Segmentation.* Journal of healthcare engineering, 2022. **2022**(1): p. 4189781.

60. Zhang, Z., et al., *DENSE-INception U-net for medical image segmentation.* Computer methods and programs in biomedicine, 2020. **192**: p. 105395.

61. Szegedy, C., et al. *Going deeper with convolutions*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015.

62. Punn, N.S. and S. Agarwal, *Inception u-net architecture for semantic segmentation to identify nuclei in microscopy cell images.* ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM), 2020. **16**(1): p. 1-15.

63. Zhang, Z., Q. Liu, and Y. Wang, *Road extraction by deep residual u-net.* IEEE Geoscience and Remote Sensing Letters, 2018. **15**(5): p. 749-753.

64. He, K., et al. *Deep residual learning for image recognition*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.

65. Williams, C., et al., *A unified framework for U-Net design and analysis.* Advances in Neural Information Processing Systems, 2024. **36**.

66. Hochreiter, S., *The vanishing gradient problem during learning recurrent neural nets and problem solutions.* International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems, 1998. **6**(02): p. 107-116.

67. Devalla, S.K., et al., *DRUNET: a dilated-residual U-Net deep learning network to segment optic nerve head tissues in optical coherence tomography images.* Biomedical optics express, 2018. **9**(7): p. 3244-3265.

68. Baldeon-Calisto, M. and S.K. Lai-Yuen, *AdaResU-Net: Multiobjective adaptive convolutional neural network for medical image segmentation.* Neurocomputing, 2020. **392**: p. 325-340.

69. Kawagoe, K., et al. *Automatic segmentation method of phalange regions based on residual U-Net and MSGVF snakes*. in *2019 19th International Conference on Control, Automation and Systems (ICCAS)*. 2019. IEEE.

70. Li, H., et al. *Improved breast mass segmentation in mammograms with conditional residual u-net*. in *Image Analysis for Moving Organ, Breast, and Thoracic Images: Third International Workshop, RAMBO 2018, Fourth International Workshop, BIA 2018, and First International Workshop, TIA 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16 and 20, 2018, Proceedings 3*. 2018. Springer.

71. Li, H., A. Zhygallo, and B. Menze. *Automatic brain structures segmentation using deep residual dilated U-Net*. in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 4th International Workshop, BrainLes 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers, Part I 4*. 2019. Springer.

72. Chen, L.-C., et al., *Semantic image segmentation with deep convolutional nets and fully connected crfs.* arXiv preprint arXiv:1412.7062, 2014.

73. Srivastava, A., et al., *MSRF-Net: a multi-scale residual fusion network for biomedical image segmentation.* IEEE Journal of Biomedical and Health Informatics, 2021. **26**(5): p. 2252-2263.

74. Yan, Y., C. Chen, and J. Gao, *Lossless segmentation of cardiac medical images by a resolution consistent network with nondamage data preprocessing.* Multimedia Tools and Applications, 2023. **82**(14): p. 20951-20973.

75. Agnes, S.A., *Boundary Aware Semantic Segmentation using Pyramid-dilated Dense U-Net for Lung Segmentation in Computed Tomography Images.* Journal of Medical Physics, 2023. **48**(2): p. 161-174.

76. Huang, G., et al. *Densely connected convolutional networks*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.

77. Lu, Z. and Y. Chen, *Dense U-Net for single image super-resolution using shuffle pooling.* Journal of Electronic Imaging, 2022. **31**(3): p. 033008-033008.

78. Li, S., et al., *Attention dense-u-net for automatic breast mass segmentation in digital mammogram.* Ieee Access, 2019. **7**: p. 59037-59047.

79. Yuan, Y., D. Zhao, and Z. Luo, *Improved Dense Recurrent Residual U-Net for Skin Lesion Segmentation.* Journal of Electronics and Information Science, 2024. **9**(1): p. 27-37.

80. Dolz, J., I. Ben Ayed, and C. Desrosiers. *Dense multi-path U-Net for ischemic stroke lesion segmentation in multiple image modalities*. in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 4th International Workshop, BrainLes 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers, Part I 4*. 2019. Springer.

81. Li, X., et al., *H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes.* IEEE transactions on medical imaging, 2018. **37**(12): p. 2663-2674.

82. Azad, R., et al. *Bi-directional ConvLSTM U-Net with densley connected convolutions*. in *Proceedings of the IEEE/CVF international conference on computer vision workshops*. 2019.

83. Kolarik, M., et al. *Superresolution of MRI brain images using unbalanced 3D Dense-U-Net network*. in *2019 42nd International Conference on Telecommunications and Signal Processing (TSP)*. 2019. IEEE.

84. Saiviroonporn, P., et al., *Cardiothoracic ratio measurement using artificial intelligence: observer and method validation studies.* BMC Medical Imaging, 2021. **21**(1): p. 95.

85. Zhou, Z., et al. *Unet++: A nested u-net architecture for medical image segmentation*. in *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4*. 2018. Springer.

86. Huang, H., et al. *Unet 3+: A full-scale connected unet for medical image segmentation*. in *ICASSP 2020-2020 IEEE international conference on acoustics, speech and signal processing (ICASSP)*. 2020. IEEE.

87. Zhou, Z., et al., *Unet++: Redesigning skip connections to exploit multiscale features in image segmentation.* IEEE transactions on medical imaging, 2019. **39**(6): p. 1856-1867.

88. Birla, R., et al., *A comparative analysis of tuberculosis-infected lung x-ray image segmentation: U-Net vs. U-Net++*, in *Multimodality Imaging, Volume 2: Heart, lungs and peripheral organs*. 2023, IOP Publishing Bristol, UK. p. 5-1-5-9.

89. Kong, R., et al., *Image segmentation based on U-Net++ network method to identify Bacillus Subtilis cells in micro-droplets.* Multimedia Tools and Applications, 2024. **83**(9): p. 27747-27759.

90. Wisaeng, K., *U-Net++ DSM: improved U-Net++ for brain tumor segmentation with deep supervision mechanism.* IEEE Access, 2023. **11**: p. 132268-132285.

91. Jahnavi, T. and D. Vasundhara. *Segmentation of medical images using U-Net++*. in *2022 4th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)*. 2022. IEEE.

92. Powers, D.M., *Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation.* arXiv preprint arXiv:2010.16061, 2020.

ÖZGEÇMİŞ

Adı Soyadı :Tülin BOYAR

Yabancı Dil : İngilizce

Öğrenim Bilgileri

Derece	**Bölüm**	**Üniversite**	**Yıl**
Lisans	Bilgisayar Öğretmenliği	Sakarya Üniversitesi	2005-2009
Lisans	Bilgisayar Mühendisliği	Yıldız Teknik Üniversitesi	2019-2021
Yüksek Lisasns	Bilgisayar Mühendisliği	Marmara Üniversitesi	2021-2024

İş Dneyimi

Yıl	**Firma Kurum**	**Görevi**
2010	Milli Eğitim Bakanlığı	Teknik Öğretmen
2022	Üçay Grup	Yazılım Uzmanı
2023	Ziraat Teknoloji	Yazılım Geliştirici

Bilimsel Eserler

1. Boyar, Tulin, et al. "A novel approach to test case prioritization for software regression tests." *Computational Science and Its Applications–ICCSA 2021: 21st International Conference, Cagliari, Italy, September 13–16, 2021, Proceedings, Part VII 21*. Springer International Publishing, 2021.
2. Boyar, Tülin, and Kazım Yıldız. "Powdery mildew detection in hazelnut with deep learning." *Hittite Journal of Science and Engineering* 9.3 (2022): 159-166.
3. Topuz, Vedat, A. K. Ayça, and Tülin Boyar. "Paralyzed Patients-oriented Electroencephalogram Signals Processing Using Convolutional Neural Network Through Python." *The Journal of Neurobehavioral Sciences* 9.3 (2022): 90-95.
4. YILDIZ, Kazım, Onur Yenigün, and Tülin BOYAR. "Determination of Optimal Location of Electrical Vehicle Charging Stations in Istanbul with Genetic Algorithm and Geographical Systems." *International Journal of InformaticsTechnologies* 17.1 (2024).