YAPAY ZEKA DESTEKLİ GÖRÜNTÜ İŞLEME YÖNTEMLERİYLE PATATES KALİTE DERECELENDİRMESİ VE HASTALIK TESPİTİ

YÜKSEK LİSANS TEZİ

Pınar KOÇ

Danışman
Dr. Öğr. Üyesi Caner BALIM

BİLGİSAYAR ANABİLİM DALI

Haziran 2026

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

YAPAY ZEKA DESTEKLİ GÖRÜNTÜ İŞLEME YÖNTEMLERİYLE PATATES KALİTE DERECELENDİRMESİ VE HASTALIK TESPİTİ

Pınar KOÇ

Danışman
Dr. Öğr. Üyesi Caner BALIM

BİLGİSAYAR ANABİLİM DALI

Haziran 2026

TEZ ONAY SAYFASI

Pınar KOÇ tarafından hazırlanan "Yapay Zeka Destekli Görüntü İşleme Yöntemleriyle Patates Kalite Derecelendirmesi ve Hastalık Tespiti" adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 29/06/2026 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Bilgisayar Anabilim Dalı'nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman **:** Dr. Öğr. Üyesi Caner BALIM

Başkan **:** Dr. Öğr. Üyesi Mehmet Ali ŞİMŞEK
Bandırma Onyedi Eylül Üniversitesi,
Mühendislik Fakültesi ..... İmza .....

Üye **:** Dr. Öğr. Üyesi Nevzat OLGUN
Afyon Kocatepe Üniversitesi,
Mühendislik Fakültesi ..... İmza .....

Üye **:** Dr. Öğr. Üyesi Caner BALIM
Afyon Kocatepe Üniversitesi,
Mühendislik Fakültesi ..... İmza .....

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
..... /..... /..... tarih ve
……. sayılı kararıyla onaylanmıştır.

…….
Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

29/07/2026

İmza

Pınar KOÇ

ÖZET

Yüksek Lisans Tezi

YAPAY ZEKA DESTEKLİ GÖRÜNTÜ İŞLEME YÖNTEMLERİYLE PATATES KALİTE DERECELENDİRMESİ VE HASTALIK TESPİTİ

Pınar KOÇ

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Caner BALIM

Tarım ürünlerinin yetiştirilmesinde kalite kontrol süreçleri büyük önem taşımaktadır. Bu durum otomasyon sistemlerine duyulan ihtiyacı artırmaktadır. Özellikle yaygın tüketilen patatesin kalite derecelendirmesi ile hastalık, şekil bozukluğu, renk gibi durumların tespiti kritik bir süreçtir. Bu çalışmanın amacı, patates yumrularının kalite derecelendirmesi ve hastalık tespiti için çoklu öğrenme (Multi-Task Learning - MTL) tabanlı bir derin öğrenme modeli geliştirmektir. Bu doğrultuda, beş farklı tarım arazisinden toplanan 1692 patatesin görseli çekilmiş ve uzmanlarca altı temel özelliğe göre etiketlenerek veri seti hazırlanmıştır. Nesne tespiti ve segmentasyon görevlerinde sıklıkla kullanılan YOLO11 (You Only Look Once) modeli ile görüntülerdeki arka plan temizlenmiş literatürdeki çalışmalarda başarılı sonuçlar üreten derin öğrenme modelleri (ConvNeXt/Base, ResNet50 ve EfficientNet-B2) transfer öğrenme yaklaşımı kullanılarak MTL modeli geliştirilmiştir. Farklı hiper parametrelerle gerçekleştirilen deneyler sonucunda, ConvNeXt mimarisinin hem kalite derecelendirmede hem de hastalık tespitinde en yüksek performansı sergilediği görülmüştür. Bulgular, geliştirilen MTL yaklaşımının patates kalite kontrol sürecinin yüksek doğrulukla analiz edilmesinde etkili bir yöntem olduğunu ortaya koymaktadır.

2026, vii + 52 sayfa

Anahtar Kelimeler: Çok görevli öğrenme (MTL), Derin öğrenme, Patates kalite değerlendirmesi, Kusur ve hastalık tespiti, Bilgisayarlı görü.

ABSTRACT

M.Sc. Thesis

POTATO QUALITY GRADING AND DISEASE TESTING WITH ARTIFICIAL INTELLIGENCE-ASSISTED IMAGE PROCESSING METHODS

Pınar KOÇ

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Computer Technologies

Supervisor: Asst. Prof. Caner BALIM

Quality control processes are of paramount importance in agricultural production, leading to an increasing demand for automated systems. Specifically, quality grading and the detection of conditions such as diseases, deformities, and color variations in widely consumed potatoes represent a critical process. This study aims to develop a Deep Learning model based on Multi-Task Learning (MTL) for the quality grading and disease detection of potato tubers. In this context, a dataset was prepared by capturing images of 1,692 potatoes collected from five different agricultural fields, which were then labeled by experts according to six fundamental features. The YOLO11 (You Only Look Once) model, frequently utilized in object detection and segmentation tasks, was employed to remove the background from the images. Subsequently, an MTL model was developed using a transfer learning approach with deep learning architectures that have demonstrated successful results in the literature, namely ConvNeXt/Base, ResNet50, and EfficientNet-B2. Results from experiments conducted with various hyperparameters revealed that the ConvNeXt architecture exhibited the highest performance in both quality grading and disease detection. These findings demonstrate that the developed MTL approach is an effective method for automating the potato quality control process with high accuracy.

2026, vii + 52 pages

Keywords: Multi-Task learning (MTL), Deep learning, Potato quality assessment, Defect and disease detection, Computer vision.

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Dr. Öğr. Üyesi Caner BALIM'a, araştırma ve yazım süresince yardımlarını esirgemeyen Sayın Dr. Öğr. Üyesi Rabia ERSAN'a ve Öğr. Gör. Dr. Funda ÖZÜSOY'a her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu araştırma boyunca maddi ve manevi desteklerini her an yanımda hissettiğim aileme, karakterimin şekillenmesinde ve bu günlere gelişimde emeği olan, üzerimde hakkı bulunan tüm güzel insanlara şükranlarımı sunarım.

Son olarak; tüm zorluklara rağmen pes etmeden bu süreci tamamlayan, sabrını ve merakını yitirmeyen kendime de teşekkür borçluyum.

Pınar KOÇ

Afyonkarahisar 2026

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET i
ABSTRACT ii
TEŞEKKÜR iii
İÇİNDEKİLER DİZİNİ iv
SİMGELER ve KISALTMALAR DİZİNİ v
ÇİZELGELER DİZİNİ vi
RESİMLER DİZİNİ vii
1. GİRİŞ 1
2. LİTERATÜR BİLGİLERİ 5
3. MATERYAL ve METOT 10
3.1 Veri Setinin Hazırlanması 10
3.2 Ön İşleme ve Veri Arttırma 15
3.3 Makine Öğrenmesi Algoritmaları 18
3.4 Derin Öğrenme 18
3.4.1 Evrişimsel Sinir Ağı (ESA) 18
3.4.1.1 ResNet50 20
3.4.1.2 ConvNeXt 21
3.4.1.3 EfficientNet 22
3.4.2 Transfer Öğrenme ve İnce ayar (Fine-Tune) 23
3.5 Çoklu Görev Öğrenme (MTL) 24
3.5.1 Hedef Görevler 25
3.6 Değerlendirme Metrikleri 29
4. BULGULAR 32
4.1 Deneysel Analiz Sonuçları 32
4.2 Regresyon Analiz Sonuçları 34
4.3 Model Ağırlık Karşılaştırma Sonuçları 36
5. TARTIŞMA ve SONUÇ 41
6. KAYNAKLAR 44
ÖZGEÇMİŞ 51

SİMGELER ve KISALTMALAR DİZİNİ

Kısaltmalar

Acc	Doğruluk
DVM	Destek Vektör Makinesi
ESA	Evrişimsel Sinir Ağı
FCM	Fuzzy C-Mean
GRN	Global Respons Normalization
MAE	Ortalama mutlak hata
MDDNet	Multi Defect Detection Network
Pre	Hassasiyet
R^2	R-Kare
Rec	Duyarlılık
RF	Random Forest
RMSE	Hataların Karesinin Ortalamasının Karekökü
ROI	Region of Interest
SVR	Support Vector Regression (Destek Vektör Regresyonu)
VGG	Visual Geometry Group (Görsel Geometri Grubu),
YOLO	You Only Look Once
YSA	Yapay Sinir Ağı

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1 Patates Kalite Değerlendirmesinde Kullanılan Öznitelikler ve Puanlama Sistemi 11
Çizelge 3.2 Veri Setinde Yer Alan Patates Hastalıklarına Ait Örnek Sayılarının Dağılımı 12
Çizelge 3.3 Patates Kalitesi İçin Puanlama Sistemi: Ölçütler ve Örnek Değerlendirmeler 13
Çizelge 3.4 Veri Setinin Eğitim, Doğrulama ve Test Alt Kümelerine Ayrılması..... 15
Çizelge 3.5 Veri Artırma Sonrası Eğitim ve Doğrulama Veri Setlerinin Dağılımı 17
Çizelge 3.6 Değerlendirme Metrikleri ve Hesaplama Formülleri 29
Çizelge 3.7 Regresyon Analizi: Model Açıklamaları ve Parametre Tahminleri..... 31
Çizelge 4.1 MTL Modellerinin İnce-Ayar Öncesi ve Sonrası Karşılaştırmalı Performans Sonuçları..... 32
Çizelge 4.2 İnce-Ayar Öncesi ve Sonrası Kalite Derece Tahmin Performansı..... 33
Çizelge 4.3 İnce-Ayar Öncesi ve Sonrası Modellerin Hastalık Tahmin Performansı.... 34
Çizelge 4.4 Modeller Arasında Regresyon Metriklerinin Karşılaştırılması (R^2, MAE, RMSE) 35
Çizelge 4.5 En İyi Performans Gösteren Modele (ConvNeXt) Ait Confusion Matrix Sonuçları 36
Çizelge 4.6 ConvNeXt/Base (Fine – Tune Uygulanmamış) Kayıp Ağırlığı Karşılaştırması 37
Çizelge 4.7 En İyi Performans Gösteren MTL Modeli İçin Gerçek ve Tahmin Edilen Değerlerin Karşılaştırılması..... 38
Çizelge 4.8 En Düşük Performans Gösteren MTL Tahminleri İçin Gerçek ve Tahmin Değerlerinin Karşılaştırması 39

RESİMLER DİZİNİ

Sayfa

Resim 1.1 Çoklu görevli öğrenme (MTL) mimarisi diyagramı 3
Resim 3.1 YOLO öncesi ve sonrası görsel yapısı 16
Resim 3.2 ESA mimarisin temel yapısı (Girshick vd., 2014) 19
Resim 3.3 ESA katmanlı yapısı (Wang, 2018) 20
Resim 3.4 ResNet50 model katman yapısı (Liu vd., 2022) 21
Resim 3.5 ConvNeXt mimari yapısı (Woo vd., 2023) 22
Resim 3.6 EfficientNet mimari yapısı (Ahmed ve Sabab, 2021) 23
Resim 3.7 Transfer öğrenme çalışma mantığı 23
Resim 3.8 Önerilen MTL mimarisi 24
Resim 3.9 Tek görevli hastalık sınıflandırma mimarisi 26
Resim 3.10 Tek görevli kalite skor tahmini mimarisi 28

1. GİRİŞ

İnsan hayatında hem besin hem de finansal olarak büyük öneme sahip olan tarım ürünlerinin yetiştirilmesi noktasında kalite ve dış piyasalara açılması dikkat gerektirmektedir (Jarén vd 2016). Teknoloji dünyasındaki hızlı gelişmeler diğer alanlarda da etkisini oldukça fazla göstermektedir. Özellikle teknolojik sistemlerin diğer sektörlerde uygulanması, sürecin daha verimli ve etkin bir şekilde yürütülmesine olanak sağlamaktadır. Bu bağlamda, tarım alanında yapay zeka sistemlerinin entegrasyonu; sistem kurulumunun kolaylaşması, iş süreçlerinin hızlanması, ürün geliştirme ve işleme aşamalarında büyük avantajlar sunmaktadır. Teknolojinin ve yapay zekanın kullanımından önce uzman kontrolleri veya laboratuvar testleri ile manuel şekilde gerçekleştirilen ürünlerdeki hastalık tespiti yapay zeka sistemlerinin geliştirilmesi sayesinde otomatik bir şekilde yapılabilir hale gelmiştir. Hastalık tespiti konusunda literatürde büyük orana sahip tarım ürünlerinden birisi patatestir. Patatesin gıda kaynaklarının tüketimi noktasında sıralamanın başında yer alma sebeplerinden olan dayanıklılık süresi ve yoğun besin oranı sebep olmaktadır (Altintaş 2024, Camire 2016).

Yapay zeka, makinelerin insan gibi düşünme süreçlerini taklit etmesini sağlayan teknoloji olarak tanımlanmaktadır. Bu teknoloji sayesinde uzmanlık gerektiren karar ve sonuç süreçleri bilgisayar sistemleri ile gerçekleştirilebilmektedir (Danielak vd. 2023). Yapay zeka sistemlerinin alt alanlarında yer alan derin öğrenme, veri setlerinin analiz edilmesi sonucunda öğrenmelerin gerçekleştirilmesini sağlayan kapsamlı çözüm ve model geliştirme imkanı sunmaktadır (Zhang ve Yang 2022). Derin öğrenme sistemleri mimari yapılardan oluşmaktadır. Bu mimari sistemler uygulama türlerine göre analizlerin başarı oranlarında belirleyici bir etkendir. Bilgisayarlı görü alanında etkili ve çok yaygın olarak kullanılan mimari Evrişimsel Sinir Ağları (ESA) mimarisidir (Zhang ve Yang 2022, Zoralioğlu ve Polat 2024).

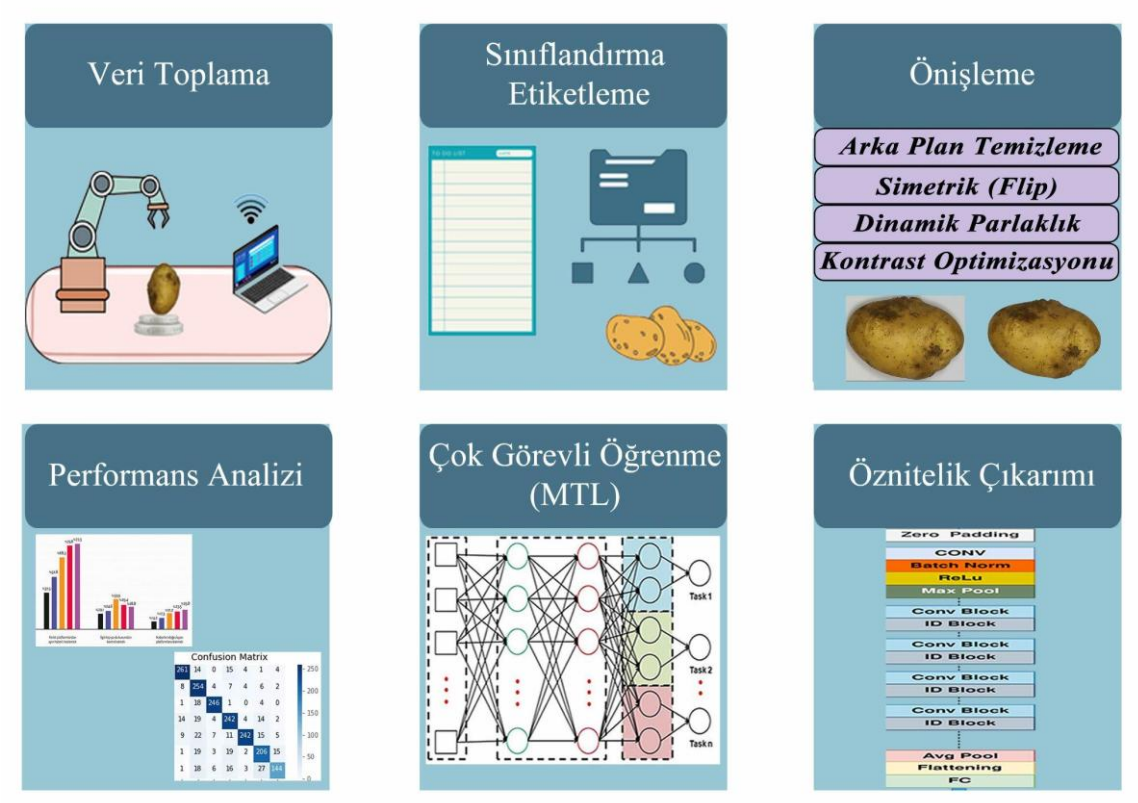
Yüksek kaliteye sahip patates üretimi sayesinde ürün ve pazarlama kayıplarının minimuma düşmesi üreticilerin bilinçlendirilmesi ile mümkün olmaktadır. Eski yöntemlerde bir ürün yetiştirme sürecinde en başından sonuna kadar ürünün hastalığını teşhis-tespit etmek için manuel yöntemler kullanılmasından dolayı maliyetli ve zaman

alıcı bir süreç olmaktadır. Son yıllarda teknoloji sistemlerinden makine öğrenme sistemlerinin tarım alanına uygulanması bu süreci kolaylaştırmakta ve hızlandırmaktadır. Hastalık tespiti (Sert 2021, Kumar ve Shukla 2022, Tambe vd. 2023, Farokhzad vd. 2024), boyut sınıflandırma (Kumar ve Shukla 2022, Zhao vd. 2024, He vd. 2023), renk ve kabuk yüzeyi analizi (Su vd. 2018, Pinhero ve Yada 2016), şekil ve deformasyon tespiti (Pinhero ve Yada 2016, Cin 2022, Visse-Mansiaux vd. 2022), filizlenme ve depolama süresinin tahmini (D'hoop vd. 2008, Razmjooy vd. 2012, Zhou vd. 2012, Pedreschi vd. 2016), verim ve kalite öngörüsü (Visse-Mansiaux vd. 2022, Pedreschi vd. 2016), hasar ve şiddet derecesi ölçümü (Pinhero ve Yada 2016, Pandey vd. 2019, Zarzyńska ve Boguszewska-Mańkowska 2024), ticari sınıflandırma ve seviye tahmini (Danielak vd. 2023, Zhang ve Yang 2022, Zoralioğlu ve Polat 2024, Kadam vd. 2022) gibi konular literatürde yoğun olarak çalışılmaktadır. Makine öğrenmesi sistemlerinin tarım alanına entegre edilmesi ile patateste hasat öncesi yapraklardan hastalık teşhisinin yapılması, hasat sonrası ise hastalıklı veya düşük kaliteli yumruların pazara karışmadan sınıflandırılmasına ve sağlıklı olan yumrulardan ayrılmasına imkân sağlayarak kalite artırma işleminin hızlandırılmasına olanak sunmaktadır.

Tarım ürünlerinde kalite derecelendirilmesi, hastalık tespiti, görüntü çeşitliliği, yüzey yapısı ve sınırlı etiketli veriler nedeniyle karmaşık bir problem olarak değerlendirilmektedir. Literatürde tekli görevlerin modellenmesinde zorluklar yaşanmasına rağmen MTL, tek bir görevin yüksek doğruluk sağlayarak modellenmesi dahi zorlu bir süreç iken çoklu görevin aynı anda ele alınması daha gelişmiş öğrenme stratejileri gerektirmektedir (Kaur vd. 2024, Yang vd. 2023).

Bu tez çalışmasında patates yumrularında kalite derecelendirmesi ve hastalık tespitini tek bir sistemde gerçekleştiren Multi-Task Learning (MTL) temelli bir yaklaşım önerilmektedir. Resim 1.1'de sistemin genel yapısı yer almaktadır. MTL modeli ile var olan bir veri seti üzerinden farklı görevlerin paralel olarak öğrenimi gerçekleştirilebilmekte ve bu görevlerin birbirileri arasında bilgi paylaşımı yöntemiyle özellik çıkarım süreci oluşturulmaktadır (Kaur vd. 2024). Çalışma kapsamında kullanılmakta olan veri seti tarafımızca konuya özel oluşturulup özgün bir yapılandırmaya sahiptir. Tez çalışması kapsamında görüntüler alanında uzman kişiler

tarafından altı kategoride (hastalık, kabuk durumu, şekil, fiziksel hasar, filizlenme ve renk) etiketlenerek puanlama mekanizması ile kalite seviyeleri belirlenmektedir. Sonrasında görüntüler ön işleme adımlarından geçirilerek son aşamada hem hastalık tespiti hem de kalite derecelendirmesini eş zamanlı gerçekleştirmek üzere ESA tabanlı bir MTL yaklaşımı önerilmiştir.



Resim 1.1 Çoklu görevli öğrenme (MTL) mimarisi diyagramı

Bu çalışmanın temel katkıları şunlardır:

- Çalışmada, patates yumrularının kalite derecelendirmesi ve hastalık tespiti için hem regresyon hem de sınıflandırma görevlerini içeren kapsamlı bir veri seti oluşturulmuştur. Bu veri seti beş farklı tarım arazisinden toplanmış 1692 görüntüden oluşmakta ve açık erişim olarak paylaşılmaktadır: (https://www.kaggle.com/datasets/pinarkoc/mtl-dataset)

- Veri setinde yer alan her bir patates yumrusu, uzmanlar tarafından şekil, kabuk durumu, renk, hastalık türü, fiziksel hasar ve filizlenme gibi altı farklı öznitelik

üzerinden ayrıntılı biçimde puanlanmıştır. Böylece nesnel, tekrarlanabilir ve daha adil bir kalite derecelendirme yapısı tasarlanmıştır.

- Çalışmada önerilen MTL tabanlı derin öğrenme modeli, aynı anda hem hastalık tespiti (sınıflandırma) hem de kalite puanı tahmini (regresyon) yapabilmektedir. Bu ortak öğrenme yapısı, görevler arası bilgi paylaşımı sayesinde modellerin genelleme kabiliyetini artırmaktadır.
- Farklı büyüklükteki modellerle gerçekleştirilen kapsamlı deneylerde, kalite tahmini ve hastalık tespiti görevleri için farklı ağırlıklandırma stratejileri uygulanmış, her iki görevin modele etkisi ayrı ayrı incelenmiş ve bu ağırlık değişimlerinin performans üzerindeki rolü sistematik olarak değerlendirilmiştir.

Yapılan çalışmada Bölüm 2'de literatür incelemesi yer almaktadır. Bölüm 3'te patates hastalıkları ve kalite değerlendirmesi amacıyla hazırlanan veri seti hakkında bilgiler barındırırken Bölüm 4'te kullanılan metodoloji bilgileri yer almaktadır. Bölüm 5'te veri seti üzerinde yapılan deneysel çalışmaların sonuçlarına dair bilgiler, Bölüm 6'da sonuçlardan elde edilen bilgiler doğrultusunda değerlendirmeler ve tartışma-bulgular yer almaktadır. Son kısım olan Bölüm 7'de çalışma sonuçlar ve gelecek çalışmalar yer almaktadır.

2. LİTERATÜR BİLGİLERİ

Tarım sektörü, uzun süredir bilgisayar alanında çalışma yapan araştırmacıların stratejik ilgi odağıdır. Özellikle dijitalleşme sürecinin ve yapay zeka sistemlerinin yaygınlaşması tarım alanı araştırmalarında teknoloji kullanımı yoğunlaşmıştır. Araştırmacılar özellikle çok fazla tüketilen patates hastalıklarının tespitine yönelik çalışmalar yürütmektedir (Zoralioğlu ve Polat 2024, Kadam vd. 2022, Kaur vd. 2024). Bu çalışmalar yapay zeka yöntemlerinden yararlanarak yüksek doğruluk oranına ulaşma amacı taşımakta, ürün kayıplarının azalmasına ve gıda güvenliğinin artmasına önemli katkılar sağlamaktadır. Ayrıca bitkilerde meydana gelen hastalıkların erken tespit edilmesinde ve tarımsal ürünlerde verimliliğin artırılmasında kritik bir rol oynamaktadır.

Zoralioğlu ve Polat (2024), yaptıkları çalışmada patates bitkisinin yapraklarından hastalık tespiti için derin öğrenme yöntemlerinden yararlanmışlardır (Zoralioğlu ve Polat 2024). Çalışmada, "*erken yanıklık - geç yanıklık"* hastalıklarının belirlemesi için yaygın olarak kullanılan PlantVillage veri setini kullanmışlar, EfficientNetB2 ile ConvNeXtSmall modellerini eğitmişlerdir. Eğitilen model ile %99,33 doğruluk oranına ulaşmışlardır. Tambe vd. (2023) yaptıkları çalışmadan patates yapraklarından "*erken yanıklık - geç yanıklık"* ve sağlıklı patates tespiti üzerine geliştirmiş oldukları ESA modeline göre %99,1 başarı elde etmişlerdir (Tambe vd. 2023). Yapılan çalışmalar sayesinde tarımda gıda güvenliği ve finansal kayıpların en aza indirgenmesine olanak sunulmakta ve bu konuda büyük bir başarı elde edilebileceği öne sürülmektedir.

Zhang vd. (2023), yaptıkları çalışmada patatesin yüzeysel kusurların tespitini gerçekleştirmek için U-Net modeline CBAM (Convolutional Block Attention Module - Evrişimli Blok Dikkat Modülü) modülünü entegre etmişlerdir. Bu sayede modelin ayırt edicilik ve odaklanma özelliği artırılarak kusurlu alanın tespitinin yanında bölgenin piksel tabanlı ölçümü yapılarak patatesin yüzeysel olarak kalite derecesini belirlemişlerdir. Temel U-Net modeline kıyasla MIoU (Mean Intersection over Union- Ortalama Kesişim Birleşimi), kesinlik skorlarında belirgin iyileşme sağladığı belirtilmiş ve %97,55'in üzerinde doğruluk elde etmişlerdir. Bu yöntem sayesinde patateslerin depolama ve derin işleme süreçlerinde güvenilir kalite değerlendirmesi elde edildiğini vurgulamışlardır.

Dacal-Nieto vd. (2011), patates yumru kalitesini düşüren ve fiyatı etkileyen "*common scab(yaygın-uyuz)"* hastalığının nesnel bir yöntem kullanılarak tespit edilmesi üzerine çalışmışlardır (Dacal-Nieto vd. 2011). Hiper spektral görüntüleme sistemi kullanılarak denetimli desen tanıma deneyini kullanarak en uygun bant seti ve sınıflandırma algoritması belirlemek amacıyla; Support Vector Machine (SVM- Destek Vektör Makineleri) ve Random Forest sınıflandırıcıları uygulamışlardır. Her pikselin sınıflandırılmasıyla yumru yüzeyinde hastalıklı alanın yüzdesi haritalanmış ve SVM sınıflandırıcısı ile %97,1 doğruluk oranı ulaşmışlardır.

Farokhzad vd. (2024), patates yumrularında "*dry rot (kuru çürük)"* hastalığının tespit edilmesi ve hastalığın ilerleme düzeyinin belirlenmesine yönelik hızlı ve güvenilir bir termografi tabanlı yöntem sunmuşlardır (Farokhzad vd. 2024). Çalışmada, yumru yüzeylerindeki sıcaklık farklılıkları esas alınarak Otsu eşikleme yöntemi ile arka plan ayrıştırması gerçekleştirilmiş; histogram ve eş-ortam matrisi (co-occurrence matrix) tabanlı olmak üzere toplam 38 ayırt edici özellik belirlemişlerdir. Bu özellikler, yapay sinir ağları (YSA) ve DVM kullanılarak hastalık şiddetinin sınıflandırılmasında değerlendirilmiş; sağlıklı yumruların belirlenmesinde %96–100, genel sınıflandırma doğruluğunda ise %93–97 arasında başarı oranı elde etmişlerdir. Kaur vd. (2024) yaptıkları derleme çalışmasında yaygın olarak kullanılan algoritmalardan ESA, MobileNet, VGG (Visual Geometry Group - Görsel Geometri Grubu), SVM ve RF(Random Forest)'nin kullanıldığını tespit etmiş ve bu modellerin doğruluk oranlarının %64-%100 değiştiğini vurgulamışlardır (Kaur vd. 2024). Ayrıca, bu yöntemlerin bilinçli üreticilerin yetişmesine katkı sağladığını ve ürün kayıplarının en aza indirilmesinde önemli bir rol oynadığını belirtmişlerdir.

Literatürde patates üzerine yapılan çalışmalarda çoğunlukla hastalıklar ve yüzey kusurları birlikte ele alınmakta, her iki durumunda ürün kalitesi ve verim üzerinde belirleyici olduğu belirtilmektedir. Bu kapsamda, hastalıklarının yanı sıra yumru üzerinde görülen çeşitli kusurların tespitine yönelik araştırmalar dikkat çekmektedir. Yang vd. (2023), patateslerde filizlenme, kabuk hastalığı, böcek gözü, kuru çürüklük ve ezilme gibi çoklu kusurların otomatik tespiti için multispektral görüntüleme ile geliştirilmiş YOLOv3-tiny tabanlı bir yöntem önermişlerdir (Yang vd. 2023). Çalışmada geliştirilen MDDNet

(Multi-Defect Detection Network) modeli görüntü başına 75 ms tespit süresi ile %90,26 ortalama doğruluk elde etmiştir. Bulgular, multispektral görüntüleme ile desteklenen MDDNet modelinin patateslerde çoklu kusur tespitinde yüksek doğruluk ve hız sağladığını ortaya koymaktadır. Li vd. (2025) patates yumrusunun dış yüzeyindeki kusurların tespiti için yaptıkları çalışmada YOLO v5s modelinin geliştirilmiş bir versiyonu sunmuşlardır (Li, vd. 2025). Modele eklenen Coordinate Attention, Adaptive Spatial Feature Fusion ve Atrous Spatial Pyramid Pooling modülleri sayesinde doğruluk önemli ölçüde arttığı gözlenmiştir. Altı kategori üzerinde yaptıkları deneylerde %82 kesinlik, %86,6 duyarlılık, %84,3 F1 skoru ve %85,1 ortalama doğruluk değeri elde etmişlerdir. Wang ve Xiao (2021), yaptıkları çalışmada patates yüzey kusurlarının tespiti amacıyla üç derin ESA modeli (SSD Inception V2, RFCN ResNet101 ve Faster RCNN ResNet101) ile transfer öğrenme tekniğini uygulamışlardır. Elde ettikleri doğruluk oranları sırasıyla %92,5, %95,6 ve %98,7 olup, hız ve doğruluk açısından en iyi performansı RFCN ResNet101 modelinin gösterdiğini belirtmişlerdir (Wang ve Xiao 2021).

Patates yumrularının yüzeyinde bulunan hastalıkların haricinde yüzeysel kusur sayılan filizlenme, renk, şekil vb. özellikler açısından tespit ve değerlendirmeler yapılması hem depolama hem de pazarlama süreçlerinde önem arz etmektedir. Bu durumdan dolayı patates yumrularında kaliteyi etkileyen özelliklerin bütüncül bir değerlendirmelerin yapılması gerekmektedir. Danielak, Przybyl ve Koszela (2023), patateslerin depolanması, ticareti ve işlenmesinde önemli rol oynayan kimyasal ve fiziksel parametreleri ile bunların besin değerleri ve sağlık yararlarını incelemişlerdir (Danielak vd. 2023). Üretim sürecinde meydana gelen kayıpların oranı analiz edilmekte ve patateslerin kaliteyi belirleyen fiziksel-kimyasal özelliklerini tahmin etmek için son yıllarda kullanılan yöntemler ve uygulamalar sunulmaktadır. Ayrıca, kalite sınıflandırmasında mekanik, ultrasonik, görüntü işleme ve yapay zeka destekli görme sistemlerinin potansiyelini ele almışlardır.

Su vd. (2020) derinlik kamerası kullanarak patates yumrusunun üç boyutlu görsellerini kullanarak otomatik kalite derecelendirme sistemi geliştirilmiştir. Softmax regresyon ve ESA modelleri ile yapılan sınıflandırmada, ESA modeli %94,5 boyut, %91,6 görünüm

doğruluğu ve %86,6 genel başarı sağlamıştır. Elde edilen bulgular, derinlik görüntülemenin patates kalite değerlendirmesinde etkin bir yöntem olduğunu göstermektedir (Su vd. 2020).

Hasankhani ve Navid (2012), yaptıkları çalışmada "*Agria"* cinsine sahip patates yumrularını RGB görüntü işleme tabanlı sistemleri kullanarak boyut ve renk özniteliğine göre otomatik sınıflandırma işlemini gerçekleştirmişlerdir (Hassankhani ve Navid 2012). 110 görselden oluşan veri setinde görüntü iyileştirme yöntemlerinden yararlanarak görüntü kriterlerine uygun bütünsel bir sınıflandırma gerçekleştirerek %96,82 oranına sahip bir doğruluk elde etmişlerdir.

ElMasry vd. (2012) patates renginin ve şeklinin görüntü açısından düzgün olması kalite parametrelerinden olduğunu belirtmişlerdir (ElMasry vd. 2012). Patateslerin gerçek zamanlı olarak şekil bozukluklarının tespiti için hızlı ve doğru bir makine görme sistemi geliştirmişlerdir. Görüntü işleme sürecinde, her patatesin çevresi, alanı, merkez noktası, eylemsizlik momenti, uzunluk ve genişlik gibi geometrik özellikleri çıkarılmış; ayrıca Fourier dönüşümü kullanılarak sekiz şekil parametresi hesaplanmıştır. Bu parametreler adım adım doğrusal disktriminant analizi ile değerlendirilmiş ve sistem, düzensiz patatesleri %96,2 doğrulukla, düzgün patatesleri boyutlarına göre sınıflandırmada ise %100 doğruluk oranı elde etmişlerdir.

Wang vd. (2016), patateslerin üç farklı açıdan elde edilen görüntülerini kullanarak ağırlık ve şekillerinin otomatik tahmini ve sınıflandırılmasına yönelik bir çalışma gerçekleştirmiştir. Patateslerin üstten ve yandan görünümlerinden çıkarılan kontur alanları ile çevreleyen dikdörtgen ölçümleri temel alınarak çoklu doğrusal regresyon ve kısmi en küçük kareler diskriminant analizi (PLS-DA) yöntemleri uygulanmıştır (Wang, vd. 2016). Sonuçlarda patates ağırlığı tahmininde korelasyon katsayısı 0.991, boyut sınıflandırmasında doğruluklar büyük, orta ve küçük boyutlar için sırasıyla %90, %100 ve %90; şekil sınıflandırmasında küresel ve elipsoidal şekiller için doğruluklar sırasıyla %89,3 ve %83,3 değerlerini elde etmişlerdir.

Abasi vd. (2018), çalışmalarında patateslerin kalite sınıflandırması için üç boyutlu görüntüleme sistemi kullanarak uzunluk, genişlik, kalınlık ve hacim gibi fiziksel özellikler çıkarmışlardır (Abasi vd. 2018). Bu özellikler, hacim tabanlı regresyon ve sınıflandırma modelleri ile analiz edilerek deformasyonlar ve yüzey düzensizlikleri tespit edilmiştir. Elde edilen sonuçlar, hacim tabanlı modellerin alan tabanlı modellere göre daha yüksek doğruluk sağladığını ve kalite sınıflandırmasında %90 doğruluk oranına ulaşmışlardır.

Brar ve Singh (2016), patates yumrusunda oluşan yeşillenme, şatla ve çürüme kusurlarının tespiti için "Fuzzy C-Mean (FCM)" segmentasyon yöntemi kullanmaktadırlar(Brar ve Singh 2016). RGB renk sistemlerine uygun analiz gerçekleştirilerek görüntülerde yer alan kusurlu ve sağlıklı bölgelerin başarılı bir şekilde ayırt etmişlerdir. Görüntü iyileştirme yöntemlerinden yararlandıklarını vurgulayarak çalışmada %95 doğruluk elde ettiklerini belirtmişlerdir.

Yusianto vd. (2022), patateslerin renk, şekil ve boyut özelliklerine göre akıllı bir kalite sınıflandırma sistemi geliştirmiştir (Yusianto vd. 2022). Çalışmada, görüntü işleme teknikleri ile bulanık mantık tabanlı sınıflandırma yaklaşımı birlikte kullanılarak, elde edilen patates görüntüleri veri tabanında yer alan referans örneklerle karşılaştırılmış ve parametreler doğrultusunda kalite değerlendirmesi gerçekleştirilmiştir. Elde edilen bulgular, önerilen sistemin geleneksel yöntemlere kıyasla daha yüksek bir performans sunduğunu ortaya koymaktadır. Sınıflandırma doğruluğu %86 olarak belirlenirken, renk okuma hatası %14 sonucunu elde etmişlerdir.

Literatür araştırmasında patates yaprakları ve yumruları üzerinden hastalık tespiti, filizlenme, renk, boyut gibi tek bir öznitelik üzerinden analizler yapılmaktadır. Kalite derecelendirme çalışmalarında 1-2 tane öznitelik üzerinden analizler yapılması tam olarak kalite derecelendirmesi amacına hizmet etmediği belirtilmekte ve ürünün genel özniteliklerini ifade eden özniteliklerin bütün olarak değerlendirmesinin daha doğru olacağına değinilmektedir (Abasi vd. 2018, Islam vd. 2021, Ramos ve Sappa 2025). Yapılan tez çalışmasında 6 farklı öznitelik üzerinden analizler gerçekleştirilmektedir. Bu durum kalite derecelendirmesi noktasında çalışmanın farkını ortaya koymaktadır.

3. MATERYAL ve METOT

3.1 Veri Setinin Hazırlanması

Çalışmada oluşturulan veri seti, patates yumrularının hem kalite derecesini sayısal olarak tahmin etmeye yönelik regresyon hem de hastalık var/yok durumunu tespit edilebilmesi için sınıflandırmaya yönelik MTL modeli geliştirmek amacıyla kullanılmıştır. Veri seti oluşturulurken aynı bölgede yetişen ancak beş farklı tarım arazisinden farklı özelliklere sahip patates yumrularının toplanarak görsellerin çekimi yapılarak oluşturulmuştur. Her bir patates görseli hem kalite puanı ile ilişkilendirilmiş hem de hastalık durumuna göre uzman ziraat mühendisleri (toprak bilimi ve bitki besleme, bahçe bitki alanında doktora eğitimlerini tamamlamış) tarafından etiketlenmiştir. Parlaklık, kontrast ve gölgelemeden kaynaklanabilecek tutarsızlıkları en aza indirmek için 48×50×28 cm (genişlik × derinlik × yükseklik) boyutlarında bir çekim standı tasarlanmış ve ürün çekimleri düz beyaz bir zemin üzerinde gerçekleştirilmiştir. Çekim için 48 MP çözünürlüğe sahip kamera kullanılmıştır. Toplamda 1692 adet farklı patatesin görselinden oluşan veri setinde, patates yumrularının kalite derecelerini belirlemek için toprak bilimi ve bitki besleme, bahçe bitki alanında doktora eğitimlerini tamamlamış ziraat mühendisleri tarafından detaylı bir etiketleme çalışması gerçekleştirilmiştir. Patates çekimlerinde her bir patates görseli tek bir defa kullanılmış ve 1692 tane farklı patates yumrusu ile veri seti oluşturulmuştur. Uzmanlar, her bir patatesin çeşitli özelliklerini incelemiş, görüş ve bilgileri doğrultusunda bir kalite derecelendirmesi için puan skalası geliştirmişlerdir. Bu sayede, her bir yumruya ait objektif ve standart bir kalite derecesi elde edilmeye çalışılmıştır. Kalite derecelendirme sürecinde etiketlemeler gerçekleştirilirken veri setinde yedi öznitelik (şekil, boyut, renk, kabuk durumu, hastalık, filizlenme, fiziksel hasar) yer almaktadır. Ancak ROI ile alana odaklama yapıldığı için yanıltıcı sonuçlar oluşmaması adına boyut özniteliği kapsam dışında bırakılmış ve 6 öznitelik üzerinde yoğunlaşılmıştır. Uzmanların görüş ve bilgileri doğrultusunda oluşturulan öznitelikler ve kategorilerine uygun geliştirilmiş puanlama sistemine ait bilgiler Çizelge 3.1'de yer almaktadır.

Çizelge 3.1 Patates Kalite Değerlendirmesinde Kullanılan Öznitelikler ve Puanlama Sistemi

Öznitelik	**Kategori**	**Puan**
Şekil	*Düzgün*	1
	Bozuk	5
Kabuk Durumu	*Kusurlu*	5
	Kusursuz	1
Renk	*Homojen*	1
	Hafif Yeşillenme	2
	Yoğun Yeşillenme	4
	Kararma	5
Hastalık	*Güve*	4
	Haşere Yeniği	5
	Soyulma	3
	Uyuz	4
	Kesik	3
	Siyah Siğil	4
	Kuru Çürük	4
	Küf	5
	Yok	1
Fiziksel Hasar	*Var*	5
	Yok	1
Filizlenme	*Var*	5
	Yok	1

Çalışmada Çizelge 3.1'e göre, her bir patates yumrusunun şekil, kabuk durumu, renk, hastalık durumu, fiziksel hasar ve filizlenme özniteliklerine göre puanlama yapılmıştır. Bu etiketleme sistemi ile her bir patates yumrusunun görseli, çok etiketli (multi-label) olarak tanımlanmıştır. Böylece model eğitimi sırasında hem kalite derecelendirmesi hem de hastalık teşhisi aynı anda yapılabilecek şekilde veri seti yapılandırılmıştır. Çalışmada kullanılan veri setinde yer alan patates yumrularına ait hastalık türleri ve bu hastalıklara ilişkin sayı dağılımı Çizelge 3.2'de sunulmaktadır.

Çizelge 3.2 Veri Setinde Yer Alan Patates Hastalıklarına Ait Örnek Sayılarının Dağılımı

Güve	**Haşere Yeniği**	**Soyulma**	**Uyuz**	**Siyah Siğil**	**Kesik**	**Kuru Çürük**	**Küf**
387	228	259	308	70	95	406	75

Çizelge 3.2'de veri setinde yer alan patates hastalıklarının sayı dağılımı gösterilmektedir. Verilerden elde edilen bilgiler ışığında *Kuru Çürüklük* (406) ve *Güve* (387) en sık görülen hastalıklar olarak belirlenirken, *Uyuz* (308), *Soyulma* (259) ve *Haşere Yeniği* (228) orta düzeyde örnek sayısına sahiptir. Buna karşılık *Kesik* (95), *Küf* (75) ve *Siyah Siğil* (70) veri setinde daha az temsil edilen hastalık türleri arasında yer almaktadır. Elde edilen dağılım, veri setinin farklı hastalık türlerini kapsadığını, ancak hastalık sınıfları arasında örnek sayıları bakımından belirli düzeyde dengesizlik bulunduğunu göstermektedir. Bu durum, model geliştirme sürecinde sınıf dengesizliğinin etkisini azaltmaya yönelik veri artırma ve uygun eğitim stratejilerinin uygulanmasını gerekli kılmaktadır.

Çalışmada kullanılan çok boyutlu etiketleme yapısı sayesinde, sadece görüntü üzerinden kalite sınıfı belirlenmekle kalmayıp aynı zamanda çeşitli hastalık türleri, fiziksel bozukluklar ve filizlenme gibi tarımsal kaliteyi doğrudan etkileyen unsurlar da yüksek doğrulukla analiz edilmektedir. Örnek olarak ele alınan bir patates yumrusu, Çizelge 3.1'deki öznitelik puanlama sistemine göre değerlendirildiğinde Çizelge 3.3'te yer alan ilk görselin puan skalası şu şekilde belirlenmektedir; Patates yumrusu şekil olarak düzgün olduğu için öznitelik puan değerlendirme kapsamında 1 puan almaktadır. Kabuk durumu, yumrunun yüzeyinde gözlenen soyulma, derin çatlak veya belirgin bir kusur

gözlenmediği için kusursuz olarak etiketlenmiş ve 1 puan verilmiştir. Renk değerlendirmesine bakıldığında homojen bir renge sahip olduğu için puan skalasında 1 puan olduğu görülmektedir. Herhangi bir filizlenme veya fiziksel hasar görülmediği için her iki öznitelik için 1'er puan eklenmiştir. Yumruda herhangi bir hastalık olmadığı için ve etiketlemelerde hastalık özniteliğine bir yumruda en fazla 3 hastalık bulunması sebebiyle her bir hastalık değerlendirmesinden kaynaklı 1'er puan olmak üzere 3 puan eklenmiştir. Tüm öznitelik değerleri dikkate alındığında yumru derecelendirmesinin puanı toplamda 8 olarak hesaplanmıştır. Patates yumrusunun düzgün olması, kabuk yapısının kusursuz olması, renk değerinin homojen olması, hastalık bulunmaması, fiziksel hazar veya filizlenme olmaması yumrunun kalite derecesini artıran temel özniteliklerdir. Bundan dolayı söz konusu olan patates yumrusu kalite derecesi açısında iyi ve tercih edilebilir yumru olarak değerlendirilmektedir. Yapılan detaylı etiketleme ve puanlama sistemi, veri setinin hem görsel hem de sayısal açıdan zengin bir kaynak olmasını sağlamakta ve patates kalitesini otomatik olarak tahmin edecek algoritmalar için sağlam bir temel oluşturmaktadır. Kalite derecelendirme puan örneklendirmesi ve puanlaması yapılan yumru görselleri Çizelge 3.3'de yer almaktadır.

Çizelge 3.3 Patates Kalitesi İçin Puanlama Sistemi: Ölçütler ve Örnek Değerlendirmeler

Patates	**Hastalık**	**Seviye**
	Yok x 3	Şekil: Düzgün x 1 Kabuk Durumu: Kusursuz x 1 Renk: Homojen x1 Filizlenme: Yok x1 Fiziksel Hasar: Yok x1 Puan: 8
	Yok x 3	Şekil: Bozuk x 5 Kabuk Durumu: Kusursuz x 1 Renk: Homojen x1 Filizlenme: Var x5 Fiziksel Hasar: Yok x1 Puan: 16

Çizelge 3.3 Devam Patates Kalitesi İçin Puanlama Sistemi: Ölçütler ve Örnek Değerlendirmeler

Patates	Hastalık	Seviye
	Haşere Yeniği x 5 Güve x 4 Yok x 1	Şekil: Bozuk x 5 Kabuk Durumu: Kusurlu x 5 Renk: Yoğun Yeşillenme x4 Filizlenme: Yok x1 Fiziksel Hasar: Var x5 Puan: 30
	Kuru Çürük x 4 Güve x 4 Soyulma x 3	Şekil: Bozuk x 5 Kabuk Durumu: Kusurlu x 5 Renk: Yoğun Yeşillenme x 4 Filizlenme: Yok x1 Fiziksel Hasar: Yok x1 Puan: 27

Patates yumrularının kalite derecelendirmesi ve sağlık durumlarına göre değerlendirme yapılabilmesi için şekil, kabuk durumu, renk, fiziksel hasar, filizlenme, hastalık olmak üzere altı öznitelik dikkate alınarak puanlama sistemi oluşturulmuştur. Bu puanlandırma skalasında hastalıklı ve sağlıklı patates yumrularının ayrılması, kalite derecelendirme yapılabilmesi amacıyla makine öğrenmesi modellerinin eğitim sürecini güvenilir ve tarafsız gerçekleştirebilmesi için veri seti; eğitim, validasyon(doğrulama) ve test süreçlerinde kullanılacak şekilde veri seti üzerinde düzenleme işlemleri yapılmıştır. Çizelge 3.4'te çalışmada kullanılan veri setinin eğitim, validasyon ve test bölümlemesine ait bilgiler yer almaktadır. Çalışma kapsamında geliştirilen tek bir model sayesinde patates yumrularının hem sağlıklı ve hasta patates yumrusu ayrımı yapılırken hem de şekil, kabuk durumu, renk, fiziksel hasar, filizlenme ve hastalık özniteliklerinden elde edilen puanlar dikkate alınrak kalite derecelendirmesi yapılmaktadır. Böylece tek bir model ile iki farklı göre eş zamanlı olarak yürütülmesi sağlanmış, hesaplama maliyeti azaltılırken modelin pratik kullanım kabiliyeti artırılmıştır.

Çizelge 3.4 Veri Setinin Eğitim, Doğrulama ve Test Alt Kümelerine Ayrılması

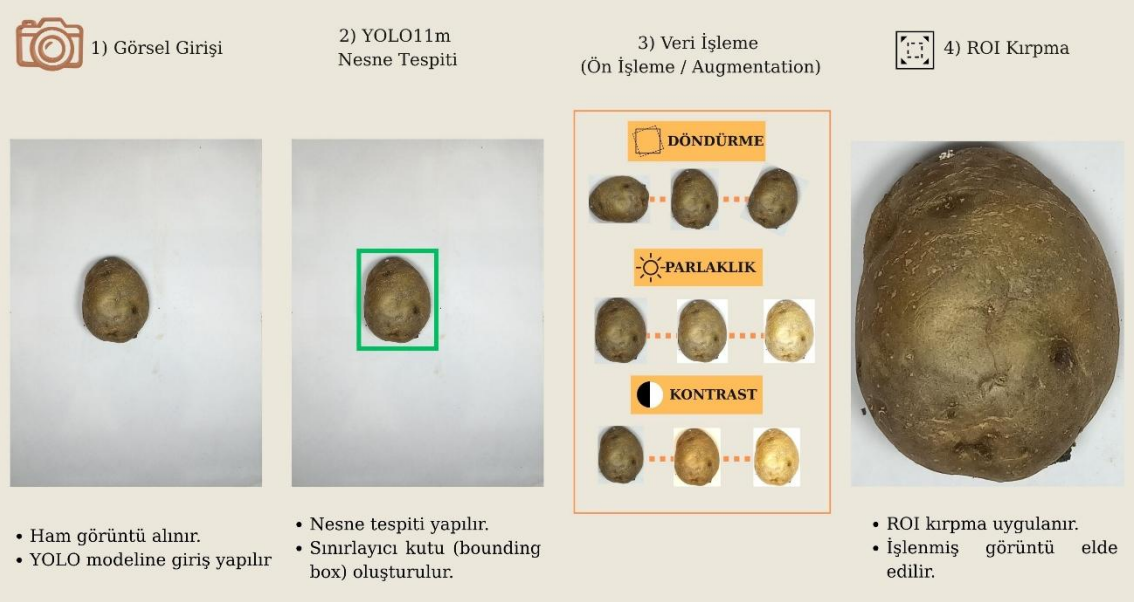
Veri Bölünmesi	Hastalıklı	Hastalıksız
Eğitim	939	210
Validasyon (Doğrulama)	167	37
Test	277	62
Toplam	1383	309

3.2 Ön İşleme ve Veri Arttırma

YOLO, nesne tespitinde hız ve doğruluk açısından öne çıkan derin öğrenme mimarilerinden biridir (Redmon vd. 2016). Literatürde YOLOv1'den YOLOv11'e kadar farklı sürümler geliştirilmiş olup her yeni versiyon model boyutu, işlem hızı ve doğruluk performansı bakımından önemli iyileştirmeler sunmaktadır. YOLO11m modeli, özellikle küçük ve orta ölçekli nesnelerde yüksek doğruluk sağlamasından dolayı çalışmada tercih edilme sebebidir (Ramos ve Sappa 2025). Çalışmada kullanılan veri setinde yer alan görsellerden ilgi alanının ROI (Region of Interest) çıkarımı yüksek doğruluk ve ölçeklendirme süreçlerinde uygunluk oluşması amacıyla YOLO11m tabanlı nesne tespiti yöntemi uygulanmıştır. ROI çıkarımı sonrasında nesne sınırlarının daha net belirlenebilmesi için her yönde 10 piksel genişletme işlemi uygulanmış ve yalnızca patates yumrusunu içeren alan analize dâhil edilmiştir. Çalışmada ROI çıkarımı için, nesne tespitinde yüksek doğruluk oranı ve güvenilir performans sunan YOLO modeli tercih edilmiştir. Ön denemelerde elde edilen başarılı sonuçlar nedeniyle farklı bir nesne tespit mimarisinin değerlendirilmesine gerek duyulmamıştır. YOLO tarafından hatalı kırpılan görüntülerin sayısı oldukça sınırlı olduğundan, bu görüntüler veri kalitesini korumak amacıyla manuel olarak yeniden düzenlenmiş ve analiz sürecine bu şekilde dâhil edilmiştir.

Ham görüntüler standart girişlere uygun 416x416 piksel çözünürlüğünde ölçeklenmiştir. Görüntülerin orijinal oranları korunarak kenarlara padding (dolgu) uygulaması yapılarak deformasyon engellenmiştir. Bu yöntem sayesinde patates yumruları doğru şekilde algılanarak konumların belirlenmesi yönünde eğitilmiştir. YOLO algoritmasının doğru

çalışması için görüntülerde yalnızca boyutlandırma yapılmamış, buna ek olarak etiketlemelere de (annotation) uyumlu şekilde hazırlanmıştır. Her bir görüntüde nesne konumu tanımlaması yapan sınır kutusu (bounding box) koordinatları kullanılarak YOLO formatına uygun olarak dosyalar kaydedilmiştir. Bu dosyalar ilgili görüntüyle aynı isimde klasörde depolanmıştır. Ayrıca görsellerin renk formatları RGB olarak saklanmış ve herhangi bir gri tonlama, renk dönüştürme, filtreleme işlemleri yapılmamıştır. Resim 3.1'de YOLO işlemi öncesi ve sonrası görsel görüntüsünün örneği yer almaktadır.



Resim 3.1 YOLO öncesi ve sonrası görsel yapısı

YOLO ile ROI çıkarımı sonrası elde edilen veriler, modelin genelleme yeteneğini artırmak amacıyla veri artırma (data augmentation) yöntemlerine tabi tutulmuştur. Bu kapsamda her bir görüntüye rastgele sağa-sola (yatay) çevirme, parlaklık ve kontrast ayarlamaları uygulanmıştır (Myshkovskyi ve Nazarkevych 2025). Uygulanan veri artırma teknikleri sayesinde veri setinin çeşitliliği artırılarak önerilen modelin farklı aydınlatma, yönelim ve kontrast koşullarına karşı daha dayanıklı ve genellenebilir bir performans sergilemesi hedeflenmiştir. Veri artırma işlemi sonrasında veri setindeki görüntü sayılarında meydana gelen değişiklikler Çizelge 3.5'te sunulmaktadır.

Çizelge 3.5 Veri Artırma Sonrası Eğitim ve Doğrulama Veri Setlerinin Dağılımı

Model Türü	**Eğitim Seti Orijinal (%80)**	**Yapılan İşlem**	**İşlem Sonrası Eğitim Verisi**	**Doğrulama (Validation) Seti (%20)**
MTL (Multi-task Learning)	1353 Görsel	Azınlık sınıfı (Hastalık yok) 4 katına çıkartılmıştır	2094 Görsel	339 Görsel
Hastalık tespiti	1353 Görsel	Azınlık sınıfı (Hastalık yok) 4 katına çıkartılmıştır	2094 Görsel	339 Görsel
Kalite skor tahmini	1353 Görsel	Fiziksel Artırım Yok (Dağılım sabit)	1353 Görsel	339 Görsel

Çalışmada 1353'ü eğitim (%80), 339'u doğrulama (%20) görüntüsü olmak üzere toplamda 1692 görüntüden oluşmaktadır. Çizelge 3.5'te çalışma kapsamında kullanılan modellerin eğitim sürecinde veri dengesizliği sorununu gidermek amacıyla uygulanan veri artırma işlemleri gösterilmektedir.

Kullanılan modellerden MTL ve tek görevli hastalık tespitinde veri dengesizliğini minimize etmek amacıyla hastalık yok sınıfı veri artırma tekniklerinden yararlanılarak 4 katına çıkartılmıştır. Bu işlem sonrasında eğitim seti 1353 görselden 2094 görsele çıkmıştır. Bu işlem, modelin çoğunluk sınıfına yönelim (bias) göstermesini önlemek ve azınlık sınıfını daha etkin öğrenmesini sağlayarak sınıflar arasındaki genelleme başarısını artırmak amacıyla uygulanmıştır. Veri artırma işlemi sadece eğitim seti üzerinden gerçekleştirilmiş 339 görselden oluşan doğrulama seti sabit tutulmuştur. Burada amaç veri sızıntısını engellemek ve modellerin gerçek dünya verileri üzerindeki başarısını objektif biçimde değerlendirilmiştir.

Kalite skor tahmini modelinde veri setinde herhangi bir fiziksel artırma işlemi gerçekleştirilmemiş orjinal veri dağılımı korunmuştur. Kalite skoru işleminde veri seti eğitilirken 1353 görselden oluşan veri seti rastgele döndürülmüş, parlaklık ve kontrast değişiklikleri yapılmış ancak veri sayısında değişiklik olmamıştır. Bu durum kalite skoruna ait sınıfların ve sürekli değerlerin veri setinde dengeli bir dağılım sergilediğini göstermektedir.

3.3 Makine Öğrenmesi Algoritmaları

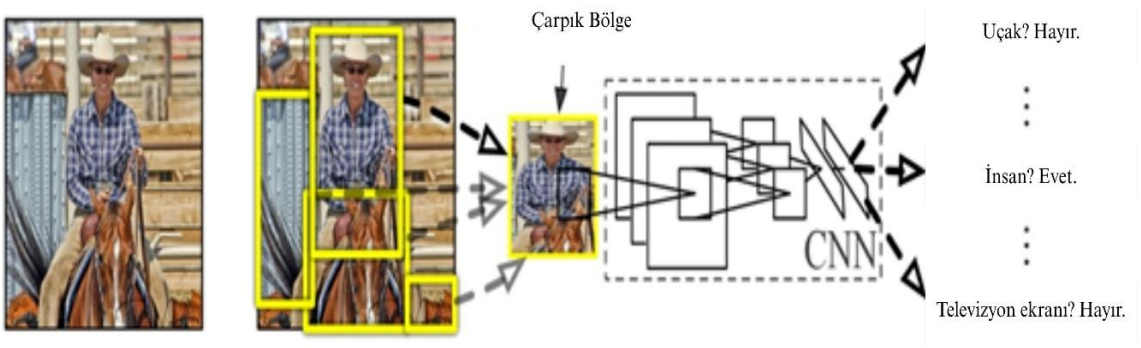
Makine öğrenmesi yapay zekanın alt alanlarındandır. Makine öğrenmesinde temel amaç; eldeki verilerden bilgi edinilmesi için hesaplama yöntemlerinden faydalanarak analizler gerçekleştirilmesidir (Gültepe 2019). Makine öğrenmesi yönteminde süreç içerisinde eldeki ham veriler ile bilgisayar sistemlerinin otomatik öğrenmesinin sağlanması amaçlanmaktadır (Pandey vd. 2019). Süreç 2 temel basamaktan oluşur; modelin eğitimi ve modelin karar verme işleminin test edilmesidir. Bundan dolayı veri seti bölümlemesi eğitim ve test verileri olarak gruplara ayrılmaktadır.

3.4 Derin Öğrenme

Derin öğrenme, bilgisayar sistemlerinin girdi değişkenlerinde yer alan verideki temsillerin hiyerarşik olarak basitten daha karmaşık kavramlara kademeli öğrenme temeline dayanmaktadır (Kim 2016). Derin öğrenmede temel mantık çok detaylı özellikler daha az detay gerektiren özelliklerden üretilerek hiyerarşik yapıda oluşturulur (Şeker, Diri ve Balık 2017). Ardışık katmanlı yapısında bir katmanın çıktısı kendinden sonraki katmanın girdisi olması mantığında çalışan bu öğrenme modelinde özellik çıkarımı için kullanılan etkili algoritmadır.

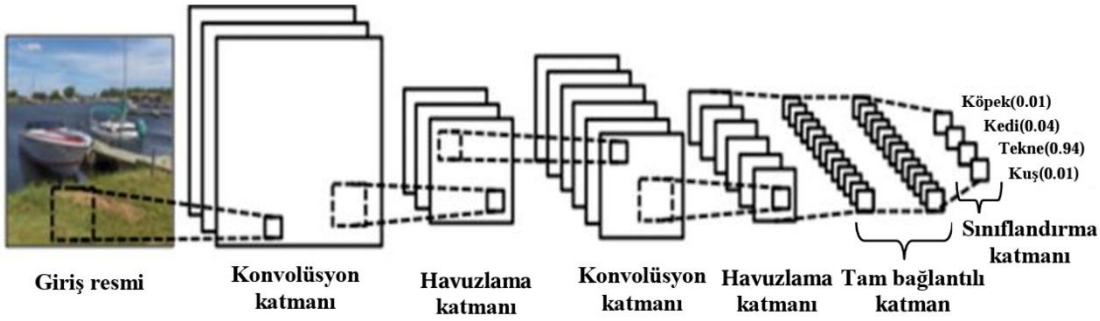
3.4.1 Evrişimsel Sinir Ağı (ESA)

Derin öğrenme kavramında yer alan temel mimari Evrişimsel Sinir Ağı (ESA) mimarisidir (İnik ve Ülker 2017). ESA birden fazla katmandan oluşan mimarisi sayesinde görüntü işleme, konuşma tanıma ve doğal dil işleme gibi çeşitli amaçlar doğrultusunda kullanılan makine öğrenmesi yöntemlerindendir (Krichen 2023, Maurício vd. 2023). ESA mimarisinin amacı, girişte alınan verinin ilgili bölgelerine odaklanarak özellik çıkarımı sağlamaktır. Mimari yapıda dikkat (attention) mekanizması sayesinde modelde tüm görüntüden ziyade ayırt edici bölgelere ağırlık verilerek analiz gerçekleştirerek sonuç çıktı kısmından elde edilmektedir. ESA mimarisinin temel mantığına ait yapı Resim 3.2'de yer almaktadır.



Resim 3.2 ESA mimarisin temel yapısı (Girshick vd., 2014)

ESA mimarisinde girdi katmanı, gizli katman ve çıktı katmanı olarak temelde 3 katmandan söz edilmektedir. Gizli katman yapısının içerisine çalışma alanına göre özelleştirilmiş katmanlar eklenebilmektedir. ESA mimarisi birbirine arka arkaya bağlanmış katmanlardan oluşur. Bu katman yapısında konvolüsyon (convolutional), havuzlama (pooling), aktivasyon (activation), normalizasyon (batch normalization), seyreltme(dropout) ve tam bağlı (full connected) katman adı verilen katmanlar elenebilmektedir. Giriş katmanından elde edilen görsel konvolüsyon katmanında belirlenen küçük boyutlu matris yapılarını tüm görüntü üzerinde gezdirilerek görüntü öznitelikleri belirgin hale getirilerek yeni görüntü elde edilir. Elde edilen görüntü havuzlama katmanında oluşturulan NxN boyutundaki boş görüntü matrisinde kaydırma yapılarak en büyük değerler alınır. Bu sayede ağda işleme alınan veri miktarı indirgenmektedir. Havuzlama katmanında gelen verilere aktivasyon fonksiyonu (ReLU) uygulanarak bir değer elde edilir. Normalizasyon katmanında katman yapılarında elde edilen verilerin düzenli olmaları için standart aralıklarda temsil edilir. Seyreltme (Dropout) katmanı, öğrenme işlemi gerçekleşen verinin aşırı öğrenme(ezberleme) durumunu engellemeyi sağlayan katmandır. Tam bağlı katman yapısında veriler tek boyutlu olarak yer almaktadır. Burada her veri (nöron) kendisinden sonra gelen veri ile bağlantı oluşturur. ESA mimarisinin çalışma mantığını açıklayan derinlemesine katman içeriğine ait yapı Resim 3.3'te yer almaktadır.



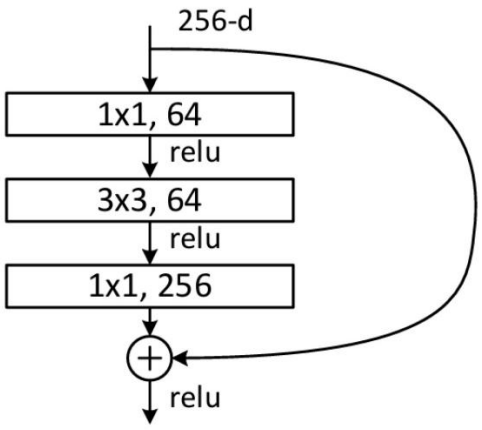
Resim 3.3 ESA katmanlı yapısı (Wang, 2018)

Öznitelik çıkarımı aşamasında amaç, görsellerden sınıflandırma ve regresyon görevleri için anlamlı özniteliklerin elde edilmesidir. Bu kapsamda literatürde yaygın olarak kullanılan ve farklı büyüklüklere sahip olan ResNet50, EfficientNet-B2 ve ConvNeXt/Base mimarileri tercih edilmiştir. Her bir mimari, ağ yapısı, parametre boyutu ve performans açısından farklılık göstermekte olup çalışmada karşılaştırmalı olarak değerlendirilmiştir. Eğitim sürecinde transfer öğrenme (transfer learning) yaklaşımı benimsenmiş; modeller ImageNet veri kümesi üzerinde önceden eğitilmiş ağırlıklarla başlatılarak, öznitelik çıkarım kapasitesinin artırılması ve daha güçlü bir genelleştirme yeteneği kazanılması sağlanmıştı (Russakovsky vd. 2015).

3.4.1.1 ResNet50

ResNet mimarisinde temel mantık, bir katmandan doğrudan son tahmini üretmek yerine, beklenen çıktıyla mevcut çıktı arasındaki farkı (delta) öğrenmeye çalışmaktadır (Kadam vd. 2022). ResNet, derin sinir ağlarında katman sayısının artmasından kaynaklı kaybolan gradyan ve bozulma sorunlarını aşmak için artık öğrenme yaklaşımını benimseyerek geliştirilmiş olup, farklı derinliklere sahip ResNet-18, ResNet-34, ResNet-50, ResNet-101 ve ResNet-152 gibi modellerden oluşmaktadır (He vd. 2016). Bu çalışmada ResNet50 modeli kullanılmıştır. ResNet50 eğitimi 1x1, 3x3, 1x1'lik evrişimsel katmanları kullanan 50 katmandan oluşan kalıntı ağlardan kısaltılan bir ağdır. ResNet50 modeli ESA ağında oluşan performans düşümü problemini çözmeyi amaçlamaktadır. Bozulma problemini indirgemek amacıyla var olan katmanlar arasında kısa bağ eklentisi yaparak problemin önüne geçmek amaçlanır. Mevcut katman ihtiyaç dahilinde değilse ESA ağırlık katmanına geçilerek bozulma engellenmiş olur. Bu eğitim seti sayesinde

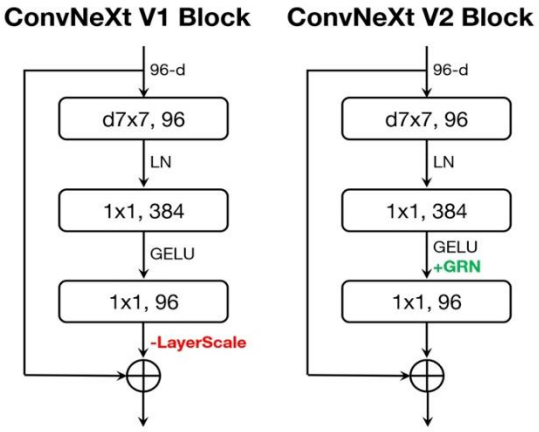
meydana gelebilecek aşırı öğrenme (ezber) engellenmeye çalışılır. ResNet50 modeline ait katmanlı yapı Resim 3.4'te yer almaktadır.



Resim 3.4 ResNet50 model katman yapısı (Liu vd., 2022)

3.4.1.2 ConvNeXt

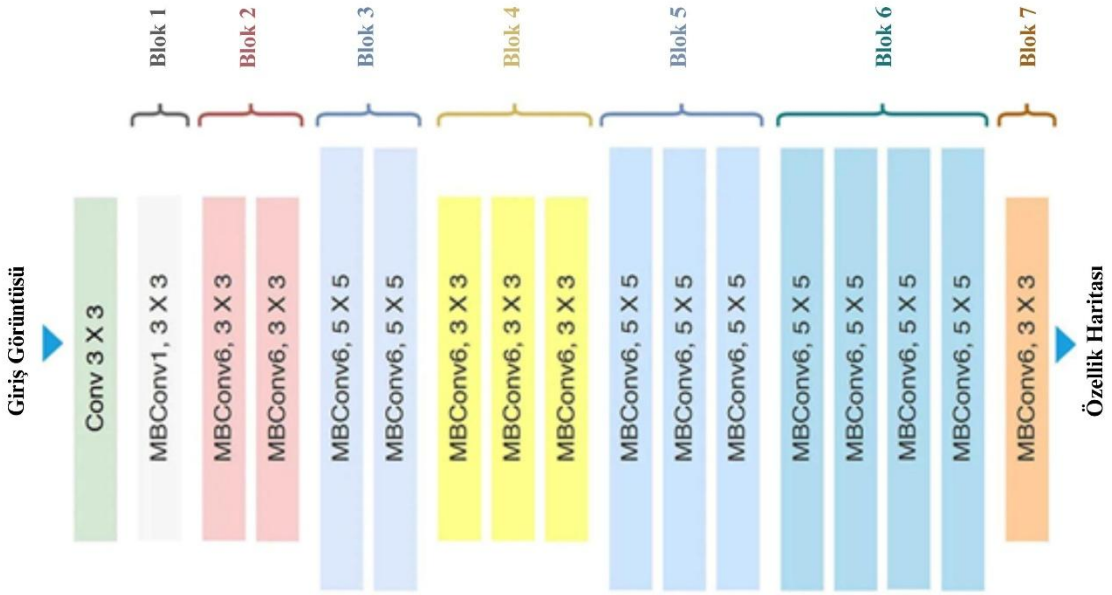
ResNet mimarisinden esinlenilerek tasarlanmış modern bir evrişimsel sinir ağı modelidir. Model, dört aşamalı hiyerarşik bir yapı üzerine inşa edilmiştir (Woo vd. 2023, Liu vd. 2022). Her aşamada farklı çözünürlüklere sahip özellik haritaları üretilerek çok ölçekli (multi-scale) bilgi çıkarımı gerçekleştirilmektedir. ConvNeXt blokları, geniş çekirdekli derinlik ayrık konvolüsyonlar, GELU aktivasyon fonksiyonu, katman ölçekleme ve katman normalizasyonu gibi modern bileşenlerle zenginleştirilmiştir. Bu tasarım, Transformer mimarilerinin avantajlarını koruyarak tamamen konvolüsyonel bir yapıda benzer performans elde etmeyi amaçlamaktadır. Ayrıca modelin geliştirilmiş versiyonu olan ConvNeXt V2, Masked Autoencoder (MAE) tabanlı kendinden denetimli öğrenme yaklaşımı ve yeni bir Global Response Normalization (GRN) katmanı ile donatılmıştır. Bu bileşenler, modelin genelleme yeteneğini artırmakta, daha yüksek doğruluk oranları sağlamakta ve hesaplama verimliliğini önemli ölçüde iyileştirmektedir. Bu çalışmada ConvNeXt mimarisinin orta ölçekli bir çeşidi olan ConvNeXt/Base modeli kullanılmıştır. ConvNeXt mimarisi Resim 3.5'te yer almaktadır.



Resim 3.5 ConvNeXt mimari yapısı (Woo vd., 2023)

3.4.1.3 EfficientNet

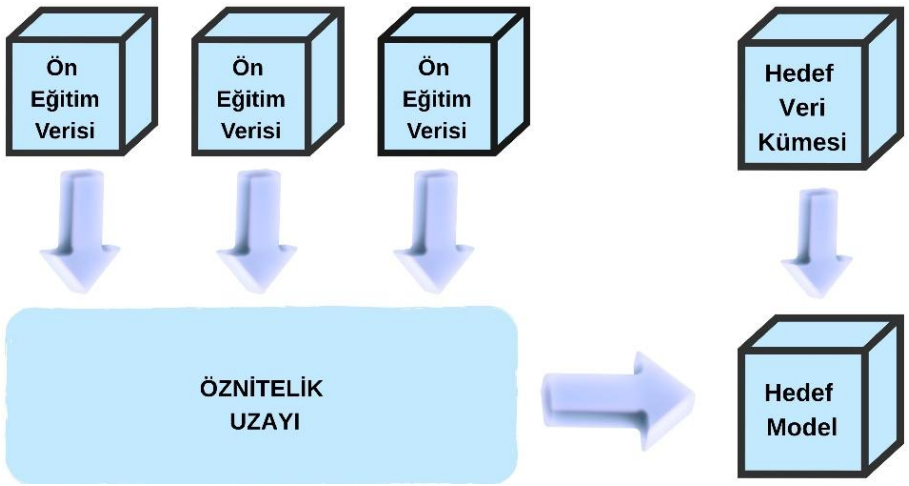
EfficientNet modelinin temel odak noktası boyutlandırma ve verimliliktir. "Compound Scaling (Bileşik Ölçeklendirme)" yaklaşımı ile geliştirilen bu model, derinlik, genişlik ve giriş görüntü boyutlarını eşzamanlı olarak optimize etmektedir(Tan ve Le 2019). Bu sayede, daha az parametre kullanılarak daha yüksek doğruluk oranları elde edilebilmektedir. MBConv bloklarından oluşan mimaride ana gövdeyi derin ayrık evrişim katmanları ile sıkma-uyarma blokları oluşturmaktadır. EfficientNet mimari yapısı Resim 3.6'da yer almaktadır. EfficientNet ailesi B1'den B7'ye kadar farklı mimarilerden meydana gelmekte olup, bu mimarilerde ölçeklendirme faktörleri değişiklik göstermektedir. Örneğin, EfficientNet-B2 mimarisi, B1 ile aynı yapıya sahip olmakla birlikte kanal sayılarındaki çeşitlilik nedeniyle parametre sayısı artmaktadır (Tan ve Le 2019, Yang vd. 2023).



Resim 3.6 EfficientNet mimari yapısı (Ahmed ve Sabab, 2021)

3.4.2 Transfer Öğrenme ve İnce ayar (Fine-Tune)

Transfer öğrenme, bilgisayar sistemlerinin herhangi bir sorunun çözümü için gerçekleştirilen eğitimden elde edilen bilgilerin benzer özelliklere sahip problem durumlarında kullanımına olanak sağlayan öğrenme modelidir (Fırıldak ve Talu 2019). Transfer öğrenmenin çalışma mantığı Resim 3.7'de yer almaktadır.

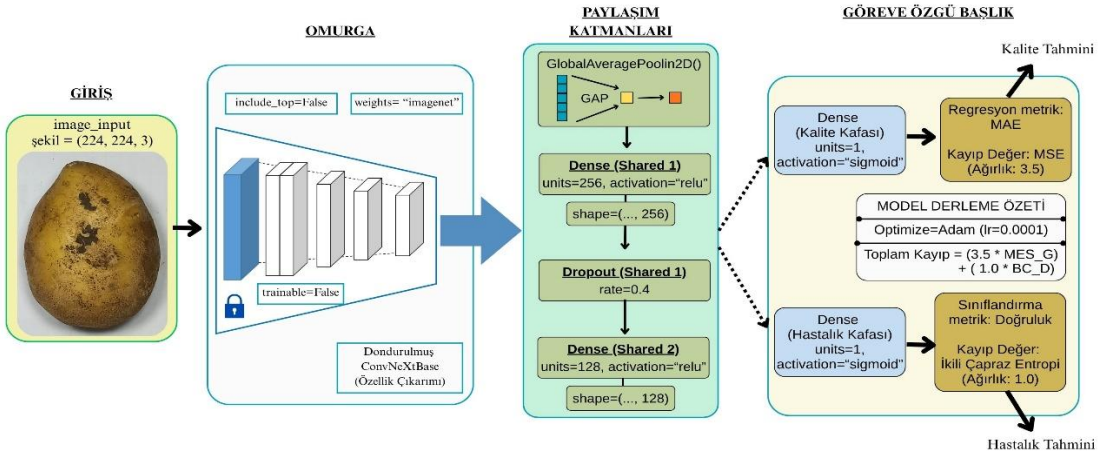


Resim 3.7 Transfer öğrenme çalışma mantığı

Eldeki veri seti ile derin öğrenme modelini baştan öğretmek yerine benzer doğrultuda eğitilmiş modelin çalışmaya belirlenen özel göreve uyarlama yapılması maliyetli ve zaman alıcı bir süreçtir. İnce ayar yapılarak transfer öğrenme yöntemiyle başlatılan analiz sürecinde modelin bazı katmanlarına dondurma işlemi uygulayarak son katmanları yeni veri setine göre eğitir (Alhawas ve Türekçi 2022). İnce ayar işlemi gerçekleştirilirken çalışmada kullanılan ağırlıklarda herhangi bir değişiklik yapılmaz. Bu sayede geliştirilen modele küçük bir öğrenme ortamı sunulmaktadır.

3.5 Çoklu Görev Öğrenme (MTL)

MTL'de transfer öğrenme, çok etiketli öğrenme ve çok çıktılı regresyon makine öğrenimine benzer bir ortam bulunur fakat MTL'de farklı görev durumlarında ayrım yapılmaksızın bütün görevlerde performans iyileştirme amaçlanmaktadır (Zhang ve Yang 2018, Zhang ve Yang 2022). MTL, makine öğreniminin büyün uygulamalarında (doğal dil işleme, konuşma tanıma, görüntü işleme vb.) başarı bir şekilde kullanılmaktadır (Ruder 2017). MTL modeli elimizde var olan tek bir veri setini farklı görevlerde aynı anda öğrenme işleminin gerçekleştirilmesine olanak sunmakla birlikte bu görevlerin birbirleriyle paylaşım yaparak özellik çıkarımı gerçekleştirilmesini sağlar (Kaur vd. 2024). Çalışmada önerilen modele ait MTL mimari yapısı Resim 3.8'de paylaşılmıştır.



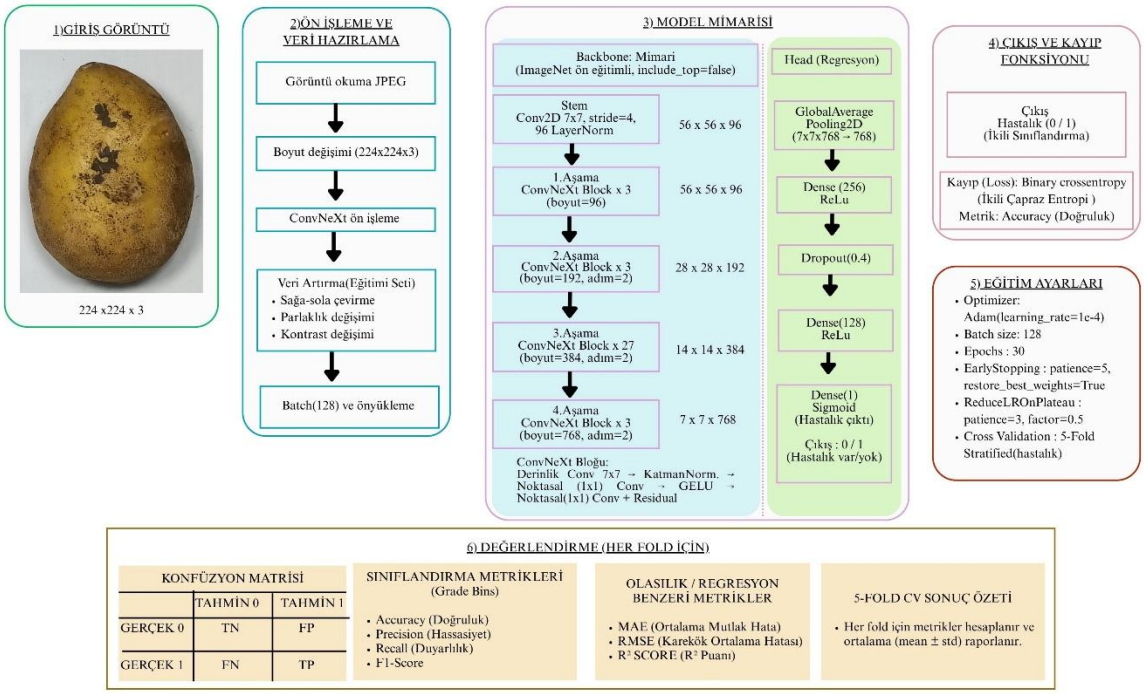
Resim 3.8 Önerilen MTL mimarisi

MTL modelinin mimari yapısında kullanılan veri seti üzerinden analizleri yapılan farklı görevlerin ortak özellik uzayını ayırmak için paylaşım katmanları yer almaktadır. Paylaşım katmanlarından elde edilen çıktılar her görevin kendi içerisinde belirlenen özellikleri yakalayabilmesi için alt dallara ayrılır(Ji vd. 2018).

3.5.1 Hedef Görevler

Çalışma kapsamında patates yumrusu kalite derecelendirmesi ve hastalık tespiti gerçekleştirebilmek için MTL tabanlı model önerilmektedir. Model kalite skor tahmini gerçekleştirmek için regresyon tabanlı olarak hazırlanmıştır. Veri setinde kalite skor tahmini için x-y aralığında değişen puanlandırmaların daha iyi hesaplanabilmesi için min-max normalizasyonu kullanılmaktadır. Bu normalizasyonda özellikler ortak [0-1] aralığına indirgenerek modelin ağırlık güncellemeleri daha karalı hale getirilmekte ve regresyon performansı artmaktadır (Aguilar-Ariza vd. 2024). Model çıktısı sonrasında MSE-loss fonksiyonu kullanılmıştır. MSE kayıp fonksiyonu, tahmin edilen değer ile gerçek değer arasındaki farkın kareler ortalaması üzerinden değerlendirme yaparak hata oranını en aza indirgemeye çalışmaktadır. Bu yöntem patates gibi düzensiz, şekil ve yüzey özelliklerine sahip tarım ürünlerinde kalite sınıflandırması için yaygın olarak kullanılmaktadır. Bununla birlikte çalışmada MTL yaklaşımı sayesinde regresyon görevi diğer görevlerden elde edilen paylaşılan temsillerle desteklenerek genel tahmin doğruluğu artırılmıştır.

MTL model kapsamında ilk görevde kalite skor tahmini gerçekleştirilirken ikinci görev olarak hastalık var-yok (binary classification) tespiti yapılmaktadır. Hastalık var-yok tespiti ve kalite skor tahmini için tek görevli mimari yapılar Resim 3.9 ve Resim 3.10'da yer almaktadır. İkili sınıflandırma yöntemi, tarım ürünlerinde kalite kontrol ve hastalıkların erken tespiti için sıklıkla başvurulan bir yöntemdir (Kamilaris ve Prenafeta-Boldú 2018). Modelde iki sınıf arasındaki ayrım için sigmoid aktivasyon fonksiyonu ve binary-crossentropy kayıp fonksiyonundan yararlanılmaktadır. Literatürde yapılan çalışmalar, bu yöntemin tarımsal ürünlerde yüzey hastalıklarının tespitinde yüksek başarı oranları elde ettiğini göstermektedir (Jorquera-Chavez vd. 2021, Too vd. 2019).



Resim 3.9 Tek görevli hastalık sınıflandırma mimarisi

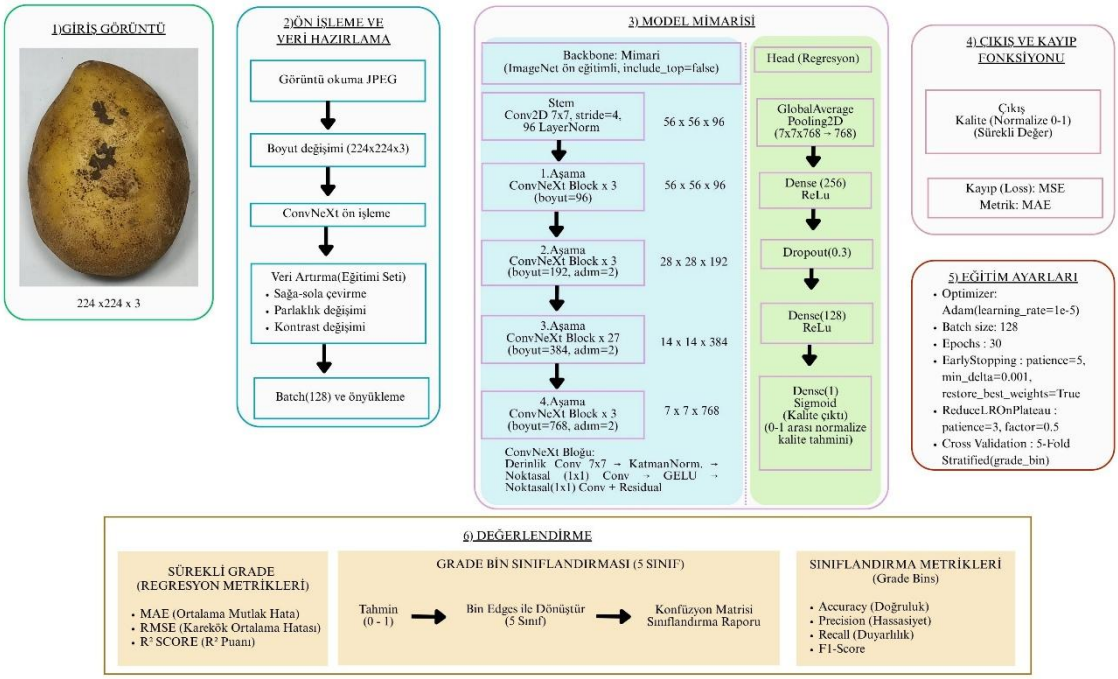
Tek görevli hastalık tespiti ikili sınıflandırma (binary classification) bağlamında tasarlanan bilgisayarlı görü mimarisinde, kullanılan modeller için tüm görseller standart girdi boyutuna dönüştürülmektedir. Bu doğrultuda ilk olarak JPEG formatındaki görseller okunmakta, 224x224x3 (RGB) çözünürlüğüne sahip olacak şekilde yeniden ölçeklendirilmekte ve standart giriş formatına getirilmektedir. İkinci aşamada veriler, veri artırma (data augmentation) işlemine tabi tutulmaktadır. Veri artırma amacıyla rastgele sağa-sola döndürme, parlaklık ve kontrast teknikleri uygulanarak eğitim veri setindeki çeşitlilik artırılmaktadır; böylece modelin aşırı öğrenme (overfitting) yapması engellenmekte, aydınlatma koşullarına karşı dayanıklılığı sağlanmakta ve genelleme yeteneği optimize edilmektedir.

Eğitim süresinin azaltılması ve GPU kullanımında verimliliğin artırılması adına batch (yığın) büyüklüğü 128 olarak ayarlanmıştır. Modelin öznitelik çıkarımı (feature extraction) aşamasında ImageNet veri kümesi ile ön eğitimli ağırlıklar kullanılmış ve orijinal sınıflandırma katmanları kaldırılmıştır. Dört aşamalı blok yapısından oluşan modelde, işlenen görsellerin blok yapısı boyunca uzamsal çözünürlüğü azaltılırken kanal

derinliği artırılmıştır. Bu hiyerarşik yapı sayesinde model; temel kenar, doku, renk gibi öznitelikleri başarılı bir şekilde yakalamaktadır.

Katman yapısından elde edilen özellik haritası, Global Average Pooling katmanı ile tek boyutlu olarak vektörleştirilmektedir. Ardından modelin karmaşık ilişkileri öğrenebilmesi adına sırasıyla 256 ve 128 nöronlu tam bağlantılı (Dense) katmanlar mimariye dahil edilmiş; araya eklenen dropout katmanı (0.4) ile her adımda rastgele nöronlar devre dışı bırakılarak ezberleme (overfitting) eğiliminin önüne geçilmiştir. Son katmanda yer alan Dense(1) katmanı ve Sigmoid aktivasyon fonksiyonu sayesinde elde edilen çıktılar [0, 1] aralığında bir olasılık değerine dönüştürülerek hastalık var/yok şeklinde ikili sınıflandırma gerçekleştirilmektedir.

Modelin optimizasyon aşamasında, ikili sınıflandırma problemleri için akademik literatürde kabul gören "Binary Crossentropy" kayıp fonksiyonu seçilmiş, hiperparametre olarak "Adam" optimizasyon algoritması ve uygun regülasyon stratejileri uygulanmıştır. Son aşamada ise "5-Fold Stratified Cross-Validation" (5 Katmanlı Tabakalı Çapraz Doğrulama) stratejisi kullanılarak veri seti, sınıf dağılımları korunacak şekilde 5 parçaya bölünmüştür. Her fold yapısı için modelin ayrı ayrı eğitilip test edilmesi, modeldeki olası yanlılığın (bias) azaltılmasını sağlamıştır. Performans değerlendirmesinde karışıklık matrisi (Confusion Matrix), doğruluk (Accuracy), hassasiyet (Precision), duyarlılık (Recall) ve F1-Skor metrikleri hesaplanmıştır. Elde edilen performans metrikleri modelin kararlılığını ve tekrarlanabilirliğini değerlendirmek amacıyla ortalama (mean) ± standart sapma (std) değerleri şeklinde raporlanmıştır.



Resim 3.10 Tek görevli kalite skor tahmini mimarisi

Tek görevli kalite skor tahmin mimarisinin hastalık tespiti mimarisinden farklı olarak bu modelde çıkış katmanı ikili sınıflandırma yerine sürekli kalite skorunun tahmin edilmesine yönelik regresyon yapısında tasarlanmıştır. Backbone'dan elde edilen özellik haritaları Global Average Pooling katmanı ile tek boyutlu öznitelik vektörüne dönüştürüldükten sonra sırasıyla 256 ve 128 nörondan oluşan tam bağlantılı (Dense) katmanlardan geçirilmektedir. Dense katmanları arasına Dropout (0.3) katmanı eklenerek eğitim sırasında aşırı öğrenme riski azaltılmıştır. Son katmanda yer alan Dense(1) çıkışı ile patateslerin 0–1 aralığında normalize edilmiş kalite değeri tahmin edilmektedir.

Hastalık tespiti mimarisinde kullanılan Binary Cross-Entropy kayıp fonksiyonu yerine, sürekli değer tahmini gerçekleştirildiği için Mean Squared Error (MSE) kayıp fonksiyonu tercih edilmiştir. Model parametrelerinin optimizasyonunda yine Adam algoritması kullanılmış; EarlyStopping ve ReduceLROnPlateau stratejileri korunmuştur.

Kalite skor tahmini mimarisinde performans değerlendirmesi hastalık tespitinden farklı olarak MAE, MSE, RMSE ve R^2 metrikleri kullanılarak gerçekleştirilmiştir. Ayrıca model tarafından tahmin edilen sürekli kalite skorları belirlenen eşik değerlerine göre

kalite sınıflarına dönüştürülerek karışıklık matrisi (Confusion Matrix) üzerinden sınıflandırma başarısı da analiz edilmiştir. Sonuçlar, önceki mimaride olduğu gibi 5-Fold Stratified Cross-Validation kapsamında elde edilen ortalama ± standart sapma değerleri şeklinde raporlanmıştır.

3.6 Değerlendirme Metrikleri

Makine öğrenimi modellerinin başarısını nesnel olarak değerlendirebilmek için uygun performans metriklerinin seçimi kritik öneme sahiptir. Özellikle çoklu görev öğrenimi (MTL) çerçevesinde hem sınıflandırma hem de regresyon görevleri için farklı hata ölçütleri kullanmak, modelin güçlü ve zayıf yönlerinin doğru analiz edilmesini sağlar (Aguilar-Ariza vd. 2024, Kamilaris ve Prenafeta-Boldú 2018). Bu çalışmada kullanılan temel metrikler ve metriklere ait formüller Çizelge 3.6'da yer almaktadır.

Çizelge 3.6 Değerlendirme Metrikleri ve Hesaplama Formülleri

Metrik	Açıklama	Formül
Doğruluk	Sınıflandırma algoritmalarında kullanılan en yaygın ölçüttür. Doğruluk oranı olarak ifade edilir.	$\frac{(TP + FP)}{(TP + FP + TN + FN)}$
Duyarlılık	Sınıflandırmanın doğru olan pozitif yapıların oran değeri ölçülür.	$\frac{TP}{(TP\ +\ FN)}$
Hassasiyet	Pozitif sınıfta yer alan toplam tahminlerden doğru tahminlerin pozitif yapıları ölçmektir.	$\frac{TP}{(TP\ +\ FP)}$
F1-Skoru	Hassasiyet ve Duyarlılık metriklerinin harmonik (ağırlıklı) ortalamasıdır.	$\frac{2 * (Hassasiyet\ *\ Duyarlılık}{Hassasiyet\ +\ Duyarlılık}$

Çizelge 3.6 Devam Değerlendirme Metrikleri ve Hesaplama Formülleri

RMSE	Gerçek değer ile tahmin edilen değerlerin arasındaki farkın karesinin toplanır elde edilen değer toplam örnek sayısına bölünür.	$\frac{1}{N}\sum_{i=1}^{N} (Yi - Y'i)^2$
MAE	Regresyon problemleri için kullanılan hata ölçütlerinin en basitidir. Yapılan tahminlerin gerçek değer arasındaki uzaklık hakkında bilgi verir.	$\frac{1}{N}\sum_{i=1}^{N} \lvert Yi - Y'i \rvert$
R2	Kullanılan veri seti varyansının model üzerinden ne kadarının açıklandığını belirtir.	$\frac{\frac{1}{N}\sum_{i=1}^{N} (Yi - Y'i)^2}{N * \sum_{i=1}^{N} (Yi - Y'i)^2}$

Çalışmada önceden eğitilmiş modeller üzerinde İnce ayar (fine-tuning) işlemi gerçekleştirilmiştir. Bu kapsamda, modellerin son 10 katmanı yeniden eğitime tabi tutulmaktadır. Özellik çıkarımı aşamasında Global Average Pooling katmanının ardından sırasıyla Dense (256 nöron), Dropout (0.4) ve Dense (128 nöron) katmanları uygulanmıştır.

Model hem kalite derecelendirmesi (kalite derece) hem de hastalık tespiti (disease) görevleri için yapılandırılmıştır. Bu doğrultuda, çıkış katmanı sigmoid aktivasyon fonksiyonuna sahip tek bir Dense katmandan oluşmaktadır. Hastalık tespitinde Binary Cross-Entropy, kalite derecelendirmesinde ise Mean Squared Error (MSE) kayıp fonksiyonları kullanılmıştır. Çoklu görev öğrenimi (MTL) kapsamında, kalite derece görevine 3,5 hastalık görevine 1 ağırlık değeri atanmıştır. Kalite derece görevine farklı ağırlık değerleri atanarak analizler yapılmış, en başarılı sonuç 3,5 ağırlık derecesinde elde edilmiştir. Ayrıca, hastalık verisindeki sınıf dengesizliğini gidermek ve modelin azınlık

sınıfını daha doğru öğrenmesini sağlamak amacıyla oversampling yöntemi uygulanmıştır. Bu sayede, eğitim sürecinde modelin genelleme kabiliyeti artırılmış ve dengesiz veri kaynaklı yanlılıkların önüne geçilmiştir.

Ek olarak, kalite derecelendirmesi (kalite derece) görevi, MTL yaklaşımıyla birlikte tekil regresyon modelleri üzerinden de test edilerek karşılaştırmalı analiz yapılmıştır. Bu modellerin parametreleri belirlenirken literatürde sık kullanılan parametre seçimleriyle birlikte GridSearchCV yönteminden yararlanılmıştır. Bu sistemlerin kısa açıklamaları ve kullanılan parametre değerleri Çizelge 3.7'de sunulmaktadır.

Çizelge 3.7 Regresyon Analizi: Model Açıklamaları ve Parametre Tahminleri

Metrikler	**Açıklama**	**Parametre**
Ridge Regression	Model doğruluğuna küçük katkı sağlayan tüm parametrelerin katsayılarının büyüklüğünü azaltmak amacıyla bir ceza terimi uygulanır (Sharma vd. 2023). Bu ceza, katsayıların büyüklüğünün karesi ile orantılıdır.	L2 sklearn.linear_model.Ridge alpha: 10
Lasso Regression	Modele eklenen küçük etkili parametrelerin katsayıları sıfıra indirgenir (Sharma vd. 2023). Katsayıların büyüklüğü, mutlak değerleri üzerinden ceza terimi (penalty) olarak modele eklenir.	L1 sklearn.linear_model.Lasso alpha: 0.1
Support Vector Regression (SVR)	Destek vektör algoritmalarından esinlenerek oluşturulmuştur (Comito ve Pizzuti 2022). Belirlenen bir özellikten temel- orijinal özelliklere en yakın tahmini oluşturan, hataların en aza indirgendiği algoritmadır.	sklearn.svm.SVR C: 1.0 Epsilon: 0.1 Gamma: auto
Random Forest Regressor	Karar ağacı mantığına dayanarak geliştirilmiş yöntemdir (Wang vd. 2021). Sınıflandırma ve regresyon işlemlerinde yoğunlukla kullanılır.	sklearn.ensemble. RandomForestRegressor n_estimators: 200
XGBoost Regressor	Gradient Boosting Makinelerinin (GBM), tahmin yeteneğini ve hızını artırmak amaçlı düzenlenmiş ölçeklenebilir algoritmadır (Wang vd. 2021).	xgboost.XGBRegressor learning_rate: 0.1 max_depth : 3 n_estimators: 100

4. BULGULAR

4.1 Deneysel Analiz Sonuçları

Tez çalışmasında önerilen MTL modellerinde ince ayar (fine-tune) öncesinde ve sonrasında elde edilen performans değerleri karşılaştırılarak sonuçlar Çizelge 4.1'de sunulmaktadır. İnce ayar uygulanmamış modellerle karşılaştırmalı olarak, son 10 katmanın yeniden eğitilmesinin, özellikle kalite derecelendirme (regresyon) görevi üzerindeki olası etkileri incelenmiştir. Karşılaştırma sonucunda (Çizelge 4.1), ince ayar model çıktıların üzerinde istatistiksel olarak anlamlı bir fark yaratmadığı ve belirgin bir iyileşme sağlamadığı görülmektedir.

Çizelge 4.1 MTL Modellerinin İnce-Ayar Öncesi ve Sonrası Karşılaştırmalı Performans Sonuçları

Model	İnce-Ayar	R2	MAE	RMSE	Doğruluk	Hassasiyet	Duyarlılık	F1-Skoru
ResNet50	☑	0,62	3,01	3,96	0,915	0,930	0,946	0,937
EfficientNetB2	☑	0,65	2,95	3,79	0,904	0,951	0,904	0,927
ConvNeXt/Base	☑	0,66	2,94	3,76	0,908	0,941	0,921	0,931
ResNet50	✕	0,63	3,08	3,93	0,902	0,942	0,912	0,926
EfficientNetB2	✕	0,61	3,08	4,00	0,904	0,952	0,903	0,927
ConvNeXt/Base	✕	**0,67**	**2,90**	**3,70**	**0,908**	**0,948**	**0,915**	**0,931**

Çizelge 4.1'de sunulan analiz sonuçlarında ince ayar uygulanmadan önce ve uygulandıktan sonraki performans değerleri karşılaştırılmaktadır. Elde edilen bulgular incelendiğinde ConvNeXt/Base mimarisinin hem ince ayarlı hem de ince ayarl uygulanmadan hastalık sınıflandırma görevinde 0,908 doğruluk ve 0,931 F1 skoru ile en başarılı modeller arasında yer almaktadır. Regresyon performansı değerlendirildiğinde

ince ayar uygulanmayan modelin MAE (2,90) ve RMSE (3,70) değerlerinin diğer modellere kıyasla daha düşük olduğu belirlenmiş olup, regresyon görevinde de ConvNeXt/Base mimarisinin üstün bir başarı elde ettiği tespit edilmiştir. EfficientNetB2 ve ResNet50 modelleri her iki görevde de kabul edilebilir performans düzeylerine ulaşmış olsa da ConvNeXt/Base modelinin gerisinde kalmışlardır. Elde edilen bu bulgular, MTL yaklaşımında kullanılan omurga (backbone) mimarisinin model başarısı üzerinde belirleyici bir etkiye sahip olduğunu, ayrıca ConvNeXt/Base modeli için ince ayar işleminin performansa belirgin bir katkı sağlamadığını göstermektedir. Kalite derece tahmin analizlerinde ince ayar öncesi ve sonrası sonuçlar Çizelge 4.2'de yer almaktadır.

Çizelge 4.2 İnce-Ayar Öncesi ve Sonrası Kalite Derece Tahmin Performansı

Model	**İnce ayar**	**R2**	**MAE**	**RMSE**
ResNet50	☑	0,63	3,15	3,94
EfficientNetB2	☑	0,60	3,26	4,09
ConvNeXt/Base	☑	**0,65**	**3,01**	**3,80**
ResNet50	✕	0,55	3,47	4,32
EfficientNetB2	✕	0,55	3,50	4,35
ConvNeXt/Base	✕	0,58	3,37	4,20

Kalite derecelendirme görevinin tek başına ele alındığında modeller arasında MTL yaklaşımıyla benzer bir performans eğilimi gözlenmiştir. Çizelge 4.2'de sunulan sonuçlar incelendiğinde, ConvNeXt/Base mimarisinin R^2=0,65, MAE=3,01 ve RMSE=3,80 değerleriyle kalite derecelendirmesinde en yüksek performansı sergilediği görülmektedir. ResNet50 ve EfficientNetB2 modellerinde belirli düzeylerde iyileşme gözlenmiş olsa da ConvNeXt/Base mimarisi diğer modellere kıyasla en başarılı sonuçları üretmiştir. Elde edilen bulgular kalite derece tahmininde ince ayar uygulama öncesi ve sonrası her iki durumda ConvNeXt/Base mimarisi diğer mimarilere göre daha avantajlı olduğunu ortaya koymaktadır. İnce ayar öncesi sonrası modellerde açıklayıcılık oranları (R^2) yaklaşık %12-18 oranında bir artış göstermektedir. Özellikle en başarılı olan ConvNeXt/Base mimarisinde R^2 değerinin 0,58'den 0,65 değerine yükselmesi modelin veri üzerinde genel varyans açıklama yeteneğini artırmaktadır. Ayrıca MAE=3,01 değeri ile en düşük hata payına sahip olması kalite derece belirlemede en kararlı sonuçları üreten mimaridir.

Hastalık tahmini üzerinde yapılan analizlerin ince ayar öncesi ve sonrası performans sonuçları Çizelge 4.3'te paylaşılmaktadır.

Çizelge 4.3 İnce-Ayar Öncesi ve Sonrası Modellerin Hastalık Tahmin Performansı

Model	**İnce-Ayar**	**Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1-Skoru**
ResNet50	☑	0,909	0,928	0,939	0,933
EfficientNetB2	☑	0,900	0,954	0,895	0,923
ConvNeXt/Base	☑	**0,915**	**0,940**	**0,933**	**0,937**
ResNet50	✕	0,888	0,937	0,896	0,914
EfficientNetB2	✕	0,901	0,950	0,901	0,925
ConvNeXt/Base	✕	0,898	0,946	0,901	0,922

Hastalık tespiti görevinde ince ayar öncesi ve sonrası performanslar dikkate alındığında ConvNeXt/Base mimarisinin diğer mimarilere göre daha başarılı olduğu gözlenmektedir. ConvNeXt/Base mimarisinin MTL ortamında sergilediği görev davranışıyla tutarlı şekilde güçlü performansa sahiptir. İnce ayar işlemi EfficientNetB2 modeli hariç diğer iki modelde (ResNet50 ve ConvNeXt) hata değerlerini azaltmakta ve doğruluk oranı artırmaktadır. Özellikle ConvNeXt/Base mimarisine ince ayar uygulandığında 0,915 doğruluk ve 0,937 F1 skoruna ulaşarak en yüksek sonucu elde eden mimari olmuştur. Özellikle F-1 skoru modelin sınıflandırma dengesinde başarılı olduğu göstermektedir. İnce ayar modeli, veri setinde daha yüksek uyum daha düşük hata durumuna ulaşılmasını sağlayarak güvenilir teşhis yeteneğine ulaştırmaktadır.

4.2 Regresyon Analiz Sonuçları

Regresyon analizleri kapsamında ResNet50, ConvNeXt/Base ve EfficientNetB2 modellerinin performans ölçütleri karşılaştırıldığında, ConvNeXt/Base mimarisinin diğer iki modele kıyasla daha yüksek doğruluk ve daha düşük hata değerleri sunduğu görülmektedir (Çizelge 4.4). Özellikle ConvNeXt/Base mimarisi üzerinde uygulanan SVR yöntemi, R^2= 0,72, MAE= 2,75 ve RMSE= 3,47 değerleriyle en yüksek regresyon başarısını elde ederek diğer regresyon yaklaşımlarını geride bırakmıştır. Bunun yanı sıra

Lasso ve XGBoost regresyon yöntemlerinde elde edilen hata metrikleri ve R^2 değerleri de ConvNeXt /Base mimarisinin kararlı ve güçlü bir yapı sunduğunu ortaya koymaktadır.

Çizelge 4.4 Modeller Arasında Regresyon Metriklerinin Karşılaştırılması (R^2, MAE, RMSE)

Model	**Regresyon**	**R2**	**MAE**	**RMSE**
	Ridge Regression	0,63	3,16	3,98
	Lasso Regression	0,66	3,06	3,82
	Support Vector Regression (SVR)	0,68	2,93	3,67
	Random Forest Regressor	0,65	3,10	3,87
ResNet50	XGBoost Regressor	0,67	2,96	3,77
	Ridge Regression	0,64	3,11	3,91
	Lasso Regression	0,71	2,80	3,50
	Support Vector Regression (SVR)	**0,72**	**2,75**	**3,47**
	Random Forest Regressor	0,69	2,89	3,63
ConvNeXt/Base	XGBoost Regressor	0,70	2,83	3,60
	Ridge Regression	0,64	3,13	3,92
	Lasso Regression	0,63	3,14	3,97
	Support Vector Regression (SVR)	0,66	3,00	3,79
	Random Forest Regressor	0,65	3,06	3,88
EfficientNetB2	XGBoost Regressor	0,64	3,08	3,93

Yapılan karşılaştırmalı analizler sonucunda, ConvNeXt/Base mimarisinden elde edilen özniteliklerin kullanıldığı regresyon modellerinin, diğer derin öğrenme mimarilerine kıyasla daha başarılı sonuçlar ürettiği belirlenmiştir. Çizelge 4.4'te yer alan tüm regresyon sonuçlarında en tutarlı ve en yüksek sonuçlar ConvNeXt/Base mimari ile elde edilmektedir. R^2 değeri 0,64 ile 0,72 aralığında değişmektedir. SVR regresyon sonucunun en iyi performans olması karmaşık öznitelik uzayında doğrusal olmayan ilişkileri modelleme yeteneğinin yüksek olduğunu göstermektedir. Ayrıca R^2 değerindeki artışa paralel olarak MAE ve RMSE değerlerinin azalması, kullanılan performans metriklerinin

birbiriyle tutarlı olduğunu ve oluşturulan regresyon modelinin güvenilir sonuçlar ürettiğini desteklemektedir. Buna karşılık ResNet50 ve EfficientNetB2 mimarileri ile elde edilen regresyon sonuçları da başarılı olmakla birlikte, ConvNeXt/Base mimarisinin özellikle SVR algoritması ile birlikte daha yüksek tahmin doğruluğu sağladığı görülmektedir. En iyi performans gösteren modele ait sınıflandırma sonuçları Confusion Matrix analizleriyle desteklenmiş olup, ilgili değerlere Çizelge 4.5'te yer verilmektedir.

Çizelge 4.5 En İyi Performans Gösteren Modele (ConvNeXt) Ait Confusion Matrix Sonuçları

	Gerçek 0	**Gerçek 1**	**Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1-Skoru**
Tahmin 0	71	13	0,930	0,935	0,969	0,952
Tahmin 1	5	187				

Çizelge 4.5'ten elde edilen sonuçlara göre model, 263 test görüntüsünün 258'ini doğru sınıflandırırken sadece 18'ini yanlış sınıflandırmıştır. Gerçek sınıfı 0 olan 84 görüntünün 71'i doğru sınıflandırılırken, 13 görüntü yanlışlıkla hastalıklı olarak tahmin edilmiştir. Gerçek sınıfı 1 olan 192 görüntünün ise 187'si doğru, yalnızca 5'i yanlış sınıflandırılmıştır. Modelin 0,930 doğruluk, 0,935 hassasiyet, 0,969 duyarlılık ve 0,952 F1-skoru elde etmesi, özellikle hastalıklı patates yumrularını tespit etmede noktasında oldukça başarılı olduğunu göstermektedir. Duyarlılık değerinin yüksek olması, hastalıklı örneklerin büyük çoğunluğunun doğru şekilde belirlenebildiğini ortaya koyarken, F1-skorunun yüksek olması ise hassasiyet ve duyarlılık arasında dengeli bir performans sergilendiğini göstermektedir. Bu sonuçlar, önerilen modelin gerçek uygulamalarda hastalık tespitinde güvenilir ve etkin bir şekilde kullanılabileceğini desteklemektedir.

4.3 Model Ağırlık Karşılaştırma Sonuçları

Çalışmada kapsamında yapılan MTL deneylerinde en yüksek performans ConvNeXt/Base modeli ile elde edilmiştir. Bu mimaride optimum sonuçlara ulaşabilmek amacıyla, herhangi bir ince ayar (fine-tuning) işlemi yapılmadan sadece kalite derecesi tahmini görevine farklı ağırlık değerleri atanarak kapsamlı analizler yapılmıştır. Bu süreçte, modelin genel başarısını maksimize eden en uygun ağırlık düzeyinin

belirlenmesine odaklanılmış. Analizlere ilişkin elde edilen sonuçlar Çizelge 4.6'da sunulmaktadır.

Çizelge 4.6 ConvNeXt/Base (Fine – Tune Uygulanmamış) Kayıp Ağırlığı Karşılaştırması

Model	Kalite ağırlık	Hastalık ağırlık	R2	MAE	RMSE	Doğruluk	Hassasiyet	Duyarlılık	F1-Skor
ConvNeXt/Base	4,5	1	0,67	2,91	3,71	0,908	0,948	0,915	0,931
ConvNeXt/Base	4	1	0,67	2,92	3,72	0,910	0,945	0,919	0,932
ConvNeXt/Base	**3,5**	**1**	**0,67**	**2,90**	**3,70**	**0,908**	**0,948**	**0,915**	**0,931**
ConvNeXt/Base	3	1	0,66	2,96	3,78	0,909	0,946	0,918	0,931
ConvNeXt/Base	2,5	1	0,66	2,96	3,79	0,904	0,952	0,904	0,927
ConvNeXt/Base	2	1	0,64	3,05	3,89	0,906	0,946	0,913	0,929
ConvNeXt/Base	1,5	1	0,65	3,01	3,84	0,909	0,945	0,918	0,931
ConvNeXt/Base	1	1	0,64	3,06	3,88	0,911	0,948	0,919	0,933

İnce ayar uygulamasının performans değerlerinde istatistiksel olarak anlamlı bir değişim oluşmaması nedeniyle, görev ağırlığı optimizasyon deneyleri hesaplama maliyetini düşürmek ve modelin saf öznitelik çıkarma kapasitesini analiz edebilmek adına ince ayar uygulanmaksızın gerçekleştirilmiştir. Elde edilen deneysel sonuçlar; ConvNeXt/Base mimarisinin sunduğu yüksek seviyeli evrişimsel özelliklerin, kalite derecelendirme ve hastalık tahmini görevleri arasında etkili bir "temsili paylaşım (representation sharing)" sağladığını ortaya koymaktadır. Yapılan sistematik denemeler sonucunda, özellikle kalite ağırlığı=3,5 ve hastalık ağırlığı=1 parametrelerinde optimize edilen konfigürasyonun, sistem genelinde en dengeli ve güçlü performans sunduğu tespit edilmiştir. Bu yapı; regresyon görevinde R^2= 0,67, MAE= 2,90 ve RMSE= 3,70 değerleri ile yüksek hassasiyetli bir tahmin başarısı sergilerken, sınıflandırma görevinde F1 = 0,931 değeri ile ayırt edici gücünü en üst seviyede korumuştur. Sonuç olarak, MTL modellerinde görev ağırlıklarının bilinçli bir stratejiyle belirlenmesi ve özellikle daha yüksek karmaşıklığa sahip olan kalite derecelendirme görevine öncelik verilmesi, modelin öğrenme kapasitesini ve genel sistem başarısını anlamlı düzeyde artırmaktadır. Yapılan analizler sonucunda geliştirilen MTL modelinin veri seti üzerinde sergilediği en yüksek performans değerlerine ilişkin karşılaştırma sonuçları Çizelge 4.7'de sunulmuştur.

Çizelge 4.7 En İyi Performans Gösteren MTL Modeli İçin Gerçek ve Tahmin Edilen Değerlerin Karşılaştırılması

Görsel	Gerçek Kalite Derecesi	Tahmini Kalite Derecesi	Hata	Hastalık	Hastalık Olasılığı
	18,0	17,896	0,103	☑	0,994
	15,0	15,120	0,120	☑	0,906
	25,0	25,171	0,171	☑	0,997

Çizelge 4.7'de verilen sonuçlar incelendiğinde, MTL modelinin hem hastalık tespiti hem de kalite derecesi tahmini görevlerinde düşük hata değerleri ürettiği görülmektedir. Bu durum, modelin regresyon görevindeki başarısının yüksek olduğunu göstermektedir. Ayrıca, modelin görsel doku özellikleri ile hastalık göstergeleri arasındaki ilişkileri etkin bir biçimde öğrendiği ve bu sayede aşırı öğrenme (overfitting) durumunda kaçınarak güçlü genelleme yeteneği kazandığı değerlendirmesine ulaşılmaktadır. Regresyon ve sınıflandırma görevlerinin eş zamanlı olarak ve birbirini olumsuz etkilemeden başarılı bir şekilde gerçekleştirilmesi, önerilen MTL modelinin uygulamada etkin ve güvenilir bir performans sunduğunu ortaya koymaktadır. Yapılan analizler sonucunda geliştirilen MTL modelinin veri seti üzerinde sergilediği en düşük performans değerlerini barındıran karşılaştırma sonuçları Çizelge 4.8'de verilmiştir.

Çizelge 4.8 En Düşük Performans Gösteren MTL Tahminleri İçin Gerçek ve Tahmin Değerlerinin Karşılaştırması

Görsel	Gerçek Kalite Derecesi	Tahmini Kalite Derecesi	Hata	Hastalık	Hastalık Olasılığı
	12,0	22,287	10,287	✕	0,982
	22,0	11,961	10,038	☑	0,127
	33,0	21,257	11,742	☑	0,998

Çizelge 4.8'de modelin yüksek hata payı sergilediği görseller ve bu görsellere ait bilgiler (gerçek değer, tahmini değer, hata ve hata olasılığı) yer almaktadır. İlk örnekte modelin hastalık olmadığını doğru biçimde tespit etmesine rağmen kalite derecesini gerçek değerin yaklaşık 10 puan üzerinde tahmin ettiği görülmektedir. Bu durum önerilen modelin kalite derecelendirme görevinde hastalıkla ilişkili yüzey bozukluklarını aşırı temsil eden örneklerde kaliteyi olduğundan yüksek değerlendirme eğiliminde olduğuna işaret etmektedir. Ayrıca MTL yapısındaki paylaşımlı özellik temsillerinde görev etkileşimi oluşabileceğini ve hastalık sinyallerinin regresyon çıktısı üzerinde baskın bir etkide bulunarak kalite skorlarının sistematik biçimde daha düşük tahmin edilmesine yol açabileceğini göstermektedir. İkinci ve üçüncü örnekte ise model, hastalık varlığını yüksek olasılıkla (%99 ve %12 olasılık seviyelerinde değişkenlik gösterse de) tespit etmiştir. Ancak bu örneklerdeki kalite tahminlerinin gerçek değerlerin çok alt seviyelerinde olması, hastalık sinyallerinin regresyon çıktısı üzerinde baskın şekilde olumsuz etkilemekte ve kalite skorlarının daha düşük tahmin edilmesine sebep olmaktadır. Bu bulgular, özellikle temsil yoğunluğu düşük olan ekstrem kalite

değerlerinde modelin kararlılığının azaldığını ortaya koymaktadır. Dolayısıyla, gelecekte alt sınıflara ait veri çeşitliliğinin artırılması ve paylaşımlı özellik temsillerindeki görev etkileşimlerinin dengelenmesi büyük önem arz etmektedir.

En düşük performans sergileyen örneklerde gözlenen yüksek hata değerlerinin, ışık farklılıkları, yüzey dokusu değişkenlikleri, görüntüleme koşulları veya etiketleme kaynaklı tutarsızlıklardan kaynaklanmış olabileceği değerlendirilmektedir. Modelin bazı karmaşık veya sıra dışı örneklerde görsel detaylara aşırı duyarlılık göstermesi, dikkat mekanizmasının belirli yüzey bölgelerine orantısız şekilde odaklanmasına yol açmış olabilir. Bu durum, gelecekte veri çeşitliliğinin artırılması, robust(dayanıklı) görüntü ön işleme prosedürlerinin uygulanması ve model genelleme kapasitesinin geliştirilmesini hedefleyen iyileştirmelerin önemini vurgulamaktadır.

5. TARTIŞMA ve SONUÇ

Tez çalışmasında, patates yumrularının kalite derecelendirmesi ve hastalık tespitini aynı mimari içerisinde eş zamanlı olarak gerçekleştirebilen çok görevli (Multi-Task Learning) derin öğrenme modeli geliştirilmiştir. Veri setinin uzmanlar tarafından çok boyutlu bir puanlama sistemiyle hazırlanması, modelin yalnızca tek bir kusura değil, bütüncül kaliteyi temsil eden çoklu özniteliklere dayanarak tahmin yapabilmesini sağlamıştır. Böylece hem akademik araştırmalar hem de endüstriyel otomasyon sistemleri için daha gerçekçi ve uygulanabilir bir değerlendirme altyapısı oluşturulmuştur. Kalite derecelerinin belirlenmesi amacıyla, çalışma kapsamında tarafımızca oluşturulan ve 1692 görüntüden oluşan veri seti; toprak bilimi ve bitki besleme ile bahçe bitkileri alanlarında doktora eğitimlerini tamamlamış ziraat mühendisleri tarafından çok boyutlu olarak etiketlenmiştir. Uzman görüşüne dayalı bu etiketleme süreci, tarımsal kalite değerlendirmelerinde öznel yargıların azaltılmasına ve daha nesnel, güvenilir yapay zekâ modellerinin geliştirilmesine katkı sağlamaktadır (Koç ve Balım, 2026).

Deneysel çalışmalar sonucunda, özellikle ConvNeXt/Base tabanlı mimarinin hem sınıflandırma hem de regresyon görevlerinde diğer mimarilere kıyasla daha kararlı ve yüksek performans sergilediği belirlenmiştir. ConvNeXt/Base mimarisinin daha güçlü öznitelik çıkarım kabiliyeti ve geniş özellik uzayını temsil edebilme yeteneği sayesinde EfficientNetB2 ve ResNet50 mimarilerine göre daha başarılı sonuçlar elde edilmiştir. Yapılan analizler sonucunda en iyi performans, görev ağırlıkları 3,5:1 olarak ayarlandığında elde edilmiş ve model $R^2 = 0,67$, MAE = 2,90, RMSE = 3,70 değerlerine ulaşmıştır. Aynı model, hastalık sınıflandırma görevinde ise 0,930 doğruluk, 0,935 hassasiyet, 0,969 duyarlılık ve 0,952 F1-skoru ile başarılı bir performans sergilemiştir. Elde edilen bulgular, önerilen MTL yaklaşımının hem kalite derecelendirmesi hem de hastalık tespitini tek bir model üzerinden yüksek doğrulukla gerçekleştirebildiğini göstermektedir. Ayrıca farklı görev ağırlıklarıyla gerçekleştirilen analizler, kalite tahmini görevine verilen ağırlığın modelin öğrenme süreci ve genel performansı üzerinde belirgin bir etkiye sahip olduğunu ortaya koymuştur.

Bununla birlikte, modelin tüm örneklerde doğru tahmin gerçekleştiremediği durumlar da gözlemlenmiştir. Yanlış sınıflandırmaların ve kalite puanı tahmin hatalarının temel

nedenleri incelendiğinde; hastalık belirtilerinin erken evrede olması nedeniyle görsel semptomların belirgin olmaması, farklı hastalıkların benzer renk ve doku özellikleri göstermesi, aynı yumru üzerinde birden fazla kusurun birlikte bulunması ve bazı kalite öznitelikleri arasındaki görsel geçişlerin keskin sınırlar içermemesi gibi etkenlerin model performansını olumsuz etkilediği değerlendirilmiştir. Ayrıca veri setinin belirli hastalık türleri ve kalite seviyeleri açısından sınırlı sayıda örnek içermesi ile kontrollü görüntüleme koşullarında oluşturulmuş olması, modelin bazı örneklerde genelleme başarısını sınırlandırabilmektedir. Bu bulgular, veri çeşitliliğinin artırılması, sınıf dengesinin iyileştirilmesi ve açıklanabilir yapay zekâ yöntemleriyle model kararlarının analiz edilmesinin gelecekte model performansının geliştirilmesine katkı sağlayabileceğini göstermektedir.

Gelecek çalışmalar kapsamında, veri setinin farklı aydınlatma koşulları, çekim ortamları ve patates çeşitlerini kapsayacak şekilde genişletilmesi planlanmaktadır. Bu sayede geliştirilen modelin gerçek dünya koşullarını daha iyi temsil etmesi ve farklı üretim ortamlarında genelleme başarısının artırılması hedeflenmektedir. Ayrıca mevcut ikili (binary) hastalık tespiti yapısının geliştirilerek her hastalık türünün ayrı bir sınıf olarak ele alındığı çok sınıflı (multi-class) bir model oluşturulması planlanmaktadır. Bunun yanında, aynı patates yumrusunda birden fazla hastalığın eş zamanlı olarak görülebildiği durumların tespit edilebilmesi amacıyla çok etiketli (multi-label) hastalık sınıflandırma yaklaşımının uygulanması, geliştirilen sistemin tarımsal kalite kontrol ve endüstriyel otomasyon uygulamalarında daha etkin kullanılmasına katkı sağlayacaktır.

Bu alanda çalışma yapmayı planlayan araştırmacılara yönelik öneriler aşağıda sunulmaktadır.

- Hazır veri setleri yerine çalışma amacına uygun özgün veri setlerinin oluşturulması önerilmektedir. Görüntü sayısının fazla olması etiketleme sürecini uzatsa da modelin öğrenme kapasitesini artırarak daha başarılı ve güvenilir sonuçlar elde edilmesini sağlamaktadır.
- Yeterli büyüklükte oluşturulan veri setleri, eğitim, doğrulama (validation) ve test kümelerinin daha dengeli şekilde oluşturulmasına olanak sağlayarak model performansının daha güvenilir biçimde değerlendirilmesine katkıda bulunmaktadır.

- Veri artırma (data augmentation) stratejilerinin yalnızca görüntü sayısını artırmaya yönelik değil, farklı aydınlatma, yönelim, renk ve doku değişimlerini de kapsayacak şekilde çeşitlendirilmesi önerilmektedir. Bu yaklaşım modelin aşırı öğrenmesini (overfitting) azaltarak farklı çalışma koşullarındaki genelleme yeteneğini artıracaktır.
- Model geliştirme sürecinde kullanılan algoritmaların ve yazılım kodlarının farklı araştırmacılar veya alan uzmanları tarafından incelenmesi, olası yazılım hatalarının erken aşamada tespit edilmesine ve modele yeni özelliklerin kazandırılmasına katkı sağlayacaktır.
- Veri etiketleme sürecine katkı sağlayan uzmanlarla proje boyunca sürekli iletişim hâlinde olunması, etiketleme sürecinde ortaya çıkabilecek belirsizliklerin hızlı bir şekilde giderilmesine ve veri kalitesinin korunmasına yardımcı olacaktır.
- Gelecek çalışmalarda farklı derin öğrenme mimarilerinin (Vision Transformer, Swin Transformer vb.) ve açıklanabilir yapay zekâ (Explainable AI) yöntemlerinin değerlendirilmesi, modelin karar mekanizmasının daha ayrıntılı analiz edilmesine katkı sağlayabilir.

6. KAYNAKLAR

Abasi S, Minaei S, Jamshidi B, Fathi D, 2018, Dedicated non-destructive devices for food quality measurement: A review, Trends in Food Science & Technology, 78, 197–205.

Aguilar-Ariza A, Sotta N, Fujiwara T, Guo W, Kamiya T, 2024, A Multi-Target Regression Method to Predict Element Concentrations in Tomato Leaves Using Hyperspectral Imaging, Plant Phenomics, 6, Article ID: 0146.

Ahmed T, Sabab N H N, 2022, Classification and understanding of cloud structures via satellite images with EfficientUNet, SN Computer Science, 3(1), 99.

Alhawas N, Tüfekci Z, 2022, The effectiveness of transfer learning and fine-tuning approach for automated mango variety classification, Avrupa Bilim ve Teknoloji Dergisi, 34, 344–353.

Altıntaş B, 2024, Patates Yetiştiriciliği ve Bunun Dünya Tarımındaki Yeri ve Önemi, Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 81s, Bursa.

Baykal O, 2003, Mühendislik Ölçmeleri I - Kara ve Demir Yollarında Geçki Geometrisi Tasarımı ve Aplikasyonu - Cilt 1: Metinler, Birsen Yayınevi, 393s, İstanbul.

Brar E A S, Singh K, 2016, Potato defect detection using fuzzy c-mean clustering based segmentation, Indian Journal of Science and Technology, 9(32), 1–6.

Camire M E, 2016, Chapter 23 - Potatoes and Human Health, In Singh J, Kaur L (Ed.), Advances in Potato Chemistry and Technology (Second Edition), (685–704), Academic Press.

Cin H, 2022, Farklı Depolama Koşullarında Depolanan Taze Patates Örneklerinin Kalite Parametrelerinin İncelenmesi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 106s, Denizli.

Comito C, Pizzuti C, 2022, Artificial intelligence for forecasting and diagnosing COVID-19 pandemic: A focused review, Artificial Intelligence in Medicine, 128, Article ID: 102286.

Crawshaw M, 2020, Multi-task learning with deep neural networks: A survey, arXiv preprint, arXiv:2009.09796.

D'hoop B B, Paulo M J, Mank R A, Van Eck H J, Van Eeuwijk F A, 2008, Association mapping of quality traits in potato (Solanum tuberosum L.), Euphytica, 161(1), 47–60.

Dacal-Nieto A, Formella A, Carrión P, Vazquez-Fernandez E, Fernández-Delgado M, 2011, Common scab detection on potatoes using an infrared hyperspectral imaging system, International Conference on Image Analysis and Processing, September, Berlin, Heidelberg, 303–312.

Danielak M, Przybył K, Koszela K, 2023, The Need for Machines for the Nondestructive Quality Assessment of Potatoes with the Use of Artificial Intelligence Methods and Imaging Techniques, Sensors, 23(4), 1787.

ElMasry G, Cubero S, Moltó E, Blasco J, 2012, In-line sorting of irregular potatoes by using automated computer-based machine vision system, Journal of Food Engineering, 112(1), 60–68.

Farokhzad S, Modaress Motlagh A, Ahmadi Moghaddam P, Jalali Honarmand S, Kheiralipour K, 2024, A machine learning system to identify progress level of dry rot disease in potato tuber based on digital thermal image processing, Scientific Reports, 14(1), 1995.

Fırıldak K, Talu M F, 2019, Evrişimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi, Computer Science, 4(2), 88–95.

Girshick R, Donahue J, Darrell T, Malik J, 2014, Rich feature hierarchies for accurate object detection and semantic segmentation, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 580–587.

Gültepe Y, 2019, Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme, Avrupa Bilim ve Teknoloji Dergisi, 16, 8–15.

Hassankhani R, Navid H, 2012, Potato Sorting Based on Size and Color in Machine Vision System, Journal of Agricultural Science, 4(5), 235–244.

He K, Zhang X, Ren S, Sun J, 2016, Deep residual learning for image recognition,

Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770–778.

He X, Li L, Liu X, Xiao Y, Jiao T, Li W, 2023, Design and Test of Potato Conveying and Grading Device with Variable Space, INMATEH - Agricultural Engineering, 69(1), 681–692.

Islam M H, Rahman A, Rana M S, 2021, Potato Grading Based on Size Features by Machine Vision Technique, Journal of the Bangladesh Agricultural University, 19(4), 528–532.

İnik Ö, Ülker E, 2017, Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85–104.

Jarén C, López A, Arazuri S, 2016, Chapter 19 - Advanced Analytical Techniques for Quality Evaluation of Potato and Its Products, In Singh J, Kaur L (Ed.), Advances in Potato Chemistry and Technology (Second Edition), (563–602), Academic Press.

Ji J, Luo C, Chen X, Yu L, Li P, 2018, Cross-domain sentiment classification via a bifurcated-LSTM, Pacific-Asia Conference on Knowledge Discovery and Data Mining, June, Cham, 681–693.

Jorquera-Chavez M, Fuentes S, Dunshea F R, Warner R D, Poblete T, Unnithan R R, vd., 2021, Using imagery and computer vision as remote monitoring methods for early detection of respiratory disease in pigs, Computers and Electronics in Agriculture, 187, Article ID: 106283.

Kadam S U, Dhede V M, Khan V N, Raj A, Takale D G, 2022, Machine learning methode for automatic potato disease detection, NeuroQuantology, 20(16), 2102–2106.

Kamilaris A, Prenafeta-Boldú F X, 2018, Deep learning in agriculture: A survey, Computers and Electronics in Agriculture, 147, 70–90.

Kaur A, Randhawa G S, Abbas F, Ali M, Esau T J, Farooque A A, vd., 2024, Artificial Intelligence Driven Smart Farming for Accurate Detection of Potato Diseases: A Systematic Review, IEEE Access, 12, 193902–193922.

Kim K G, 2016, Book review: Deep learning, Healthcare Informatics Research, 22(4),

351–354.

Koç P, Balım C, 2026, Potato Quality Grading and Disease Testing with Artificial Intelligence–Assisted Image Processing Methods, Food Analytical Methods, 19(10), 279.

Krichen M, 2023, Convolutional Neural Networks: A Survey, Computers, 12(8), 151.

Kumar S, Shukla A, 2022, Automatic Grading of Potato Leaf using Machine learning & Computer Vision, Research Square Preprint.

Li X, Wang F, Guo Y, Liu Y, Lv H, Zeng F, vd., 2025, Improved YOLO v5s-based detection method for external defects in potato, Frontiers in Plant Science, 16, Article ID: 1527508.

Li Z, Liu F, Yang W, Peng S, Zhou J, 2022, A Survey of Convolutional Neural Networks: Analysis, Applications and Prospects, IEEE Transactions on Neural Networks and Learning Systems, 33(12), 6999–7019.

Liu Z, Mao H, Wu C Y, Feichtenhofer C, Darrell T, Xie S, 2022, A ConvNet for the 2020s, arXiv preprint, arXiv:2201.03545.

Maurício J, Domingues I, Bernardino J, 2023, Comparing Vision Transformers and Convolutional Neural Networks for Image Classification: A Literature Review, Applied Sciences, 13(9), 5521.

Myshkovskyi Y, Nazarkevych M, 2025, Exponential Data Augmentation Methods for Improving Yolo Performance in Computer Vision Tasks, Journal of Lviv Polytechnic National University "Information Systems and Networks", 17, 189.

Pandey N, Kumar S, Pandey R, 2019, Grading and Defect Detection in Potatoes Using Deep Learning, First International Conference CNC 2018, March 22–24, 2018, Gwalior, India, 329–339.

Pedreschi F, Mery D, Marique T, 2016, Chapter 15 - Grading of Potatoes, In Sun D W (Ed.), Computer Vision Technology for Food Quality Evaluation (Second Edition), (369–382), Academic Press.

Pinhero R G, Yada R Y, 2016, Chapter 10 - Postharvest Storage of Potatoes, In Singh J, Kaur L (Ed.), Advances in Potato Chemistry and Technology (Second Edition),

(283–314), Academic Press.

Ramos L T, Sappa A D, 2025, A Decade of You Only Look Once (YOLO) for Object Detection: A Review, arXiv preprint, arXiv:2504.18586.

Razmjooy N, Mousavi B S, Soleymani F, 2012, A real-time mathematical computer method for potato inspection using machine vision, Computers & Mathematics with Applications, 63(1), 268–279.

Redmon J, Divvala S, Girshick R, Farhadi A, 2016, You Only Look Once: Unified, Real-Time Object Detection, arXiv preprint, arXiv:1506.02640.

Rehman H U, 2024, Binary Image Classification using ResNet50, Medium Web Sitesi, Erişim Tarihi: 15.05.2024.

Ruder S, 2017, An overview of multi-task learning in deep neural networks, arXiv preprint, arXiv:1706.05098.

Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, vd., 2015, ImageNet Large Scale Visual Recognition Challenge, International Journal of Computer Vision, 115(3), 211–252.

Sert E, 2021, A deep learning based approach for the detection of diseases in pepper and potato leaves, Anadolu Tarım Bilimleri Dergisi, 36(2), 167–178.

Sharma U, Gupta N, Verma M, 2023, Prediction of compressive strength of GGBFS and Flyash-based geopolymer composite by linear regression, lasso regression, and ridge regression, Asian Journal of Civil Engineering, 24(8), 3399–3411.

Su Q, Kondo N, Al Riza D F, Habaragamuwa H, 2020, Potato Quality Grading Based on Depth Imaging and Convolutional Neural Network, Journal of Food Quality, 2020, Article ID: 8815896.

Su Q, Kondo N, Li M, Sun H, Al Riza D, Habaragamuwa H, 2018, Potato quality grading based on machine vision and 3D shape analysis, Computers and Electronics in Agriculture, 152, 261–268.

Şeker A, Diri B, Balık H H, 2017, Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme, Gazi Mühendislik Bilimleri Dergisi, 3(3), 47–64.

Tambe U Y, Shobanadevi A, Shanthini A, Hsu H C, 2023, Potato Leaf Disease

Classification using Deep Learning: A Convolutional Neural Network Approach, arXiv preprint, arXiv:2311.02338.

Tan M, Le Q, 2019, EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, Proceedings of the 36th International Conference on Machine Learning, 6105–6114.

Too E C, Yujian L, Njuki S, Yingchun L, 2019, A comparative study of fine-tuning deep learning models for plant disease identification, Computers and Electronics in Agriculture, 161, 272–279.

Visse-Mansiaux M, Soyeurt H, Herrera J M, Torche J M, Vanderschuren H, Dupuis B, 2022, Prediction of potato sprouting during storage, Field Crops Research, 278, Article ID: 108396.

Wang C, Xiao Z, 2021, Potato Surface Defect Detection Based on Deep Transfer Learning, Agriculture, 11(9), 863.

Wang F, Wang Y, Zhang K, Hu M, Weng Q, Zhang H, 2021, Spatial heterogeneity modeling of water quality based on random forest regression and model interpretation, Environmental Research, 202, Article ID: 111660.

Wang H, Xiong J, Li Z, Deng J, Zou X, 2016, Potato grading method of weight and shape based on imaging characteristics parameters in machine vision system, Transactions of the Chinese Society of Agricultural Engineering, 32(8), 272–277.

Wang J, 2018, A Survey on Convolutional Neural Network Accelerators, Computer Science Department, University of California, Unpublished report, Los Angeles, 12p.

Woo S, Debnath S, Hu R, Chen X, Liu Z, Kweon I S, vd., 2023, ConvNeXt V2: Co-designing and Scaling ConvNets with Masked Autoencoders, arXiv preprint, arXiv:2301.00808.

Yang Y, Liu Z, Huang M, Zhu Q, Zhao X, 2023, Automatic detection of multi-type defects on potatoes using multispectral imaging combined with a deep learning model, Journal of Food Engineering, 336, Article ID: 111213.

Yusianto R, Suprijono H, Islahudin N, Nugroho D S, 2022, Smart potato grading using

image processing and fuzzy grading system, 2022 International Seminar on Application for Technology of Information and Communication (iSemantic), September, IEEE, 333–337.

Zarzyńska K, Boguszewska-Mańkowska D, 2024, Commercial Quality of Potato Tubers of Different Varieties from Organic and Conventional Production System, Agronomy, 14(4), 778.

Zhang K, Wang S, Hu Y, Yang H, Guo T, Yi X, 2023, Evaluation method of potato storage external defects based on improved U-Net, Agronomy, 13(10), 2503.

Zhang Y, Yang Q, 2018, An overview of multi-task learning, National Science Review, 5(1), 30–43.

Zhang Y, Yang Q, 2022, A Survey on Multi-Task Learning, IEEE Transactions on Knowledge and Data Engineering, 34(12), 5586–5609.

Zhao H, Deng W, Xie S, Zhao Z, 2024, Performance Optimization and Experimental Study of Small-Scale Potato-Grading Device, Agriculture, 14(6), 822.

Zhou Z, Li X, Tao H, Gao H, 2012, Detection of potato external defects based on hyperspectral imaging technology, Transactions of the Chinese Society of Agricultural Engineering, 28, 221–228.

Zoralioğlu Y, Polat Ö, 2024, Detection of Potato Plant Disease from Leaf Images Using Deep Learning Models, 2024 Innovations in Intelligent Systems and Applications Conference (ASYU), 1–5.

ÖZGEÇMİŞ

Adı Soyadı : Pınar KOÇ

Doğum Yeri ve Tarihi : Sandıklı 01.01.1995

Yabancı Dili : İngilizce

İletişim (Telefon / e-posta) : 0 (507) 587 09 58 / pkoc@aku.edu.tr

Eğitim Durumu (Kurum ve Yıl)

Lise	:Sandıklı Zübeyde Hanım Kız Mesleki ve Teknik Anadolu Lisesi, Web Programcılığı, (2008 – 2012)
Lisans	:Süleyman Demirel Üniversitesi, Bilgisayar ve Öğretim Teknolojileri Eğitimi (BÖTE) Böl., (2013–2016)
Yüksek Lisans	:Süleyman Demirel Üniversitesi, Eğitim Bilimleri Ens., Bilgisayar ve Öğretim Teknolojileri Bölümü, ABD, (2016 – 2018)
2.Yüksek Lisans	:Afyon Kocatepe Üniversitesi, Fen Bilimleri Ens., Bilgisayar Anabilim Dalı, ABD, (2024 – 2026)

Çalıştığı Kurum/Kurumlar ve Yıl

: Süleyman Demirel Üniversitesi (2016 –2017)

: Ankara Bilim Üniversitesi (2023 –2024)

: Afyon Kocatepe Üniversite (2024 – Devam Ediyor)

Yayınları (SCI ve diğer) :

Alakus F, Koc P, Duzenli O, Unlu K, 2019, Production of Myoelectrically Controlled 3D Bionic Hand, The International Conference on Artificial Intelligence and Applied Mathematics in Engineering, April, Springer, Cham, 736–743.

Koç P, Yalçın C, 2020, Future of Deep Learning for Cancer Diagnosis, Springer, Cham.

Koç P, 2017, Internet addiction and subjective well-being in university students, Journal of Positive School Psychology, 1(1), 34–41.

Koç P, Albayrak M, 2020, Akademisyen dijitalleşme ölçeği geliştirilmesi, International Journal of Social Sciences and Education Research, 6(1), 41–53.

Koç P, Albayrak M, 2017, Farklı Gelişim Düzeylerindeki Bireyler Üzerinde İnternet Bağımlılığının Etkileri, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 22(Kayfor 15 Özel Sayısı), 2391–2404.

Balım C, Koç P, 2024, Anthracnose Detection from Chili Leaf Images with Deep Learning, 2024 Innovations in Intelligent Systems and Applications Conference (ASYU), October, IEEE, 1–5.

Koç P, Balım C, 2026, Potato Quality Grading and Disease Testing with Artificial Intelligence–Assisted Image Processing Methods, Food Analytical Methods, 19(10), 279.

Yayınları (Kitap Bölümleri) :

Koç P, 2022, Transhümanizm ve Yapay Zeka, Köse U (Ed.), Yapay Zeka Etiği (283-296), Nobel Akademik Yayıncılık, Ankara.

Koç P, 2022, Yapay Zekanın Mesleklere Etkisi, Köse U (Ed.), Yapay Zeka Etiği (267-281), Nobel Akademik Yayıncılık, Ankara.

Koç P, 2023, İklim Krizi ve Orman Yangınları, Köse U (Ed.), İklim Krizi: Kavramsal Çerçeve ve Teknolojik Gelişmeler (29-39), Doğu Kitabevi, İstanbul.

Koç P, Köse U, 2023, İklim Krizine Karşı Yapay Zeka, Köse U (Ed.), İklim Krizi: Kavramsal Çerçeve ve Teknolojik Gelişmeler (217-241), Doğu Kitabevi, İstanbul.

Koç P, 2023, Yenilenebilir Enerji Çözümleri, Köse U (Ed.), İklim Krizi: Kavramsal Çerçeve ve Teknolojik Gelişmeler (321-340), Doğu Kitabevi, İstanbul.

Köse U, Koç P, 2023, İklim Krizi Odağında Körfez ve Jet Akımları / Kutup Akıntıları, Köse U (Ed.), İklim Krizi: Kavramsal Çerçeve ve Teknolojik Gelişmeler (73-82), Doğu Kitabevi, İstanbul.

Koç P, 2024, Sağlık Turizmi ile Yapay Zeka İlişkisi / Kullanılan Yapay Zeka Uygulamaları, Köse G, Çolakoğlu O E (Ed.), Sağlık Turizmi: Güncel Konular ve Gelecek (152-165), Detay Yayıncılık, Ankara.

Koç P, 2025, Sağlık Turizmi Özelinde İleri Teknolojilerin Yaşama Etkisi ve Gelecek Öngörüleri, Köse G, Köse U (Ed.), Sağlık Turizminde İleri Teknolojiler (196-208), Detay Yayıncılık, Ankara.