



**TARIMSAL UYGULAMALAR İÇİN DERİN ÖĞRENME TEMELLİ
UÇ SİSTEM MODELLERİNİN GELİŞTİRİLMESİ VE OPTİMİZASYONU**

Doruk SÖNMEZ

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

EKİM 2024

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Doruk SÖNMEZ

17/10/2024

TARIMSAL UYGULAMALAR İÇİN DERİN ÖĞRENME TEMELLİ UÇ SİSTEM MODELLERİNİN GELİŞTİRİLMESİ VE OPTİMİZASYONU

(Yüksek Lisans Tezi)

Doruk SÖNMEZ

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ekim 2024

ÖZET

Derin öğrenme tabanlı bilgisayarlı görme uygulamalarının kullanımı, AlexNet evrimsel sinir ağı mimarisinin 2012'de ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını (ILSVRC) kazanmasının ardından ivme kazanmıştır. Bu ivme derin öğrenme yöntemlerinin savunma sanayi, akıllı şehirler, akıllı video analitiği, endüstriyel denetim ve sağlık hizmetleri gibi çeşitli alanlarda yaygın bir şekilde uygulamaya başlanmasına sebep olmuştur. Bu ve benzeri alanlarda elde edilen yüksek başarımlar, son yıllarda tarım ve hayvancılık da dahil olmak üzere diğer alanlarda yapay zeka yöntemlerinin yaygınlaşmasına sebep olmuştur. Bu tezde; yapay zeka modeli eğitimi, model optimizasyonu, model çalıştırma, meta veri akışı, meta veri kaydı, sonuç filtreleme/arama ve veri görselleştirme işlemlerini kolaylaştırmak amacıyla, derin öğrenme tabanlı bilgisayarlı görme uygulamaları için uçtan uca bir iş akışı önerilmiştir. Önerilen akışta son teknoloji derin öğrenme algoritmaları ve altyapıları kullanılarak hem model eğitimi hem de çıkarım performansı odaklı olarak, sınıflandırma modellerinin karşılaştırması gerçekleştirilmiştir. Tarımda yapay zeka kullanımında birçok farklı yöntem bulunmaktadır. Ancak önerilen çözümlerin büyük bir bölümünün, saha uygulamalarında güç tüketimi, sınırlı donanım kaynağı ve cihaz boyutu gibi önemli kısıtlar bulunmaktadır. Bu tez kapsamında geliştirilen modelleri, literatürdeki diğer çalışmalarda geliştirilen modellerle karşılaştırmak için eğitim ve çıkarım süreci, aynı açık kaynak veri seti üzerinde test edilmiştir. Önerilen iş akışı hem modern x86 bilgisayar sistemlerine hem de NVIDIA Jetson gibi ARM64 gömülü cihazlara uygulanabilecek bir çözüm olarak önerilmektedir. Bu nedenle, tez kapsamında NVIDIA Jetson aygıtları için model çalıştırma performansı kıyaslamaları da sağlanmıştır.

Bilim Kodu : 92413

Anahtar Kelimeler : Derin öğrenme, bilgisayarlı görme, tarım, gömülü sistemler, uçta yapay zeka

Sayfa Adedi : 70

Danışman : Prof. Dr. Aydın ÇETİN

DEVELOPMENT AND OPTIMIZATION OF DEEP LEARNING BASED
EDGE SYSTEM MODELS FOR AGRICULTURAL APPLICATIONS

(M. Sc. Thesis)

Doruk SÖNMEZ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

October 2024

ABSTRACT

The use of deep learning enabled computer vision applications gained momentum after AlexNet convolutional neural network architecture won the ImageNet Large Scale Visual Recognition Challenge (ILSVRC) in 2012. This led to the implementation of such methods in various application fields including defense industry, smart cities, intelligent video analytics, industrial inspection, and healthcare. Success of these applications enabled agriculture and livestock management to benefit from such implementations in recent years. In this work, we proposed an end-to-end workflow for deep learning-based computer vision applications to facilitate the AI model training, model optimization, model deployment, metadata streaming, metadata recording, result filtering/searching and data visualization. The source data of the visualizations as result of the analysis are stored in a high-performance database presented within the scope of the study. On the other hand, using the state-of-the-art deep learning algorithms and infrastructures, both model training and inference performance-oriented classification model comparison were carried out. In order to compare the developed models with the models developed in other studies in the literature, the training and inference process were tested on the same open-source data set. The workflow is proposed as a hybrid solution that can be deployed both on streamline x86 computer systems and ARM64 embedded devices. Therefore, deployment benchmarks for servers and NVIDIA Jetson devices are also provided within the paper.

Science Code : 92413

Key Words : Deep learning, computer vision, agriculture, embedded devices, edge deployment

Page Number : 70

Supervisor : Prof. Dr. Aydın ÇETİN

TEŞEKKÜR

Yüksek lisans tez sürecimde sunulan modellerin ve iş akışlarının geliştirilmesi ve çalıştırılması için gerekli donanımsal kaynakları hiçbir şekilde esirgemeyen ve farklı platformlarda testlerin gerçekleştirilmesine imkan sağlayan OpenZeka Teknoloji A.Ş. yönetim ve personel ekibine; yapmış olduğumuz çalışmanın akademik mecra ile paylaşılabilmesi için çalışmanın her aşamasında güçlü desteği ve değerli yönlendirmeleri için danışmanım Sayın Prof. Dr. Aydın ÇETİN hocama, çalışmanın daha doğru ve etkin bir biçimde literatüre kazandırılmasında yol gösterici olan düzeltme ve katkıları için Sayın Prof. Dr. Baha ŞEN ve Sayın Prof. Dr. Yusuf SÖNMEZ hocalarıma ve süreç boyunca manevi desteğini her zaman hissettiğim sevgili eşim Senem Gizem SÖNMEZ'e içten teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	7
2.1. Metodoloji	8
2.2. Değerlendirme	20
3. YÖNTEM VE ARAÇLAR	23
3.1. Veri Toplama, Önışlem ve Model Eğitimi	24
3.2. Niceleme Farkındalıklı Eğitim	24
3.3. Otomatik Karma Hassasiyet	28
3.4. Çevresel Uyarlama	29
3.5. Model Budama.....	29
3.6. Kablosuz Şebeke Yoluyla Model Güncelleme	32
3.7. Veri Seti	32
3.8. Veri Çeşitlendirme	36
3.9. Öğrenme Aktarımı	40
3.10. Model Eğitimi	42
3.11. NVIDIA TAO Toolkit	45
3.12. Yazılım ve Donanımlar	48

4. ÇALIŞTIRMA	51
4.1. Model Çalıştırma, Çıkarım ve Meta Veri Yönetimi	52
4.2. TensorRT ile Model Optimizasyonu	53
4.3. Ölçeklendirilmiş Gerçek Zamanlı Analitik için DeepStream SDK	54
4.4. Ölçeklenebilir Veri Akışı için Apache Kafka Entegrasyonu	54
4.5. NVDEC ve NVENC ile Donanım Hızlandırıcılı Kamera Yayını	55
5. BULGULAR VE DEĞERLENDİRME	57
6. SONUÇLAR	59
KAYNAKLAR	61
EKLER	67
EK-1. Literatür taramasına konu olan çalışmalarda kullanılan model başarımlar ve sonuçları	68
ÖZGEÇMİŞ	70

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Modellere dair budama öncesi ve sonrası parametre sayıları	42
Çizelge 5.1. Budama öncesi ve sonrası eğitim doğruluklarının karşılaştırılması	57
Çizelge 5.2. Çalışma verimi ve gecikme değerleri	58

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Veri toplama, önışlem ve model eğitimi akış diyagramı.....	23
Şekil 3.2. Veri kümesi oluşturma ve sürekli model eğitimi iş akışı	24
Şekil 3.3. Kayan nokta tensörü x^f 'in 8-bitlik işaretli tamsayı nicelemesi.....	26
Şekil 3.4. Niceleme farkındalıklı eğitim yönteminin akıştaki yeri ve başarıma etkisi ...	28
Şekil 3.5. Sinir ağı mimarisinden 1 nöron çıkarılarak bağlantı sayısının azaltılması.....	30
Şekil 3.6. Model eğitim ve optimizasyon sürecindeki yöntem ve araçlar	32
Şekil 3.7. PlantVillage Veri Setinden Örnekler	36
Şekil 3.8. Otomatik Karma Hassasiyet Akışı.....	43
Şekil 3.9. Ham ve budanmış modeller arasındaki çıkarım performansı karşılaştırması.	45
Şekil 3.10. NVIDIA TAO Toolkit çalışma şematığı	47
Şekil 4.1. Model çalıştırma ve meta veri analitiği akış diyagramı.....	51
Şekil 4.2. Model çıkarımı, meta veri yönetimi ve meta veri görselleştirme iş akışı.....	52
Şekil 4.3. Gömülü sistemlerde meta veri yönetim elemanlarının kullanım akışı	53
Şekil 4.4. NVIDIA NVENC ve NVDEC kodek bileşenlerinin format özellikleri	55

1. GİRİŞ

Günümüzde savunma sanayisi, akıllı şehirler, akıllı görüntü analiz sistemleri, sağlık ve daha birçok alana yaygın bir şekilde uyarlanan derin öğrenme yöntemlerinin, bu alanlarda görülen yüksek başarımlar ışığında nihai olarak birçok farklı sektördeki problemlerin direkt olarak çözüm mekanizmalarına da entegre edilmesine devam edilmektedir. Kronolojik olarak gelişen derin öğrenme ve yapay zekâ teknolojileri, literatürdeki tarım ve hayvancılık [1,2], endüstriyel denetim [3,4], otonom sürüş [5,6], spor analitiği [7,8] ve güvenlik [9,10] gibi alanlarda yapılan çalışmalara da yansımıştır. İlk dönemlerde sadece renk uzayları üzerinden bölütleme gibi ham görüntü işleme algoritmaları ile gerçekleştirilen çalışmalar, zaman içerisinde yerlerini evrişimli sinir ağlarına bırakmıştır. Yapay zekâ yöntemlerinin bahsedilen alanlarda kullanılmasının mevcut ve potansiyel faydaları;

- Analitik sırasında insan kaynaklı ortaya çıkan hataların giderilmesi veya azaltılması,
- Sürekli bir gözetmen ihtiyacının ortadan kaldırılması,
- Yeterli donanım altyapısının mevcut olduğu durumlarda daha yüksek hassasiyet ile analiz yapılması,
- 7/24 çalışma esasında maliyetlerin düşürülmesi şeklinde sıralanabilir.

Tarım ve hayvancılık sektörleri hem insanlığın devamına sağladıkları katkılardan hem de artan dünya nüfusunun gelecekte sağlıklı bir şekilde sürdürülebilmesi açısından kritik bir öneme sahiptir. Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) ve Uluslararası Telekomünikasyon Birliği'ne (ITU) göre, 2050 yılına kadar dokuz milyar eşğine gelmesi beklenen dünya nüfusunun yiyeceğe olan talebini karşılayabilmek için tarım üretiminin %70 oranında artmasının gerektiği belirtilmektedir [1]. Fakat insanlığın toprak, su gibi doğal gezegen kaynaklarını verimsiz kullanmasına ve hızlı sanayileşmeye bağlı olarak, ekilebilir arazi alanları büyük bir hızla daralmaktadır. Öte yandan iklim değişiklikleri, küresel su kıtlığı ve yetersiz kalan su-tarım politikaları bu süreci hızlandırmaktadır. Bu sebeplerle, hali hazırda birçok kamusal ve özel gerçek dünya problemlerine yönelik yüksek başarımlı çözümler geliştirilmesine olanak sağlamış olan görüntü işleme ve derin öğrenme tekniklerinin, tarım ve hayvancılık alanlarına uyarlanması, bu alandaki verimi ve üretim gücünü artırabilir.

Doğal etmenler dışında tarımdaki üretim verimini etkileyen en önemli unsurlardan birisi insan; dolayısıyla nitelikli iş gücü ihtiyacıdır. Nitelikli iş gücünün bulunmadığı durumlarda ortaya çıkan yanlış tür ve oranda ilaç kullanımı tüketiciler için sağlık sorunları teşkil etmesine ek olarak toprak, su, gübre ve diğer bitkileri kirletebilmektedir. Pestisitlerin, haşere ve yabancı otlarla birlikte kuşlar, balıklar, yararlı böcek türleri ve hedef olmayan diğer bitkiler için de öldürücü etkisi olabilmektedir [2]. Bu tip durumlar göz önüne alındığında dijital tarım üretkenlik, çevresel etki, gıda güvenliği ve sürdürülebilirlik açısından birçok zorluğun çözümü için önemli olmaktadır [3].

Yapay zekanın özelleştirilmiş alt dalları olarak tanımlanan derin öğrenme ve makine öğrenmesi, kendi içlerinde barındırdıkları istatistiksel yöntemler aracılığıyla, tanımlanmış olan problemlerin çözümünde hem görüntülerin hem de zamana bağlı verinin analiz edilmesini sağlar. Bu analiz geleceğe dair yüksek başarımlı ve hassasiyette tahminler oluşturulur. Burada makine öğrenmesi teknikleri ağırlıklı olarak Çizelge yapısına sahip veri kümeleri üzerinde uygulanabilir yöntemler sunarken; derin öğrenme yöntemleri görüntü analizi gibi karmaşık problemlerin çözümünde derin sinir ağlarını kullanarak, geçmiş veriden “edinilen tecrübeler” ile yeni verilere dair tahmin üretmektedir. Derin öğrenme, çeşitli evrişim işlemleri aracılığıyla verilerin hiyerarşik bir temsilini sağlayan “derin” sinir ağları ile ilgilidir. Bu, daha büyük öğrenme yeteneklerinin ve dolayısıyla daha yüksek performans ve hassasiyet değerlerinin elde edilmesini mümkün hale getirir [4].

Tarımda yapay zekâ uygulamalarının hali hazırda kullanımda olan ve potansiyel olarak sağlayabileceği faydalar arasında aşağıdaki maddeler sıralanabilir.

- Gelişmekte olan bitkilerin ihtiyaç duyduğu su ve besini tüketen yabancı otların yüksek hassasiyetli bir şekilde ilaçlanarak ayıklanması.
- Haşerelerin tespit edilip görüntü analizi ile zararlı ve zararsız olarak ayırt edilmesi, zararlı olanlar için yüksek hassasiyetli ilaçlamanın yapılması.
- Çeşitli bitkilerin yaprakları üzerinde görüntü analizi yapılarak bitkideki hastalıkların ve seviyelerinin tespit edilip doğru tür ve oranda ilaçlamanın yapılması.
- Yüksek hasat verimliliği için farklı olgunluk evrelerindeki meyvelerden hangilerinin toplanmaya uygun olduğunun ayırt edilmesi.
- Hali hazırda elde edilmiş olan hasattaki çürüklerin otomatik bir şekilde analiz edilip ayıklanması.

Sıralanmış olan yapay zekâ temelli uygulamaların arka planında görüntü analizinin yapılabilmesi için ağırlıklı olarak derin öğrenme yöntemleri kullanılmaktadır. Derin öğrenme alanı ile ilgili olarak derin sinir ağlarının “öğrenmesini” ve yüksek başarımın elde edilmesini sağlayan temel ister ise yüksek kaliteli ve kullanılabilir veridir. Farklı türde veri kümelerinin elde edilmesi ile görüntü sınıflandırma, bölütlendirme ve nesne tespiti gibi işlemler, bitki fotoğrafları üzerinde uygulanabilmektedir.

Yapay zekâ temelli uygulamaların arka planında görüntü analizinin yapılabilmesi için ağırlıklı olarak derin öğrenme yöntemleri kullanılmaktadır. Literatürde incelenen çalışmalardaki en yaygın derin öğrenme görevi türleri, esas olarak yüksek doğrulukta sınıflandırma, nesne tespiti ve semantik bölümlendirme modellerinin eğitimine yöneliktir.

Gelişen ve dijitalleşen tarım alanında makine öğrenmesi, görüntü işleme ve derin öğrenme gibi ileri teknolojilerin entegrasyonu üretkenliği, sürdürülebilirliği ve verimliliği artırmada çok önemli bir rol oynamaktadır. Özellikle bitkilere yönelik problemlerin, düşük maliyet ve yüksek doğrulukla tanımlanması ve buna yönelik olarak doğru ilaçlandırmanın uygulanması açısından, çeşitli tarımsal problemleri çözmeyi amaçlayan sınıflandırma modellerinin gömülü cihazlara uyarlanması, kritik bir teknolojik gelişmedir. Verileri önceden tanımlanmış ve etiketlenmiş sınıflara ayırmak için makine öğrenimi algoritmalarını kullanan sınıflandırma modelleri, bitki hastalıklarının tespiti, yabancı otların tanımlanması, verim tahmini ve toprak kalitesi değerlendirmesi gibi uygulamalarda büyük bir potansiyel ortaya koymuştur.

Ancak bu modellerin pratik bir şekilde uygulamaya konulması sırasında çeşitli zorluklar ortaya çıkmaktadır. Sıradan tarım ve hayvancılık bölgelerinde, genellikle sınırlı bağlantı kabiliyeti ve kısıtlı hesaplama kaynağı bulunmaktadır. Bu durum hem yüksek verimli hem de kendi kendini idame ettirebilen çözümler gerektirmektedir. Nispeten küçük boyutlu, düşük güç tüketimine sahip ve kendi içerisinde veri işleme yeteneğine sahip gömülü cihazlar, bu uygulamalar için ideal bir sistem altyapısı sunmaktadır. Gömülü sistemlerin sahip oldukları potansiyele rağmen sınırlı hesaplama güçleri, sınırlı bellek kapasiteleri ve düşük enerji bütçeleri gibi kısıtlamalar nedeniyle karmaşık sınıflandırma modellerinin bu cihazlar üzerinde uygulamaya konulması, ileri seviyede uzmanlık gerektirmektedir. Sonuç olarak, derin öğrenme modellerinin gömülü sistemlerin sahip olduğu donanım kaynak

sınırları dahilinde etkili bir şekilde çalışması için gereken uyarılma ve optimizasyon süreçlerine duyulan ihtiyaç gün geçtikçe artmaktadır.

Sınıflandırma modellerinin gömülü sistemlerde uygulamaya konulmasındaki zorlukların aşılması, aşağıda sıralanan sebeplerden dolayı büyük önem taşımaktadır:

Gelişmiş hassas tarım: Çiftçiler, optimize edilmiş sınıflandırma modellerinin çalışabildiği gömülü sistemlerden yararlanarak mahsullerini ve arazi topraklarını gerçek zamanlı olarak takip edebilir ve yönetebilirler. Bu sayede sulama, gübreleme ve ilaçlama miktarı gibi uygulamaların, hassas bir şekilde yapılmasını sağlayarak atıkların ve çevresel etkinin azaltılmasına olanak sağlayabilirler.

Erişilebilirlik ve ölçeklenebilirlik: Gömülü sistemler genellikle düşük maliyetli ve taşınabilir olup, gelişmiş tarım teknolojilerini küçük çiftçiler ve kırsal bölgelerdeki uygulamalar için de erişilebilir hale getirir. Böylece hassas tarım araçlarına erişim kolaylaşmış ve kaynakların yetersiz olduğu bölgelerde de tarımsal kalkınmanın desteklenmesi sağlanmış olur.

Sürdürülebilirlik ve verimlilik: Cihazın kendi içerisinde yapılan işlemler, bulut sunucularına sürekli veri aktarımı ihtiyacını en aza indirerek; bant genişliğinden tasarruf edilmesiyle birlikte veri aktarımının ve uzaktan hesaplamanın gerektirdiği enerji tüketimini de azaltmaktadır. Böylece ek bir avantaj olarak, genel karbon ayak izinin azaltılmasıyla tarımsal uygulamaların sürdürülebilirliğine katkıda bulunmak mümkündür.

Dayanıklılık ve otonomluk: Gömülü sistemler, tarımsal faaliyetlerin harici ağ koşullarından bağımsız olarak çalışmaya devam etmesini sağlar. Dolayısıyla, özellikle internet bağlantısının mümkün olmadığı veya güvenilmez olabileceği kırsal veya izole bölgelerde gömülü sistemlerle çalışabilmek çok değerli bir hale gelmektedir. Otonom sistemler, tarımsal uygulamaların bağlantı kesintilerine karşı dayanıklılığını artırabilmektedir.

Ekonomik faydalar: Gömülü sistemlerde çalışan sınıflandırma modelleri verim tahminlerini, bitki hastalık tanımlamalarını ve kaynak yönetimini iyileştirerek daha yüksek ürün verimliliği ve kalitesi elde edilmesini sağlayabilir. Bu sayede tarım faaliyetlerinin ekonomik sürdürülebilirliğini artırarak, tarım sektörünün genel karlılığına ve sürdürülebilirliğine katkıda bulunulabilir.

Özetlenecek olursa; sınıflandırma modellerinin tarımsal uygulamalara yönelik olarak gömülü sistemlerde uygulamaya konulması, modern tarıma yönelik bir dönüşümde büyük bir etkiye sahip olacaktır. Bu dönüşüm, yalnızca geleneksel yöntemlerin yetersizliklerini çözmekle kalmayıp, aynı zamanda daha verimli, sürdürülebilir ve kapsayıcı bir tarımsal geleceği de beraberinde getirmektedir. Bu çalışma, mevcut zorlukların üstesinden gelebilecek optimize edilmiş çözümleri keşfetmeyi ve geliştirmeyi; böylece tarım uygulamalarını, ileri bir seviyeye taşımada gömülü sistemlerin tüm potansiyelini ortaya koymayı amaçlamaktadır.

Sınıflandırma modellerinin gömülü sistemler kullanılarak tarımsal uygulamalara entegrasyonu, geleneksel tarım uygulamalarında maliyet etkin bir şekilde verimliliği artırmayı hedeflemektedir. Bu çalışmada, bahsedilen modellerin nasıl yüksek doğruluklu bir şekilde eğitileceği, gömülü sistemlerde nasıl optimize bir şekilde çalıştırılacağı, model çıktılarının son kullanıcıya nasıl daha verimli bir şekilde aktarılacağı, ölçeklendirme probleminin çözümü ve bunların potansiyel etkilerini vurgulayan ekonomik ve akademik yanlar açıklanmıştır.

Tarım, küresel ekonomiye önemli ölçüde katkıda bulunan ve özellikle gelişmekte olan ülkelerde nüfusun önemli bir bölümü için istihdam imkanları yaratan kritik bir sektördür. Gömülü sistemler, yapay zekâ ve görüntü işleme gibi teknolojilerin, tarımda uygulanması önemli ekonomik faydalar sağlayabilmektedir.

Maliyetleri düşürme açısından, sınıflandırma modellerinin uygulamaya konulduğu gömülü sistemler, çeşitli tarımsal süreçleri otomatize ederek işçilik maliyetlerini ve elle takip etme ihtiyacını azaltabilir. Örneğin, otomatik haşere tespit sistemleri, pestisit kullanımını potansiyel olarak %30'a kadar azaltıp, önemli ölçüde maliyet tasarrufu sağlayabilmektedir. Bu teknolojilerin daha çok benimsenmesiyle birlikte, 2020'de 7,4 milyar dolar olan gömülü sistemleri de içeren küresel tarım robotu pazarının, 2025'e kadar 20,6 milyar dolara çıkması beklenmektedir [11,12].

Bu teknolojiler aynı zamanda, üretkenliği artırmak için gerçek zamanlı çıkarım sonuçlarına dayanan analitikler sağlayarak, mahsul yönetim sürecindeki kararların iyileştirilip, verimin artmasına katkıda bulunmaktadır. Gerçek zamanlı çıkarım sonuçlar ve analitiklerin sağlayacağı hassas tarım teknolojilerinin, mahsul verimini %10-15 oranında artırdığı

görülmüştür [11,2]. Küresel anlamda bir örnek olarak; toprak sağlığının takibi için gömülü sistemlerin kullanılması sayesinde, gübreleme ve sulamayı optimize ederek mahsul verimini potansiyel olarak %25'e kadar artırmak mümkündür. Bu iyileştirmeler, 2050 yılına kadar 9,7 milyara ulaşması beklenen dünya nüfusu için hayati önem taşıyan, küresel tarıma dayalı gıda üretiminde önemli bir artışa katkıda bulunabilir [11,12].

Bu teknolojileri benimseyen çiftçiler ve tarımsal işletmeler, ürünlerinin kalitesini ve miktarını artırarak rekabet avantajı kazanabilirler. Sınıflandırma modelleri aracılığıyla bitki hastalıklarının erken tespiti, yıllık mahsul kayıplarının %20-30'unu önleyebilir. Böylece ürünlerin daha iyi pazarlanabilmesi ve daha yüksek fiyatlarla satılabilmesi de mümkün olacaktır. Bu teknolojilerin uygulanması, çiftçi veya işletme kârlılığını %15-20 oranında artırabilir [11,12].

Ekonomik gelişme açısından incelendiğinde, bu teknolojilerin yaygın şekilde kullanılması kırsal kalkınmayı teşvik ederek yüksek teknoloji yeni tarımsal iş alanları yaratacak ve tarımsal teknoloji sektörlerine yatırımı teşvik edecektir. Yalnızca ABD'de, hassas tarım pazarının 2030 yılına kadar 80,000'den fazla istihdam oluşturması beklenmektedir. Ayrıca, küresel hassas tarım pazarının büyüklüğünün, 2027 yılına kadar 12,9 milyar dolara ulaşması ve 2020 yılından itibaren yıllık bileşik büyüme oranının (CAGR) %13,1 olması beklenmektedir [5].

Tarımsal uygulamalara yönelik gömülü sistemler üzerinde sınıflandırma modellerinin çalıştırılması yalnızca ekonomik açıdan değil, aynı zamanda akademik kazanımlar açısından da avantajlıdır. Bu çalışma alanı, araştırma-geliştirme ve yenilikler açısından birçok fırsat sunmaktadır.

2. LİTERATÜR TARAMASI

Disiplinler arası arařtırmalar ve uygulamalar aısından deęerlendirildięinde; bilgisayar bilimi ve mhendislięi, tarım alanında birok probleme özüm sunabilir ve disiplinler arası iř birlięine de katkıda bulunabilir. Arařtırmacılar sensör geliřtirme, makine öęrenimi algoritmaları ve sistem entegrasyonu gibi eřitli aılardan özüm geliřtirebilir. Hali hazırda, hassas tarım alanında her yıl yayınlanan 1,500'ün üzerinde makale, bu alana yönelik akademik ilgiyi ve poplerlięi yansıtmaktadır.

Gömülü sistemlerin sınırlı hesaplama kabiliyetleriyle alıřabilen verimli ve yüksek doęruluęa sahip sınıflandırma modellerinin geliřtirilmesi ařılması gereken bir zorluktur. Bu zorluklar, makine öęrenmesi tekniklerinde, özellikle model optimizasyonu ve hafif algoritmaların geliřtirilmesi konularında uzmanlık gerektirir. Hafif makine öęrenimi modelleri ile ilgili akademik makalelerin sayısı son beř yılda yıllık %25 artış göstermiřtir [6].

Akademik alıřmalar aynı zamanda, bu teknolojilerin sürdürülebilir tarım uygulamalarına nasıl katkıda bulunduęunu da ortaya ıkarabilecek potansiyele sahiptir. Yapılan alıřmalar, zirai ilaların kullanımının azaltılması ve kaynak yönetiminin iyileřtirilmesi gibi çevresel faydalara odaklanarak, bu tür sistemlerin uygulamaya konulmasını daha da teřvik edebilir. Örneęin hassas tarım teknolojileri, su kullanımını %20'ye kadar azaltarak daha sürdürülebilir tarım uygulamalarına katkıda bulunabilir [6].

Ek olarak bu teknolojilerin üniversite ve dięer akademik kurum müfredatlarına entegre edilmesi, öęrencilere hem tarım hem de teknoloji alanında uygulamalı deneyim elde edilmesini saęlayacaktır. Bu sayede, geliřmiř tarım sistemlerinin daha yaygın bir řekilde kurulması ve yönetilmesi konularında nitelikli yeni nesil uzmanlar ortaya ıkabilir. Son on yılda, hassas tarım ve ilgili alanlara dair ierik sunan üniversitelere kayıtlarda %30'luk bir artış görlmüřtür [6].

Akademik alan aısından arařtırmacılar aynı zamanda bu teknolojilerin uygulanmasına ilişkin politik sonuçları ve etik hususların da üzerinde alıřabilirler. Buna veri gizlilięi, küçük ölekli iftçi ve iřletmeler iin teknolojiye eriřilebilirlik ve kırsal bölgelerde yařayan

nüfus üzerindeki sosyoekonomik etki ile ilgili sorunların ele alınması da dahildir. Hassas tarım teknolojilerinin benimsenmesini destekleyen politikalar, çiftçilerin teknoloji adaptasyonu konusunda %5-10 oranında bir artışa yol açabilir [6].

Akademik açıdan özetlenecek olursa, sınıflandırma modellerinin tarımsal uygulamalara yönelik gömülü sistemler üzerinde uygulanması, önemli ekonomik ve akademik fırsatlar sunmaktadır. Bu çalışma, belirtilen açuları araştırmayı ve bu teknolojilerin tarımsal üretkenliği ve sürdürülebilirliği artırmak ve aynı zamanda araştırma-geliştirme konusunda da farklı açılardan katkı sağlamak için nasıl etkili bir şekilde uygulanabileceğine dair bilgiler sunmayı amaçlamaktadır.

Bu çalışmanın literatür taraması sürecinde incelenen bütün çalışmalarda, ağırlıklı olarak tarif edilmiş olan hususlar üzerinde durulmuş ve genel anlamda yüksek başarımlı görüntü işleme modellerinin “eğitilmesi” sürecine odaklanılmıştır. Fakat tarım çalışmalarının otomatikleştirilmesi ve karar destek sistemlerinin geliştirilmesi açısından bakıldığında, incelenen modellerin nihai bir robotik veya özerk bir sistemde çalıştırılması gerekmektedir. Belirtilen sistemler sahada çalışacak olan asıl etmenler olacağından hafif, enerji verimliliği yüksek ve küçük alan kaplayan hesaplama birimlerine sahip olmalıdır. Dolayısıyla incelenen modellerin, bu gerekliliği karşılayan gömülü ve uç sistemlerde yüksek verimli bir şekilde çalıştırılması da kritik bir öneme sahiptir. Bu sebeple incelenen bütün modeller, aynı zamanda çalıştırma performansı açısından da değerlendirilmiştir.

2.1. Metodoloji

Makale analizi yapılan alana dair ilgili çalışmalara Science Direct, Web of Science, IEEE Xplore ve Google Scholar akademik kaynaklarında anahtar kelime tabanlı aramalar yapılarak ulaşılmıştır. Odağa uygun çalışmaların sıralanmış bilimsel veri tabanlarında bulunabilmesi için kullanılmış olan anahtar kelimeler aşağıdaki şekildedir:

“deep learning”, “artificial intelligence”, “agriculture”, “crop”, “edge ai”, “embedded systems”.

Ulaşılan sonuçlar arasından, alana dair daha güncel ve detaylı bir değerlendirmenin yapılabilmesi amacıyla, 2018 yılından sonraki yalnızca dergi makalesi türünden çalışmalar

ayıklanmıştır. Sonuç olarak belirtilen kriterlere uygun 17 makale, aşağıdaki temel başlıklar özelinde detaylı bir şekilde analiz edilmiştir.

- Odaklanılan tarım problemi
- Problemi tanımlayan veri seti
- Veri setindeki sınıflar ve etiketleme türü
- Uygulanan veri çeşitlendirme yöntemleri
- Eğitilen evrişimli sinir ağı (CNN) mimarisi
- Model eğitiminde kullanılan hiperparametreler
- Modelin eğitim ve test performans sonuçları
- Modelin diğer modeller veya yöntemler ile karşılaştırması
- Model eğitiminde ve varsa çıkarımda kullanılan donanım özellikleri
- Modelin çıkarım aşamasındaki çalışma hızı

Belirtilmiş olan 17 çalışma ile ilgili olarak odaklanılan problem, kullanılan veri seti ve özellikleri, görüntü ön işlem yöntemleri, modeller ile ilgili teknik detaylar ve performans sonuçları bu bölümde açıklanmıştır.

Odaklanılan problem türleri

İncelemeye konu olan 17 makalede odaklanılan konular arasında; meyve tespiti ve sınıflandırma, bitki hastalık tespiti ve sınıflandırma, haşere tespiti, meyve olgunluk ve meyve sağlık durumları bulunmaktadır. Çalışmalarda ağırlıklı olarak bu konulardan meyve tespiti ve sınıflandırma ile bitki hastalık tespiti ve sınıflandırma konuları üzerinde durulmuştur. Bazı çalışmalar ise birden fazla odak konusu üzerinde karma çözümler üretmiştir.

Veri kaynakları

Bütün makalelerde sunulmuş olan derin öğrenme modellerinin eğitileceği verilerin hangi kaynaklar üzerinden elde edildiği detaylı bir şekilde incelenmiştir. Ulaşılan sonuçlara göre makalelerde ağırlıklı olarak yazarın kendisi tarafından direkt olarak uygulama sahasından

toplanan veriler kullanılırken; makalelerin bir kısmında internette amaca yönelik hazırlanmış hazır veri kümeleri ile özel veri kümeleri harmanlanmıştır. İncelemesi yapılan makalelerden bir tanesinde ise hem hazır veri kümesi hem de geliştirilen model tarafından üretilen sentetik veri kümesi harmanlanarak nihai veri kümesi elde edilmiştir.

İncelenen makalelere göre veri kümesi kaynaklarının dağılımı aşağıda listelendiği şekildedir:

- PlantVillage [7]
- BRACOT [8]
- Forestry Images [9]
- Pest24 [10]
- AgriPest21 [11]
- Özel Veri Kümesi [13-20]

Listelenmiş olan veri setlerinin tamamı kara araçları, dijital fotoğraf kameraları veya akıllı telefon kameraları kullanılarak toplanmıştır. Özel veri kümesi kategorisi altında toplanan ve makalenin yazarı tarafından oluşturulmuş olan veri kümelerinin neredeyse tamamında, farklı ışık ve hava durumu koşullarında verilerin toplanmasına özen gösterilmiştir. Bu koşullar altında oluşturulmayan veri kümelerinde ise Veri Ön İşleme başlığı altında açıklanan yöntemlere göre farklı ışıklandırma koşulları yapay bir şekilde oluşturulmuştur.

Veri ön işleme

Veri ön işleme, görüntü, metin veya ses tabanlı verilerin yapay zekâ modeline girdi olarak verilmeden önce modele uygun format veya yapıya uygun hale getirilmesi sürecidir. Bu incelemede, üzerinde durulan makalelerin tamamı görüntü tabanlı yaklaşım sergilediğinden yalnızca görsel veri üzerinde uygulanan ön işlem adımlarından bahsedilmiştir.

İncelenen makalelerin tamamında model eğitimi için kullanılan veri setleri üzerinde veri ön işleme yöntemleri uygulanmıştır. Bunun sebebi, bütün yapay sinir ağı mimarilerinin, girdi katmanı için uygun görüntü boyutlarının geliştirme aşamasında belirlenmiş olmasıdır. Veri kümelerinin oluşturulması aşamasında görüntüleri elde etmek için kullanılan ve günümüz teknolojisine sahip dijital kameralar 1280x720 (720p), 1920x1080 (1080p), 2048x1080 (2K)

ve 3840x2160 (4K) gibi farklı profillerde yüksek çözünürlüklü görüntü elde edilmesini sağlar.

Fakat modern derin sinir ağı mimarilerinde, hesaplama verimliliğini artırabilmek amacıyla 512x512, 256x256 veya 229x229 gibi kameraların sağladığından çok daha düşük çözünürlükte girdiler kabul edilir. Bu sebeple, incelenen bütün makale çalışmalarında, veriler modele beslenmeden önce yeniden boyutlandırma işlemi gerçekleştirilmiştir. Örnek olarak Tian ve diğerleri (2019) [12] çalışmasında elma bahçelerinden kendisinin elle topladığı görüntüleri kullanarak özel bir veri seti oluşturdu. Fakat topladığı görseller 3000x4000 piksel çözünürlüğe sahipken geliştirmiş oldukları model 512x512 girdi boyutuna sahip olduğundan yeniden boyutlandırma işlemi uygulanmıştır. Benzer şekilde Too ve diğerleri (2019) [13] model başarımlarını karşılaştırması yaparken kullandığı 256x256 çözünürlükte görsellerden oluşan PlantVillage veri setini, Inception V4 modeli için 299x299 boyutlarına genişletirken; VGG-16, ResNet-50/101/152 ve DenseNet modelleri için 224x224 boyutlarına küçülmüştür.

Ma ve diğerleri (2018) [14]'nin çalışmasına göre bir başka ön işlem yöntemi olarak Excess Red Index, HSV ve L*a*b* gibi farklı renk uzaylarına göre görüntünün geri kalanından ayrıştırılan ve yalnızca anormallik bulunma ihtimali olan alan, nihai karar ve sınıflandırma için modele beslenmiştir.

İncelenen çalışmaların bir kısmında ise nesne tespiti, semantik bölütleme ve semantik öge bölütleme yöntemlerinin kullanımından kaynaklı olarak VIA [15], CVAT [16], LabelMe [17] ve LabelImg [18] gibi araçlar kullanarak veri etiketleme işleminin yapılması gerekmektedir. Verilerin etiketlenme türlerine göre dağılımları aşağıdaki gibidir.

Sınıflandırma için Dizin Ayırıştırma ile etiketlenen çalışmalar:

- Too ve diğerleri [13]
- Tassis ve diğerleri [19]
- Ma ve diğerleri [14]
- Momeny ve diğerleri [20]
- Zhao ve diğerleri [21]
- Gonzales-Huitron ve diğerleri [22]

- Partel ve diğlerleri [23]
- Abbas ve diğlerleri [24]

Nesne Tespiti için Çevre Kutusu (Bounding Box) ile etiketlenen çalışmalar:

- Tian ve diğlerleri [12]
- Ngo ve diğlerleri [25]
- Partela ve diğlerleri [26]
- Rao ve diğlerleri [27]
- Wang ve diğlerleri [10]
- Partel ve diğlerleri [23]
- Wang ve diğlerleri [11]
- Garcia-Manso ve diğlerleri [28]

Semantik Bölütleme ve Semantik Öge Bölütleme için Bölgesel Maske (Region Mask) ile etiketlenen çalışmalar:

- Tassis ve diğlerleri [19]
- Rao ve diğlerleri [27]
- Lin ve diğlerleri [29]
- Yu ve diğlerleri [30]

Veri çeşitlendirme

Derin öğrenme modellerinin daha az veriyle yüksek başarımlarına ulaşabilmesini sağlayan yöntemlerden bir tanesi, ham veri seti üzerinde uygulanan veri çeşitlendirme işlemleridir. Veri çeşitlendirme, görüntülere ait renk kanalları ve geometrik bulunuşları üzerinde bir takım görüntü işleme algoritmalarının uygulanmasıyla tek bir görüntüden birçok farklı varyasyonda görüntünün elde edilebilmesini sağlar. Derin sinir ağları, insan gözünden farklı olarak görüntüleri birer anlamlı şekil veya renk olarak algılamak yerine piksel tabanlı değerlerden algılama yoluyla çalıştığından, oluşacak her yeni varyasyon derin öğrenme modeli için yeni bir görüntü anlamına gelmektedir. Böylece tek bir görüntü sahnesinin farklı varyasyonlar ile derin öğrenme modeline beslenmesi sayesinde hem veri miktarı artırılmış olur hem de daha genelleştirilebilir bir model elde edilebilir.

Derin öğrenme uygulamalarında yaygın bir şekilde kullanılan on üç tane veri çeşitlendirme metodu aşağıdaki şekilde listelenebilir:

- Rastgele Gürültü (Random Noise)
- Kırpma (Cropping)
- Döndürme (Flipping)
- Ölçeklendirme (Scaling)
- Parlaklık (Brightness)
- Renk Değişimi (Color Augmentation)
- Yoğunluk (Saturation)
- Doygunluk (Contrast)
- Rotasyon (Rotation)
- Kaydırma (Translation)

Fakat tarım alanında yapılan derin öğrenme tabanlı görüntü işleme çalışmalarında eğer üzerinde çalışılan problem bitki yaprakları, çiçekler ve meyveler ile alakalıysa, yukarıda listelenmiş olan her yöntem uygulanamamaktadır. Renk kanallarında yapılacak değişimler Yeşil kanal üzerindeki problemi tanımlayan özneliklerin kaybolmasını sağlayabileceğinden tercih edilmemektedir. Benzer şekilde Yoğunluk ve Doygunluk yöntemleri de bitkiyi tanımlayıcı renk verisinde değişime sebep olabileceğinden ya çok düşük oranlarda uygulanmalı veya hiç uygulanmamalıdır.

İncelenen makaleler kapsamında iki tanesi [13,24] hariç diğer bütün çalışmalarda veri çeşitlendirme yöntemleri farklı şekillerde uygulanmıştır. Özel olarak bu beş çalışmadan ilkinde kullanılan PlantVillage veri seti üzerinde çeşitlendirme yapılmamasının asıl sebebi, karşılaştırma yapılacak modellerin farklı verilerden etkilenmeden ham veri üzerinde üreteceği sonuçların karşılaştırılmasının yapılmak istenmesidir. Veri çeşitlendirme yöntemlerine dair detaylar EK-1'deki tabloda gösterilmiştir.

Çalışmalarda kullanılan yöntemler incelendiğinde en yaygın şekilde kullanılan yöntemler olan Döndürme ve Rotasyon ön plana çıkmaktadır. Kullanım yaygınlığı açısından bu iki yöntemi Parlaklık, Renk Değişimi, Yoğunluk ve Kaydırma yöntemleri takip etmektedir. Uygulanan veri çeşitlendirme yöntemleri arasından ham görüntü işleme algoritmalarından farklı olarak en dikkat çeken ise Abbas ve diğerleri [24]'nin çalışmasıdır. Bu çalışmada

Çekişmeli Üretici Ağ tabanlı cGAN (Conditional Generative Adversarial Network) modeli ile rastgele gürültüden sentetik veri üretilmiş ve yenilikçi bir şekilde sentetik veri üretimi sağlanmıştır.

Derin öğrenme tabanlı mimari detayları

Tarım alanında yapay zekâ uygulamaları kapsamı altında bu makalede incelenen bütün çalışmalarda derin öğrenme tabanlı Evrişimli Sinir Ağları kullanılmıştır. Fakat kullanılan ağ mimarileri, modele girdi olarak verilecek görüntülere dair ön işlemler ve bazı çalışmalarda model çıktısından elde edilen çıktı görüntüleri üzerinde yapılan son işlemler konularında değişiklik göstermektedir. Örnek olarak altı çalışmada asıl önerilen derin öğrenme modeline verilecek olan girdi görüntüleri; histogram veya renk uzayı bölütleme [14, 20, 21], semantik bölütleme [19], [26] veya bir sınıflandırıcı modeli öznitelik çıkarıcısı olarak kullanma [28] şeklindeki iş akışı ile daha yüksek başarımlar elde edilmeye çalışılmıştır.

İncelenen bütün çalışmalardan farklı olarak Abbas ve diğerleri [24]'nin çalışmasında bir ön işlem yöntemi olarak cGAN mimarisi ile fotoğrafı çekilen görüntüden sentetik veri oluşturulmuştur. Oluşturulan sentetik veri daha sonra hem orijinal veri setine eklenmiş hem de sunulan derin öğrenme modeline bir girdi olarak beslenmiştir. Diğer çalışmalarda ise görüntüler, geliştirilen modele herhangi bir ön işleme tabi tutulmadan ham halde beslenmiştir. Çalışmalarda uygulanan çıkarım sonrası işlemler incelendiğinde ise [25]'de YOLOv3-tiny nesne tespit modeli ile fotoğraftaki konumu tespit edilen bal arıları daha sonra KF ve Hungarian algoritmaları kullanılarak takip akışına dahil edilmişlerdir. [26]'de ise YOLOv3 modeli ile tespit edilen ilgili bitki alanı 64x64 piksel boyutlarında kırılarak daha yüksek başarımlı bir sınıflandırma yapılabilmesi için YOLOv1 modeline girdi olarak beslenmiştir. Bir diğer çıkarım sonrası işlem olarak ise [29]'de FCN8 s adlı semantik bölütleme modelinden elde edilen maske görüntüsü üzerinde Canny Kenar Tespit [31] algoritması kullanılarak, tarım robotunun ilerleyeceği tarla sınırlarının belirlenmesi amaçlanmıştır.

Uyarlanmış olan evrişimli sinir ağı mimarilerine bakıldığında ise 6 çalışmada sunulan ana model veya karşılaştırma yapılan rakip modellerden en az bir tanesinde ResNet [31] mimarisine sahip türev modeller kullanılmıştır [11,13,19,23,27,28]. ResNet tabanlı

mimarilerden ise hem hesaplama verimliliği hem de hızlı çalışabilirlik açılarından avantajı sayesinde ResNet-50 türevi ağırlıklı olarak tercih edilmiştir. Odaklanılan derin öğrenme görevlerinin temelinde incelendiğinde; sınıflandırma problemi için ResNet'ten sonra en yaygın olarak VGG-16, nesne tespiti için YOLO-V3 ile Faster R-CNN ve bölütleme için Mask R-CNN mimarileri kullanılmıştır.

Kullanılan mimarilerin tercih edilmesindeki sebeplerin arasında, bu mimarilerin popüler derin öğrenme kütüphanelerince desteklenmesi ve böylece model eğitim süreçlerinin kolay bir şekilde yapılabilmesidir. İncelenen makaleler arasında kütüphane ve kullanılan yazılım detayları aktarılan on çalışma içerisinde PyTorch, TensorFlow ve MATLAB kullanımı görülmektedir. Kullanım dağılımı açısından incelendiğinde dört çalışmada PyTorch, üç çalışmada Tensorflow, iki çalışmada MATLAB ve diğer bir çalışmada ise TensorFlow ve MATLAB bir arada kullanılmıştır. Bu çalışmalarda geliştirilen modellerin, tarım sahalarında çalışan gömülü sistemlerde uygulamaya konulması dikkate alındığında ise optimizasyon ve model hızlandırma önemli hale gelmektedir. Tercih edilen gömülü sisteme bağlı olarak, bu optimizasyon ve hızlandırma işlemi NVIDIA firması tarafından geliştirilen TensorRT [32] kütüphanesi ile uygulanabilmektedir. Hali hazırda birçok endüstriyel ve ticari uygulamada kullanılmakta olan bu kütüphane, incelenen çalışmalar arasında yalnızca iki makalede kullanılmıştır.

İrdelenmiş olan mimariler kullanılırken, yüksek parametre ve derin katman yapılarına sahip olduğundan ImageNet [33] gibi yüksek veri sayısına sahip veri kümeleri ile eğitilerek yüksek başarımlara ulaşılabilir. Fakat tarım alanı için geliştirilmiş ve açık kaynaklı olarak sunulan Veri Kaynakları başlığı altındaki veri kümeleri, her ne kadar Veri Çeşitlendirme başlığı altında sunulan yöntemlerle veri sayıları artırılmaya çalışılmış olsa da yüksek başarımlara sahip derin sinir ağlarının sıfırdan eğitilmesi için yeterli veri sayısına sahip değildir. Bu sebeple incelenen çalışmaların çoğunluğunda öğrenme aktarımı [34] yöntemi kullanılmıştır. Öğrenme aktarımı yönteminde, daha önceden ImageNet gibi çok yüksek hacimli veri kümelerinde eğitilen modellerin öznelik çıkarımına dair yeteneklerinden yararlanır. Girdi katmanına yakın olan katmanlarda renk, kenar ve şekil gibi bütün nesnelere için ortak olabilecek genel tanımlamalar bulunurken; çıktıya yakın olan katmanlarda nesnelere direkt olarak betimleyebilecek daha özel tanımlamalar bulunur. Dolayısıyla mimariye ve katman yapısına bağlı olarak, belirli bir seviyedeki katmana kadar olan ağırlıklar sabit tutularak, tarım alanına dair odaklanılan problemi tanımlayabilecek yalnızca

daha sonraki katmanlar eğitim sürecine dahil edilir. Böylece hem hesaplama verimliliği hem de derin ağ yapılarının çok daha kısa sürelerde eğitilmesi sağlanabilmektedir. İncelenen çalışmalardan sekiz tanesinde öğrenme aktarımı uygulanarak model eğitimi gerçekleştirilmiştir [10,13, 21,22, 24,27, 28,30]. Önceden eğitilmiş modellerin tamamı, ImageNet veri kümesinde eğitilmiş ağırlıklara sahiptir.

Model çıktıları

İncelenen çalışmalardaki derin öğrenme modellerine ve görüntü işleme görevleri açısından bakıldığında, uyarlanan modellerin çıktı katmanları da uygun olacak şekilde değişkenlik göstermektedir. Öğrenme aktarımı yönteminin uygulandığı durumlarda, önceden eğitilmiş model için kullanılan veri kümesinin sınıf sayısı kadar çıktı katmanında birimi bulunmaktadır. Sınıflandırma problemine yönelik olarak uyarlanmış olan çalışmaların tamamı ImageNet veri seti ile önceden eğitilmiş modeller kullanılarak öğrenme aktarımı yapıldığından, çıkış katmanındaki bin sınıfa dair sonuç üreten birim sayısının kullanılan veri kümesine uygun olarak değiştirilmesi gereklidir.

Derin öğrenme modellerinde katmanlar boyunca yapılan matematiksel hesaplamalar, katmanlar için tanımlanan aktivasyon fonksiyonları aracılığıyla gerçekleştirilmektedir. Çıktı katmanında, girdi görüntüsüne dair veri kümesindeki her bir sınıf için üretilen aidiyet olasılık değerleri de bu katman içi belirlenmiş olan özel aktivasyon fonksiyonları ile elde edilir. Hali hazırda sınıflandırma modelleri için çıktı katmanlarında en yaygın olarak kullanılan aktivasyon fonksiyonu Softmax'tir. Bu çalışma kapsamında eğitilmiş bütün modellerde Softmax fonksiyonunun kullanılma sebepleri aşağıda sıralanmıştır:

- Karşılaştırma yapılan diğer çalışmalarda tarım alanındaki problemleri çözmeye yönelik olarak başarılı model mimarilerinde Softmax fonksiyonu yaygın olarak kullanılmıştır. Bu çalışmanın amacı kapsamında; farklı fonksiyonlar ile daha yüksek başarımlar elde etmeye çalışmak yerine, literatür taramasındaki diğer çalışmalarda yaygın bir şekilde kullanılan Softmax aktivasyon fonksiyonu temel alınarak hem yüksek başarımlar hem de çalışma anında yüksek performans elde edilmeye çalışılmıştır.
- Softmax aktivasyon fonksiyonu, çok sınıflı sınıflandırma görevleri için sinir ağlarının çıktı katmanında kullanılan en yaygın aktivasyon fonksiyonudur. Modelin ham çıktı puanlamalarını (logitleri) sınıflar üzerinde bir olasılık dağılımına dönüştürür. NVIDIA firması konu ile ilgili resmi bir açıklama yapmış olmasa da, TAO Toolkit'in

TensorFlow2 tabanlı eğitimlerinde yalnızca Softmax desteklenerek, modellerin en yaygın kullanılan uygulamalarla uyumlu ve tutarlı bir şekilde eğitilmesinin amaçlanmış olma olasılığı yüksektir.

- Bu çalışma kapsamında NVIDIA TAO Toolkit'in model eğitim altyapısı olarak kullanılan TensorFlow2, Softmax fonksiyonu özelinde belirli optimizasyonlara ve uyumluluk özelliklerine sahiptir. Bu sebeple Softmax tek seçenek olarak sunulmuş çalışmalar arası istikrarlı sonuç elde edilmesini ve birden fazla aktivasyon işlevini desteklemekten kaynaklanabilecek karmaşıklıkların önüne geçilmesi amaçlanmış olabilir.
- Son katmanda Softmax kullanılarak eğitilen modellerin, NVIDIA donanımlarında çıkarım için çalıştırılması ve optimizasyonu daha kolaydır. Softmax, TensorRT gibi NVIDIA çıkarım motorlarında desteklenmektedir ve bu sayede ürün seviyesinde çalıştırılacak modeller için tercih edilecek güçlü bir seçenek haline gelmektedir.

Nesne tespiti, semantik bölütleme ve semantik öge bölütleme modellerinde ise süreç daha farklı işlemektedir. Daha karmaşık ve yüksek hesaplama kabiliyeti gerektiren bu gelişmiş modellerin çıktı katmanlarında birden fazla dal kullanılarak hem sınıflandırma hem aranan nesnenin görüntü üzerindeki konumu hem de nesnenin görüntüde kapladığı alan gibi daha ileri seviye bilgiler elde edilebilmektedir. Bunun için nesne tespiti modellerinin çıktı katmanında nesnenin konumunu dikdörtgen kutu içine alabilecek dört adet koordinat değeri ile bu alandaki nesne için tahmin edilen sınıf ismi ve aidiyet olasılık değerleri de çıktı olarak verilir. Bölütleme modellerinde ise nesnenin görüntü üzerinde hangi piksellerde yer aldığı sınıflandırması pikseller temelinde yapıldığından, nesnenin görüntünün geri kalanında maskelenerek ayırt edilmesi durumu söz konusudur. Semantik bölütlemeye bu durum nesnelerin sınıflarına farklı renkler atanarak yapılırken; semantik öge bölütlemeye sınıftan bağımsız olarak nesnelerin her birine özel farklı bir renk atanmasıyla yapılır. Renk atamaları, ilgili nesnelerin görüntüdeki konumlarında piksel renk değerlerinin değiştirilmesi ile gerçekleştirilir. İncelenen çalışmaların sınıflandırma, nesne tespiti ve semantik bölütlemeye dair dağılımı, Veri Ön İşleme başlığı altında ayrıntılı olarak aktarılmıştır.

Hiperparametreler

Eğitim yöntemi belirtilmiş olan çalışmaların büyük çoğunluğunda öğrenme aktarımı kullanıldığından, yeniden eğitime sürecinde kullanılan hiperparametre değerleri de benzer

olmuştur. Bütün çalışmalar optimize edici algoritma, başlangıç öğrenme katsayısı (initial learning rate), paket boyutu (batch size), ağırlık düşümü (weight decay), öğrenme katsayısı optimize edici algoritma (learning rate optimizer), momentum, paket normalizasyonu (batch normalization), aktivasyon fonksiyonu (activation function) ve epok (epoch) hiperparametreleri açısından kıyaslanmıştır.

Eğim düşümü için kullanılan optimize edici algoritmaya dair yöntem belirtilen 6 çalışmanın tamamında Mini-batch Stochastic Gradient Descent algoritması kullanılmıştır. Bu yöntemin en büyük tercih sebebi ise, diğer optimize edici algoritmalara kıyasla çok daha hızlı ve daha yüksek başarılı model eğitimi sağlıyor olmasıdır. Bu sebeple mevcut bütün popüler derin öğrenme kütüphanelerinde de model eğitimi için varsayılan optimize edici yöntem Mini-batch Stochastic Gradient Descent'tir.

Başlangıç öğrenme katsayısı değeri, modellerin sıfırdan veya öğrenme aktarımı ile eğitilmesi durumlarına göre değişken bir şekilde tanımlanmaktadır. Öğrenme aktarımı yöntemi tercih edildiğinde ise ince ayar işleminde eğitime dahil edilmeyen katman sayısına bağlı olarak farklı değerler tercih edilebilmektedir. İncelenen çalışmaların tamamında kullanılan başlangıç öğrenme katsayısı değerleri belirtilmiş ve değer dağılımına göre; on yedi çalışma içerisinde geliştirilen iki modelde 0,0001, sekiz modelde 0,001, beş modelde 0,01, iki modelde 0,0025, bir modelde 0,005, bir modelde 0,0005 ve diğer bir modelde ise 0,0003 olarak kullanılmıştır.

Çalışmalarda uyarlanan derin öğrenme model türü ve eğitim işleminin yapıldığı bilgisayarın hesaplama kabiliyetlerine göre farklı paket boyutu değerleri kullanılmıştır. Genellikle sınıflandırma modellerinde, öğrenme aktarımı için ImageNet uyarlamaları değiştirilmeden kullanıldığında, 224x224 veya 256x256 gibi düşük çözünürlüklü girdiler üzerinde evrişim işlemi yapıldığından, aynı anda modelin işleyebileceği görüntü paketinin boyutu yüksek olabilmektedir. Bilgisayarın hesaplama kabiliyetine bağlı olarak 32, 64, 128, 256 veya 512 değerleri yaygın olarak kullanılmaktadır. İncelenen çalışmalar arasında sınıflandırma model uyarlaması yapılanlarda Too ve diğerleri [13] Inception V4, VGG-16, ResNet-50/101/152 ve DenseNet-121 model mimarilerini kıyaslamalı bir şekilde eğitilirken NVIDIA Tesla K40 grafik kartının kısıtları sebebiyle paket boyutu değeri olarak 16 kullanılmıştır. Tassis ve diğerleri [19] ise çalışmalarında öncelikle semantik bölütleme daha sonra semantik öge bölütleme ve en sonunda ResNet-50 modeli ile bölütlenen alandaki hastalığa dair

sınıflandırma yapmayı amaçlamışlardır. Buradaki ResNet-50 modeli ise [35] çalışmasında ortaya konulmuştur. Modelin orijinal makalede eğitilmesi sırasında kullanılan paket boyutu ise 32'dir. Orijinal çalışmada NVIDIA GeForce GTX 1060 grafik kartının kısıtlamaları sebebiyle yine düşük bir paket boyutu tercih edilmiştir. Benzer şekilde sınıflandırma modeli içeren ve bu modellerin eğitilmesi sırasında kullanılan paket boyutu değerleri aşağıdaki gibidir:

- Too ve diğerleri [13]: 16, Tesla K40
- Tassis ve diğerleri [19]: 32, GTX 1060
- Ma ve diğerleri [14]: 128, Quadro P4000
- Momeny ve diğerleri [20]: 25, Belirtilmemiş
- Zhao ve diğerleri [21]: 50, RTX 2080Ti
- Gonzales-Huitron ve diğerleri [22]: 24, GTX 1070
- Partel ve diğerleri [23]: Belirtilmemiş
- Abbas ve diğerleri [24]: 32, Belirtilmemiş
- Tian ve diğerleri [12]: 8, Tesla V100
- Ngo ve diğerleri [25]: 64, 2x RTX 2080
- Partel ve diğerleri [23]: Belirtilmemiş
- Rao ve diğerleri [27]: Belirtilmemiş
- Wang ve diğerleri [10]: Belirtilmemiş
- Wang ve diğerleri [11]: 2, GTX 1080Ti
- Garcia-Mansove diğerleri [28]: 2, GTX 1070Ti

Uyarlanan nesne tespit modelleri kapsamında irdelendiğinde ise, sınıflandırıcı model mimarilerine kıyasla daha karmaşık ağ yapıları olması sebebiyle daha düşük paket boyutu değerleriyle model eğitimleri gerçekleştirilmiştir.

İncelenen çalışmalar arasında semantik bölütleme ve semantik öge bölütleme temelli modellerde kullanılan paket boyutu ise aşağıdaki gibi gerçekleşmiştir:

- Lin ve diğerleri [29]: 10, GTX 1080Ti
- Yu ve diğerleri [30]: 32, GTX 1080

İncelenen çalışmalarda geliştirilmiş olan modellerin sınıflandırma, nesne tespiti ve semantik bölütleme türlerine göre başarımlar açısından değerlendirilme yöntemleri de değişkenlik göstermektedir.

Sınıflandırma modelleri ve nesne tespit modellerinin sınıflandırma aşaması için bütün çalışmalarda endüstri standardı haline gelmiş olan Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall) ve F1-Score ölçütleri bütün çalışmalarda ortak olarak kullanılmıştır.

Ek olarak nesne tespit modellerinde dikdörtgen kutu ile konumlandırmanın doğruluğunu belirten Intersection of Union (IoU) ve Mean Average Precision (mAP) değerlerine göre performans değerlendirmesi gerçekleştirilir. İncelenen semantik bölütleme çalışmalarında ise Mean Intersection of Union (MIoU), Overlap Coefficient (OC) ve Mean IU ölçütlerine göre performans değerlendirmesi yapılmıştır. Abbas ve diğerleri [27] çalışmasındaki sentetik veri üretimi için kullanılan cGAN modeli, diğer model türlerinden farklı olarak PSNR ölçütü üzerinden değerlendirilmiştir. Fakat diğer hiçbir çalışmada benzer metot uyarlanmadığından, herhangi bir karşılaştırma yapmak mümkün değildir.

Bütün çalışmalara dair sonuçlar ve performans değerleri, EK-2'deki çizelgede sunulmuştur.

2.2. Değerlendirme

Literatür taraması bölümünde aktarıldığı üzere, incelenen bütün çalışmalardaki ortak amaç, ağırlıklı olarak tarım alanında çok fazla uzmanlık ve iş gücü gerektiren süreçlerin derin öğrenme ve görüntü işleme yaklaşımıyla kolaylaştırılması ve mümkünse otomatik hale getirilmesidir. Hem sınıflandırma hem nesne tespiti hem de semantik bölütleme tabanlı yapılan çalışmaların 12 tanesinde %95'lik başarımlar eşliğinin aşıldığı ve bunlar içerisinde 10 çalışmada %99'luk başarımlara ulaşılabildiği görülmüştür. Dolayısıyla tarım alanında derin öğrenme destekli görüntü işleme yöntemleri kullanılarak yüksek başarımlı bir şekilde var olan problemleri çözmek mümkündür. Fakat buradaki en büyük kısıt, incelenen çalışmalarda geliştirilen modellerin, tarım alanında asıl çalışmayı yapacak olan ve düşük enerji tüketimi ile kısıtlı hesaplama kabiliyetine sahip gömülü sistemlerde uygulamaya koyulup koyulamayacağıdır. Bu kapsamda incelendiğinde, 17 çalışmadan yalnızca 6 tanesinde geliştirilen yöntemin bir gömülü sistemde uygulamaya konulmasına dair test

gerçekleştirilmiştir. Bu 6 çalışmada kullanılan gömülü sistemler irdelendiğinde; 5 tanesinde NVIDIA Jetson platformu ve diğer 1 çalışmada ise Raspberry Pi 4 kullanılmıştır. NVIDIA Jetson platformunun kullanım açısından üstünlüğe sahip olmasının sebebi, platformun kendi gömülü GPU biriminin bulunması ve modellerin TensorRT kütüphanesi ile optimize edilebilirliği ve model çalışma performansının bu sayede artırılabilir olmasıdır.

Gömülü sistemlerde çalıştırılmaya yönelik olarak geliştirme yapılmayan çalışmalarda, sahadan toplanan görüntülerin bir yerel ağ veya internet üzerinden modelin çalışacağı, grafik kartına sahip asıl hesaplama birimine iletilmesi ve sonrasında sonuçların yetkili noktalara bildirilmesi gerekmektedir. Fakat bu senaryoda hem toplanan kamera görüntülerinin sıkıştırılması, transcode işleminin yapılması ve görüntülerin diğer uç noktaya aktarılması hem uç platformda ek işlemler yapılmasına hem ağ trafiğinin artmasına hem de karar alınması konusunda gecikmeler yaşanmasına sebep olabilecektir. Eylemlere yönelik yaşanacak gecikmenin, gıda kaybının önüne geçebileceği durumlarda, bir otonom makinenin analiz ve eylem sürecini gerçek zamanlı olarak bir arada gerçekleştirmesi en yüksek faydayı sağlayacaktır. Bu sebeple geliştirilen modellerin uç sistemler odaklı olarak geliştirilip test edilmesi, hali hazırda güncel olarak üzerinde çalışılan bir konudur.

Bu karşılaştırmalı çalışmada, tarım alanına dair uygulamalı olarak gerçekleştirilen derin öğrenme tabanlı görüntü işleme yöntemlerinin incelemesi yapılmıştır. İncelemeye, 2018 yılından başlanarak benzer problemler üzerine odaklanılmış 17 adet makale çalışması konu olarak ele alınmıştır. Çalışmalarda kullanılan veri kümeleri, veri ön işleme yöntemleri, evrişimli sinir ağı mimarileri, model eğitimi için kullanılan yöntemler ve hiperparametreler ile nihai olarak başarımlar sonuçları tartışılmıştır. Sınıflandırma, nesne tespiti ve semantik bölütleme yöntemlerinin her biri için elde edilen örnek niteliğindeki yüksek başarımlar değerleri sayesinde, derin öğrenme yöntemlerinin insan eliyle yapılan ve yüksek iş gücü gerektiren birçok tarım tabanlı problemini otomatik bir şekilde çözebileceği görülmüştür. Fakat hali hazırda tarım alanı odaklı olarak yapılan çalışmaların büyük çoğunluğunun, otonom makinelerde çalışma üzerine odaklanmadan yapıldığı, tartışma ve sonuçlar bölümünde ortaya konulmuştur.

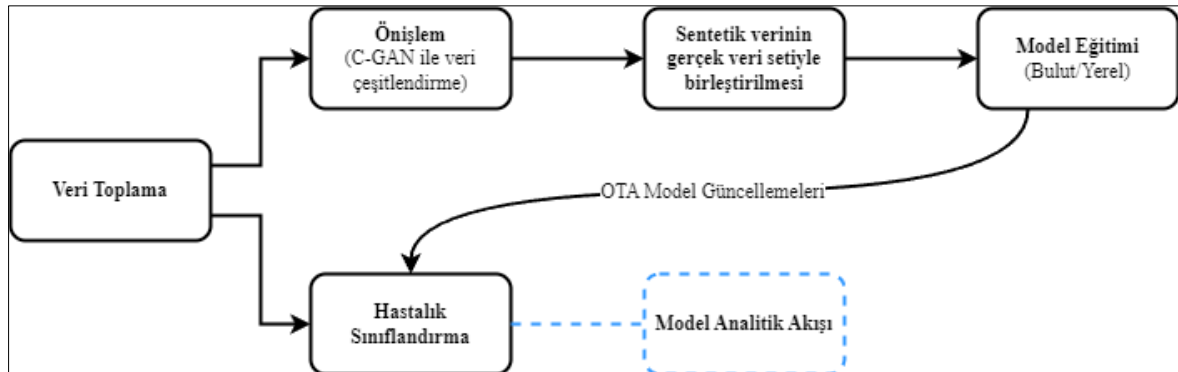
Derin öğrenme tekniklerinin, ilerleyen süreçte tarım alanındaki çeşitli problemlerin çözümüne yönelik uygulamaya konulmasının, daha verimli ve sürdürülebilir bir tarım-gıda zincirinin oluşturulmasına olumlu katkı sağlayacağı değerlendirilmektedir.

Literatürdeki birçok çalışmada karşılaşılan temel sorun ise geliştirilen derin öğrenme modellerinin yalnızca "Model Eğitimi" aşamasının başarımına (accuracy/F1-Score) odaklanmasıdır. Bu durum kümülatif olarak yüksek karmaşıklığa sahip yapay sinir ağı mimarilerinin ortaya çıkmasına sebep olmuştur. Ancak karmaşık sinir ağı mimarileri oluşturmak, tarım ve otonom sürüş gibi gömülü sistemlerin kullanıldığı robotik ve otonom sistemler gerektiren alanlar için donanımsal kısıt sorununu da beraberinde getirmektedir. Çünkü model çıkarımı, veri görselleştirme ve iş akışı dağıtım performansının da gömülü ve uç sistemler için mümkün olduğunca verimli olması beklenmektedir. Yüksek başarımlı ve genelleştirilebilir derin öğrenme modellerinin elde edilebilmesi için yüksek miktarda veri ve hesaplama kabiliyetine sahip donanımlar gerekmektedir. Fakat Öğrenme Aktarımı yöntemi sayesinde az veri ile yüksek başarımlı modelleri kısa sürelerde eğitmek mümkün hale gelmiştir.

3. YÖNTEM VE ARAÇLAR

Günümüzde hala gelişmekte olan ve yeni mimariler eklenen derin öğrenme alanında, farklı görüntü işleme problemleri için var olan modeller farklı başarımlar, genelleştirme ve çıkarım anı performansı sunmaktadır. Bu tezde tek bir mimariden yüksek başarımlar elde etmek yerine, endüstride yaygın bir şekilde kullanılan sekiz temel evrişimli sinir ağı mimarisi kullanılarak farklı katman sayıları ve hiperparametreler ile toplamda yirmi adet sinir ağı kombinasyonu üzerinde kıyaslama yapılmıştır.

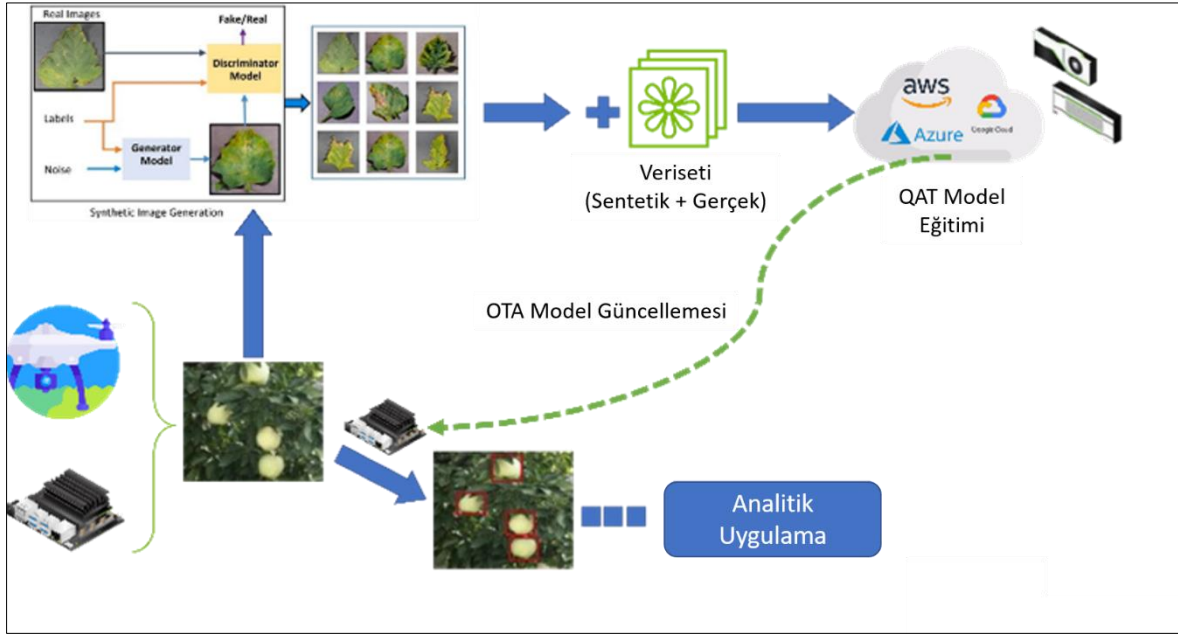
Bu sınıflandırma modelleri, çevrimdışı veri çeşitlendirme yöntemleri kullanılarak genişletilmiş olan PlantVillage veri seti eğitilmiştir. Bu veri setinin orijinalinde 54 306 görüntü; 14 farklı bitki çeşidi ve 26 farklı bitki hastalığı bulunan, toplamda 38 sınıf altında toplanmıştır.



Şekil 3.1. Veri toplama, önilem ve model eğitimi akış diyagramı

Süreç aşamalara bölüldüğünde; ilk adımda sahada çalışan robot veya drone üzerindeki kamera, sensör veya gömülü sistemden veri elde edilmiştir. Bir sonraki aşama eş zamanlı olarak çalışan iki ayrı iş akışına bölünmüştür. Bu akışların birinde elde edilen veri, C-GAN ile veri çeşitlendirme işlemine tabi tutularak, gerçek veri ile üretilen sentetik verinin birleştirilmesi sağlanmış bir şekilde model eğitim sürecine dahil edilirken; diğer akışta ise hali hazırda cihaz üzerinde çalışan modele gerçek zamanlı girdi olarak verilmiştir. Model eğitim süreci sürekli olarak devam ederken, elde edilen nihai modelin başarımlarını eğer Hastalık Sınıflandırma adımıyla çalışan modelden yüksekse, OTA yöntemiyle model güncellemesi gerçekleştirilmiştir.

3.1. Veri Toplama, Önışlem ve Model Eğitimi



Şekil 3.2. Veri kümesi oluşturma ve sürekli model eğitimi iş akışı

İlk aşama, 3.7. Veri Seti bölümünde bahsedilen PlantVillage veri setinin, yetersiz sayıda veri olması ve sınıflar arası veri sayısındaki dengesizliği sebepleriyle 3.1.7. Veri Çeşitlendirme bölümünde bahsedilen metotlarla çeşitlendirilmesiydi. Bu görüntüler daha sonra nesne tespiti için ilgili özniteliklerin çıkarılması amacıyla NVIDIA TAO Toolkit kullanılarak model eğitime dahil edilmiştir.

Veri setini genişletmek için üretken çekışmeli ağ tarafından oluşturulan sentetik veriler ile çeşitli çiftliklerden toplanan gerçek dünya verilerinin bir kombinasyonu, çalışmanın geri kalanında sürekli model eğitimi süresince başarıyı artırmak için kullanıldı. Bu yaklaşım, modelin sürekli farklı bir veri kümesi üzerinde eğitilmesini ve böylece daha geliştirilebilir bir model elde edilmesini sağlamıştır.

3.2. Nicelme Farkındalıklı Eğitim

Model niceleme hem parametrelerin hem de aktivasyon çıktılarının kayan nokta gösteriminden genellikle 8-bitlik tam sayılar kullanılarak daha düşük hassasiyetli bir gösterime dönüştürüldüğü bir derin öğrenme optimizasyon yöntemidir.

Model niceleme işleminin, model eğitim sürecinde sağlayacağı faydalar aşağıda sıralanmıştır:

- Grafik kartları, 8-bitlik tamsayı verilerini işlerken, evrişim ve matris çarpımı işlemlerini hesaplamak için daha hızlı ve daha az maliyetli 8-bit tensör çekirdeklerini kullanır. Bu sayede, özellikle hesaplama zorluğu yüksek katmanlardan daha yüksek hesaplama verimi elde edilmesi mümkün hale gelir.
- Verilerin grafik kartı belleğinden hesaplama çekirdeklerine taşınması, zaman ve enerji maliyeti yüksek bir işlemdir. Aktivasyon sonuçlarını ve parametre değerlerinin hassasiyetini 32-bitlik ondalıklı sayılardan, 8-bitlik tam sayılara indirgemek, 4 kat daha az veri üzerinde hesaplama yapılmasını ve dolayısıyla güç tasarrufu sağlar.
- Bazı katmanların hesaplama performansı, bant genişliğine bağlıdır. Bu durum, belirtilen katmanlarda harcanan hesaplama zamanının çoğunu veri okuma ve yazmaya harcanmasına ve bu nedenle sadece işlem sürelerini azaltmanın, bu katmanlarda harcanan genel zamanı azaltmadığı anlamına gelmektedir. Bant genişliği performansına bağlı olan katmanlar, tam sayılar sayesinde azaltılmış bant genişliği ihtiyacından büyük bir fayda sağlamaktadır.
- İndirgenen sayısal değerler sayesinde düşürülen bellek alanı ihtiyacı, modelin daha az depolama alanı gerektirmesi, parametre güncellemelerinin daha küçük olması ve önbellek kullanımının artırılması gibi birçok fayda sağlar.

Model niceleme işleminin yukarıda belirtildiği üzere birçok faydası bulunmaktadır ancak parametrelerin ve verilerin hassasiyetindeki azalma bir modelin tutarlılık sonuçlarının düşmesine sebep olabilir. 32-bit ondalıklı değer aralığında $[-3,4 \times 10^{38}, 3,4 \times 10^{38}]$ yaklaşık 4 milyar sayının temsil edilebileceği bu aralık, dinamik aralık olarak da bilinmektedir. Bu durumda temsil edilebilir iki komşu değer arasındaki uzaklık, hassasiyeti göstermektedir [36].

Ondalıklı sayılar, dinamik aralıkta eşit olmayan bir dağılıma sahiptir ve temsil edilebilir ondalıklı sayıların yaklaşık yarısı $[-1,1]$ aralığındadır. Dolayısıyla $[-1,1]$ aralığındaki temsil edilebilir sayılar, $[1,2]$ aralığındaki sayılardan daha yüksek hassasiyete sahip olacaktır [36].


$[1,1]$ aralığındaki temsil edilebilir 32-bit ondalıklı sayıların yoğunlukta olması, parametrelerin ve verilerin dağılımının çoğunluk olarak sıfır civarında olduğu derin öğrenme

modellerinde faydalı hale gelmektedir. Ancak 8-bitlik bir tamsayı temsili kullanarak yalnızca 2^8 farklı değer temsil edilebilir. Bu 256 değer, daha yüksek hassasiyet için eşit veya eşit olmayan bir şekilde sıfır civarında dağıtılabilir. Genel kullanım amaçlı tüm derin öğrenme donanım ve yazılımlarında, hesaplamalar için yüksek verimli paralel veya vektörleştirilmiş tamsayı matematik akışları kullanıldığından, eşit dağılım üzerinden temsil yöntemi tercih edilmektedir [36].

Ondalıklı sayı tensörünün (x^f) temsilini 8-bitlik gösterime (x_q) dönüştürmek için, ondalıklı sayı tensörünün dinamik aralığını $[-128, 127]$ 'ye eşlemek amacıyla bir ölçek faktörü kullanılır [36]:

$$x_q = \text{clip}(\text{round}(\frac{x^f}{\text{scale}})) \quad (3.1)$$

Bu işlem, dinamik aralık orijine göre simetrik olduğundan simetrik nicelemedir. *round*, rasyonel sayıları tam sayılara yuvarlamak için kullanılan; *clip* ise, $[-128, 127]$ aralığının dışında kalan aykırı değerleri kıran bir fonksiyondur. Çalışma kapsamında modelin çalışma anı performans optimizasyonu için kullanılan NVIDIA TensorRT, hem aktivasyon değerlerini hem de model ağırlıklarını temsil etmek için simetrik niceleme kullanmaktadır [36].



Şekil 3.3. Kayan nokta tensörü x^f 'in 8-bitlik işaretli tamsayı nicelemesi [36]

Şekil 3.3.'ün üst bölümünde, x^f ondalıklı sayı tensör elemanlarının dağılımının bir histogramı olarak gösterildiği hayali bir diyagram yer almaktadır. Nicelenmiş tensörde temsil etmek için ise $[-amax, amax]$ olarak simetrik bir katsayı aralığı seçilmiştir. Burada, $amax$ temsil edilecek en büyük mutlak değere sahip elemandır. Niceleme ölçeğini hesaplamak için ise ondalıklı sayı dinamik aralığı 256 eşit parçaya bölünmüştür [36]:

$$amax = \max(abs(x^f)) \quad (3.2)$$

$$scale = \frac{(2 \times amax)}{256} \quad (3.3)$$

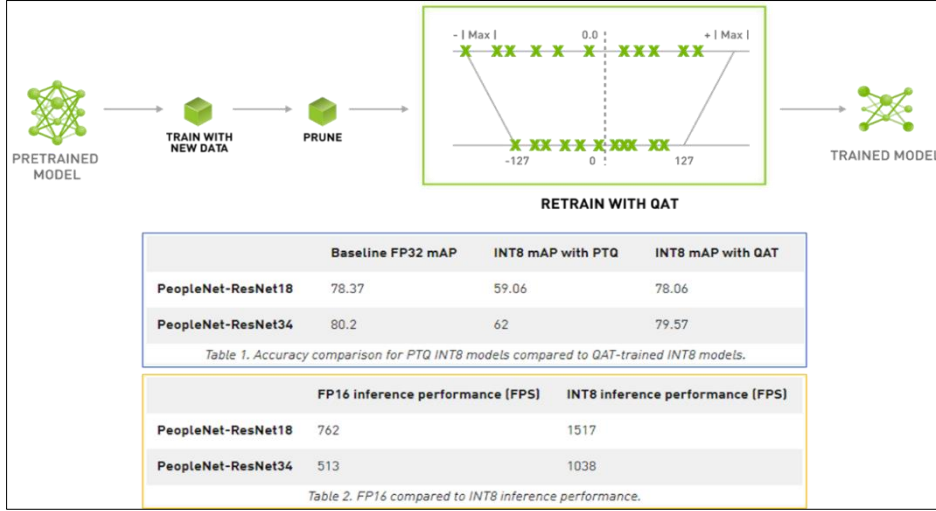
Burada ölçeği hesaplamak için gösterilen yöntem, 8-bitlik tam sayılarla temsil edilebilecek tam aralık olan $[128, 127]$ 'yi kullanır. TensorRT Explicit Precision (Q/DQ) ağları, ağırlıkları ve aktivasyonları nicelerken bu aralığı kullanır [36].

8-bitlik tamsayıları kullanarak temsil etmek için seçilen dinamik aralık ile yuvarlama işleminin getirdiği hata arasında bir bağlantı bulunmaktadır. Daha geniş bir dinamik aralık, orijinal ondalıklı sayı tensöründen nicelenmiş tensörde daha fazla değer temsil edilmesi anlamına gelmektedir. Ancak aynı zamanda daha düşük bir hassasiyet kullanılması ve daha büyük bir yuvarlama hatasının ortaya çıkmasına sebep olmaktadır [36].

Daha küçük bir dinamik aralık seçmek ise yuvarlama hatasını azaltacak fakat bir kırpma hatası oluşturacaktır. Dinamik aralığın dışında kalan ondalıklı sayı değerleri, dinamik aralığın en küçük ve en büyük değerine göre kırılmaktadır [36].

Hassasiyetin azaltılmasının, görev doğruluğu üzerindeki olumsuz etkilerini azaltmak için çeşitli niceleme teknikleri geliştirilmiştir. Bu tekniklerden bir tanesi de niceleme farkındalıklı eğitimidir (QAT) [36].

Niceleme Farkındalıklı Eğitim, eğitim aşaması sırasında azaltılmış hassasiyete sahip aritmetik hesaplamaların etkisini simüle etmek için nicelemenin etkilerini ortaya koyar. QAT yönteminde hem ağırlıklar hem de aktivasyonlar eğitim sırasında tipik olarak 8-bitlik tamsayılara (INT8) indirgenir.



Şekil 3.4. Niceleme farkındalıklı eğitim yönteminin akıştaki yeri ve başarıma etkisi

Jacob ve diğerleri [37] yaptığı çalışmalarda, QAT yöntemiyle ağırlıklar ve aktivasyonlar 8 bitlik tamsayılar nicelendiğinde bile modeller eğitilirken orijinal hallerine yakın doğruluk elde edilebildiğini göstermişlerdir. Ek olarak yapılan Banner ve diğerleri [38]'nin yaptığı çalışmada, ImageNet veri seti üzerinde ResNet-50 gibi yüksek karmaşıklığa sahip modeller için model eğitim doğruluğunda %1'den daha az bir düşüş olduğu gösterilmiştir.

3.3. Otomatik Karma Hassasiyet

Otomatik Karma Hassasiyet (AMP), float32 ve float16 aritmetiğinin bir karışımını kullanarak sinir ağı eğitimini optimize etmek amacıyla kullanılmaktadır. AMP, işlemin hassasiyet değişikliklerine olan duyarlılığına bağlı olarak her işlemin hassasiyet değerini dinamik olarak seçer.

Bu optimizasyon işleminin matematiksel karşılığı ise aşağıdaki şekilde gösterilebilir:

$$\text{İleri yayılım aşaması: } y = f(x^{float16}) \quad (3.3)$$

$$\text{Geri yayılım aşaması: } \frac{\partial L}{\partial x} = \frac{\partial L^{float32}}{\partial y} \cdot \frac{\partial y^{float32}}{\partial x} \quad (3.4)$$

Gösterilen eşitliklerde x ve y katmanın girdi ve çıktıları; L ise kayıp fonksiyonunu temsil etmektedir.

NVIDIA firması, bu çalışmada da kullanılan NVIDIA TAO Toolkit içeriğinde gelen Otomatik Karma Hassasiyet özelliğinin, model eğitim sürelerini üç kata kadar ve bellek kullanımını %50'ye kadar azaltabildiğini ve aynı zamanda tam hassasiyete sahip eğitim doğruluk oranlarıyla karşılaştırılabilir doğruluğu koruduğunu belirtmektedir [39]. Konu ile ilgili olarak verilen örneğe göre; bir BERT modelini, GLUE karşılaştırmalı testinde AMP ile eğitmek, tam hassasiyetli eğitime kıyasla yalnızca %0,1'lik bir doğruluk farkıyla sonuçlanırken, iki buçuk kat hızlanma elde edilmesini sağlamaktadır [40].

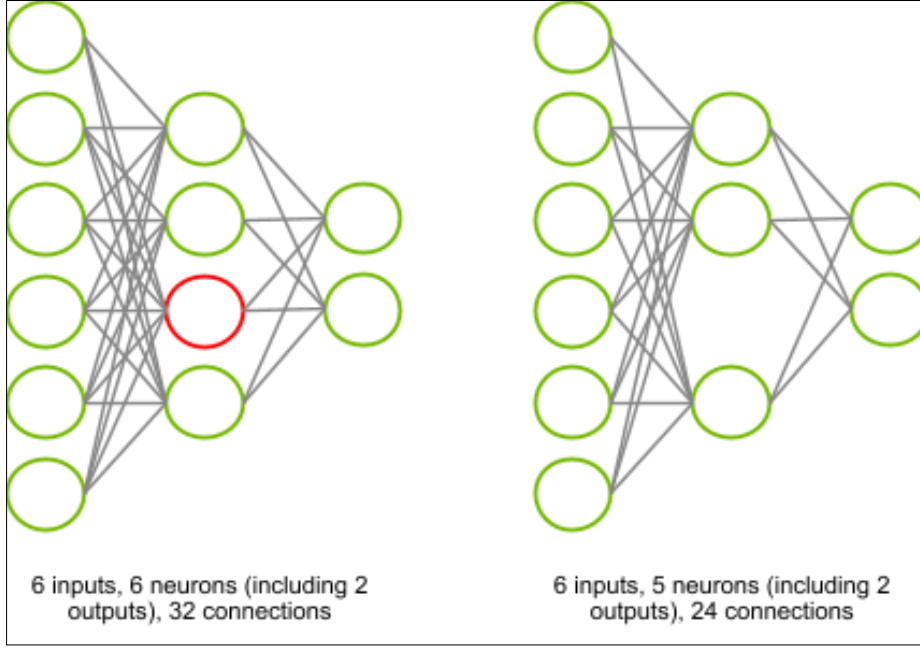
3.4. Çevresel Uyarlama

Çevresel Uyarlama teknikleri, bir modelin daha önce eğitildiği veri setindeki çevresel özniteliklerden, hedef görevin ve ilişkili veri setinin özniteliklerine genelleştirebilme kabiliyetini artırmaktadır. Bu tekniklerden en yaygın olanı, öznitelik çıkarıcının çevresel faktörlere bağlı olarak değişmeyen öznitelikler çıkarmasını sağlamak amacıyla çekişmeli etki alanı model eğitimini içerir.

Ganin ve diğerleri [41], çekişmeli etki alanı sinir ağlarının, çevresel alan uyarlaması olmadan eğitilen modellere kıyasla, hedef görevin veri setinde yer alan çevresel etmenler üzerindeki genelleştirme başarımında %5'e kadar bir artış elde edilebildiğini göstermiştir. Tarım uygulamalarında çevresel uyarlamanın, sentetik veriler üzerinde eğitilen modeller gerçek dünya tarla verilerine uyarlandığında, sınıflandırma modellerinin nihai doğruluğunu %4-6 oranında artırdığı görülmüştür [42].

3.5. Model Budama

Model budama, sinir ağı mimarisindeki sonuç için daha az önemli olan ağırlıkları ve nöronları kaldırarak, sinir ağlarının boyutunu ve karmaşıklığını azaltma işlemidir. Budama işlemi, ağırlıkların büyüklüğü gibi çeşitli etkenler üzerinde uygulanabilir.



Şekil 3.5. Sinir ağı mimarisinden 1 nöron çıkarılarak bağlantı sayısının azaltılması

Model budama işleminin uygulanışı ile ilgili olarak Şekil 3.5'te örnek bir Çok Katmanlı Perceptron (MLP) [43] ağı mimarisi gösterilmiştir. Bu örnek mimariden yola çıkarak, gizli katmandaki kırmızı ile işaretlenmiş nöronun, sinir ağının sonuçlarına çok büyük bir etkisi olmadan silindiği varsayıldığında, hesaplanması gereken $(2 \times 4) + (4 \times 6) = 32$ parametre, $(2 \times 3) + (3 \times 6) = 24$ parametreye düşürülerek, toplam hesaplama maliyetinde ve parametrelerin bellekte tutulması kapsamında %25'lik bir kazanç sağlanmış olur. MLP yapısındaki l katmanında yer alan bir nöron i 'nin aktivasyonu $x_{l,i}$ 'yi hesaplamak için verilen F fonksiyonu, bir ağırlık vektörü olan $w_{l,i,j}$ ve bir yanlılık (bias) değeri olan $b_{l,i}$ ile matematiksel formülasyon açısından, hesaplama maliyeti yüksek olan ağırlıklandırılmış girdilerin toplamı işlemine bakılacak olursa, eşitlik 3.5 elde edilecektir [44]:

$$x_{l,i} = F(\sum_j w_{l,i,j} \times x_{l-1,j} + b_{l,i}) \quad (3.5)$$

Bu çalışma kapsamında model eğitimi için kullanılmış olan NVIDIA TAO Toolkit, model budama işlemi sırasında eşitlik 3.5'te verilmiş olan b yanlılık değerini dikkate almamaktadır. Bu durumun sebebi, budama işleminin herhangi bir Derin Öğrenme kütüphanesinde uygulanmasının kolaylaştırılmasıdır [44].

Tam bağımlı katman kapsamında yapılan nöron bazında budama işlemine ek olarak,

NVIDIA TAO Toolkit kapsamında daha önceki aşamalarda yer alan evrimsel katmanlarda da bütün bir filtrenin kaldırılması söz konusudur [44].

Budama işlemi için TAO Toolkit kapsamında kullanılan yöntemler, Veri Odaklı Budama ve Veriden Bağımsız Budama olarak iki ayrı başlık altında incelenmiştir. Veri Odaklı Budama, nöronları teker teker yinelemeli olarak kaldırmayı ve her kaldırma işleminden sonra, modelin yeniden doğrulama veri kümesi üzerinde başarımının ölçülmesini içerir. Doğrulama ölçümünde en küçük azalmaya neden olan nöron, en gereksiz olarak kabul edilir ve kaldırılır. Bu işlem, istenen budama düzeyine ulaşılan kadar tekrarlanır. Fakat bu işlem çok fazla iş yüküne sebep olacağından, Yan LeCun ve arkadaşlarının yaptığı çalışmada [45], bunun yerine m 'nin ölçüt fonksiyon, x 'in sinir ağı parametrelerinin güncel değeri ve u 'nun bir nöronun ağırlıklarını 0'a eşitlemek olduğu $m(x + \delta u)$ ölçütünün yerel bir yaklaşımının hesaplanabileceği ima edilmiştir. Bu yaklaşım aşağıdaki eşitlikte görülebileceği şekilde temsil edilebilir [44]:

$$m(x + u) = \sum_{i=0}^{\infty} \frac{m^{(i)}(x)}{i!} u^i \quad (3.6)$$

Eşitlik 3.6'ya göre; $m^{(i)}$ fonksiyon m 'nin i 'nci türevidir. Ölçütün sadece u ile nasıl değiştiğiyle ilgilenildiğinden, tek dikkate alınması gereken durum, bu fonksiyonun türevleridir. Optimal Brain Damage (OBD) makalesine göre [45], ağıın hali hazırda yakınsadığı ve yerel bir minimuma ulaştığı varsayıldığından, birinci dereceden türevlerin sıfıra yakın olması ve ikinci dereceden türevlerin bilginin çoğunu taşıması gerektiği iddia edilmektedir [44].

Veriden Bağımsız Budama yöntemi ise, en küçük ağırlık değerlerine sahip nöronların en az önemli nöronlar olduğu yaklaşımına dayanan, en basit nöron seçim yöntemidir ve veriye ihtiyaç yoktur. Bu işlemde, aktivasyona dayalı nöron seçimine benzer olarak öğrenme sürecinde önemli bir değişiklik yapılmadığı sürece, büyük ağırlıklara sahip nöronlar “cezalandırılmaktadır”. Bu teknik yaygın olarak kullanılan ağırlık-düşüm düzenlenileştirilme (weight-decay regularization) olarak adlandırılır ve toplam hata değeri L_{toplam} 'a bir terim daha ekleyerek, eşitliği optimize etme sürecini kapsar:

$$L_{toplam} = L + \lambda \sum_i \| W_i \|^2 \quad (3.7)$$

Eşitlik 3.7’de; L temel hata değeri fonksiyonu ve W_i modelin ağırlıklarıdır. Burada sadece temel hata değerine etkisi olan ağırlıkların, yüksek ağırlık değerlerine sahip olmasına imkân sağlayan bir düzenleme eklenmektedir. Bu eşitlik TAO Toolkit kapsamında programatik olarak bir API çağrısına dahil edilmiştir. Böylece sadece bir komutla eşitlik, eğitim döngüsünün dışında çalışarak sadece ağırlıkları inceler ve normu belirlenen bir eşik değeri t ’nin altında olan tüm nöronları budar: “pruned_model = TLT.prune(model, t)”.

Han ve arkadaşları tarafından yapılan bir çalışmaya göre, görmezden gelinebilecek bir doğruluk kaybıyla AlexNet’teki parametre sayısında dokuz kat; VGG-16’da ise on üç kat azalma elde edilebilmiştir [46]. Ek olarak farklı bir çalışmada ise Li ve diğerleri (2020) [47], budama işleminin gömülü sistemlerde model çıkarım hızını beş kata kadar artırabildiğini ve orijinal modelle elde edilen başarımdan % 1-2’lik bir sapmayla, modelin başarımının korunabildiği belirtilmiştir:

Nicelik Farkındalıklı Eğitim, Otomatik Karma Hassasiyet, Çevresel Uyarılma ve Model Budama tekniklerinin kullanılmasıyla, sınıflandırma modellerinin gömülü sistemlerde tarımsal uygulamalara yönelik çalıştırılması daha makul hale gelmekte ve kısıtlı donanım kabiliyetlerinin olduğu cihazlarda bile hızlı ve yüksek doğruluğa sahip gerçek zamanlı analitiğe olanak sağlanabilmektedir.

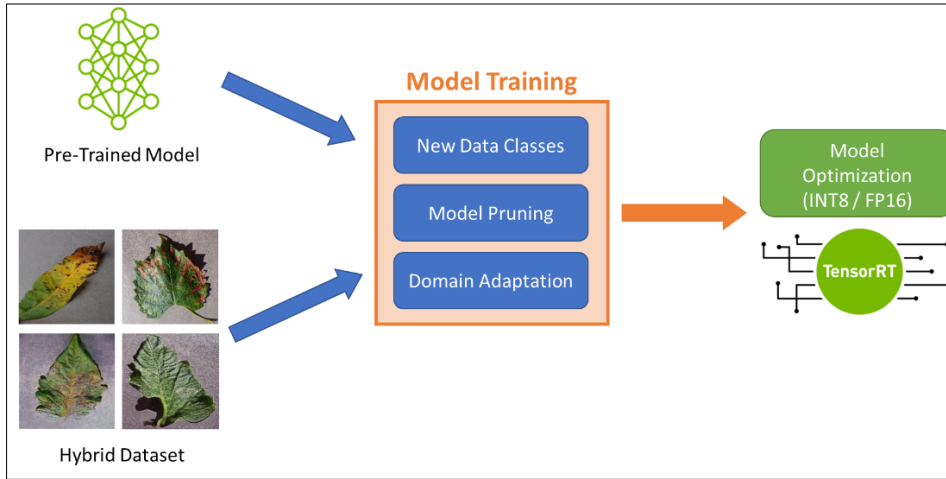
Model eğitimi sırasında Nicelik Farkındalıklı Eğitim, Otomatik Karma Hassasiyet ve Model Budama tekniklerini kullanarak sınıflandırma modellerini eğitmek için NVIDIA GPU’ları üzerinde çalışan NVIDIA TAO Toolkit’ten yararlanılmıştır. Elde edilen modeller, sahada konuşlandırılan mevcut bir modele göre sürekli olarak değerlendirilip başarımdan kıyaslanmıştır.

3.6. Kablosuz Şebeke Yoluyla Model Güncelleme

Kablosuz Şebeke Yolu (OTA-Over the Air Update) güncellemeleri, yazılım veya alt elemanların güncellemelerini, uçtaki cihazlara kablosuz olarak iletmeyi sağlayan bir yöntemdir. Gömülü sistemlerde tarımsal uygulamalara yönelik sınıflandırma modellerinin uygulamaya konulması açısından, cihazlara fiziksel erişim gerekmeden, modellerde kesintisiz ve uzaktan iyileştirmelere olanak tanınmasıyla Kablosuz Şebeke Yolu güncellemeleri büyük bir avantaj sağlar.

Kablosuz Şebeke Yolu güncellemeleri; yeni yazılım versiyonlarının, cihaz bellek versiyonlarının veya bu çalışma için derin öğrenme modellerinin sahada konuşlandırılan gömülü sistemlere kablosuz olarak gönderilmesi sürecini ifade eder. Bu yaklaşım, cihazların özellikle tarım alanları düşünüldüğünde geniş, kırsal bölgelerde çalıştırılabileceği ve güncellemeler için her cihaza fiziksel olarak erişmenin mümkün olmadığı veya yüksek maliyetli olacağı tarımsal uygulamalarda özellikle faydalıdır.

Yeni modelin daha iyi bir başarıya ulaşması durumunda, tarım uygulamaları için en doğru sınıflandırma yeteneklerinin mevcut olmasını sağlamak üzere önceki modelin yerine yeni model, Kablosuz Şebeke Yoluyla Model Güncelleme yöntemiyle uygulamaya konulmuştur.



Şekil 3.6. Model eğitim ve optimizasyon sürecindeki yöntem ve araçlar

Eğitilen model daha sonra TensorRT kütüphanesi kullanılarak Jetson AGX Orin Developer Kit 32GB’de uygulamaya koyma için optimize edilmiştir.

3.7. Veri Seti

PlantVillage veri seti, tarım üzerine yapılan yapay zekâ ve derin öğrenme çalışmalarında, özellikle bitki hastalıklarının sınıflandırılması ve tespiti için yaygın bir şekilde kullanılan bir veri setidir. Çiftçilere ve tarım alanındaki yatırımcılara, ürün geliştirme konusunda avantaj sağlayabilmeleri için teknolojiden yararlanmayı amaçlayan PlantVillage projesinin bir parçası olarak geliştirilen bu veri seti, sağlıklı ve hastalıklı bitki yapraklarının yüksek kaliteli görüntülerinden oluşan kapsamlı bir kaynaktır. Veri setindeki görüntüler, elma, üzüm, mısır

ve patates gibi çeşitli mahsulleri kapsamaktadır ve her mahsul için birden fazla hastalık sınıfı içermektedir.

PlantVillage veri setinin temelinde en büyük avantajlarından biri ölçeği ve sunduğu veri çeşitliliğidir. Bitki hastalıkları ve sağlıklı yapraklara ilişkin 38 sınıfa ait 54,000'den fazla görüntü içerir. Veri setinin sahip olduğu kapsam, bu veri kümesi üzerinde eğitilen modellerin, farklı bitki sağlığı koşullarıyla bağlantılı olarak birçok çeşitlilikte görsel öznitelikleri öğrenmesini sağlayarak, bu modellerin çeşitli gerçek dünya senaryolarına uyum sağlayabilmelerini ve modellerin bu koşullar için daha iyi genelleştirilebilmelerine imkân tanır. Ek olarak bu veri seti, görsel gürültüyü ve öğrenmeyi olumsuz etkileyebilecek yabancı unsurları en aza indirgeyen, düz renklerde arka plana sahip ve kontrollü koşullar altında alınan görüntüler içerir. Bu sayede görüntü tabanlı derin öğrenme modellerinin geliştirilmesi ve kıyaslanabilmesi açısından birçok imkân sağlar.

PlantVillage veri seti, aynı zamanda diğer tarımsal veri setleriyle kıyaslandığında birçok avantaja sahiptir. İlk olarak, veri sayısı ve çeşitliliği, yüksek doğruluk değerleri elde etmek için genellikle büyük miktarda veri gerektiren derin öğrenme modellerinin eğitimi için kritik öneme sahiptir. Diğer birçok tarımsal içerikli veri seti, çeşitlilik eksikliği veya sınırlı veri sayısı; genellikle tek bir bitkiye veya sınırlı sayıda hastalık sınıfına odaklı olarak, bu veri setleri üzerinde eğitilen modellerin genelleştirilebilirliğini kısıtlamaktadır. Özetle PlantVillage veri setinin geniş kapsamı, daha fazla boyutlu ve yüksek doğrulukta modellerin geliştirilmesine olanak sağlamaktadır.

İkinci olarak, tekrarlanabilirliğe ve karşılaştırmalı çalışmalara olanak sağlayan PlantVillage veri seti açık kaynaklıdır. Bu sayede araştırmacılar, öğrenciler ve ticari ürün geliştiricileri, veri setine kolayca erişebilir ve kendi modellerini tarım alanındaki diğer çalışmalarla karşılaştırabilmektedirler. Böylece tarım alanındaki derin öğrenme ve yapay zekâ çözümlerinin geliştirilmesinde tartışmalı sonuçları önler ve iyileştirme konusundaki devamlılığı sağlar.

Literatürdeki karşılaştırmalı çalışmalar, PlantVillage veri setinin yüksek doğruluklu derin öğrenme modellerinin elde edilmesi sürecini kolaylaştırma konusundaki etkinliğini göstermiştir. Örneğin, endüstri standardı haline gelmiş çeşitli evrişimli sinir ağları (Convolutional Neural Networks-CNN) bu veri seti üzerinde eğitilmiş, doğrulanmış ve

yüksek doğruluk oranlarına ulaşılmıştır. Yapılan bazı çalışmalarda AlexNet, VGG16 ve ResNet50 gibi modeller ile elde edilmiş %90'dan yüksek sınıflandırma doğruluğu sonuçları, veri setinin hassas ve güvenilir bitki hastalığı tespit sistemlerinin geliştirilmesini destekleyebileceğini göstermiştir.


Ayrıca PlantVillage veri setinin kategorize edilmiş ve etiketlenmiş içeriği, güçlü derin öğrenme modellerinin geliştirilmesinde kritik öneme sahip olan veri ön işleme ve veri artırma sürecini basitleştirmektedir. Her bir görüntü, ilgili bitki türü ve hastalık kategorisiyle etiketlenmiştir. Bu sayede çeşitli derin öğrenme akışlarına hiçbir ek ön işlem yapmadan doğrudan entegrasyona olanak tanımaktadır. Bu yapısal yaklaşım aynı zamanda, özellikle gömülü sistemler gibi hesaplama kaynaklarının kısıtlı olduğu cihazlarda, model çalışma performansını önemli ölçüde artırabilen öğrenme aktarımı ve ince ayar gibi tekniklerin uygulanmasını da kolaylaştırmaktadır.

Açıklandığı üzere PlantVillage veri seti, tarımsal alanda görüntü tabanlı araştırma ve bitki hastalıkları tespiti konularında önemli bir kaynak haline gelmiştir. Kapsamlı içeriği, açık kaynak olarak erişilebilirliği ve derin öğrenme modellerini karşılaştırmaya imkân sağlaması konularındaki kanıtlanmış etkinliği, diğer tarımsal veri setlerine kıyasla avantaj sağlamaktadır. Gömülü sistemlerde tarımsal uygulamalara yönelik nesne algılama ve sınıflandırma modellerinin geliştirilmesinde bu veri setinin kullanılması, bu alanda daha hızlı ilerleme sağlamayı, daha yüksek doğruluklu ve erişilebilir tarım uygulamalarına ulaşımı kolaylaştırmaktadır.

Çalışma kapsamında, PlantVillage veri seti üzerinde Veri Çeşitlendirme başlığı altında sunulmuş olan veri çeşitlendirme yöntemleri uygulanmıştır. Uygulama sonucunda 54,306 olan görüntü sayısı toplamda 87,867'ye çıkarılmıştır. Daha sonra %75-%25 oranıyla eğitim ve doğrulama veri seti olarak ikiye ayrılmıştır. Veri setinin artırılmış versiyonu, hali hazırda bu ayırım oranına sahip olduğundan ek olarak bir ayırma işlemi uygulanmamıştır. Test veri seti olarak 38 sınıftan rastgele bir şekilde toplamda 286 görüntü toplanmıştır. Sonuç olarak veri seti ayrımı; 70,295 eğitim, 17,572 doğrulama ve 286 test olacak şekilde elde edilmiştir. Veri setinin sahip olduğu sınıflar aşağıda listelendiği şekildedir:

1. Apple_scab
14. Grape_leaf_blight
27. Strawberry_healthy

- | | | |
|---------------------------|---------------------------|--------------------------------|
| 2. Apple_black_rot | 15. Grape_healthy | 28. Strawberry_leaf_scorch |
| 3. Apple_ced._ap._rust | 16. Orange_haunglo. | 29. Tomato_bacterial_spot |
| 4. Apple_healthy | 17. Peach_bacterial_spot | 30. Tomato_early_blight |
| 5. Blueberry_healthy | 18. Peach_healthy | 31. Tomato_healthy |
| 6. Cherry_pow._mildew | 19. Pepper_bacterial_spot | 32. Tomato_late_blight |
| 7. Cherry_healthy | 20. Pepper_healthy | 33. Tomato_leaf_mold |
| 8. Corn_gray_leaf_spot | 21. Potato_early_blight | 34. Tomato_sept._leaf_spot |
| 9. Corn_common_rust | 22. Potato_healthy | 35. Tomato_spider_mites |
| 10. Corn_north._leaf_bli. | 23. Potato_late_blight | 36. Tomato_target_spot |
| 11. Corn_healthy | 24. Raspberry_healthy | 37. Tomato_mosaic_virus |
| 12. Grape_black_rot | 25. Soybean_healthy | 38. Tomato_yel._le._curl_virus |
| 13. Grape_black_measles | 26. Squash_powdery_mil. | |



Şekil 3.7. PlantVillage veri setinden örnekler (a) Peach Bacterial Spot, (b) Grape Black Measle, (c) Squash Powdery Mildew

Orijinal veri setindeki görüntülerin boyutları 256x256 ve kullanılan bütün model mimarileri 224x224 olarak önceden belirlendiği için veri setindeki görüntülerin her biri, eğitim anında modele beslenmeden önce yeniden boyutlandırılmıştır. Piksel kaybı yaşanması ihtimaline karşılık, doldurma (interpolasyon) yöntemi olarak BICUBIC doldurma yöntemi tercih edilmiştir.

3.8. Veri Çeşitlendirme

Veri çeşitlendirme, makine öğrenmesi ve derin öğrenme alanlarında, özellikle görüntü tabanlı tarım uygulamaları açısından kritik bir öneme sahiptir. Modellerin doğruluğunu ve genelleştirilmesini artırmaya yardımcı olabilecek varyasyonlar üretmek için eğitim verilerinin sistematik olarak düzenlenmesiyle gerçekleştirilir. Bu durum, özellikle

modellerin deęişken gerçek dünya koşulları altında daha güvenilir bir performans göstermesi gereken tarım uygulamalarında gereklidir.

Veri artırma birkaç temel amaca hizmet etmektedir; ilk olarak, elde edilmesi maliyetli ve zaman alıcı olan ek etiketli verilere ihtiyaç duymadan veri kümesinin sayısal boyutunu artırmayı sağlar. Çeşitli yöntemlerle yapay olarak yeni görüntüler üretilerek modeller daha fazla çeşitlilikte girdiler üzerinde eğitilebilir, aşırı uyum ihtimali azaltılabilir ve modelin daha önce maruz kalmadığı verilere daha iyi genelleştirilebilmesi kolaylaştırılır. İkinci olarak veri çeşitlendirme, gerçek dünya senaryolarını taklit edebilecek varyasyonlar üretilmesini sağlayabilir. Böylece modeller çevresel koşullar, ışık, mevsim ve tarımsal görüntüleri etkileyebilecek diğer faktörlerdeki deęişikliklere karşı daha uyumlu hale getirebilir.

Tarımsal çalışmalarda çeşitli veri artırma teknikleri uygulanabilir:

Rastgele gürültü (Random noise): Görüntülere rastgele gürültü eklenerek, modellerin kamera kalitesindeki deęişikliklere veya çevresel müdahalelere karşı daha dayanıklı olması sağlanabilir. Örneğin gürültü, düşük ışık koşullarında oluşabilecek karıncalanmayı veya kamera sensörlerinden gelen dijital gürültüyü simüle edebilir.

Renk deęişimi (Color augmentation): Görüntülerin renk dengesinde deęişiklik yapmak, farklı aydınlatma koşullarını simüle edebilir. Bu sayede, farklı ortamlardaki bitkilerin görünüşünü etkileyebilecek güneş ışığı veya yapay aydınlatmadaki deęişiklikleri yansıtacak şekilde renk tonlarının, doygunluğun ve parlaklığın deęiştirilmesi sağlanarak farklı durumlar karşılanmış olur.

Kırpma (Cropping): Görüntülerin rastgele kırılması, modellerin bitkinin farklı bölümlerine odaklanmasına yardımcı olabilir; bu da bitkinin belirli bölgelerinde ortaya çıkabilecek hastalıkların tanımlanmasına fayda sağlayabilir. Ek olarak, bitkinin yalnızca kısmi görüntüleri mevcut olduğunda bile modelin hastalıkları tanımlamayı öğrenmesine yardımcı olabilir.

Yoęunluk (Saturation): Görüntülerin doygunluğunun deęiştirilmesi, bitki rengindeki sağlık veya hastalık durumunu ayırt edebilecek farklılıkların öğrenilmesine yardımcı olabilir.

Yüksek doygunluk, renklerin canlılığını vurgulayabilirken; düşük doygunluk kapalı hava durumu veya gölgeli koşulları simüle edebilir.

Döndürme (Flipping): Yatay ve dikey döndürme, modelin, yönelimlerine bakılmaksızın bitkileri ve hastalıkları tanımayı öğrenmesini sağlayabilir. Bu durum, özellikle fiziksel olarak büyüyen veya birden fazla açıdan fotoğrafı çekilebilen bitkiler için kullanışlı olabilir.

Doygunluk (Contrast): Doygunluğun değiştirilmesi, modelin bitki dokusu ve rengindeki ince farkları ayırt etmesine yardımcı olabilir; bu da doğru hastalık teşhisi için kritik öneme sahip olabilir.

Ölçeklendirme (Scaling): Görüntülerin ölçeğinin değiştirilmesi, odaklanılan bitkinin boyutuna göre modelin olumsuz olarak etkilenmemesine yardımcı olabilir. Bitkiler, kameraya olan mesafeye veya görüntünün çözünürlüğüne bağlı olarak farklı ölçeklerde görünebileceğinden bu yöntem fayda sağlayabilir.

Rotasyon (Rotation): Görüntülerin rastgele açılarda döndürülmesi, bitkilerin yönelimine karşı modelin olumsuz etkilenmemesini sağlar. Bu durum, özellikle görüntülerin isteğe bağlı açılarda çekilebildiği senaryolarda kullanışlıdır.

Parlaklık (Brightness): Parlaklığın değiştirilmesi günün farklı zamanlarını veya değişen bulut örtüsünü simüle edebilir ve modelin farklı aydınlatma koşullarında genelleştirilmesine yardımcı olabilir.

Kaydırma (Translation): Görüntüyü farklı yönlerde kaydırmak, modelin merkezin veya kısmen odağın dışında olabilecek nesnelere veya hastalıkları tanımayı öğrenmesine yardımcı olabilir.

Derin öğrenme modellerinin daha az veriyle yüksek başarımlarına ulaşabilmesini sağlayan yöntemlerden bir tanesi, ham veri seti üzerinde uygulanan veri çeşitlendirme (data augmentation) işlemleridir. Veri çeşitlendirme, görüntülere ait renk kanalları ve geometrik bulunuşları üzerinde bir takım görüntü işleme algoritmalarının uygulanmasıyla tek bir görüntüden birçok farklı varyasyonda görüntünün elde edilebilmesini sağlar. Derin sinir ağları, insan gözünden farklı olarak görüntüleri birer anlamlı şekil veya renk olarak

algılamak yerine piksel tabanlı değerlerden algılama yoluyla çalıştığından, oluşacak her yeni varyasyon derin öğrenme modeli için yeni bir görüntü anlamına gelmektedir. Böylece tek bir görüntü sahnesinin farklı varyasyonlar ile derin öğrenme modeline beslenmesi sayesinde hem veri miktarı artırılmış olur hem de daha genelleştirilebilir bir model elde edilebilir.

Derin öğrenme uygulamalarında yaygın bir şekilde kullanılan on üç tane veri çeşitlendirme metodu aşağıdaki şekilde listelenebilir:

- Rastgele Gürültü (Random Noise)
- Kırpma (Cropping)
- Döndürme (Flipping)
- Ölçeklendirme (Scaling)
- Parlaklık (Brightness)
- Renk Değişimi (Color Augmentation)
- Yoğunluk (Saturation)
- Doygunluk (Contrast)
- Rotasyon (Rotation)
- Kaydırma (Translation)

Fakat tarım alanı gibi görüntü renk ve açı değerlerinin, görüntü içeriği açısından önem taşıyan durumlarda; örneğin bitki yaprakları, çiçekler ve meyveler ile ilgili çalışmalarda, yukarıda listelenmiş olan her yöntem uygulanmamaktadır. Renk kanallarında yapılacak değişimler Yeşil (Green) kanal üzerindeki problemi tanımlayan özneliklerin kaybolmasını sağlayabileceğinden tercih edilmemektedir. Benzer şekilde Yoğunluk ve Doygunluk yöntemleri de bitkiyi tanımlayıcı renk verisinde değişime sebep olabileceğinden ya çok düşük oranlarda uygulanmalı veya hiç uygulanmamalıdır. Literatür taraması sırasında hem gömülü sistem platformlarını hem de tarımsal bağlamı içeren on altı kadar ayrı makale bulunabildi. Ayrıca incelenen makalelerden dördü dışında tüm bu çalışmalarda veri çeşitlendirme yöntemlerinin farklı şekillerde uygulandığı görülmektedir. Özellikle, bahsedilen bu dört çalışmada PlantVillage veri setini genişletmeme kararı, modellerin performansını ham veriler üzerinde karşılaştırma niyetinden kaynaklanmıştır. Bu yaklaşım, çeşitlendirme tekniklerinin sebep olduğu görsel değişim etkisi olmadan sonuçların değerlendirilmesine olanak tanır. Bu seçimin ardındaki mantık, diğer çalışmalarda kullanılmış olan veri çeşitlendirme yöntemlerinin dağılımı ile de desteklenmektedir. Örneğin, yedi çalışmada rotasyon; beşinde döndürme ve ikişer çalışmada yansıtma, kaydırma, yoğunluk, renk değişimi ve parlaklık değişikliği uygulanmıştır. Öte yandan rastgele gürültü, kırpma, ölçeklendirme, doygunluk, tanımlama (definition), pozlama (exposure), Hue ve cGAN yöntemlerinin yalnızca birer çalışmada kullanıldığı görülmüştür.

Literatürdeki çalışmalarda kullanılan yöntemler incelendiğinde en çok kullanılan

yöntemlerin ham görüntülerin piksel ve kanal düzeyinde manipüle edilmesi olduğu görülmektedir. Uygulanan veri çeşitlendirme yöntemleri arasından ham görüntü işleme algoritmalarından farklı olarak en dikkat çeken ise Abbas ve diğerleri [24]'nin çalışmasıdır. Bu çalışmada Çekişmeli Üretici Ağ tabanlı cGAN modeli ile rastgele gürültüden sentetik veri üretilmiş ve yenilikçi bir şekilde sentetik veri üretimi sağlanmıştır.

3.9. Öğrenme Aktarımı

Etki alanı uyarlaması veya ince ayar işlemi olarak da adlandırılabilir olan öğrenme aktarımı, önceden eğitilmiş modellerin sınırlı etiketli verilere sahip yeni, modelin daha önce görmediği alanlar için iyi bir şekilde genelleştirilmesini sağlayan derin öğrenmenin bir alt alanıdır. Bu yaklaşım, nesne tespit modellerinin özellikle gömülü cihazlar üzerindeki çeşitli tarımsal uygulamalarda verimli bir şekilde uygulamaya konulmasına olanak sağlayarak bilgisayarlı görü alanında devrim yaratmıştır.

Öğrenme aktarımının ana fikri, spesifik bir görevi gerçekleştirmek üzerine eğitilen bir modelin, öğrenilen özniteliklerden yararlanılabilmesi ve bu özniteliklerin, alakalı başka bir görev için ince ayar sürecinde kullanılabilmesidir. Nesne algılama açısından bakıldığında bu durum, Common Objects in Context (COCO) veya PASCAL Visual Object Classes (VOC) gibi büyük ölçekli bir veri kümesi üzerinde önceden eğitilmiş bir modelin, bitkiler, yabani otlar ve hayvanlar gibi belirli tarımsal nesnelere algılamak için de uyarlanabileceği anlamına gelmektedir.

Öğrenme aktarımı süreci genel anlamda üç aşamadan oluşur: öznitelik çıkarımı, ince ayar ve uyarılama. İlk olarak, model girdi görüntülerinden öznitelikleri çıkarmak için önceden eğitilmiş model kullanılır. Bu öznitelikler, çok çeşitli ve farklı gerekliliklere sahip olan farklı uygulamalar için yararlı olabilecek kenarlar, dokular ve şekiller gibi genel görsel kavramları temsil etmek üzere öğrenilir. Daha sonra, önceden eğitilmiş modelin ağırlıkları üzerinde, hedef tarımsal uygulamaya özel sınırlı miktarda etiketli veri kullanılarak ince ayar işlemi yapılmıştır. İnce ayar süreci, modelin yeni göreve uyum sağlamasına ve göreve özgü öznitelikleri öğrenmesine yardımcı olmaktadır.

Uyarılama aşaması, hedef uygulama için mevcuttaki etiketli verilere dayanarak model ağırlıklarının güncellenmesi sürecidir. Bu süreç, birkaç katmanın yeniden eğitilmesi veya

ağın son katmanının etiketli yeni verilere göre güncellenmesi gibi çeşitli tekniklerle sağlanabilmektedir. Amaç, önceden eğitilmiş modelin yeni veri üzerindeki tahminleri ile hedef uygulamanın spesifik nesne algılama görevi arasındaki farkı en aza indirmektir.

Öğrenim aktarımının tarımsal uygulamalar için çeşitli avantajları vardır. İlk olarak, hesaplama kaynakları ve bellekleri nedeniyle kısıtlı donanımsal kabiliyetlere sahip olan gömülü cihazlarda hızlı bir şekilde uygulama geliştirmeye olanak sağlar. Önceden eğitilmiş bir modelden yararlanılarak kapsamlı bir yeniden model eğitimi veya büyük ölçekli veri toplama ihtiyacı azaltılır ve modeller bu cihazlarda uygulamaya konulmaya daha uygun hale gelir. İkinci durum, öğrenim aktarımı sınırlı etiketli verilerle tarımsal uygulamalarda nesne algılama performansını geliştirebilir. Bunun nedeni, önceden eğitilmiş modelin birçok farklı alanda yararlı olan genel görsel kavramları hali hazırda öğrenmiş olmasıdır.

Özetle, öğrenim aktarımı, büyük ölçekli veri kümelerinden öğrenilen özniteliklerden yararlanılarak ve bu öznitelikleri ince ayar ve uyarlama yoluyla hedef uygulamaya uyarlayarak nesne tespit modellerinin yeni tarımsal uygulamalara daha iyi bir şekilde geliştirilmesini sağlar.

Gerçek problem sahası koşulları açısından değerlendirildiğinde, açıklanan problemler ve tanımlara yönelik olarak bu çalışmada, tarım alanında kullanıma yönelik olarak geliştirilmiş olan PlantVillage veri seti kullanılmıştır. Ek olarak PlantVillage veri setinin aşağıda listelenmiş modeller üzerinde eğitilmesi için ise NVIDIA tarafından geliştirilen TAO (Transfer Adapt Optimize) Toolkit aracı tercih edilmiştir.

- ResNet-34/50
- VGG-16
- GoogLeNet
- MobileNet V2
- DarkNet-19
- EfficientNet-B0/B1

Listelenmiş olan modellerin her biri eğitim ve budama işlemlerinden sonra yüksek hızlı çıkarım performansı için yine NVIDIA tarafından geliştirilmiş olan TensorRT formatına dönüştürülmüştür. Dönüşümü yapılan modeller, NVIDIA Jetson AGX Orin Developer Kit

64GB uç sistem platformunda çalıştırılarak, model çıkarım performansları incelenmiştir. Çalışmanın geri kalan kısmında ise, gömülü sistemde optimize edilmiş bir şekilde çalıştırılan model çıktılarının, son kullanıcıya aktarılabilmesi için gerekli altyapıya odaklanılmıştır. Bu altyapı kapsamında, uçtan uca gerçek bir senaryoyu canlandırmak için akış yöneticisi, veri tabanı, arama motoru ve veri görselleştirme araçları da kullanılmıştır.

3.10. Model Eğitimi

Çalışmada karşılaştırma amacıyla kullanılan modeller ve modellerin mimari özellikleri Çizelge 3.1'de özetlenmiştir.

Çizelge 3.1. Modellere dair budama öncesi ve sonrası parametre sayıları

Mimari	Katman Sayısı	Parametre Sayısı (Ham Model)	Parametre Sayısı (Budanmış Model)
ResNet-34	34	21 325 542	14 729 590
ResNet-50	50	23 639 014	14 952 334
EffNet-B0	237	4 098 242	3 763 538
EffNet-B1	-	6 623 910	4 778 590
Darknet-19	19	19 870 726	15 600 918
GoogleNet	22	6 034 342	5 342 542
Mobilenet-V2	53	2 306 662	2 112 366
VGG-16	16	14 746 854	9 200 182

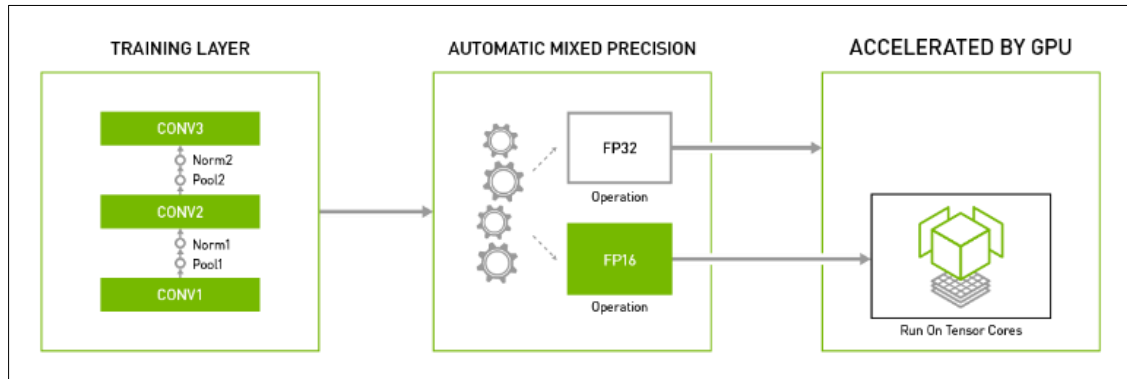
Çizelge 3.1'de gösterilen tüm modellerin eğitim sürecinde, model eğitimine ilişkin hiperparametreler sabit tutulurken, model mimarisine göre değişen hiperparametreler farklı şekilde kullanılmıştır. Eğitim süreci için sabit tutulan hiperparametreler aşağıdaki gibidir;

- Paket Normalizasyonu (Batch Normalization): Evet
- Yanlılık (Bias): Evet
- Pooling Katmanları: Evet – MaxPooling
- ImageNet Uyumlu Girdi/Çıktı Katmanları: Evet
- Doldurma (Interpolation) Metodu: BICUBIC
- Model Girdi Boyutları: 3x224x224(Kanal/Genişlik/Yükseklik)

Bütün modellerin eğitilmesi sırasında Otomatik Karma Hassasiyet (Automatic Mixed Precision) ayarlama özelliği kullanılmıştır. Geleneksel model eğitimi sürecinde matematiksel hesaplamalar sırasında IEEE standardındaki tam hassasiyetli (single precision-

FP32) hesaplama yöntemi uygulanmıştır. Bunun sebebi ise daha düşük hassasiyet değerlerinde daha yüksek performans elde edilirken, eğitim sürecinde elde edilen başarımın düşmesidir. Fakat karma hassasiyet ayarı sayesinde, yarı hassasiyette (half precision-FP16) eğitim yapılırken de tam hassasiyetli süreçte alınana çok yakın değerler alınabilmesi mümkün olmuştur. Böylece hem modellerin daha hızlı eğitilmesi hem de daha düşük hesaplama gereksinimine ihtiyaç duyulması hem de daha az zamanda daha yüksek başarım değerlerine ulaşılması mümkün hale gelmiştir.

Yazılım ve Donanım bölümünde aktarıldığı üzere, çalışmada model eğitimi için kullanılan GeForce RTX 3090 grafik kartının sahip olduğu Ampere GPU mimarisi, karma hassasiyetli model eğitimi sürecinde FP16 kullanılarak TF32'ye kıyasla üç kata kadar daha yüksek başarım değerleri elde edilmesini sağlamaktadır. TF32 ise FP32'nin yenilenmiş bir hali ve FP32'den yaklaşık altı kat daha hızlı olan bir formattır.



Şekil 3.8. Otomatik karma hassasiyet akışı

Modellerin eğitim sürecinde mimari bakımından hiperparametrelerde farklı kullanımlar uygulanmıştır. Bunun sebebi, her modelin farklı veri setleri üzerinde farklı hiperparametrelerle daha yüksek başarım değerlerine ulaşabilmeleridir.

Çizelge I'de listelenen modeller, bu çalışma kapsamında aşağıda sunulan hiperparametreler kullanılarak PlantVillage veri seti üzerinde eğitilmiştir. Belirtilen değerlerin seçimi, modellerin daha önce ImageNet veri setinde sergilediği en yüksek performansa göre yapılmıştır. Aynı sebeple ortak değerlerden olan *all_projections* parametresi, ImageNet'e uygun formatlı giriş ve çıkış değerlerinin her modelde aynı elde edilebilmesi için bazılarında Evet bazılarında Hayır olarak belirtilmiştir.

Eđitim sırasında uygulanan farklı hiperparametre ayarları belirtildiđi gibidir: Darknet-19 için 0,01 öğrenme katsayısı (learning rate) (0,05'ten başlayan cosine annealing), no decay, 0,9 momentum, 128 paket boyutu ve 3×10^{-5} faktörlü ađırlık azalımıyla (weight decay) L2 düzenlileştirmeye (regularization) sahip Stokastik Gradyan Düşümü (SGD) kullanılmıştır. Benzer olarak GoogleNet için 0,05 öğrenme katsayısı (0,05'ten başlayan cosine annealing ile), no decay, 0,9 momentum, 256'lık daha büyük bir paket boyutu ve 3×10^{-6} faktörlü ađırlık azalımıyla (weight decay) L2 düzenlileştirmeye (regularization) sahip Stokastik Gradyan Düşümü (SGD) kullanılmıştır.

Mobilenet-V2 ve VGG-16, SGD optimizasyonu, 0,05'lik bir öğrenme oranı (0,05'ten cosine annealing ile), no decay, 0,9'luk bir momentum ve L2 düzenlileştirmesi ile ortak konfigürasyonlar kullanılarak eğitilmiştir. Bununla birlikte, Mobilenet-V2'de farklı olarak 128'lik bir paket boyutu ve 15×10^{-6} faktörlü bir ađırlık azalımı kullanılırken; VGG-16 için paket boyutu 64 ve ađırlık azalımı faktörü 5×10^{-5} olarak kullanılmıştır.

ResNet-34 ve ResNet-50 modellerinde ise no decay olarak, 0,9'luk momentum değeri, 256'lık daha büyük bir paket boyutu ve 15×10^{-6} faktörlü ađırlık azalımıyla L2 düzenlileştirmeye sahip SGD kullanılmıştır. Bu iki modelde GoogleNet ve MobileNet-V2'den farklı olarak cosine annealing olmadan 0,05'lik bir öğrenme katsayısıyla model eğitimi gerçekleştirilmiştir.

MobileNet-V2 ve VGG-16 kullanılan SGD yöntemi, 0,05'lik öğrenme katsayısı (0,05'ten başlayan cosine annealing ile), no decay, 0,9'luk momentum değeri ve L2 düzenlileştirme (regularization) ayarları açısından ortak konfigürasyon ile eğitilmişlerdir.

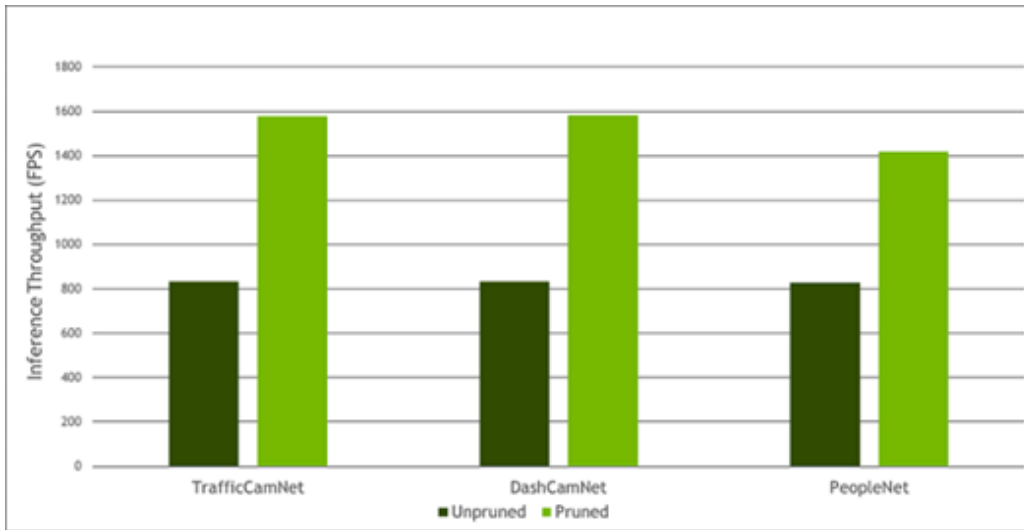
EfficientNet-B0 [17] modelinde ise yine SGD kullanılmış olup öğrenme katsayısı farklı olarak 0,01 ile başlatılmıştır (0,01'ten başlayan cosine annealing ile). Geri kalan ayarlar açısından no decay, 0,9'luk momentum değeri, no Nesterov, 128'lik paket boyutu ve 5×10^{-6} 'lik ađırlık azalımı değerine sahip L2 düzenlileştirme yöntemleri kullanılmıştır. Bu konfigürasyonlar kullanılırken, her bir EfficientNet modeli için eğitim sürecinin optimize edilmesi amaçlanmıştır.

Öğrenme katsayıları, paket boyutları ve ađırlık azalımı değerlerindeki bu belirgin farklılıklar, her bir mimari için eğitim sürecine ince ayar (fine tune) yapmayı amaçlıyordu.

Tüm modeller yukarıda verilen otomatik karma hassasiyet ve parametrelerle eğitildikten sonra değerlendirme (evaluation) sürecine tabi tutulmuştur. Ek olarak Precision, Recall ve F1-Score ölçütleri de her bir model için otuz sekiz sınıf bazında elde edilmiştir. Modellerin tutarlılık (accuracy) değerleri, Sonuçlar bölümünde belirtilmiştir.

Çizelge II'den görüleceği üzere modellerin ham versiyonları, her mimariye göre değişen çok sayıda parametreye sahip olabilir. Ancak yüksek parametre sayısına sahip modeller, özellikle uç ve gömülü sistem uygulamaları için özel olarak optimize edilmedikleri takdirde, çalışma zamanında çıkarım işlem hızının yavaşlamasına neden olmaktadır.

Yazılım ve Donanım bölümünde tanıtılan NVIDIA TAO Toolkit sayesinde modellerin sinir ağı yapısında "Budama" işlemi yapılabilmektedir. Model budama, sonuçta modelin genel doğruluğuna daha az katkıda bulunan nöronların, ağ yapısından kaldırılması işlemidir. Böylece yüksek doğruluklu model mimarileri, sınırlı işlem gücüne sahip sistemlerde daha yüksek verim, çok daha az katman ve dolayısıyla daha az sayıda parametre ile çalışabilmektedir. Şekilde 3.7'de, budanmamış bir modelden budanmış bir modele geçişin, NVIDIA T4 grafik kartı üzerinde model çalışma anına dair performans kazanımı gösterilmiştir. Temelde araç ve insan tespitine yönelik olan TrafficCamNet; yaya, bisikletli ve araç tespitine yönelik olan DashCamNet ve sadece insan tespiti görevine odaklı geliştirilmiş olan PeopleNet, NVIDIA TAO Toolkit kapsamında sunulan üç adet önceden eğitilmiş modeldir.



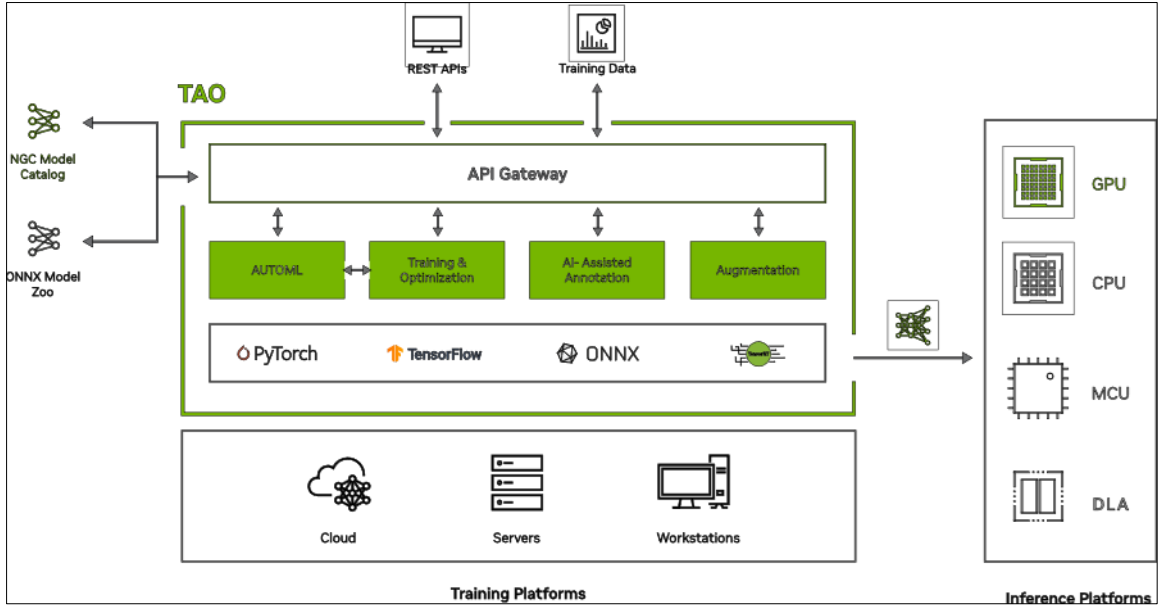
Şekil 3.9. Ham ve budanmış modeller arasındaki çıkarım performansı karşılaştırması

Çalışmada karşılaştırılan tüm modellere budama işlemi uygulanmış olup, model parametre sayıları arasındaki karşılaştırma Çizelge 3.1’de gösterilmiştir. Model budama, genel tutarlılık üzerinde çok fazla etkisi olmayan düğümlerin ve ağırlıklarının silinmesini içeren bir işlem olmasına rağmen tutarlılık sonucunda bir miktar azalmaya neden olur. Bununla birlikte, budanmış modelin aynı veri seti ve aynı hiper parametreler kullanılarak ince ayara tabi tutulması, kaybedilen tutarlılık değerini yeniden kazandırabilir.

Bu iki aşamalı eğitim sürecinin sonunda budanmış model kaydedilir. Kaydetme işlemi sırasında modelin hassasiyet ayarı belirtilirse, model kalibrasyonu ve TensorRT optimizasyonu da yine NVIDIA TAO Toolkit ile gerçekleştirilebilir. Bu çalışmada karşılaştırılan tüm modeller INT8 hassasiyet türüne göre optimize edilmiş ve kalibrasyon uygulanmıştır.

3.11. NVIDIA TAO Toolkit

NVIDIA TAO (Train-Eğitim, Adapt-Uyarlama, Optimize-Optimizasyon) Toolkit, yapay zeka modellerini oluşturma, eğitme ve uygulamaya koyma sürecini basitleştirmek için tasarlanmış kapsamlı bir yazılım kütüphanesidir. Tarımsal uygulamalarda yaygın olarak kullanılan uçtaki gömülü sistemler için yüksek düzeyde optimize edilmiş modeller oluşturmak açısından özellikle uygun bir araçtır. TAO Toolkit; önceden eğitilmiş modeller, kullanıcı dostu API’ler ve hem yeni başlayan hem de deneyimli geliştiricilere hitap eden kolaylaştırılmış iş akışları sağlayarak, derin öğrenme modeli geliştirme sürecinin karmaşıklığını azaltır.



Şekil 3.10. NVIDIA TAO Toolkit çalışma şematığı

TensorFlow, Keras, PyTorch vb. geleneksel model eğitim kütüphanelerine kıyasla kullanım kolaylığı, uç sistemler için hazır optimizasyon süreçleri, NVIDIA ekosistemindeki bütün ürünlerle entegrasyon uyumluluğu, öğrenme aktarımı desteği ve basitleştirilmiş iş akışı açılarından birçok avantaja sahiptir.

Kullanım kolaylığı açısından TAO Toolkit, derin öğrenme modellerini eğitme sürecini basitleştiren yüksek seviyeli bir API sunmaktadır. Kullanıcılar, derin öğrenme veya temel kütüphaneler hakkında kapsamlı bilgiye ihtiyaç duymadan modelleri eğitebilir ve ince ayar yapabilir. Belirli görevler için ince ayar yapılabilecek çeşitli önceden eğitilmiş modeller sağlayarak, sıfırdan bir model geliştirmek için gereken süreyi ve hesaplama kaynaklarını önemli ölçüde azaltır.

Ek olarak bu araç, eğitilen modelleri NVIDIA donanımında, özellikle de Jetson serisi gibi gömülü sistemlerde uygulamaya koyulacak şekilde optimize etmeye odaklanır. Bu sayede, modellerin yalnızca yüksek doğruluğa sahip olmasını değil aynı zamanda hesaplama kaynakları ve güç tüketimi açısından da verimli olmasını sağlar. Ayrıca kısıtlı hesaplama kabiliyetine sahip ortamlar için çok önemli olan model boyutunun azaltılmasına ve çıkarım hızının iyileştirilmesine yardımcı olan niceleme ve budama gibi özellikleri içerir.

TAO Toolkit, uçta uca çözüm oluşturulabilmesi açısından yüksek performanslı çıkarım için

TensorRT ve kamera yayını gerektiren uygulamalarda modelleri uygulamaya koymak için DeepStream SDK gibi diğer NVIDIA teknolojileriyle ek bir geliştirme sürecine ihtiyaç duyulmadan sorunsuz bir şekilde entegre olur. Böylece eğitimden çalıştırmaya kadar tüm iş akışını kolaylaştıran uyumlu bir ekosistem oluşturulmasını sağlar. NVIDIA'nın GPU'larını ve özel donanım hızlandırıcılarını da kullanmayı sağlayan TAO Toolkit, NVIDIA platformlarındaki yapay zeka modellerinin performansını en üst düzeye çıkararak geleneksel kütüphanelerdeki uygulamalara kıyasla önemli bir artış sağlar.

TAO, belirli görevlere uyum sağlama açısından öğrenme aktarımında öne çıkmakta ve kullanıcıların önceden eğitilmiş modelleri nispeten daha küçük veri setleriyle belirli tarımsal görevlere uyarlamasına olanak sağlamaktadır. Bu sayede, etiketli verilerin az ve elde edilmesinin maliyetli olabildiği tarım alanında yüksek fayda sağlamaktadır. Mahsul takibi, haşere tespiti ve verim tahmini gibi tarımsal senaryolara doğrudan uygulanabilecek nesne algılama, sınıflandırma ve bölütleme gibi belirli uygulamalar için özel olarak tasarlanmış modelleri içerir.

Araç aynı zamanda, kullanıcılara eğitim ve optimizasyon süreçleri boyunca rehber adımları gösteren, öğrenme sürecini kolaylaştıran ve bütün bir süreci daha geniş kitlelere erişilebilir hale getiren sezgisel bir komut arayüzü sunar.

Sonuç olarak NVIDIA TAO Toolkit, gömülü sistemlerde tarımsal uygulamalar için özel olarak tasarlanmış yapay zeka modellerinin geliştirilmesi için sağlam ve kullanıcı dostu bir platform altyapısı sağlamaktadır. TensorFlow veya PyTorch gibi geleneksel kütüphanelere kıyasla avantajları arasında kullanım kolaylığı, uçta model çalıştırma için optimizasyon, NVIDIA ekosistemiyle entegrasyon, öğrenme aktarımı için güçlü destek ve kolaylaştırılmış iş akışı maddeleri yer almaktadır. Bu özellikler toplu olarak araştırmacıların ve geliştiricilerin, tarımsal uygulamaların çeşitli zorluklarını ve gereksinimlerini karşılayan yüksek performanslı yapay zeka modellerini verimli bir şekilde oluşturmasını ve uygulamaya koymasını mümkün hale getirmektedir.

3.12. Yazılım ve Donanımlar

Çalışmada kullanılan mimarilerin tercih edilmesinin sebepleri arasında bu mimarilerin popüler derin öğrenme kütüphaneleri tarafından desteklenmesi ve bu sayede model eğitim

işlemlerinin kolaylıkla yapılabilmesi gösterilebilir.

İncelenen makaleler arasında kütüphane ve yazılım detaylarının verildiği on çalışma arasında PyTorch, TensorFlow ve MATLAB kullanımı görülmektedir. Kullanım dağılımı açısından dört çalışmada PyTorch, üç çalışmada TensorFlow, iki çalışmada MATLAB ve bir çalışmada TensorFlow ve MATLAB birlikte kullanılmıştır.

Bahsedilen çalışmalarda geliştirilen modellerin tarım alanlarında faaliyet gösteren gömülü sistemlerde uygulanması düşünüldüğünde optimizasyon ve model hızlandırma önem kazanmaktadır. Tercih edilen gömülü sisteme bağlı olarak bu optimizasyon ve hızlandırma, NVIDIA tarafından geliştirilen TensorRT kütüphanesi ile uygulanabilmektedir. Halihazırda birçok endüstriyel ve ticari uygulamada kullanılan bu kütüphane, incelenen çalışmalar arasında sadece iki makalede kullanılmıştır.

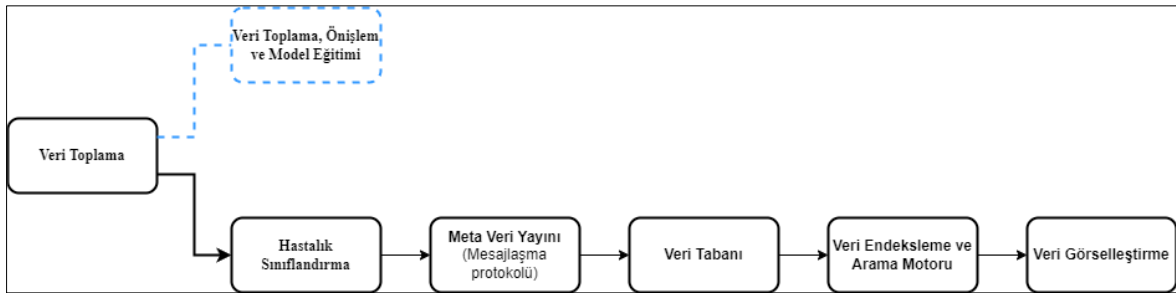
Önerilen iş akışı kapsamında, öğrenme aktarımı yöntemini kullanarak modelleri eğitmek için NVIDIA TAO Toolkit yazılımı kullanılmıştır. Bu araç temel olarak Python programlama dili ile daha yüksek düzeyde kodlamaya olanak tanıyan TensorFlow derin öğrenme kütüphanesinin optimize bir şekilde sunulduğu Docker konteyneridir.

Çalışma kapsamında evrişimli sinir ağı mimarilerini eğitmek için Intel Core i9-10920X işlemci, 64 GB bellek ve iki adet RTX 3090 24 GB (NVLink ile 48GB) grafik kartına sahip bir iş istasyonu kullanılmıştır. Daha sonra söz konusu sistemle eğitilen modeller, tarım odaklı gömülü sistemlerde yüksek performanslı birlikte çalışabilirliği test etmek amacıyla NVIDIA Jetson AGX Orin Developer Kit 32GB uç cihazında uygulamaya konulmuştur.

4. ÇALIŞTIRMA

Çalışmanın model çıktılarının bir arayüzde son kullanıcı ile buluşturulması açısından model çıktıları büyük ölçekte yönetebilecek bir akış yöneticisi, NoSQL tabanlı bir veri tabanı olan CassandraDB, veri tabanından bir bağlam bütünlüğüne uygun şekilde verilerin elde edilmesi için arama motoru olan Elasticsearch ve nihai olarak verilerin görselleştirilmesi için web tabanlı bir görselleştirme aracı olan Kibana kullanılmıştır.

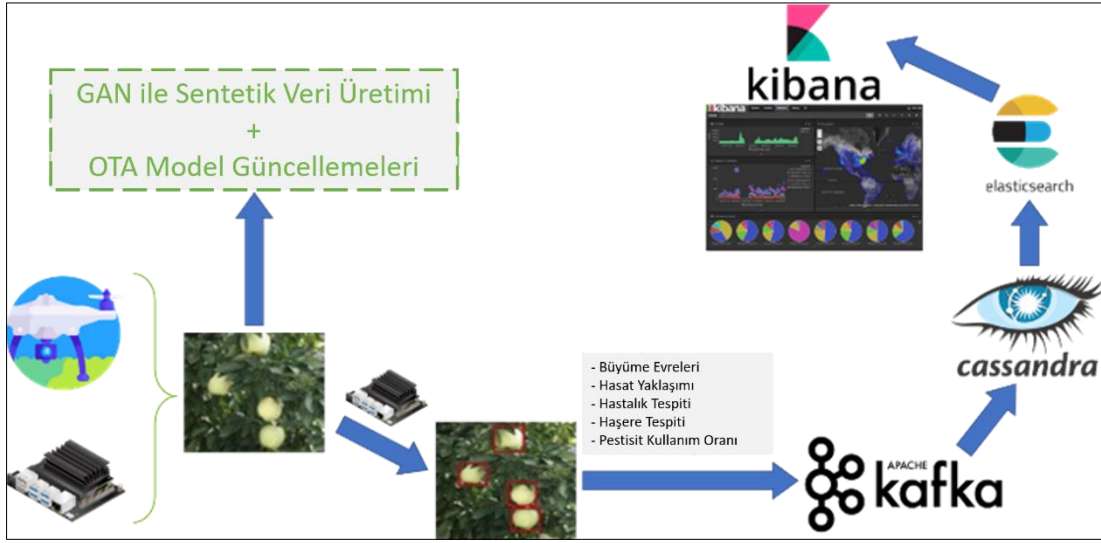
NVIDIA Jetson platformunda optimize yapay zekâ iş akışı oluşturmaya yönelik önerilen sürekli model eğitimi ve veri analitiği çözümünü oluşturmak için tüm süreci optimize etmek amacıyla çeşitli bileşenleri entegre eden kapsamlı bir iş akışı tasarlanmıştır. Bu bölümde iş akışının ikinci aşaması olan Model Çalıştırma, Çıkarım ve Meta Veri Yönetimi ele alınmıştır.



Şekil 4.1. Model çalıştırma ve meta veri analitiği akış diyagramı

Model çalıştırma süreci aşamalara bölündüğünde; ilk adımdaki sensör veya gömülü sistemden elde edilen veri, bir sonraki aşamada optimize bir şekilde çalıştırılan Hastalık sınıflandırma modeline gerçek zamanlı girdi olarak verilmiştir. Model çıktısı olarak elde edilen meta veri, bir sonraki bölümde detaylandırılmış olan mesajlaşma protokolü ile veri tabanı elemanına yayınlanmıştır. Veri tabanında depolanan yüksek hacimli verinin daha hızlı sorgulanabilmesi ve görselleştirilebilmesi için, veri görselleştirme arayüzüne aktarılmadan önce endekslenmiş ve arama motoru ile bütünleştirilmiştir.

4.1. Model Çalıştırma, Çıkarım ve Meta Veri Yönetimi

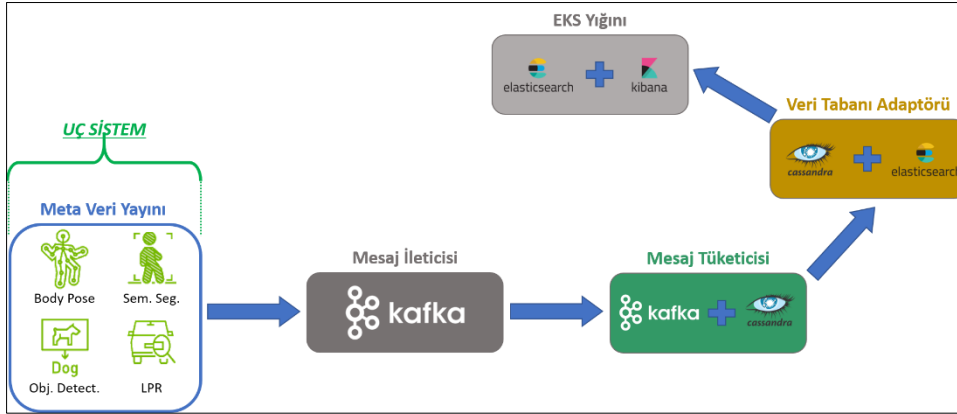


Şekil 4.2. Model çıkarımı, meta veri yönetimi ve meta veri görselleştirme iş akışı

Bu bölümde, NVIDIA Jetson AGX Orin Geliştirici Kiti kullanılarak yüksek verimliliğe sahip nesne algılama görevi için önerilen iş akışında kullanılan optimizasyon stratejileri açıklanmaktadır. Model çalıştırmayı, akış performansını ve veri aktarımını optimize etmek için TensorRT, DeepStream SDK, NVDEC ve NVENC çiplerinin birlikte nasıl kullanıldığı belirtilmiştir.

Bir önceki bölümde geliştirme süreci açıklanan model, Jetson AGX Orin Developer Kit 32GB cihazında uygulamaya konulduktan sonra tarım alanlarına kurulan yine aynı cihaza bağlı kameralardan gelen kareler üzerinde gerçek zamanlı çıkarım görevini gerçekleştirmiştir. Ortaya çıkan çıktı, algılanan nesnelere ilişkin konumları, boyutları ve türleri gibi bilgileri içeren meta verilerdir.

Apache Kafka, çeşitli kaynaklardan gelen yüksek hacimli veri akışını yönetmek için bir mesaj aracı olarak kullanılmıştır ve adaptörler aracılığıyla iş akışının geri kalanıyla kusursuz meta veri akışı entegrasyonunu sağlar.



Şekil 4.3. Gömülü sistemlerde meta veri yönetim elemanlarının kullanım akışı

Bu mesaj araçlarından alınan meta verileri gerçek zamanlı olarak yönetmek için, çıkarım sonuçlarını depolamak üzere yine cihazda yerel olarak çalıştırılan bir NoSQL veri tabanı olarak Apache Cassandra kullanılmıştır. Bu veri tabanı, meta verilerin yerel cihazda verimli bir şekilde sorgulanmasını ve analizini sağlar.

Daha ileri düzeyde işleme veya görselleştirme amacıyla meta verilere hızlı erişimi kolaylaştırmak için bir arama ve analiz motoru olarak Elasticsearch kullanılmıştır. Meta veriler, Elasticsearch motorunda indekslenerek karmaşık sorguların hızlı bir şekilde çalıştırılması ve ilgili bilgilerin elde edilmesine olanak tanımıştır.

Son olarak Kibana, sonuçları özelleştirilebilir bir gösterge Çizelgesi formatında sunmak için bir veri görselleştirme aracı olarak kullanılmış ve kullanıcıların nesne algılama çıktılarını kolayca anlamlandırmalarını ve analiz etmelerini sağlamıştır.

4.2. TensorRT ile Model Optimizasyonu

TensorRT, Jetson AGX Orin'de model çalıştırma için nesne algılama modelinin optimize edilmesinde çok önemli bir rol oynamaktadır. Süreç boyunca birkaç önemli optimizasyon gerçekleştirerek yüksek performanslı bir çıkarım motoru görevi görmektedir.

Katman Füzyonu: Ardışık birden fazla katmanı tek ve daha verimli bir işlemde birleştirmek, hesaplama yükünü azaltıp ve çıkarım hızını artırmaktadır.

Hassasiyet düşümü: TensorRT, model ağırlıklarının ve aktivasyonlarının yüksek hassasiyetli

formatlardan (örn. FP32) daha düşük hassasiyetli formatlara (örn. FP16 veya INT8) minimum doğruluk kaybıyla dönüştürülmesine olanak tanımaktadır. Bu durum, bellek kullanımını azaltır ve Jetson'un yerleşik donanımı üzerindeki hesaplamaları hızlandırır.

Çekirdek (Kernel) optimizasyonu: TensorRT, Jetson mimarisine özel olarak uyarlanmış, yüksek düzeyde optimize edilmiş çekirdekler üretir. Bu çekirdekler, NVIDIA GPU'ların yeteneklerinden yararlanarak çıkarımların daha hızlı yürütülmesini sağlar.

4.3. Ölçeklendirilmiş Gerçek Zamanlı Analitik için DeepStream SDK

DeepStream SDK, NVIDIA platformlarında yüksek performanslı iş akışları oluşturmaya yönelik kapsamlı bir geliştirme altyapısıdır. İş akışı için çeşitli optimizasyon özellikleri sunmaktadır.

Donanım duyarlı çizelgeleyici: DeepStream, Jetson'ın işlem birimlerindeki (CPU, GPU, Derin Öğrenme Hızlandırıcı-DLA) görevleri iş yükü uygunluklarına göre akıllı bir şekilde çalıştırmaktadır. Bu durum, optimum kaynak kullanımını sağlar ve işlem gecikmelerini en aza indirir.

Ön işleme ve art işleme akışları: DeepStream, nesne algılama modeli için verimli ön işleme ve art işleme akışları oluşturmaya olanak tanımaktadır. Bu iş akışları Jetson donanımı için optimize edilebilir, böylece veri hazırlama ve sonuçların yorumlanması için harcanan süre azaltılabilmektedir.

TensorRT entegrasyonu: DeepStream, TensorRT ile hali hazırda bütünleşik olarak optimize edilmiş modellerin akış içerisinde doğrudan yüklenmesine ve çalıştırılmasına olanak tanır. Bu sayede, çıkarım süreci kolaylaştırılmış ve yazılım katmanları arasındaki veri hareketi en aza indirilmiştir.

4.4. Ölçeklenebilir Veri Akışı için Apache Kafka Entegrasyonu

DeepStream, video kareleri ve bunlarla ilişkili çıkarım meta verilerini içeren büyük ölçekli veri akışlarını verimli bir şekilde yönetmek için dağıtık bir mesaj yayınlama platformu olan Apache Kafka'yı kullanacak şekilde yapılandırılmıştır. Kafka, bu çalışmada sunulan iş akışı


için çeşitli avantajlar sağlamıştır:

Yüksek verim: Kafka, büyük hacimli verileri düşük gecikmeyle işleyerek modelin yeniden eğitimi için video karelerinin, Jetson'dan bulut sunucusuna sorunsuz bir şekilde aktarılmasını sağlamıştır.

Ölçeklenebilirlik: Kafka, kümeye daha fazla düğüm ekleyerek yatay olarak kolayca ölçeklenebilir, bu da sistemin tarımsal uygulama boyutu büyüdükçe artan veri hacimlerine uyum sağlamasına olanak tanımaktadır.

4.5. NVDEC ve NVENC ile Donanım Hızlandırıcılı Kamera Yayını

Çalışmanın, video akış optimizasyonu bölümünde NVIDIA Jetson AGX Orin'in, video kod çözme ve kodlama için özel donanım bileşenlerinden yararlanılmıştır:



Şekil 4.4. NVIDIA NVENC ve NVDEC kodek bileşenlerinin format özellikleri

NVDEC (NVIDIA Kod Çözücü): NVDEC, çeşitli video kodek bileşenlerini (ör. H.264, H.265) verimli bir şekilde işleyen bir donanım kod çözücüdür. Kod çözme sürecinin yükünü CPU'dan alır ve kaynakları model çıkarımı gibi diğer görevler için serbest bırakır. Bu durum, Jetson'daki işlem yükünü önemli ölçüde azaltır ve genel akış performansını artırır.

NVENC (NVIDIA Kodlayıcı): NVENC, video kodlama görevlerini optimize eden bir

donanım kodlayıcıdır. Gerekirse video akışını bulut sunucusuna iletmeden önce kodlamak için kullanılabilir, böylece bant genişliği tüketimi daha da azaltılır ve veri aktarım verimliliği artırılır.

Önerilen iş akışı, bu optimizasyon stratejilerini birleştirerek akış performansında, çıkarım hızında ve veri aktarım verimliliğinde önemli iyileştirmeler elde edilmesini sağlamıştır. Bu sayede, Jetson AGX Orin'de gerçek zamanlı nesne algılamaya olanak tanınırken, toplanan veri akışını kullanarak bulut sunucusunda sürekli model eğitim süreci de kolaylaştırılmıştır.

5. BULGULAR VE DEĞERLENDİRME

Eğitilen modeller hem eğitim doğruluğu hem de çıkarım performansı açısından karşılaştırılmıştır. Eğitim doğruluğu karşılaştırması hem budama öncesi hem de budama sonrası aşamalar için yapılırken, çalışma zamanı performansı karşılaştırması bütün modellerin Jetson AGX Orin'deki işlem süresi üzerinden yapılmıştır.

Orijinal parametre sayısı ile budanmış modellerin parametre sayısı arasındaki model eğitim doğruluğu karşılaştırması Çizelge 5.1 ve Çizelge 5.2'de sunulmuştur. Bu çizelgelere göre literatürdeki çoğu çalışmanın yüksek doğruluk odağına dayalı olarak geliştirilen parametre sayısı yüksek modellerle elde edilen doğruluk oranı, aynı modellerin çok daha hafif versiyonlarıyla da elde edilebilmektedir. Bu sayede mimarinin avantajlarından ödün vermeden, aynı mimariye sahip fakat çok daha hafif modeller kullanılarak yüksek doğruluğa sahip yapay zekâ senaryoları uygulanabilmektedir.

Çizelge 5.1'deki sonuçlardan da görülebileceği gibi EfficientNet-B1 modeli hem budama öncesi hem de budama sonrası aşamalarda en yüksek doğruluğa sahiptir. Aynı zamanda budama sonrası elde edilen 3 763 538 parametre sayısı sayesinde gömülü sistemlerde yüksek performansla çalışması da mümkün olmuştur.

Çizelge 5.1. Budama öncesi ve sonrası eğitim doğruluklarının karşılaştırılması

Model Mimarisi	Parametre		Doğruluk	
	(Ham)	(Budanmış)	Budama Öncesi	Budama Sonrası
ResNet-34	21 325 542	14 729 590	0,995	0,9969
ResNet-50	23 639 014	14 952 334	0,994	0,9958
EffNet-B0	4 098 242	3 763 538	0,9796	0,9892
EffNet-B1	6 623 910	4 778 590	0,9985	0,9989
Darknet-19	19 870 726	15 600 918	0,9972	0,9972
GoogleNet	6 034 342	5 342 542	0,9969	0,9861
Mobilenet-V2	2 306 662	2 112 366	0,9619	0,9655
VGG-16	14 746 854	9 200 182	0,9966	0,9921

Son bölümde parametre sayısı ve doğruluk açısından karşılaştırılan tüm modeller, birçok platformda çalışmaya uygun jenerik çalıştırma için öncelikle ONNX model formatına dönüştürüldü ve ardından NVIDIA TensorRT model formatlarına dönüştürülmüştür.

ONNX model formatı, yapay zeka modellerinin Raspberry Pi, Google Coral ve hatta kişisel bilgisayarlar da dahil olmak üzere her tür bilgisayar sisteminde çalıştırılması sağlamaktadır. Bir sonraki adım olan NVIDIA TensorRT model formatı ise daha yüksek çalışma verimi elde etmek için yapay zeka modellerinin NVIDIA Jetson gömülü cihazlarında ve NVIDIA grafik kartlarında çalıştırılmasına olanak tanımaktadır. Böylelikle gerçek zamanlı analitik uygulamalarında ham yapay zeka modeli çalıştırmaya kıyasla daha yüksek kare hızlarına ve minimum gecikme süresi elde edilmesini sağlamaktadır.

Bu çalışmada, karşılaştırmaya tabi olan yapay zeka modelleri, çalışma verimi ve gecikme süresi ölçümlerini kıyaslamak için bir NVIDIA Jetson AGX Orin Geliştirici Kiti'nde NVIDIA TensorRT formatıyla çalıştırılmıştır. Çıkarım kıyaslaması sırasında sırasıyla minimum profil için sekiz, optimum profil için on altı ve maksimum profil için otuz iki paket boyutu kullanılmıştır. Tüm TensorRT model format dönüşümleri, ortak bir yaklaşım olarak yarı hassasiyet (FP16)'e göre yapılmıştır.

Çizelge 5.2. Çalışma verimi ve gecikme değerleri

Model Mimarisi	Çalışma Verimi (Görüntü/saniye)	Gecikme (ms)	Bellek Kullanımı (MB)
ResNet-34	384,632	3,11	~360-440
ResNet-50	366,000	3,36	~400-500
EffNet-B0	325,463	3,75	~240-320
EffNet-B1	234,993	4,92	~280-360
Darknet-19	178,215	5,89	~200-260
GoogleNet	533,741	2,97	~180-240
Mobilenet-V2	612,316	2,30	~120-200
VGG-16	507,000	3,08	~800-1000

Çizelge 5.2'de sunulan değerler, TensorRT ile FP16 formatında, 16 paket boyutu ve 256x256 standardında girdiler üzerinde, herhangi bir ön veya son işlem uygulanmadan gerçekleştirilmiş testlere aittir.

6. SONUÇLAR

Çizelge 5.2'den de anlaşılacağı üzere Mobilenet-V2 diğer modellere kıyasla en hafif model olduğundan çalışma zamanı performansı açısından da en yüksek verimi ve en düşük gecikmeyi elde etmiştir. Ancak bu modelin eğitim doğrulama tutarlılığı sonucu, EfficientNet-B1 modeli ile karşılaştırıldığında en yüksek doğruluk beklenen görevlerde MobileNet-V2 en iyi seçenek olmayabilir.

EfficientNet-B1'in 234,993'lük verimlilik değerinin, gerçek zamanlı analitik yeteneklerini yeterince iyi sağlayabileceği ve 0,9989 budama sonrası eğitim doğrulama tutarlılığı oranı göz önüne alındığında, bir gömülü sistem üzerinde yüksek performanslı ve gerçek zamanlı tarımsal analitik uygulaması için en uygun seçenek olacaktır.

KAYNAKLAR

1. Radoglou, G. (2020) A compilation of UAV applications for precision agriculture, *Computer Networks*, 172, (107148).
2. Aktar, M. W. (2009) Impact of pesticides use in agriculture: their benefits and hazards, *Interdiscip Toxicol*, 2(1), 1–12.
3. Gebbers, R. ve Adamchuk, V. I. (2010) Precision Agriculture and Food Security, *Science*, 327, (5967), 828-831.
4. Kamilaris, A. (2018) Deep learning in agriculture: A survey, *Computers and Electronics in Agriculture*, 147, (0168-1699), 70-90.
5. Business Wire (2020) *Research and Markets: Global Agricultural Robots Market Report 2020-2025 with COVID-19 Impact Analysis*, Dublin.
6. Mordor Intelligence (2024) *Agricultural Robots Market Analysis*, Hyderabad.
7. Hughes, D. P. ve Salathé, M. (2015) An open access repository of images on plant health to enable the development of mobile disease diagnostics, *Agricultural and Food Sciences, Computer Science, Environmental Science*, abs/1511.08060, 1-13.
8. Minervinia, M. Fischbachb, A. Scharrb, H. ve Tsiftaris, S. A. (2016) Finely-grained annotated datasets for image-based plant phenotyping, *Pattern Recognition Letters*, 81, 80-89.
9. İnternet: Forestry Images, Web: <https://www.forestryimages.org> Son Erişim Tarihi: 11/08/2024.
10. Wang, Q.-J. Zhanga, S.-Y. Dong, S.-F. Zhang, G.-C. Yang, J. Li, R. ve Wang, H.-Q. (2020) Pest24: A large-scale very small object data set of agricultural pests for multi-target detection, *Computers and Electronics in Agriculture*, 175, (105585).
11. Wang, R. Jiao, L. Xie, C. Chen, P. ve Du, J. (2021) S-RPN: Sampling-balanced region proposal network for small crop pest detection, *Computers and Electronics in Agriculture*, 187, (106290).
12. Tian, Y. Yang, G. Wang, Z. Wang, H. Li, E. ve Liang, Z. (2019) Apple detection during different growth stages in orchards using the YOLO Models, *Computers and Electronics in Agriculture*, 157, 417-426.
13. Too, E. C. Yujiana, L. Njuki, S. ve Yingchun, L. (2019) A comparative study of fine-tuning deep learning models for plant disease identification, *Computers and Electronics in Agriculture*, 161, 272-279.

14. Maa, J. Dua, K. Zhenga, F. Zhangb, L. Gongc, Z. ve Suna, Z. (2018) A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network, *Computers and Electronics in Agriculture*, 154, 18-24.
15. Dutta, A. ve Zisserman, A. (2019) *The VIA Annotation Software for Images, Audio and Video*, MM '19: Proceedings of the 27th ACM International Conference on Multimedia, New York.
16. İnternet: GitHub Intel, Web: <https://github.com/openvinotoolkit/cvat> Son Erişim Tarihi: 20/07/2024.
17. İnternet: GitHub LabelMe, Web: <https://github.com/wkentaro/labelme> Son Erişim Tarihi: 20/07/2024.
18. İnternet: GitHub LabelImg, Web: <https://github.com/tzutalin/labelImg> Son Erişim Tarihi: 20/07/2024.
19. Tassis, L. M. Souza, J. E. T. d. ve Krohling, R. A. (2021) A deep learning approach combining instance and semantic segmentation to identify diseases and pests of coffee leaves from in-field images, *Computers and Electronics in Agriculture*, 186, (106191).
20. Momeny, M. Jahanbakhshi, A. Jafarnezhad, K. ve Zhang, Y.-D. (2020) Accurate classification of cherry fruit using deep CNN based on hybrid pooling approach, *Postharvest Biology and Technology*, 166, (111204).
21. Zhao, G. Quan, L. Li, H. Feng, H. Li, S. Zhang, S. ve Li, R. (2021) Real-time recognition system of soybean seed full-surface defects based on deep learning, *Computers and Electronics in Agriculture*, 187, (106230).
22. Gonzalez-Huitron, V. Le'on-Borges, J. A. Rodriguez-Mata, A. Amabilis-Sosa, L. E. Ramirez-Pereda, B. ve Rodriguez, H. (2021) Disease detection in tomato leaves via CNN with lightweight architectures implemented in Raspberry Pi 4, *Computers and Electronics in Agriculture*, 181, (105951).
23. Partel, V. Costa, L. ve Ampatzidis, Y. (2021) Smart tree crop sprayer utilizing sensor fusion and artificial intelligence, *Computers and Electronics in Agriculture*, 191, (106556).
24. Abbas, A. Jain, S. Gour, M. ve Vankudothu, S. (2021) Tomato plant disease detection using transfer learning with C-GAN synthetic images, *Computers and Electronics in Agriculture*, 187, (106279).
25. Ngo, T. N. Rustia, D. J. A. Yang, E.-C. ve Lin, T.-T. (2021) Automated monitoring and analyses of honey bee pollen foraging behavior using a deep learning-based imaging system, *Computers and Electronics in Agriculture*, 187, (106239).

26. Partela, V. Nunesa, L. Stanslyb, P. ve Ampatzidis, Y. (2019) *Automated vision-based system for monitoring Asian citrus psyllid in orchards utilizing artificial intelligence*, *Computers and Electronics in Agriculture*, 162, 328-336.
27. Rao, U. S. Swathi, R. Sanjana, V. Arpitha, L. Chandrasekhar Chinmayi, K. ve Naik, P. K. (2021) *Deep Learning Precision Farming: Grapes and Mango Leaf Disease Detection by Transfer Learning*, *Global Transitions Proceedings*, 2, 535-544.
28. García-Manso, A. Gallardo-Caballero, R. García-Orellana, C. J. H. Gonz'alez-Velasco, M. ve Macías-Macías, M. (2021) Towards selective and automatic harvesting of broccoli for agri-food industry, *Computers and Electronics in Agriculture*, 188, (106263).
29. Lin, Y.-K. Chen, S.-F. Kuo, Y.-F. Liu, T.-L. ve Lee, S.-Y. (2021) Developing a guiding and growth status monitoring system for riding-type tea plucking machine using fully convolutional networks, *Computers and Electronics in Agriculture*, 191, (106540).
30. Yu, Y. Zhang, K. Yang, L. ve Zhang, D. (2019) Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN, *Computers and Electronics in Agriculture*, 163, (104846).
31. Canny, J. (1986) A Computational Approach to Edge Detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8, (6), 679-698.
32. İnternet: NVIDIA TensorRT (Ocak, 2022), Web: <https://developer.nvidia.com/tensorrt> Son Erişim Tarihi: 17 Ağustos 2024
33. Deng, J. Dong, W. Socher, R. Li, L.-J. Li, K. ve Fei-Fei, L. (2009) *ImageNet: A Large-Scale Hierarchical Image Database*, IEEE conference on computer vision and pattern recognition, 248–255.
34. Pan, S. J. ve Yang, Q. (2010) *A Survey on Transfer Learning*, IEEE Transactions on Knowledge and Data Engineering, 22, 1345-1359.
35. İnternet: NVIDIA, Achieving FP32 Accuracy for INT8 Inference Using Quantization Aware Training with NVIDIA TensorRT, (Temmuz, 2021), Web: <https://developer.nvidia.com/blog/achieving-fp32-accuracy-for-int8-inference-using-quantization-aware-training-with-tensorrt/> Son Erişim Tarihi: 17 Ağustos 2024.
36. Jacob, B. Kligys, S. Chen, B. Zhu, M. M. Tang, Howard, A. G. Adam, H. ve Kalenichenko, D. (2017) Quantization and Training of Neural Networks for Efficient Integer-Arithmetic-Only Inference, *CoRR*, abs/1712.05877.
37. Banner, R. Hubara, I. Hoffer, E. ve Soudry, D. (2018) Scalable Methods for 8-bit Training of Neural Networks, *CoRR*, abs/1805.11046.

38. İnternet: NVIDIA, Mixed Precision Training, (Temmuz 2020), Web: <https://developer.nvidia.com/mixed-precision-training> Son Erişim Tarihi: 12 Haziran 2024.
39. İnternet: Microsoft, Efficient Training of BERT by Using 16-bit Floating Point Numbers (2019), Web: <https://www.microsoft.com/en-us/research/blog/efficient-training-of-bert-by-using-16-bit-floating-point-numbers> Son Erişim Tarihi: 12 Haziran 2024.
40. Ganin, Y. Ustinova, E. Ajakan, H. Germain, P. Larochelle, H. Laviolette, F. M. ve Marchand, V. ve Lempitsky, S. (2015) *Domain-Adversarial Training of Neural Networks*, Journal of Machine Learning Research.
41. Hughes, D. Ramcharan, A. Baranowski, K. McCloskey, P. Ahmed, B. ve Legg, J. (October, 2017) *Deep Learning for Image-Based Cassava Disease Detection*, Frontiers in Plant Science, 8, 1852.
42. Murtagh, F. (1991) *Multilayer perceptrons for classification and regression*, Neurocomputing, 2, 183-197.
43. İnternet: NVIDIA, Pruning Models with NVIDIA Transfer Learning Toolkit, (Mart 2019), Web: <https://developer.nvidia.com/blog/transfer-learning-toolkit-pruning-intelligent-video-analytics> Son Erişim Tarihi: 25 Ağustos 2024.
44. LeCun, Y. Denker, J. ve Solla, S. (1989) *Optimal Brain Damage*, Advances in Neural Information Processing Systems.
45. Han, S. Pool, J. Tran, J. ve Dally, W. J. (2015) Learning both Weights and Connections for Efficient Neural Networks, *CoRR*, abs/1506.02626.
46. Li, H. Kadav, A. Durdanovic, I. Samet, H. ve Graf, H. P. (2016) Pruning Filters for Efficient ConvNets, *CoRR*, abs/1608.08710.
47. Grand View Research Inc. (2022) *Agricultural Robots Market Size, Share & Trends Analysis Report By Application (Milking, Planting & Seeding Management), By Type (Driverless Tractors, UAVs), By Offering (Software, Hardware), By Region, And Segment Forecasts, 2023 – 2030*, California.
48. Giancola, S. ve Ghanem, B. (2021) *Temporally-Aware Feature Pooling for Action Spotting in Soccer Broadcasts*, IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Los Alamitos.
49. He, T. ve Soatto, S. (Temmuz, 2019) *Mono3D++: Monocular 3D Vehicle Detection with Two-Scale 3D Hypotheses and Task Priors*, Proceedings of the AAAI Conference on Artificial Intelligence, 33, 8409-8416.

50. Jiang, S. Lin, Z. Li, Y. Shu, Y. ve Liu, Y. (2021) *Flexible high-resolution object detection on edge devices with tunable latency*, Proceedings of the 27th Annual International Conference on Mobile Computing and Networking, New York.
51. Li, P. Zhao, H. Liu, P. ve Cao, F. (2020) *RTM3D: Real-Time Monocular 3D Detection from Object Keypoints for Autonomous Driving*, Computer Vision – ECCV, Cham.
52. Li, X. Zhang, Z. Tan, X. Chen, C. Y. Qu, Xie, Y. ve Ma, L. (2024) *PromptAD: Learning Prompts with only Normal Samples for Few-Shot Anomaly Detection*, 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Los Alamitos.
53. Liu, J. ve Wang, F. (2024) *Mixed-Attention Auto Encoder for Multi-Class Industrial Anomaly Detection*, ICASSP 2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing.
54. Merhej, C. Beal, R. Matthews, J. T. ve Ramchurn, S. (2021) *What Happened Next? Using Deep Learning to Value Defensive Actions in Football Event-Data*, Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, New York.
55. Xu, M. Xu, T. Liu, Y. ve Lin, F. X. (2021) *Video Analytics with Zero-streaming Cameras*, 2021 USENIX Annual Technical Conference (USENIX ATC 21).

EKLER

EK-1. Literatür taramasına konu olan çalışmalarda kullanılan model başarımlar ölçüt ve sonuçları

Çalışma	Performans Ölçütleri	Sonuçlar
Too ve diğerleri (2019) [13]	Accuracy Precision Recall F1-Score	Acc = 98,08
		Acc = 81,83
		Acc = 99,66
		Acc = 99,75
Tassis ve diğerleri (2021) [19]	average precision (AP) average recall (AR)	AP = 73,00% AR = 78,90%
	accuracy (AC) mean intersection over union (MIoU)	AC = 99,54 MIoU = 94,25
		AC = 99,33 MIoU = 93,54
Ma ve diğerleri (2018) [14]	Precision Sensitivity F1-Score	Acc = 93,4% Precision = 92,18 Sensitivity = 92,1 F1-Score = 91,98
Momeny ve diğerleri (2020) [20]	Precision Specificity Sensitivity F1-Score	Acc = 99,4 %
Tian ve diğerleri (2019) [12]	IoU Precision Recall F1-Score	IoU= 89,6 F1-Score = 81,7
Ngo ve diğerleri (2021) [25]	Precision Recall F1-Score	mAP = 95 F1-Score = 94 Precision = 91 Recall = 0,99
Partela ve diğerleri (2019) [26]	-	-
Rao ve diğerleri (2021) [27]	Accuracy Precision Recall F1-Score	Acc = 99,03 Grape/Mango (P) = 98,9/89,5 Grape/Mango (R) = 98,5/90,5 Grape/Mango (F1) = 98,85/90
Lin ve diğerleri (2021) [29]	Mean Acc Mean IU	Mean Acc = 98,9 Mean IU = 96,4
		Mean Acc = 91,6 Mean IU = 95,5

EK-1. (devam) Literatür taramasına konu olan çalışmalarda kullanılan model başarımlar ölçüt ve Sonuçları

Çalışma	Performans Ölçütleri	Sonuçlar
Zhao ve diğerleri (2021) [21]	Accuracy Precision Recall F1-Score	Accuracy = 97,65 Precision = 99,54 Recall = 99,53 F1-Score = 99,53
Gonzales-Huitron ve diğerleri (2021) [22]	Accuracy Precision Recall F1-Score	75, 89, 75, 78
		98, 98, 98, 98
		84, 88, 84, 85
		100, 100, 100, 100
Partel ve diğerleri (2021) [23]	Accuracy Precision Recall F1-Score	Acc = 84,26
		P = 96 R = 83 F1 = 89
Wang ve diğerleri (2021) [11]	mAP Average Recall	mAP = 78,7 AR = 89
Abbas ve diğerleri (2021) [24]	PNSR (db)	Mean psnr = 28,15
	Accuracy Precision Recall F1-Score	Acc = 97,11 P = 97 R = 97 F1 = 97
Garcia-Manso ve diğerleri (2021) [28]	IoU Precision Recall F1-Score	Acc = 97,11 P = 97,3 R = 96,67 F1 = 96,67



Gazili olmak ayrıcalıktır