

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**X-IŞINI FINDIK GÖRÜNTÜLERİNDE KUSUR BELİRLEMeye
YÖNELİK DERİN ÖĞRENME TABANLI BİR YAKLAŞIM**

DOKTORA TEZİ

Sultan Murat YILMAZ

Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı

Bilgisayar ve Bilişim Mühendisliği Bilim Dalı

ARALIK 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**X-IŞINI FINDIK GÖRÜNTÜLERİNDE KUSUR BELİRLEMeye
YÖNELİK DERİN ÖĞRENME TABANLI BİR YAKLAŞIM**

DOKTORA TEZİ

Sultan Murat YILMAZ

Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı

Bilgisayar ve Bilişim Mühendisliği Bilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Serep ÇAKAR KAMAN

Ortak Danışman: Dr. Öğr. Üyesi Erkan GÜLER

ARALIK 2025

Sultan Murat YILMAZ tarafından hazırlanan “X-IŞINI FINDIK GÖRÜNTÜLERİNDE KUSUR BELİRLEMEYE YÖNELİK DERİN ÖĞRENME TABANLI BİR YAKLAŞIM” adlı tez çalışması 31.12.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı Bilgisayar ve Bilişim Mühendisliği Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Doç. Dr. Gökçen ÇETİNEL
	Sakarya Üniversitesi
Jüri Üyesi :	Dr. Öğr. Üyesi Serap ÇAKAR KAMAN
	Sakarya Üniversitesi
Jüri Üyesi :	Dr. Öğr. Üyesi Gözde YOLCU ÖZTEL
	Sakarya Üniversitesi
Jüri Üyesi :	Doç Dr. Gülçin ERSÖZ DEMİR
	Düzce Üniversitesi
Jüri Üyesi :	Dr. Öğr. Üyesi Doğan KÜÇÜK
	Giresun Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “X-IŞINI FINDIK GÖRÜNTÜLERİNDE KUSUR BELİRLEMeye YÖNELİK DERİN ÖĞRENME TABANLI BİR YAKLAŞIM” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(31/12/2025).

Sultan Murat YILMAZ





Aileme



TEŞEKKÜR

Doktora tez çalışmamın konu seçiminden planlanmasına, uygulama ve analiz aşamalarından sonuçlandırılmasına kadar geçen tüm süreçte; bilgi birikimi, deneyimi, yönlendirici eleştirileri ve sabırlı yaklaşımıyla bana her zaman destek olan kıymetli danışmanım Dr. Öğr. Üyesi Serap ÇAKAR KAMAN'a en içten teşekkürlerimi sunarım. Bilimsel yaklaşımı, disiplinli çalışma anlayışı ve yol gösterici tutumu, bu çalışmanın sağlıklı ve nitelikli bir biçimde tamamlanmasında belirleyici olmuştur.

Aynı zamanda, çalışmanın farklı aşamalarında değerli görüşleri, yapıcı önerileri ve katkılarıyla sürece önemli ölçüde destek veren ortak danışmanım Dr. Öğr. Üyesi Erkan GÜLER'e de teşekkür ederim. Hem teorik hem de uygulamaya dönük önerileri, karşılaşılan problemlerin çözümünde yol gösterici olmuş ve çalışmanın bilimsel derinliğini artırmıştır.

Tez sürecim boyunca yalnızca akademik anlamda değil, moral ve motivasyon açısından da her an yanımda olan aileme; bitmek bilmeyen sabırları, sonsuz anlayışları ve koşulsuz destekleri için en derin şükranlarımı sunuyorum. Zaman zaman yoğun çalışma temposu ve uzun araştırma süreçleri nedeniyle kendilerine yeterince vakit ayıramadığım anlarda dahi, bana hep anlayışla yaklaşımları bu zorlu süreci daha güçlü, daha kararlı ve daha umutlu bir şekilde sürdürmemi sağlamıştır. Bununla birlikte, hayatımın her döneminde sevgisini, güvenini ve desteğini benden esirgemeyen canım anneme, babama ve ağabeyime; bugünlere gelmemdeki en büyük pay sahipleri olarak, yürekten teşekkür ederim.

Sultan Murat YILMAZ



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1. Fındık Kalitesi ve Etki Eden Faktörler	2
1.2. Tahribatsız Gıda Analizi Yöntemleri	6
1.3. Bilgisayar Tabanlı Fındık Sınıflandırma	10
1.4. Sınırlayıcı Kutular ve Regresyonu	13
1.5. Tezin Katkıları	14
2. FINDIK KALİTESİ BELİRLEME SİSTEMİ	17
2.1. Veriseti Oluşturma	20
2.2. Görüntü Ön İşleme	24
2.3. Derin Öğrenme Yöntemi YOLOv7	25
3. SINIRLAYICI KUTU REGRESYON YÖNTEMLERİ VE ÖNERİLEN	
DCIOU METRİĞİ	29
3.1. Birleşim üzerindeki Kesişim	33
3.2. Genelleştirilmiş Birleşim Üzerinden Kesişim	36
3.3. Mesafe Kapsamlı Birleşim Üzerinden	38
3.4. Tam Kapsamlı Birleşim Üzerinden	39
3.5. Merkezler Arası Mesafe Birleşim Üzerinden	41
4. TAHMİNİ SINIRLAYICI KUTULARIN BELİRLENMESİ VE ÖNERİLEN	
KOMLUŞUK İLİŞKİ ALGORİTMASI	45
4.1. K-Means Algoritması	49
4.2. Komşuluk İlişki Algoritması	50
5. DENEYSEL ÇALIŞMALAR VE TARTIŞMA	57
5.1. DCIoU Simülayson Testleri	57
5.2. DCIoU Performans Testi	61
5.3. Komşuluk İlişkisi Algoritması Testi	69
5.4. Fındık Kalite Belirleme Sisteminin Karşılaştırmalı Performans Analizi	74
6. SONUÇLAR	79
KAYNAKLAR	85
ÖZGEÇMİŞ	95



KISALTMALAR

A2	: Area Attention
AR	: Alpha-Refine
C2f	: Cross Stage Partial with fused features
C2PSA	: Cross-Stage Partial with Position Sensitive Attention
CIoU	: Complete Intersection over Union
CLAHE	: Contrast Limited Adaptive Histogram Equalization
CNN	: Convolutional Neural Network
DCIoU	: Distance Centers Intersection over Union
DIoU	: Distance Intersection over Union
DQE	: Detective Quantum Efficiency
E-ELAN	: Extended Efficient Layer Aggregation Network
FAOUN	: Food and Agriculture Organization of the United Nations
GELAN	: Generalized Efficient Layer Aggregation Network
GIoU	: Generalized Intersection over Union
IoU	: Intersection over Union
NMS	: Non-Maximum Suppression
OA-MIL	: Object-Aware Multiple Instance Learning
ORB	: Oriented Bounding Box
OECD	: Organization for Economic Co-operation and Development
PGI	: Programmable Gradient Information
RGB	: Red-Green-Blue
RPB-Pose	: Residual Object Bounding Box Projection Pose
SIoU	: Scale-Sensitive IOU
TMO	: Toprak Mahsulleri Ofisi
UNECE	: United Nations Economic Commission for Europe Standard
YOLO	: You Only Look Once



TABLO LİSTESİ

Sayfa

Tablo 2.1. Veri seti etiket dağılımları.....	22
Tablo 2.2. X-Işını fındık veri seti 5-fold gösterimi	23
Tablo 5.1. YOLOv7 eğitiminde kullanılan hiperparametreler	63
Tablo 5.2. X-Işını Fındık ve COCO- 128 verisetlerinin IoU, GIoU, DIoU ve DCIoU kullanarak performans değerlendirme tablosu	67
Tablo 5.3. Önerilerin fındık kalite belirleme sisteminin literatürdeki farklı çalışmalarla karşılaştırılması	76



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Fındık çekirdeği ve işlenmiş fındık çekirdeği görüntüsü.	4
Şekil 1.2. (a) Fındık çekirdeği görüntüsü, (b) işlenmiş fındık çekirdeği görüntüsü, (c) X-Işını fındık çekirdeği görüntüsü.	9
Şekil 2.1. Fındık kalitesi belirleme sistemi	18
Şekil 2.2. Fındık seçme aparatı	19
Şekil 2.3. X-Işını fındık görüntüleri	21
Şekil 2.4. Sırasıyla X-Işını fındık görüntüsü, Otsu filtresi, CLAHE filtresi, Gauss Blur filtresi ve Anisotropic Diffusion filtresi uygulaması	25
Şekil 2.5. YOLOv7 mimarisi [87]	28
Şekil 3.1. Gerçek, tahmini ve kapsayıcı kutular ile kutularda kullanılan parameterler	33
Şekil 3.2. Farklı örtüşmelerde IoU, GIoU, DIoU ve DCIoU ölçümleri. (a) merkez noktaları ve en-boy oranları aynı olan birbirini kapsayan kutular. (b) Merkezleri farklı ancak en-boy oranları aynı olan kesişen kutular. (c) Merkezleri çakışan, yüksekliği aynı ancak genişliği farklı olan kutular. (d) Aynı merkez noktasına sahip ancak farklı en-boy oranlarına sahip kutular.	43
Şekil 4.1. 2D X-Işını görüntüsünün matris formuna dönüştürülmesi	51
Şekil 4.2. Komşuluk ilişki algoritması adımları. (a) Komşuluk ilişki algoritması yönleri, (b) kümelenmiş X-Işını fındık matris formu görüntüsü, (c) kontrol matrisi uygulanmış görüntü, (d) komşuluk ilişki algoritması tensör yapısı.	53
Şekil 4.3 Komşuluk ilişki algoritması ile sınırlayıcı kutu oluşumu. (a) X-Işını görseli, (b) ön işleme yapılmış görüntü, (c) eşik değeri kullanmadan oluşan sınırlayıcı kutular, (d) eşik değeri kullanarak oluşan sınırlayıcı kutular... ..	54
Şekil 5.1. (a) Simülasyon için oluşturulan sınırlayıcı kutu regresyon örnekleri, (b) Sınırlayıcı kutuların IoU, GIoU, DIoU, CIoU ve DCIoU için regresyon sonuçlarının grafiksel gösterimi	58
Şekil 5.2. IoU, GIoU, DIoU, CIoU ve DCIoU için 50, 100, 150 ve 200 iterasyonda kutu optimizasyon davranışları. Mavi kutu gerçek kutuyu, kırmızı kutu tahmin kutusunu yeşil kutu ise örtüşme kutusunu temsil etmektedir.	60
Şekil 5.3. X-Işını Fındık Görüntülerinde IoU, GIoU, DIoU, CIoU ve DCIoU kayıp fonksiyonları için elde edilen karmaşıklık (confusion) matrisleri	64
Şekil 5.4. Farklı örnekler için fındık kusur gösterimi. (a) YOLOv7 ile kusur tespiti, (b) DCIoU ve Komşuluk ilişki algoritması ile kusur tespiti, (c) DCIoU ve Komşuluk ilişki algoritması ile kusur segmentasyonu.	71



X-IŞINI FINDIK GÖRÜNTÜLERİNDE KUSUR BELİRLEMeye YÖNELİK DERİN ÖĞRENME TABANLI BİR YAKLAŞIM

ÖZET

Fındık hem Türkiye ekonomisi hem de dünya genelinde tarımsal üretim açısından stratejik öneme sahip bir tarım ürünüdür. Fındığın kalitesi ve randımanı, üretici gelirlerinden ürünün endüstriyel kullanım potansiyeline kadar pek çok parametreyi doğrudan etkilemektedir. Geleneksel kalite ve randıman belirleme yöntemleri, genellikle elle yapılan kontroller, görsel değerlendirmeler ve sınırlı ölçüm cihazlarıyla gerçekleştirilmekte olup, zaman alıcı, yoğun iş gücü gerektiren ve insan faktöründen kaynaklanan hata riskine açık süreçlerdir. Özellikle büyük ölçekli üretim tesislerinde bu yöntemler kalite kontrolünün hızını ve doğruluğunu sınırlamakta, endüstriyel verimliliği düşürmektedir. Bu bağlamda, bu tez çalışması kapsamında fındık üretim süreçlerinde kalite kontrol ve randıman belirleme süreçlerini modern, hızlı, güvenilir ve tekrarlanabilir yöntemlerle iyileştirmek amacıyla tahribatsız X-Işını görüntüleme ve derin öğrenme tabanlı bir fındık kalite belirleme sistemi önerilmiştir. Önerilen sistem, kusurlu, az kusurlu ve kusursuz fındıkları ayrıntılı biçimde tespit ederek, üretim zincirine veri tabanlı karar desteği sağlamış ve kalite kontrol süreçlerinin doğruluğunu önemli ölçüde artırmıştır. Böylece, doğru ve güvenilir fındık randımanı belirleme olanağı sunarak, üreticiden tüketiciye kadar tüm tedarik zincirinde kaliteyi güvence altına almakta ve ekonomik değerlemeyi doğrudan etkilemektedir.

Fındık kusur tespitinde kullanılan YOLO (You Only Look Once) v7 derin öğrenme mimarisi, sınırlayıcı kutu regresyonu için geliştirilen DCIoU (Distance Centers Intersection over Union) kayıp fonksiyonu ile entegre edilmiştir. DCIoU, kutu merkezleri arasındaki mesafeyi, genişlik-yükseklik ve en-boy oranlarını eşzamanlı olarak optimize ederek, minimal çakışma alanlarına sahip veya birbirine yakın konumlanmış küçük nesnelerde diğer IoU tabanlı kayıp fonksiyonlarına göre çok daha hızlı ve hassas yakınsama sağlamaktadır. Bu özellik, özellikle fındık çekirdeği üzerindeki küçük veya kısmi kusurların doğru bir şekilde tespit edilmesini mümkün kılmış ve model performansında belirgin iyileşmelere yol açmıştır. DCIoU'nun sağladığı hızlı yakınsama ve düşük regresyon sapması, modelin öğrenme sürecinde stabilizeyi artırmakta ve sınırlayıcı kutu optimizasyonunun erken aşamalarda daha etkili bir biçimde gerçekleşmesini sağlamaktadır. Böylece, küçük boyutlu ve örtüşen kusurların ayrıştırılmasında klasik IoU (Intersection over Union), GIoU (Generalized Intersection over Union), DIoU (Distance Intersection over Union) ve CIoU (Complete Intersection over Union) tabanlı yaklaşımlara kıyasla belirgin avantajlar sağlanmıştır.

Sistem ayrıca önerilen Komşuluk İlişkisi Algoritması ile desteklenmiş, model tarafından üretilen sınırlayıcı kutular arasındaki uzamsal süreklilik ve piksel bazlı ilişkileri dikkate alarak segmentasyon çıktıları üretmiştir. Tensör tabanlı bu yapı, her bir pikselin ait olduğu küme ve komşuluk ilişkilerini kapsamlı şekilde temsil ederek manuel etiketleme gereksinimini ortadan kaldırmaktadır. Böylece fındık çekirdekleri üzerindeki kusurların boyut, şekil ve konum bilgileri yüksek doğrulukla elde

edilebilmekte ve bu bilgiler randıman hesaplama süreçlerinde doğrudan kullanılabilir hâle gelmektedir. Segmentasyon çıktıları, yalnızca nesne varlığını değil, aynı zamanda her bir kusurun piksel düzeyindeki dağılımını, alanını ve yoğunluğunu belirleyerek fındıkların kusurlu, az kusurlu veya kusursuz olarak sınıflandırılmasını sağlamaktadır. Bu sayede sistem, üretim zincirinde kalite kontrol süreçlerinde daha güvenilir ve tekrarlanabilir sonuçlar üretmektedir.

Sistem, X-Işını fındık veri seti ve genel nesne tespiti amacıyla kullanılan COCO-128 veri seti üzerinde test edilmiş, DCIoU ve Komşuluk İlişkisi algoritmaları entegre edilerek eğitilen YOLOv7 modeli, her iki veri setinde de yüksek doğruluk ve kararlı performans sergilemiştir. Kesinlik, duyarlılık, F-1 skoru ve mAP metriklerindeki yüksek değerler, modelin hem fındık kusur tespitinde hem de farklı nesne tespiti senaryolarında güvenilirliğini ortaya koymaktadır. X-Işını veri seti üzerindeki deneylerde, DCIoU tabanlı modelin hem doğruluk hem de hassasiyet açısından önceki IoU tabanlı yaklaşımlara göre üstün performans sağladığı gözlemlenmiştir. Özellikle segmentasyon çıktılarıyla desteklenen yaklaşım, küçük ve örtüşen kusurların ayrıştırılmasında klasik YOLOv7 modeline kıyasla çok daha başarılı sonuçlar üretmiştir.

Tez kapsamında yapılan deneysel çalışmalar, DCIoU'nun optimizasyon sürecindeki üstün yakınsama davranışını ve regresyon sapmasını minimize etme kapasitesini doğrulamıştır. Ayrıca Komşuluk İlişkisi algoritması, NMS (Non-Maximum Suppression) süreçlerine alternatif bir yaklaşım kazandırarak sınırlayıcı kutuların seçimini optimize etmiş ve segmentasyon süreçlerinin doğrudan nesne tespiti çıktılarından türetilebileceğini göstermiştir.

Bu tez çalışması, X-Işını görüntüleme ve derin öğrenme tabanlı analizleri bütünleştirerek fındık kalite belirleme ve randıman hesaplama süreçlerinde hassas, hızlı ve güvenilir bir sistem geliştirmiştir. Sistem, yalnızca kusur tespitini iyileştirmekle kalmayıp, üretim süreçlerinde otomasyon, veri tabanlı karar mekanizmaları ve kalite kontrol verimliliğini artırmaktadır. Bu özellikler, fındık üretiminde hem akademik hem de endüstriyel açıdan yüksek katma değer sağlayacak bir kalite kontrol ve randıman hesaplama çözümü sunmaktadır.

A DEEP LEARNING BASED APPROACH FOR DEFECT DETECTION IN X-RAY HAZELNUT IMAGES

SUMMARY

Hazelnut is a strategic agricultural product for both the Turkish economy and global agricultural production. Its annual production volume and position in the world market allow hazelnuts to play a critical role within the agricultural production chain. Agricultural hazelnut quality and the hazelnut kernel percentage directly affect numerous parameters, ranging from producer income to the industrial utilization potential of the product. Therefore, accurately and reliably assessing the quality level of hazelnuts is of great importance not only for securing producer income but also for determining the industrial usage potential of the product and ensuring the sustainability of the agricultural production chain. In the literature and current practices, the most common method used to determine agricultural hazelnut quality is the calculation of the hazelnut kernel percentage, also known as the sound hazelnut ratio. Türkiye is the leading country in global hazelnut production, with intensive cultivation in Giresun, Ordu, Samsun, and other regions of the Black Sea; this provides strategic importance in both the domestic market and international trade.

Traditional methods for determining agricultural hazelnut quality and the hazelnut kernel percentage are typically carried out through manual inspections, visual assessments, and limited measuring instruments. These methods are time-consuming, labor-intensive, and prone to errors arising from human factors. Especially in large-scale production facilities, such traditional approaches limit the speed and accuracy of quality control and reduce industrial efficiency. In this context, this thesis proposes a non-destructive X-ray imaging and deep learning-based hazelnut quality determination system to improve quality control and hazelnut kernel percentage estimation processes in hazelnut production using modern, fast, reliable, and repeatable techniques. The proposed system provides data-driven decision support to the production chain by accurately identifying defective, slightly defective, and defect-free hazelnuts, thereby significantly enhancing the accuracy of quality control procedures. In doing so, it offers the ability to determine the hazelnut kernel percentage accurately and reliably, ensuring quality throughout the entire supply chain-from producer to consumer-and directly influencing economic valuation.

In this thesis, a dedicated X-ray hazelnut dataset was constructed for the training and evaluation of the deep learning model developed for hazelnut defect detection. The dataset includes five different hazelnut varieties collected from the provinces of Samsun, Ordu, and Giresun in Türkiye, consisting of a total of 1320 labeled X-ray images. The images were meticulously annotated to accurately reflect the internal structure of the hazelnut kernel and possible defects, with each defective region marked in detail at the pixel level. This comprehensive annotation process ensured high accuracy in regional defect detection and enabled reliable assessment of the object detection and segmentation performance of the developed methods. During dataset construction, each hazelnut sample was scanned at high resolution using an X-ray device, and preprocessing steps were applied to preserve image quality and maximize

the visibility of defects. In the preprocessing stage, hazelnut kernel regions were identified using the Otsu filtering method, while defect areas were enhanced using CLAHE, blur, and Anisotropic Diffusion filters, simultaneously reducing noise, improving contrast, and increasing object clarity. This process played a critical role in accurately detecting small, partial, or overlapping defects and provided the model with clean, optimized input data for training.

For hazelnut defect detection, the YOLOv7 deep learning architecture, known for its high accuracy and fast inference capabilities, was selected. In particular, the DCIoU (Distance Centers Intersection over Union) loss function was proposed and integrated into the model to enhance bounding box regression performance. DCIoU overcomes the limitations of traditional IoU-based loss functions, which consider only the overlap area, by simultaneously optimizing the distance between box centers, width-height ratios, and aspect ratio consistency. Consequently, even in cases where there is minimal overlap between boxes or defects occupy very small pixel areas, the model can learn the correct regression direction at early stages and achieve rapid convergence.

Since most defects encountered within the internal structure of hazelnuts—such as rot, voids, cracks, mold, and deformations—appear with low contrast, in fragmented forms, or partially, correct alignment of box centers plays a critical role in detection performance. DCIoU penalizes these center misalignments, enabling the model to localize defect regions with more precise boundaries; this provides a significant advantage over traditional IoU, GIoU, DIoU, and CIoU methods, particularly for defects that are closely positioned or overlapping. Moreover, including the geometric ratios of the boxes in the optimization contributes to more consistent modeling of defects with varying sizes and shapes.

The low regression deviation produced by DCIoU enhances stability during the learning process and allows the model to establish a more balanced error distribution, particularly in the early epochs. Experimental results indicate that the YOLOv7 model utilizing DCIoU demonstrates significant improvements in detecting small and partial defects, marking them with high accuracy, and overall enhances object detection performance. Consequently, the requirements for high precision and low error tolerance, which are essential in hazelnut quality grading systems, are effectively met.

To enhance the model's detection performance and generate segmentation outputs, a Neighborhood Relationship Algorithm was developed and integrated. This algorithm evaluates spatial continuity and pixel-level relationships among multiple bounding boxes produced by the model, selecting the most appropriate boxes and filtering out unnecessary duplicates. The output of the algorithm generates tensor structures that can be directly used in the segmentation process. This tensor-based structure comprehensively represents the cluster and neighborhood relationships of each pixel, eliminating the need for manual annotation. Consequently, the size, shape, and location information of defects on hazelnut kernels can be obtained with high accuracy and used directly in hazelnut kernel percentage calculations. The segmentation outputs not only identify the presence of objects but also determine the pixel-level distribution, area, and density of each defect, enabling hazelnuts to be classified as defective, slightly defective, or defect-free. In this way, the system produces more reliable and repeatable results in quality control processes throughout the production chain.

Within the scope of this thesis, two separate simulation tests were conducted to compare the performance of DCIoU with existing IoU-based approaches. In these

simulation environments, various synthetic data scenarios were created in which object sizes varied, overlap ratios between boxes changed, and center positions were systematically shifted. The findings indicate that the DCIoU loss function achieves significantly faster convergence during optimization compared to other commonly used approaches such as IoU, GIoU, DIoU, and CIoU. Furthermore, DCIoU was observed to maintain lower regression error levels and to perform more stable and accurate bounding box alignment, particularly in scenarios involving small or partial objects. This demonstrates that DCIoU's capacity to precisely optimize the distances between box centers substantially improves the overall performance of the model and provides supportive evidence for the results obtained on real data.

In addition to these simulation tests, the system was evaluated on both the X-ray hazelnut dataset and the COCO-128 dataset, which is commonly used for general object detection. The YOLOv7 model trained with the integration of DCIoU and the Neighborhood Relationship Algorithm demonstrated high accuracy and stable performance on the X-ray hazelnut dataset as well. High values in precision, recall, F-1 score and mAP metrics indicate the model's reliability in both hazelnut defect detection and various object detection scenarios. In experiments on the X-ray dataset, the DCIoU-based model exhibited superior performance in terms of both accuracy and sensitivity compared to previous IoU-based approaches. In particular, the approach supported by segmentation outputs produced significantly better results in distinguishing small and overlapping defects than the standard YOLOv7 model.

The experimental studies confirmed DCIoU's superior convergence behavior during optimization and its capacity to minimize regression deviation. Additionally, the Neighborhood Relationship Algorithm provided an alternative approach to classical NMS (Non-Maximum Suppression) processes, optimizing the selection of bounding boxes and demonstrating that segmentation processes can be directly derived from object detection outputs. By integrating X-ray imaging with deep learning-based analyses, the system offers a precise, fast, and reliable solution for hazelnut quality assessment and hazelnut kernel percentage calculations. It not only improves defect detection but also enhances automation, data-driven decision-making, and quality control efficiency in production processes.

In conclusion, this thesis combines deep learning and non-destructive X-ray imaging methods to provide an innovative and practical solution that ensures high accuracy, reliability, and operational efficiency in hazelnut quality assessment and hazelnut kernel percentage calculation processes. The system offers a comprehensive and automated workflow, from detecting small and overlapping defects to segmentation, thereby securing quality throughout the hazelnut production chain and directly supporting economic valuation.



1. GİRİŞ

Fındık (*Corylus avellana* L.), dünya genelinde yüksek ekonomik değere sahip ve gıda endüstrisinde yaygın olarak kullanılan önemli bir tarım ürünüdür. Fındık, yıllık 863 bin tonu aşan üretimiyle küresel kabuklu yemişler pazarında üçüncü sırada yer almaktadır [1]. Yüksek üretim hacmiyle ve zengin besin içeriği ile sağlık üzerindeki olumlu etkileri sayesinde tüketici talebi görmektedir [2]. Türkiye, yıllık ortalama 776.046 tonluk üretimiyle dünya fındık üretiminde lider konumdadır [1]. Başlıca üretici ülkeler arasında İtalya, Amerika Birleşik Devletleri, Gürcistan, Azerbaycan ve İspanya da yer almaktadır, Türkiye üretim miktarı bakımından açık ara farkla dünya liderliğini sürdürmektedir [3]. Türkiye, dünya üretiminin yaklaşık %70'ini karşılamasıyla yalnızca lider üretici ülke değil, aynı zamanda küresel fındık ticaretinde belirleyici aktör konumundadır [4]. Bu durum, fındığı Türkiye için yüksek ekonomik katma değer sağlayan ve tarımsal ihracat politikalarında stratejik önem taşıyan bir ürün hâline getirmiştir.

Besin bileşimi açısından oldukça zengin olan fındık; %10-24 protein, %50-73 yağ, %10-22 karbonhidrat, %1-3 selüloz ve pektin, vitaminler, mineraller, fenolik bileşikler ve diyet lifleri içermektedir [5]. Özellikle tekli doymamış yağ asitleri, tokoferoller ve fitosteroller gibi yağda çözünen biyoaktif bileşenler, fındığın kardiyovasküler hastalık riskini azaltma, kolesterol seviyelerini düşürme ve metabolik sendromu önlemede önemli rol oynamasını sağlamaktadır [6]. Ayrıca fındık yan ürünleri, özellikle sert kabuklar, kateşin, epikateşin ve gallik asit gibi fenolik bileşikler açısından değerli bir kaynaktır [7]. Bu özellikler, fındığı yalnızca beslenme açısından değil; kozmetik, ilaç ve gıda endüstrisi için de stratejik bir tarım ürünü haline getirmektedir [8].

Fındığın hem ulusal hem de uluslararası pazarındaki değeri, ürünün kalite özelliklerinin titizlikle değerlendirilmesini zorunlu kılmaktadır. Fındık çeşidi, yetiştirme teknikleri, coğrafi köken, hasat zamanı, hasat sonrası işlemler ve depolama koşulları; nihai ürünün fiziksel, kimyasal ve duyuşsal özelliklerini etkileyen temel faktörlerdir [9]. Ancak özellikle “çürük fındık”, “şekli bozuk fındık” küf, acı veya topraksı tat gibi olumsuz duyuşsal özellikler, ticari değeri düşüren ve tüketici

memnuniyetini olumsuz etkileyen en önemli kusurlar arasında yer almaktadır. Bu nedenle fındık kalite değerlendirmesi yalnızca üretim ve işleme süreçlerinin değil, aynı zamanda küresel ticaretin ve tüketici sağlığının da merkezinde bulunmaktadır.

Ürün kalitesi, tarımsal ürünlerin ekonomik ve besinsel değerini belirleyerek tüketici tercihlerini ve alıcı kabulünü doğrudan etkileyen temel bir faktördür [10]. Kalitesi yüksek ürünler hem iç piyasada hem de dış pazarlarda daha yüksek fiyatla alıcı bulmakta; bu durum üretici gelirlerini ve ülke ekonomisine katkıyı artırmaktadır. Fındık özelinde değerlendirildiğinde, meyve kalitesi; ürünün işlenebilirliğini, dayanıklılığını ve nihai tüketici tarafından kabul edilme düzeyini belirlemektedir.

Yüksek meyve kalitesi, fındığı ulusal ve uluslararası pazarlarda talep gören, rekabet gücü yüksek bir ürün haline getirmiştir [11]. Kalite düzeyinin yüksekliği, fındığın işleme sanayisinde tercih edilme oranını artırmakta ve ihracat pazarlarında sürekliliğin sağlanmasında belirleyici rol oynamaktadır. Bu nedenle üretim sürecinde kaliteyi etkileyen tüm aşamaların (hasat, kurutma, depolama ve işleme gibi) dikkatle yürütülmesi büyük önem taşımaktadır. Bu bağlamda, üreticilerin kalite standartlarına uyumu, ürünün pazarda değerini koruyabilmesi açısından zorunludur. Aynı şekilde, fındık endüstrisinde faaliyet gösteren işletmelerin de fındık kusurlarının doğru ve tutarlı biçimde tespiti için etkili değerlendirme sistemleri geliştirmesi gerekmektedir [12]. Bu tür sistemler, kalite yönetiminin sürdürülebilirliğini sağlayarak ürünün güvenilirliğini, pazarlanabilirliğini ve tüketici memnuniyetini artıracaktır.

1.1. Fındık Kalitesi ve Etki Eden Faktörler

Fındık meyvesi hem bireysel tüketiciler hem de gıda endüstrisi tarafından yüksek kaliteli kabuklu meyve olarak giderek artan bir talep görmektedir [13]. Özellikle dünya fındık üretimi ve ihracatında lider konumda bulunan Türkiye açısından bu durum büyük önem taşımaktadır. Ancak fındık meyveleri, zaman zaman istenmeyen tat oluşumlarıyla ilişkilendirilen çeşitli kalite kusurlarından etkilenebilmekte ve bu durum, ürünün endüstriyel işlemlerdeki kullanılabilirliğini önemli ölçüde sınırlamaktadır. Dünya genelinde fındık üretiminde kaliteyi artırmaya yönelik devlet politikaları, modern üretim teknikleri ve eğitim yatırımları hızla gelişmektedir [14]. Bu gelişmeler, üreticiler arasındaki rekabeti her geçen gün daha da yoğunlaştırmaktadır. Böyle bir rekabet ortamında Türkiye'nin güçlü konumunu koruyabilmesi, yalnızca yüksek verim elde etmeye değil, aynı zamanda fındık

kalitesini doğru ve güvenilir biçimde belirlemeye bağlıdır. Fındık kalitesinin doğru şekilde belirlenmesi hem üretim süreçlerinin iyileştirilmesi hem de uluslararası pazarlarda müşteri memnuniyetinin sağlanması açısından kritik bir öneme sahiptir. Fındık kalitesinin doğru ve etkin bir şekilde belirlenebilmesi için öncelikle fındıkta görülen kusurların eksiksiz ve doğru biçimde tespit edilmesi gerekmektedir. Kusurlar hem kabuk üzerinde hem de iç meyvede ortaya çıkabilmektedir ve her iki bölgede meydana gelen bozulmalar, telafisi mümkün olmayan kalite kayıplarına yol açabilir. Fındıkta rastlanan başlıca kusurlar arasında kabukta kahverengi lekeler, çıtlak meyve ve küçük meyve; iç meyvede ise buruşuk iç, boş veya eksik (abortif) iç, çift iç, büyük göbek boşluğu, liflilik, siyah uçlu iç, küflü iç ve böcek zararına uğramış iç yer almaktadır [15]. Bu kusurların bilinmesi ve uygun şekilde tespit edilmesi üretici, sanayici ve tüketici açısından büyük önem taşımaktadır.

Ülkemizde son dönemlerde fındık alanlarında görülen hastalık ve zararlılar fındığın meyve kalitesinde önemli düzeyde kayıplara neden olmaktadır. Türkiye’de bölgelere göre farklılık göstermek üzere fındıkta %10’un üzerinde “lekeli iç” şeklinde zarara neden olmaktadır [16]. Bu zararların çoğuna delici ve emici böcekler neden olmaktadır [17]. Özellikle son yıllarda artan kahverengi kokarca böceği istilasını fındık kalitesini belirlerken daha dikkatli olunmasını gerektirmektedir [18].

Ürün kalitesi, tarımsal ürünlerin ekonomik ve besinsel değerini belirleyerek tüketici tercihlerini ve alıcı kabulünü etkiler [9]. Yüksek meyve kalitesi, fındığı ulusal ve uluslararası pazarlarda talep gören bir ürün yapmıştır [19]. Bu nedenle, üreticilerin kalite standartlarına uyumu ve endüstrilerin fındık kusurlarını etkili biçimde tespit edebilmesi oldukça önemlidir.

Fındıkta kalite belirleme işlemleri genellikle fındıkların satın alım merkezlerine satışı (TMO, Fisikobirlik, özel alım merkezleri, vs.) aşamasında yapılır. Fındık alım merkezlerinde üreticilerin fındık alım şartlarına göre fındıklarını hazırlaması gerekir. Fındıklarda yetiştikleri yere ve yıla göre farklı kusurlar görülebilir. Bu sebepten dolayı Ekonomik İş birliği ve Kalkınma Örgütü (Organization for Economic Co-operation and Development-OECD) ve Birleşmiş Milletler Avrupa Ekonomik Komisyonu Standardı (United Nations Economic Commission for Europe Standard- UNECE) tarafından yayınlanan raporlarda fındık için asgari pazar ve ticaret kalite standartları belirlenmiştir [20-21].

Fındık kalitesi belirlenirken farklı yöntemler olsa da literatürde önerilen en iyi (yaygın) yöntemin sağlam iç oranı ile olduğu belirtilmiş ve fındık alım merkezlerinde de yaygın olarak da kullanılmaktadır [22-24]. İç oranı, fındıkta incelenen özellikler arasındaki ilişkiler içerisinde kalite belirlemede en etkili parametre olarak tespit edilmiştir [22]. Fındıkta sağlam iç çekirdek oranı, randıman kabul edilir fındık çekirdek ağırlığının kabuklu fındık ağırlığına oranı ile belirlenir ve yüzde olarak ifade edilir (1.1). Fındık kalite belirlemede kullanılan sağlam iç oranı, randıman ölçümü olarak da tanınmaktadır. Randıman ölçümünde standartların belirlenmesi ve bu standartlara uyulması büyük önem taşır. Bu bağlamda, OECD ve UNECE tarafından yayınlanan raporlarda fındık için asgari pazar ve ticaret kalite standartları belirlenmiştir [20-21]. Ayrıca, fındık alım merkezleri (Toprak Mahsulleri Ofisi (TMO), Fiskobirlik gibi), yıllık fındık gelişim süreçlerindeki farklılıklara göre kendi alım standartlarını oluşturabilmektedir.

Fındık randımanı belirleme işlemi genellikle hasat sonrası ürünlerin fındık alım merkezlerine satışı sırasında yapılmaktadır. Fındık alım merkezlerinde randıman belirleme süreçleri çoğunlukla geleneksel yöntemlerle yapılmaktadır ve bu süreçler genellikle fındık uzmanlarının gözlemleri ile gerçekleştirilmektedir [25]. Ancak, bu yöntemin insan faktörüne bağlı olması, subjektif hatalara yol açabilmekte ve gözle tespit edilmesi zor olan kusurların belirlenmesini güçleştirebilmektedir (Şekil 1.1.). Bu durum, fındığın depolama süresi, endüstriyel kullanımı ve adil fiyatlandırılması gibi parametreleri olumsuz etkilemektedir.



Şekil 1.1. Fındık çekirdeği ve işlenmiş fındık çekirdeği görüntüsü.

$$\text{Randıman} = \frac{\text{Sağlam iç Ağırlığı}}{\text{Kabuklu Fındık Ağırlığı}} \times 100 \quad (1.1)$$

Fındıkta doğru randıman ölçümü için kusurların eksiksiz ve hatasız bir şekilde tespit edilmesi gerekmektedir. Çürükler, renk bozulması veya fındığın geri kalanıyla belirgin bir tezat oluşturan lekeler ve yarı kesimden sonra gözlenen iç kahverengileşme gibi kusurlar, fındığın ticari kalitesini ve pazar değerini önemli ölçüde etkiler [26]. Pazarın gerektirdiği kalite standartlarına uymayan kusurlu fındıkların randıman hesaplaması yapılırken tespiti oldukça önemlidir. Fındıkta gözlemlenen kusurlar, yetiştirme koşulları ve yetiştirme alanına bağlı olarak yıllık %1 ile %15 arasında değişiklik göstermektedir [27]. Birleşmiş Milletler Gıda ve Tarım Organizasyonu (Food and Agriculture Organization of the United Nations - FAOUN) verilerine göre, yılda 1 milyon tonun üzerinde fındık üretimi yapılmaktadır, bu da 10.000 ton ile 150.000 ton arasında kusurlu fındık oluşabileceği anlamına gelmektedir.

Fındıkta kusurların doğru, sistematik ve dikkatli bir şekilde tespit edilmesi; ürün kalitesinin korunması, standartların sürdürülebilirliği ve üretim sürecinde meydana gelebilecek ekonomik kayıpların önlenmesi açısından büyük önem taşımaktadır. Özellikle dış ticarete kalite standartlarının giderek daha fazla önem kazandığı günümüzde, fındıkta kalite sınıflandırmasının güvenilir ve tekrarlanabilir biçimde yapılması, üretici ve ihracatçılar açısından rekabet gücünü doğrudan etkilemektedir.

Günümüzde fındık kalite değerlendirmeleri büyük ölçüde geleneksel yöntemlerle gerçekleştirilmektedir [25]. Bu yöntemler; fındığın kalibresi, şekil özellikleri, görünür fiziksel hasarları ve duyu kusurlarının alanında deneyimli uzmanlar tarafından görsel ve duyu gözlemlerle değerlendirilmesini kapsamaktadır [23]. Ancak bu tür geleneksel yaklaşımlar, yüksek derecede insan faktörüne bağlı olmaları nedeniyle öznel yorumlara açık olup, farklı değerlendiriciler arasında tutarsız sonuçlara yol açabilmektedir. Ayrıca, süreçlerin manuel olarak yürütülmesi hem zaman hem de maliyet açısından önemli bir yük oluşturmakta, bu da artan üretim hacimleri ve pazar talepleri karşısında yöntemin etkinliğini sınırlamaktadır. Bu nedenlerle, fındıkta kalite ve kusur değerlendirme süreçlerinde daha hızlı, nesnel ve tekrarlanabilir sonuçlar sunabilen otomatik analiz sistemlerine olan ihtiyaç giderek artmaktadır. Dolayısıyla fındıkta kalite değerlendirmesi, yalnızca tarımsal üretim ve endüstriyel işleme süreçleri açısından değil, aynı zamanda uluslararası ticaret ve tüketici beklentileri bakımından da önemli bir araştırma alanıdır.

Fındık kabuğundaki kusurlar gözlem yoluyla kolayca görülürken fındık çekirdeğindeki kusurlar bazı durumlarda kolay tespit edilemez. Özellikle fındık

çekirdek kusurları bulunduğu iç yapısında meydana geldiğinden, dış görünüm üzerinden yapılan değerlendirmelerde fark edilmeden gözden kaçabilmektedir. Fındık çekirdeğinin gelişim sürecinin son aşaması, kahverengi dış zarın tam oluşumudur [24]. Bu aşamaya kadar olan süreçte, dış etkenlere bağlı çeşitli yapısal deformasyonlar veya biyokimyasal değişimler meydana gelebilmektedir. Bu tür kusurlar, zaman zaman zarın altında gizlenerek görünmez hale gelebilir (Şekil 1.1.) [16,18]. Fındıkta kalite değerlendirmesi yapılırken, dışarıdan fark edilmeyen bu iç kusurların belirlenmesi çoğu zaman zorlayıcı olmaktadır. Kusurların tespit edilemediği durumlarda, bulunduğu kesilerek incelenmesi yaygın bir yöntem olarak kullanılmaktadır. Kusurlar, gözle görülemediğinde fındık kesilerek incelenebilir ancak zar ile çekirdek arasında kalan kusurlar bu yöntemle de belirlenemeyebilmektedir. Geleneksel randıman ölçüm yöntemleri yavaş, maliyeli ve sınırlı olup lipid oksidasyonu ve iç çekirdek kusurlarını tespit etmekte yetersiz kalır [28,29]. Ayrıca, geleneksel yöntemler insan faktörüne dayalı olduğundan hata oranı standartlaştırılmaz ve kontrolü oldukça güçtür [30]. Bu noktada, fındık çekirdeklerindeki kusurların daha etkili bir şekilde tespit edilebilmesi ve standartlaştırılması için tahribatsız yöntemlere başvurulması gerekmektedir [31].

1.2. Tahribatsız Gıda Analizi Yöntemleri

Tahribatsız yöntemler, kalite kontrol doğruluğunu artırarak fındığın ticari değerini korumada kritik öneme sahiptir [32]. Tarım ürünlerinin kalitesi, tüketici ilgisi, pazar kabulü ve dolayısıyla depolama ve hasat sonrası işleme operasyonlarını doğrudan etkilemesi açısından büyük önem taşımaktadır. Meyve, sebze ve gıda ürünlerinin kalite ölçümü, gıda endüstrisinin ilgi odağıdır. Kalite parametrelerinin tahribatsız ölçümleri birçok tarım ürünüde gerçekleştirilmiş ve ilgili kalite faktörlerinin tahmininde hızlı ve doğru sonuçlar vermiştir [33]. Tahribatsız yöntemler, ürünün yapısına veya içeriğine zarar vermeden kaliteli ve güvenli değerlendirme yapmayı sağlayan tekniklerdir. Bu yöntemler, örnek üzerinde herhangi bir fiziksel veya kimyasal değişikliğe yol açmadan analiz yapılmasına imkân tanır ve bu sayede ürünün bütünlüğü korunmuş olur. Tahribatsız teknikler, geleneksel tahribatlı yöntemlere kıyasla daha hızlı ve verimli sonuçlar sağlar, bu da özellikle yüksek değerli ve hassas ürünlerde önemli bir avantajdır [34]. Ayrıca bu yöntemler, tekrarlanabilirlik ve standartlaşma açısından yüksek güvenilirlik sunar; bir ürünün farklı örnekleri üzerinde yapılan ölçümler tutarlı ve karşılaştırılabilir sonuçlar verir [30]. Bunun yanı sıra, tahribatsız yöntemler kimyasal atık üretmediği ve çevreye zarar vermediği için


sürdürülebilir bir analiz yaklaşımı olarak da öne çıkar [33]. Gıda kalite kontrolünde, özellikle üretim ve ticaret süreçlerinde ürünün kalitesinin hızlı ve güvenilir bir şekilde belirlenmesi kritik öneme sahiptir ve tahribatsız yöntemler bu ihtiyacı karşılamada etkili bir araç olarak kullanılmaktadır.

Görüntü işleme ve derin öğrenme alanındaki son gelişmeler, tarım, gıda işleme, biyomedikal ve askeriye gibi çeşitli sektörlerdeki bilgisayarlı görme uygulamalarında devrim yaratmıştır [35]. Bu gelişmeler, süreçleri otomatikleştirme ve verimliliği artırma çabalarını hızlandırmaktadır. Teknolojik yenilikler, gıda kalite kontrolünde önemli bir rol üstlenmiş, zaman alıcı ve insan faktörüne dayalı geleneksel yöntemlerin yerini almaya başlamıştır [36]. Tahribatsız yöntemler, gıda kalite kontrolünde bu bağlamda kritik bir rol üstlenmektedir. Ürün üzerinde herhangi bir fiziksel veya kimyasal değişikliğe yol açmadan gerçekleştirilen analizler hem ürün bütünlüğünü korumakta hem de hızlı ve standart bir değerlendirme sağlamaktadır. Bu yöntemler, gıda işleme ve kalite kontrol süreçlerinde verimlilik, doğruluk ve tekrarlanabilirlik açısından geleneksel yöntemlerin önüne geçmektedir. Gıda işlemede yaygın olarak kullanılan tahribatsız yöntemler arasında optik (Spektral), akustik, ultrasonografik, radyografik (X-Işını, bilgisayarlı tomografi) ve elektrik-elektronik tabanlı yöntemler öne çıkmaktadır [29,37,38]. Bu yöntemler, gıda ürünlerinin kalite kontrolünde ürün bütünlüğünü koruyarak hızlı, güvenilir ve tekrarlanabilir analizler yapılmasına olanak tanımaktadır. Özellikle radyografik tabanlı yöntemlerden biri olan X-Işını görüntüleme, gıda sektöründe son yıllarda en etkili tahribatsız analiz tekniklerinden biri olarak öne çıkmıştır. X-Işını görüntüleme, meyveler ve kabuklu yemişler gibi hassas ürünlerin hem dış hem de iç yapısında meydana gelen kusurları, fiziksel hasarları ve yabancı maddeleri hızlı ve yüksek doğrulukla tespit etme imkânı sunar [39]. Bu teknik, yoğunluk farklarına dayalı olarak ürün iç yapısındaki bozulmaları görünür hâle getirir ve bu yönüyle yalnızca yüzeysel inceleme yapan optik sistemlere kıyasla önemli bir avantaj sağlar [29]. Yüksek çözünürlük ve güçlü penetrasyon kabiliyeti sayesinde, X-Işını analizi büyük hacimli örneklerde dahi tutarlı, nicel ve güvenilir sonuçlar üretebilmektedir [40]. Ayrıca, bu yöntemin hızlı veri üretim kapasitesi, üretim hatlarında gerçek zamanlı kalite kontrol uygulamalarına imkân tanımakta ve süreç verimliliğini önemli ölçüde artırmaktadır [41]. Bununla birlikte, X-Işını sistemleri, analiz sırasında kimyasal reaktif gerektirmemesi ve ürüne fiziksel zarar vermemesi nedeniyle çevre dostu ve sürdürülebilir bir kalite kontrol yaklaşımı

sunar. Tüm bu özellikleri, X-Işını teknolojisini gıda sektöründe tahribatsız kalite değerlendirmesi, hata tespiti ve ürün sınıflandırması için kritik ve güvenilir bir araç hâline getirmektedir.

Fındık randımanının doğru bir şekilde hesaplanabilmesi, fındık çekirdeğinin hem iç hem de dış yüzeyinde oluşabilecek kusurların güvenilir biçimde tespit edilmesine bağlıdır. Özellikle, insan gözüyle kolayca fark edilemeyen kusurlar veya iç bozulmalar, çekirdeğin işlenebilirliğini ve nihai ürün kalitesini doğrudan etkileyebilmektedir (Şekil 1.2.). Bu nedenle, kalite kontrol süreçlerinde görsel inceleme yöntemlerinin ötesine geçen, yüksek hassasiyetli tahribatsız analiz tekniklerinin kullanımı büyük önem taşımaktadır.

Bu kapsamda, X-Işını görüntüleme teknolojisi, fındık çekirdeğinin iç yapısında meydana gelen kusurları fiziksel temasa gerek kalmadan ve ürün bütünlüğünü bozmadan tespit edebilme kapasitesiyle öne çıkmaktadır. X-Işını sistemleri, çekirdek içerisindeki yoğunluk farklılıklarını yüksek çözünürlükte görüntüleyebilmekte; bu sayede dışarıdan fark edilmeyen deformasyonlar, boşluklar veya yabancı materyaller etkin biçimde saptanabilmektedir. Ayrıca yapılan çalışmalar, X-Işını kullanımının uygun dozlarda uygulandığında insan sağlığı üzerinde herhangi bir olumsuz etki yaratmadığını ve bu nedenle gıda endüstrisinde güvenle kullanılabileceğini ortaya koymuştur [42]. Bu yönüyle X-Işını görüntüleme, fındık randımanının doğru belirlenmesi ve ürün kalitesinin standartlaştırılması açısından güvenilir, tekrarlanabilir ve sürdürülebilir bir yöntem olarak öne çıkmaktadır.



Şekil 1.2. (a) Fındık çekirdeği görüntüsü, (b) işlenmiş fındık çekirdeği görüntüsü, (c) X-Işını fındık çekirdeği görüntüsü.

Tahribatsız gıda analiz teknolojilerinin, sinyal işleme, makine öğrenmesi, bilgisayarlı görü ve yapay zekâ sistemleriyle entegrasyonu son yıllarda hızla artmaktadır [41-43]. Bu entegrasyon, gıda endüstrisinde yalnızca fiziksel kalite parametrelerinin değerlendirilmesini değil, aynı zamanda süreçlerin otomatikleştirilmesi ve insan kaynaklı hataların azaltılmasını da mümkün kılmaktadır. Özellikle gıda işleme uygulamalarında, ürünlerin boyut, ağırlık, şekil, doku ve renk gibi fiziksel özelliklerinin yanı sıra, insan gözüyle tespit edilmesi güç olan mikroyapısal veya içsel farklılıkların da yüksek doğrulukla analiz edilmesi sağlanmaktadır [44]. Bu teknolojik yaklaşımlar, gıda kalitesi ve güvenliğinin belirlenmesinde yüksek doğruluk, güvenilirlik ve tekrarlanabilirlik sunarak geleneksel değerlendirme yöntemlerine kıyasla önemli avantajlar sağlamaktadır [43]. Tahribatsız yöntemlerin en belirgin üstünlükleri arasında; analiz süresinin kısalığı, ölçüm sonuçlarının standardize edilebilir olması, hata oranının düşük olması ve tekrarlanabilir sonuçlar elde edilmesi yer almaktadır. Son yıllarda bu yöntemlerin, görüntü işleme, makine öğrenmesi,

bilgisayarlı görü ve yapay zekâ teknolojileri ile entegre edilmesi, analiz süreçlerinin doğruluk ve hız açısından önemli ölçüde gelişmesini sağlamıştır. Bu entegrasyon, yalnızca verilerin daha etkin bir şekilde işlenmesini değil, aynı zamanda karmaşık kalite parametrelerinin otomatik olarak sınıflandırılmasını da mümkün kılmaktadır. Böylece, geleneksel insan gözlemine dayalı değerlendirmelerde görülen sübjektiflik azaltılmakta, sistematik ve nesnel bir kalite kontrol yaklaşımı geliştirilmektedir. Ayrıca, bu teknolojik birleşim sayesinde büyük veri kümeleri üzerinde yüksek çözünürlüklü analizler yapılabilmekte, gıda ürünlerindeki mikroskobik düzeydeki kusurların dahi tespiti mümkün hâle gelmektedir [45]. Bu durum, özellikle fındık gibi ekonomik değeri yüksek ürünlerde kalite standardizasyonunu güçlendirerek hem üretim verimliliğini hem de ticari güvenilirliği artırmaktadır.

1.3. Bilgisayar Tabanlı Fındık Sınıflandırma

Derin öğrenme tabanlı yöntemler, son yıllarda bilgisayar görüşü, nesne tanıma ve otomatik sınıflandırma alanlarında giderek daha yaygın bir şekilde kullanılmakta ve yüksek başarı oranları elde edilmektedir [46]. Geleneksel makine öğrenmesi yaklaşımlarından farklı olarak, derin öğrenme modelleri özellik çıkarımını manuel tanımlamalara gerek kalmadan otomatik biçimde gerçekleştirebilmekte ve yüksek boyutlu, karmaşık verilerden anlamlı temsiller öğrenebilmektedir. Bu yetenek, özellikle karmaşık yapıya sahip tarımsal ürünlerin kalite değerlendirmesinde yüksek doğruluk ve genellenebilirlik sağlamaktadır.

Son yıllarda derin öğrenme algoritmalarının tahribatsız gıda analiz yöntemleriyle entegrasyonu, kalite kontrol süreçlerinde önemli bir dönüşüm yaratmıştır [40,47]. Tahribatsız yöntemler ürünün fiziksel yapısına zarar vermeden iç ve dış özellikleri hakkında çok boyutlu veri elde etmeye olanak tanırken, derin öğrenme modelleri bu veriler üzerinde güçlü sınıflandırma ve kusur tespiti gerçekleştirebilmektedir. Bu iki teknolojinin birlikte kullanımı; analiz süresinin kısalması, hata oranlarının azalması, sonuçların standartlaştırılması ve süreçlerin otomatik hale gelmesi açısından büyük avantaj sağlamaktadır [48].

Fındık özelinde değerlendirildiğinde, derin öğrenme destekli tahribatsız analiz yöntemleri, çekirdek yapısındaki kusurların, renk varyasyonlarının, yüzey deformasyonlarının ve iç çatlakların insan gözüyle fark edilemeyecek düzeyde dahi tespit edilmesine olanak tanımaktadır [24]. Böylece, kalite sınıflandırma süreci hem

hızlanmakta hem de daha objektif ve tekrarlanabilir hale gelmektedir. Bu özellikleri sayesinde derin öğrenme tabanlı tahribatsız sistemler, fındık randıman hesaplaması ve kalite değerlendirmesi alanlarında geleneksel yöntemlere kıyasla çok daha güvenilir, hızlı ve standardize edilmiş bir çözüm sunmaktadır.

Fındık kalite ve çeşit sınıflandırması alanında yapılan güncel araştırmalarda, özellikle bilgisayarlı görü ve derin öğrenme tabanlı yaklaşımlar son dönemlerde ön plana çıkmaktadır. Erbaş ve arkadaşları [49], Türkiye’de üretilen fındıkların kalite sınıflandırması için AlexNet mimarisine dayalı bir derin öğrenme modeli önermiş ve beş farklı kalite sınıfını yüksek doğruluk oranıyla başarılı bir şekilde sınıflandırmıştır. Gençtürk ve arkadaşları [50], fındık sınıflandırmasında InceptionV3 ve ResNet50 modellerinin özelliklerini birleştirerek veri füzyonu gerçekleştirmiş ve geliştirdikleri mobil uygulama aracılığıyla kusur tespit süreçlerinin daha kolay ve erişilebilir bir şekilde yapılmasını sağlamıştır. Unal ve Aktaş [51] çalışmasında, mekanize ayıklama sonrasında kalan az miktardaki hasarlı çekirdek, kabuk ve küçük çekirdek gibi sınıflardan, fındığın bütün çekirdeğinin ayrılması amacıyla derin öğrenme tabanlı yüksek doğruluklu bir ağ yapısı kullanmıştır. Dönmez ve arkadaşları [52], fındık çeşitlerinin sınıflandırılmasında BiT-M $R50 \times 1$, BiT-M $R101 \times 3$ ve BiT-M $R152 \times 4$ modellerini kullanmış, toplam 3627 fındık görseli üzerinden deneyler gerçekleştirmiştir. Çalışmada BiT-M $R152 \times 4$ modeli en yüksek başarıyı göstermiştir. Aydın ve Aldara [53] modern mikroservis mimarisi üzerine inşa edilmiş bütünleşik bir veri bankası sistemi olan Fındık Veri Bankası Sistemi 18 Türk fındık çeşidini DNN + ResNet50 tabanlı derin öğrenme modeli ile sınıflandırmakta ve web, masaüstü ve mobil platformlarla uyumlu çok yönlü bir uygulama sunmuştur. Giraudo ve arkadaşları yaptıkları çalışmada kusurlu fındıkların tespiti için RGB (Red-Green-Blue) görüntüleri renk gramlarına dönüştürerek Kısmi En Küçük Kareler-Ayrıcı Analizi ile sınıflandırma yapılmış ve değişken seçimi ile hatalı fındık bölgelerini görselleştirdiler [54]. Gadalla ve Öztekin’in çalışmalarında, görüntü işleme ve derin öğrenme yöntemleri kullanılarak Kahverengi Kokarca ile enfekte olmuş ve sağlıklı fındıklar sınıflandırılmıştır [55]. 400 RGB görüntü üzerinde yapılan analizlerde, Boruta algoritmasıyla seçilen yedi renk özelliği kullanılmış ve Destek Vektör Makinesi modeli en yüksek doğruluk oranını elde etmiştir.

Son yıllarda tahribatsız analiz yöntemleri ile derin öğrenme yaklaşımlarının entegrasyonu, gıda endüstrisinde kalite kontrol süreçlerinde önemli ilerlemelere yol

açmıştır. Bununla birlikte, bu iki teknolojinin birlikte kullanımına yönelik çalışmaların çoğu meyve, tahıl ve sebze gibi ürün gruplarına odaklanmış olup, fındık özelinde yapılan araştırmaların oldukça sınırlı olduğu görülmektedir.

Vitale ve arkadaşlarının çalışmasında, fındık çekirdeklerindeki böcek hasarlarını (cimiciato) tespit etmek amacıyla X-Işını radyografileri kullanılarak on iki farklı önceden eğitilmiş Evrişimli Sinir Ağı (Convolutional Neural Network- CNN) mimarisi karşılaştırılmıştır [48]. Analizler sonucunda InceptionV3 modeli doğruluk, hassasiyet ve kesinlik açısından en dengeli performansı gösterirken, Xception modeli en yüksek özgülüğü sağlamıştır. İkrarullah Hosa ve Eros Pasero [56], X-Işını görüntüleriyle fındıkların otomatik tespiti ve sınıflandırılmasını amaçlamış; görüntü işleme, temel bileşen analizi ve anomali tespit algoritması kullanarak yüksek doğrulukta sonuçlar elde etmiştir.

Literatürdeki mevcut çalışmalar, tahribatsız yöntemler ve derin öğrenme tabanlı analizlerin fındık kalite tespitindeki potansiyelini göstermektedir. Bununla birlikte, fındık çekirdeğindeki kusurların bölgesel dağılımı ve yoğunluk şiddeti üzerine detaylı incelemeler yapılmamaktadır. Çoğu çalışma, fındıkları yalnızca kusurlu veya kusursuz olarak sınıflandırmakta ve kusurun fındığın hangi bölgesinde bulunduğu ve boyutunun ne kadar olduğu bilgisini sunmamaktadır. Oysa randıman hesaplamaları ve daha hassas kalite değerlendirmeleri için, kusurun bölgesel olarak tanımlanması önemlidir; çünkü kusurun konumu ve yoğunluğu, ürün kalitesini ve kullanım potansiyelini doğrudan etkileyen önemli bir parametredir.

Ayrıca literatürde, X-Işını ile fındık randıman hesaplamalarında tahribatsız kalite değerlendirmesi ve derin öğrenme yöntemlerinin birlikte kullanıldığı çalışmalara rastlanmamıştır. Çoğu mevcut araştırma, fındıkların sadece genel kalite durumunu belirlemekle sınırlı kalmakta ve kusurların bölgesel dağılımı veya yoğunluk şiddeti üzerinde durmamaktadır. Bu tez çalışmasında, fındıktaki kusurlu bölgelerin tespitinde X-Işını görüntüleme tekniği kullanılarak ürünün iç yapısı detaylı olarak incelenmiştir.

Literatürde ve açık kaynaklarda, fındık çekirdekleri üzerine oluşturulmuş herhangi bir X-Işını veri seti bulunmamaktadır. Bu bağlamda, çalışmamızın yeniliklerinden biri, X-Işını görüntüleri kullanılarak kapsamlı ve etiketlenmiş bir fındık veri seti oluşturulmasıdır; bu veri seti hem kusurların bölgesel analizini hem de derin öğrenme tabanlı otomatik sınıflandırma ve randıman hesaplamalarını mümkün kılmaktadır.

1.4. Sınırlayıcı Kutular ve Regresyonu

Derin öğrenme alanında kaydedilen son gelişmeler, tahribatsız gıda işleme yöntemlerinin etkinliğini ve doğruluğunu önemli ölçüde artırmıştır. Özellikle sınırlayıcı kutu (bounding box) tabanlı derin öğrenme yaklaşımları; yüksek doğruluk oranı, düşük hata payı, hızlı işlem süresi, geniş uygulama alanı ve yapısal bilgiyi etkili biçimde kullanabilme gibi avantajlarıyla öne çıkmakta ve bu nedenle literatürde yaygın olarak tercih edilmektedir [57]. Bu özellikler, nesne tespiti ve konumlandırma gibi görevlerde kritik bir rol oynamaktadır.

Bununla birlikte, sınırlayıcı kutu tabanlı yöntemlerin sunduğu avantajlara rağmen halen çözüm bekleyen bazı önemli sorunlar bulunmaktadır [58]. Bu sorunlar, genellikle uygun sınırlayıcı kutularının belirlenmesi [59] ve sınırlayıcı kutu regresyonundaki hata oranlarının minimize edilmesi [60-61] konuları etrafında yoğunlaşmaktadır. Zira, hedef kutularının doğru şekilde oluşturulması ve regresyon hatalarının azaltılması hem nesne yerleştirme doğruluğunu hem de genel model performansını doğrudan etkilemektedir [62].

Bu çalışmada, literatürde sınırlayıcı kutu yerleştirme doğruluğunu artırmaya yönelik çeşitli yaklaşımlar geliştirilmiştir. Bu yaklaşımlardan birisi olan Object-Aware Multiple Instance Learning (OA-MIL) yöntemi, sınırlayıcı kutuların daha tutarlı ve nesne odaklı biçimde belirlenmesini sağlamak amacıyla önerilmiştir [63]. Ayrıca, sınırlayıcı kutuların tespit doğruluğunu artırmaya yönelik yeni bir yöntem geliştirilmiş ve literatüre kazandırılmıştır [64]. Bunun yanında, nesne poz tahminini ve yüzey izdüşümlerini daha hassas bir şekilde hesaplamaya olanak tanıyan RBP-Pose (Artık Nesne Sınırlayıcı Kutu İzdüşüm Duruşu - Residual Object Bounding Box Projection Pose) modeli geliştirilmiştir [65]. Sınırlayıcı kutu tahmin doğruluğunu artırmak amacıyla, esnek ve hassas bir iyileştirme modülü olan Alpha-Refine (AR) yöntemi de uygulanmıştır [66]. Bunlara ek olarak, nesne tespitinde yaygın olarak kullanılan sınırlayıcı kutu regresyon yöntemleri arasında Intersection over Union (Birleşim Üzerindeki Kesişim- IoU) [67], Generalized Intersection over Union (Genelleştirilmiş Birleşim Üzerindeki Kesişim- GIoU) [68], Distance Intersection over Union (Mesafe Kapsamlı Birleşim Üzerindeki Kesişim- DIoU) [69] ve Complete Intersection over Union (Tam Kapsamlı Birleşim Üzerindeki Kesişim- CIoU) [69] gibi metrikler öne çıkmaktadır. Bu metrikler, literatürde temel ve en yaygın kullanılan yaklaşımlar arasında yer almakta olup, sınırlayıcı kutuların konumlandırma doğruluğunu

değerlendirmede standart bir referans ölçütü olarak kabul edilmektedir. Ayrıca, bu yöntemler nesne tespit modellerinin doğruluk ve güvenilirlik düzeylerini artırarak, tahribatsız muayene ve diğer görsel algılama uygulamalarında daha etkin ve kararlı sonuçlar elde edilmesine olanak sağlamaktadır.

1.5. Tezin Katkıları

Sınırlayıcı kutu tabanlı nesne dedektörlerinde yürütülen araştırmaların temel eğilimleri, sınırlayıcı kutu regresyonunun iyileştirilmesi ve doğru sınırlayıcı kutu tahminine yönelik yeni yöntemlerin geliştirilmesi üzerinde yoğunlaşmaktadır. Bu tez kapsamında, fındık randımanının belirlenmesi amacıyla X-Işını görüntüleme ve derin öğrenme yöntemleri kullanılarak bir randıman belirleme sistemi önerilmiştir.

Ayrıca, sınırlayıcı kutu tabanlı derin öğrenme yöntemlerinde sıkça karşılaşılan nesne yerleştirme problemini azaltmak amacıyla yeni bir sınırlayıcı kutu regresyon yöntemi olan Distance Centers Intersection over Union (Merkezler Arası Mesafede Birleşim Üzerinden Kesişim- DCIoU) metriği önerilmiştir. Bununla birlikte, hedef sınırlayıcı kutuların daha etkili biçimde seçilmesini sağlamak ve tespit edilen alan içinde segmentasyon işleminin yapılması için Komşuluk İlişki Algoritması (Neighbourhood Relation Algorithm) önerilmiştir. Önerilen algoritma, k-means kümeleme algoritmasından yararlanarak benzer özelliklere sahip sınırlayıcı kutuları gruplayıp aralarındaki ilişkileri analiz etmektedir. Bu sayede, sınırlayıcı kutuların daha doğru biçimde seçilmesiyle birlikte daha hassas bir segmentasyon işlemi de gerçekleştirilmektedir.

Önerilen yöntemlerin etkinliği, sınırlayıcı kutu ve çapa tabanlı derin öğrenme tekniklerinden biri olan YOLO (You Only Look Once) v7 mimarisi kullanılarak oluşturulan fındık kusur tespiti geliştirilen veri seti üzerinde test edilmiş ve elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir. Ayrıca DCIoU yönteminin performansı, yöntemin genellenebilirliğini göstermek amacıyla COCO-128 [70] veri seti üzerinde de test edilmiştir.

Yukarıda verilen bilgiler ölçüsünde bu tezin temel katkıları şunlardır:

- X-Işını fındık görüntü veri seti oluşturulmuştur.
- Fındık randıman hesaplamasına yardımcı fındık çekirdek kusurlarının tespiti sağlanmıştır.

- Çapa ve sınırlayıcı kutu tabanlı derin öğrenme yöntemleri için yeni bir sınırlayıcı kutu regresyon yöntemi olan DCIoU metriği geliştirilmiştir.
- Sınırlayıcı kutu tabanlı derin öğrenme yöntemlerinde segmentasyon işlemi için “Komşuluk ilişki algoritması” önerilmiştir.
- Yukarıda belirtilen işlemler gerçekleştirilerek fındık randımanı belirlenirken gerçekleşebilecek hataları minimize eden bir sistem modeli önerilmiştir.

Bu tez kapsamında geliştirilen yöntemler ve elde edilen katkılar, çalışmanın ilerleyen bölümlerinde detaylı olarak ele alınmıştır. Bölüm 2’de, fındık randımanının ölçülmesi amacıyla oluşturulan sistemin genel yapısı ve veri toplama sürecini kapsamaktadır. Bölüm 3’de, sınırlayıcı kutu regresyon yöntemlerini incelemekte ve geliştirilen DCIoU yöntemini ayrıntılı biçimde sunmaktadır. Bölüm 4’de, hedef sınırlayıcı kutuların seçimi ve Komşuluk İlişki Algoritmasının işleyişini açıklamaktadır. Bölüm 5’de, önerilen yöntemlerin performansının farklı veri setleri üzerinde deneysel olarak değerlendirilmesini ve elde edilen sonuçların yorumlanmasını içermektedir. Son olarak, Bölüm 6’da tezde gerçekleştirilen çalışmaların genel değerlendirmesini, elde edilen bulguları ve gelecekteki araştırma önerilerini kapsamaktadır.



2. FINDIK KALİTESİ BELİRLEME SİSTEMİ

Fındık, Türkiye'nin en önemli tarımsal ihracat ürünlerinden biri olup, ekonomik değerinin belirlenmesinde randıman kavramı kritik bir rol oynamaktadır. Randıman, kabuklu fındık içerisindeki sağlam iç fındık oranını ifade eder ve fındığın ticari kalitesinin belirlenmesinde temel bir ölçüt olarak kullanılmaktadır. Bu nedenle, randımanın doğru ve güvenilir biçimde hesaplanması hem üretici hem de alıcı açısından büyük önem taşımaktadır.


Geleneksel fındık kalitesi belirleme süreci, genellikle uzman kişiler (fındık eksperleri) tarafından manuel olarak gözlem yoluyla gerçekleştirilmektedir. Bu süreçte, randımanı belirlenecek fındık grubundan genel olarak 250 gramlık rastgele bir örnek alınmakta ve örnek kabuklarından ayrılarak iç fındık haline getirilmektedir. Ardından, iç fındıklar arasında çürük, buruşuk, küflenmiş veya abortif gibi sağlam kabul edilmeyen örnekler gözlemsel yöntemlerle ayıklanmaktadır. Ancak bu sınıflandırma işlemi, eksperin deneyim düzeyi, çevresel koşullar ve alım merkezinin kalite kriterleri gibi unsurlara bağlı olarak önemli ölçüde farklılık gösterebilmektedir. Ayrıca, değerlendirme sürecinin tamamen insan gözlemine dayalı olması, kişisel algı ve yorum farklılıklarından kaynaklanan subjektif değerlendirmelere yol açmakta ve bu durum ölçüm sonuçlarının standartlaşmasını güçleştirmektedir. Dolayısıyla, farklı eksperler tarafından yapılan analizler arasında tutarlılık eksiklikleri ve randıman sonuçlarında değişkenlikler meydana gelebilmektedir.

Randıman parametresi hem ürünlerin kalite sınıflandırılmasında hem de ekonomik değerinin belirlenmesine dayalı fiyatlandırma süreçlerinde önemli bir değerlendirme ölçütü olarak kullanılmaktadır. Bu parametre, ürünün fiziksel bütünlüğü ve kusur durumu ile doğrudan ilişkili olduğundan, kalite kontrol aşamalarında temel referans noktalarından biri olarak kabul edilmektedir. Ancak randıman esaslı geleneksel değerlendirme yöntemleri; ölçüm ve sınıflandırma süreçlerinin büyük ölçüde manuel olarak yürütülmesi nedeniyle zaman alıcı olmakta, operatör deneyimine ve dikkatine bağlı olarak değişkenlik gösterebilmekte ve insan kaynaklı hatalara açık bir yapı sergilemektedir. Bu durum, modern kalite kontrol sistemlerinin gerektirdiği hız,

doğruluk ve sürdürülebilirlik kriterlerinin karşılanmasını zorlaştırmakta ve daha otomatik, güvenilir ve standardize edilmiş yaklaşımlara olan ihtiyacı ortaya koymaktadır

Özellikle, insan gözlemine dayalı değerlendirmelerde görsel yorgunluk, dikkat dağınıklığı ve öznel karar verme eğilimleri; ölçüm doğruluğunu ve tutarlılığını olumsuz yönde etkilemektedir. Ayrıca, farklı eksperler tarafından yapılan ölçümler arasında önemli varyasyonlar oluşabilmekte, bu durum hem kalite sınıflandırmasının güvenilirliğini hem de ticari süreçlerin adaletini zedeleyebilmektedir. Literatürde de benzer şekilde, manuel kalite belirleme yöntemlerinin objektiflikten uzak, tekrarlanabilirliği düşük ve ölçeklenebilirliği sınırlı olduğu vurgulanmaktadır.

Bu bağlamda, geleneksel yöntemlerin yerine otomatik, objektif ve tekrarlanabilir bir ölçüm sistemi geliştirilmesi gerekliliği ortaya çıkmıştır. Bu tez kapsamında, fındık randımanının hızlı ve doğru biçimde hesaplanabilmesi amacıyla tahribatsız X-Işını görüntüleme ve derin öğrenme tabanlı görüntü işleme teknikleri bir arada kullanılarak yeni bir sistem önerilmiştir (Şekil 2.1.).



Şekil 2.1. Fındık kalitesi belirleme sistemi.

Önerilen sistem, fındık örneklerinin fiziksel yapısına zarar vermeden iç kusurların tespitini mümkün kılmakta; aynı zamanda gözlem hatalarını ortadan kaldırarak değerlendirme sürecini otomatikleştirmektedir. Bu yaklaşım, hem kalite kontrol sürecinde zaman tasarrufu sağlamayı hem de ölçüm doğruluğunu artırmayı hedeflemektedir.

Şekil 2.1.'de önerilen sistemin genel iş akışı gösterilmektedir. Bu sistemde, fındık numunelerinin toplanması, işlenmesi, görüntülenmesi ve sınıflandırılması aşamaları ardışık biçimde gerçekleştirilmektedir.

İlk aşamada, kalitesi belirlenecek fındık örnekleri, Şekil 2.2.'de belirtilen özel olarak tasarlanmış bir numune toplama aparatı yardımıyla bir kap içerisinde toplanmaktadır. Elde edilen numuneler temsili bir dağılım elde edilebilmesi amacıyla homojen olacak şekilde karıştırılır. Daha sonra, kalite ölçüm sürecine alınacak örnek olarak 250 gramlık bir alt örnek rastgele seçilir ve bu örnek randıman hesaplama sürecinde kullanılır.



Şekil 2.2. Fındık seçme aparatı.

İkinci aşama olan “Fındık Kırma İşlemi” basamağında, rastgele seçilen fındık örnekleri özel olarak tasarlanmış bir kırma makinesi kullanılarak kabuklarından ayrılır. Bu işlem sonucunda kabuklu ve iç fındıklar birbirinden ayrıştırılır. Ayrıştırma işleminin ardından, sağlam ve kusurlu fındıkların tespitine yönelik analizlerin yapılabilmesi için iç fındıklar X-Işını görüntüleme aşamasına gönderilir.

Üçüncü aşama olan “X-Işını Görüntüleme” sürecinde, iç fındıklar tahribatsız muayene prensibiyle incelenmektedir. Bu aşamada, fındık çekirdeğinin iç yapısının bütünlüğüne zarar vermeden X-Işını görüntüleri elde edilmektedir. Sistem, bu görüntüler üzerinden fındığın iç yapısındaki kusurları ve anomalileri belirleyebilmekte, her bir fındığın kalite durumu hakkında veri üretebilmektedir. Kullanılan görüntüleme teknolojisi, farklı yoğunluklardaki yapıları ayırt edebilme kapasitesine sahip olup, sistemin otomatik analiz algoritmalarıyla entegre çalışarak, her bir numunenin hızlı ve güvenilir biçimde değerlendirilmesini sağlamaktadır.

Son aşama olan “Sınıflandırma ve Randıman Hesaplama” sürecinde, elde edilen X-Işını görüntüleri üzerinde önerilen derin öğrenme tabanlı sınıflandırma algoritmaları uygulanmaktadır. Bu aşamada, fındıklar kusurlu (defective), az kusurlu (slightly defective) ve kusursuz (non- defective) olmak üzere üç ana kategoriye ayrılmakta; her bir sınıfın oranı belirlenerek fındık randıman değeri hesaplanmaktadır. Sınıflandırma sonuçları, fındık alım merkezlerinin belirlemiş olduğu kalite kriterleri doğrultusunda değerlendirilmekte ve randıman hesaplamasında kullanılmaktadır.

Bu süreçte, derin öğrenme algoritması olarak YOLOv7 kullanılmıştır. YOLOv7 modeli üzerinde ayrıca önerilen yöntemlerden DCIoU metriği ve Komşuluk İlişki algoritması da uygulanarak, fındık içindeki kusurların sınırları ve konumları hassas bir şekilde tespit edilmekte ve kusurlar arasındaki yapısal ilişkiler analiz edilmektedir. Bu sayede sınıflandırma doğruluğu artırılmakta ve randıman hesaplaması için güvenilir bir veri sağlanmaktadır.

Bunun yanı sıra, kalite değerlendirme sürecinin son adımında nem ölçümü gerçekleştirilmektedir. Nem miktarı, uygun dijital nem ölçüm cihazı kullanılarak tespit edilmekte ve elde edilen değerler alım merkezinin kabul ettiği nem aralıklarıyla karşılaştırılmaktadır. Ölçülen nem oranı ve randıman değeri, alım merkezinin kalite standartlarıyla uyumlu olduğu takdirde fındığın kabul süreci tamamlanmaktadır.


2.1. Veriseti Oluşturma

X-Işını görüntüleme yöntemi, fındık çekirdeklerindeki iç kusurların tespiti için etkili bir çözüm sunmaktadır. Ancak, X-Işını görüntüleme kullanılarak fındık kusurlarının tespiti için mevcut bir veri setinin bulunmaması nedeniyle, özgün bir veri seti oluşturulması gerekli hale gelmiştir.

Tez kapsamında veri seti hazırlanırken Türkiye’deki en fazla üretim alanı olan Samsun, Ordu ve Giresun’da yetiştirilen en yaygın fındık türleri olan foşa, palaz, çakıldak, tombul ve sivri fındıklar kullanılmıştır [7]. Her şehirde üretilen fındıklardan kusursuz, az kusurlu ve kusurlu fındıklar için 5’er kilogram fındık alınarak toplam 75 kg fındık toplanmıştır. Toplanan fındıklar içerisinden rastgele olacak şekilde 1320 adet fındık seçilerek veri seti için ayrılmıştır.

Fındık çekirdeklerinin doğru ve güvenilir bir şekilde görüntülenmesi için düşük dozlu yumuşak X-Işını görüntüleme sistemi kullanılmıştır. Cihaz, 40 ila 150 kV arasında

değişen ayarlanabilir tüp voltajı kapasitesine sahip olup hassas örnek görüntüleme için oldukça uygundur. Piksel başına yaklaşık 100 mikrometre mekansal çözünürlük sunan dijital düz panel dedektör ile donatılmıştır. Dedektörün performansı, yaklaşık %70'lik bir Dedektif Kuantum Verimliliği (Detective Quantum Efficiency - DQE) ve 16 bitlik dinamik aralık ile artırılmış; bu iki özellik, minimum pozlama koşullarında bile net ve yüksek kontrastlı görüntüler elde edilmesini sağlamaktadır.



Şekil 2.3. X-Işını fındık görüntüleri.

Kabuklu fındıklar iç fındık haline getirilip veri seti oluşturmak için röntgen cihazı kullanılarak X-Işını görüntüleri elde edilmiştir. Tekli fındık röntgen görüntülerinin tamamı 640x640 piksel çözünürlüğünde oluşturulmuştur. Elde edilen fındık X-Işını görüntüleri (Şekil 2.3.) kusurlu, az kusurlu ve kusursuz olmak üzere üç kategoriye ayrılarak model eğitimi için kapsamlı bir veri seti oluşturulmuştur. Etiketleme işlemleri YOLO formatında gerçekleştirilmiş olup, fındık konusunda uzmanlaşmış bir ziraat mühendisinin yardımı ve uzman görüşüyle gerçekleştirilmiştir. Etiketleme sürecinde X-Işını görüntüleri, fındık tanelerinin gerçek fiziksel görünümüyle karşılaştırılmıştır. Kusur sınıflandırması, X-Işını görüntülerinde gözlemlenen kusurların boyutuna ve kapsamına göre yapılmıştır: tespit edilebilir kusuru olmayan fındıklar "kusursuz", kusur oranı %5'in altında olan örnekler "hafif kusurlu", %5'in

üzerinde olanlar ise "kusurlu" olarak etiketlenmiştir. Tüm veri setinin görüntü dağılımları Tablo 2.1’de gösterilmiştir.

Tablo 2.1. Veri seti etiket dağılımları.

Sınıf	Görüntü sayısı	Etiket Sayısı
Hepsi	1320	2349
Kusurlu	465	973
Kusursuz	440	440
Az Kusurlu	415	936

Oluşturulan veri kümesinin en uygun eğitim ve test bölümlendirmesini belirlemek amacıyla 5 katlı çapraz doğrulama (5-fold cross-validation) yöntemi uygulanmıştır. Bu kapsamda, toplam 1320 X-Işını görüntüsü ve 2349 etiketli nesne örneğinden oluşan veri kümesi, her biri benzer büyüklükte beş alt kümeye (katlama) ayrılmıştır. Her eğitim döngüsünde dört kat eğitim, bir kat ise test verisi olarak kullanılmıştır. Bu yöntem, veri kümesindeki tüm örneklerin hem eğitim hem de test aşamalarında değerlendirilmesini sağlayarak modelin genelleme yeteneğinin daha sağlam ve güvenilir bir şekilde ölçülmesine olanak tanımaktadır.

Eğitim sürecinde, YOLOv7 mimarisi kullanılmış ve her katlamada varsayılan eğitim parametreleriyle 200 epoch boyunca model eğitilmiştir. Her katlamadaki görüntü ve etiket sayıları Tablo 2.2’de ayrıntılı olarak verilmiştir. Model performansını kapsamlı bir şekilde değerlendirmek için her katlamada kesinlik (precision), duyarlılık (recall), mAP@50 (Mean Average Precision – Ortalama Kesinlik) ve F-1 skoru (F-1 score) performans metrikleri hesaplanmış ve Tablo 2.2’de sunulmuştur.

Elde edilen sonuçların incelenmesi, modelin farklı alt kümelerdeki performansını detaylı biçimde gözlemlemeye olanak tanımıştır. Özellikle, 5 katlı çapraz doğrulama süreci sonucunda en yüksek performansın ikinci katta elde edildiği belirlenmiştir. Bu kapsamlı değerlendirme, YOLOv7 modelinin veri kümesindeki farklı örnekler üzerindeki tutarlılığını ve genelleme yeteneğini ortaya koymaktadır.

Tablo 2.2. X-Işını findık veri seti 5-fold gösterimi.


Fold	Sınıf	Resim	Etiket	Kesinlik	Duyarlılık	mAP@50	F-1 Skoru
		Sayısı	Sayısı				
1	Tamamı	263	373	0.8636	0.8576	0.8816	0.8606
	Kusurlu	112	191	0.8416	0.8726	0.9316	0.8568
	Kusursuz	74	74	0.9870	1.0000	0.9940	0.9935
	Az kusurlu	77	108	0.7786	0.8236	0.8326	0.8005
2	Tamamı	262	372	0.9056	0.9070	0.9112	0.9063
	Kusurlu	110	192	0.8506	0.9586	0.9396	0.9014
	Kusursuz	74	74	0.9919	1.0000	0.9940	0.9959
	Az kusurlu	78	106	0.8446	0.8376	0.8516	0.8411
3	Tamamı	262	372	0.8636	0.8516	0.8666	0.8576
	Kusurlu	110	193	0.8696	0.8386	0.9066	0.8538
	Kusursuz	74	74	0.9890	0.9890	0.9900	0.9890
	Az kusurlu	78	105	0.8176	0.7936	0.8196	0.8054
4	Tamamı	263	375	0.8316	0.8606	0.8526	0.8459
	Kusurlu	109	196	0.8136	0.9136	0.9106	0.8607
	Kusursuz	74	74	0.9670	0.9660	0.9770	0.9665
	Az kusurlu	80	105	0.8176	0.8266	0.8256	0.8221
5	Tamamı	263	372	0.8826	0.8936	0.9036	0.8881
	Kusurlu	111	189	0.8306	0.9356	0.9686	0.8800
	Kusursuz	74	74	0.9880	1.000	0.9940	0.9940
	Az kusurlu	78	109	0.8246	0.8086	0.8326	0.8165

2.2. Görüntü Ön İşleme

Derin öğrenme tabanlı görüntü işleme sistemlerinde modelin doğruluk ve genelleme kapasitesini artırmak için giriş verilerinin ön işleme adımlarından geçirilmesi büyük önem taşımaktadır. Ham görüntüler, gürültü, arka plan karmaşası veya düşük kontrast gibi etkenlerden dolayı model tarafından doğru şekilde yorumlanamayabilir. Bu nedenle, YOLOv7'nin kusurlu bölgeleri doğru bir şekilde öğrenebilmesi ve sınırlayıcı kutuları etkili biçimde tespit edebilmesi için görüntülerin normalize edilmesi, gürültülerin giderilmesi ve nesne bölgelerinin ön plana çıkarılması önemlidir. Ön işleme aşamaları hem modelin performansını artırmakta hem de gereksiz hesaplama yükünü azaltarak eğitim sürecini daha verimli hâle getirmektedir.

Tüm fındık görüntülerinde, fındık dışındaki arka planın analiz sürecine dahil edilmemesi amacıyla Otsu filtresi uygulanmış ve arka plan alanları beyaz renge dönüştürülmüştür. Bu işlem sırasında, otomatik eşikleme için Otsu yöntemi, yüzdelik değere dayalı eşikleme ve yerel uyarlamalı eşikleme teknikleri bir arada kullanılmıştır; bu birleşik yaklaşım hatalı eşikleme ve yanlış nesne tespitlerini minimize etmektedir. Fındık alanlarının doğru şekilde seçilmesi için, önce görüntüdeki küçük gürültü parçacıkları ve önemsiz noktalar temizlenmiş, ardından eksik veya boş alanlar doldurulmuş ve morfolojik işlemler uygulanarak fındığın bulunduğu en büyük nesne bölgesi belirlenmiştir. Bu adımlar, yalnızca fındık bölgesinin doğru şekilde tespit edilmesini sağlamakla kalmayıp, derin öğrenme modelinin gereksiz arka plan bilgisiyle yanlış yönlendirilmesini de önlemektedir.

Ayrıca, veri setindeki görüntülerde öğrenmeyi kolaylaştırmak amacıyla sırasıyla Contrast Limited Adaptive Histogram Equalization (CLAHE) [71], Gauss Blur [72], ve Anisotropic Diffusion filtreleri [73] uygulanmıştır (Şekil 2.4.). Bu filtreler, kusurlu bölgelerin ön plana çıkarılmasını sağlayarak sınırlayıcı kutu tespitinde daha doğru ve etkili sonuçlar elde edilmesine olanak tanımaktadır. Beyaz renge dönüştürülen alanların nesne olma olasılığının düşük olması ise, tahmin edilen sınır kutularının elenmesine ve derin öğrenme sisteminin performansının artmasına önemli ölçüde katkı sağlamaktadır. Bu sayede, geliştirilen komşuluk ilişkisi algoritması sınırlayıcı kutuları daha etkin bir şekilde tespit edebilmekte ve fındık görüntüleri derin öğrenme işlemine hazır hâle getirilmektedir.



Şekil 2.4. Sırasıyla X-Işını fındık görüntüsü, Otsu filtresi, CLAHE filtresi, Gauss Blur filtresi ve Anisotropic Diffusion filtresi uygulaması.

2.3. Derin Öğrenme Yöntemi YOLOv7

YOLO (You Only Look Once), nesne tespitini tek bir ileri besleme ile gerçekleştiren, hız ve doğruluk arasında etkili bir denge sunan tek aşamalı bir derin öğrenme algoritmasıdır. Geleneksel iki aşamalı yaklaşımların aksine, YOLO girdi görüntüsünü yalnızca bir kez değerlendirerek hem sınırlayıcı kutu konumlarını hem de sınıf olasılıklarını eş zamanlı olarak tahmin eder. Bu amaçla görüntü, $S \times S$ boyutlarında bir ızgara yapısına ayrılır ve her bir hücre, nesnenin merkezinin kendi alanına düşmesi durumunda tespitten sorumlu olur. Her hücre, birden fazla sınırlayıcı kutu için merkez koordinatları (x, y) , boyutlar (w, h) ve nesne varlık olasılığını içeren güven puanı üretirken, aynı anda ilgili sınıf olasılıklarını da hesaplar. Tahmin edilen kutuların doğruluğu, IoU ölçütü ile değerlendirilir ve aynı nesneye ait birden fazla yüksek olasılıklı tahmin oluşması durumunda Maksimum Olmayan Bastırma yöntemi kullanılarak en güvenilir kutu seçilir.

YOLO serisi, 2015 yılındaki ilk çıkışından bu yana nesne tespiti alanında hız ve doğruluk dengesini sürekli olarak geliştiren, mimari ve metodolojik açıdan evrimsel bir süreç izlemiştir. YOLOv1, YOLO ailesinin tanıtılan ilk sürümü olup, nesne tespit problemini uçtan uca tek bir regresyon problemi olarak ele alan ve bu yaklaşımı başarıyla uygulayan ilk tek aşamalı dedektör olarak literatürde yerini almıştır [74]. Bu modelde girdi görüntüsü sabit boyutlu bir ızgara (grid) yapısına ayrılmakta ve her bir hücre, kendi sorumluluk alanına düşen nesneler için sınırlayıcı kutu parametrelerini ve sınıf olasılıklarını tek bir ağ geçişinde tahmin etmektedir. Bu bütünlük yapı gerçek zamanlı çıkarımı mümkün kılmış olsa da sabit ızgara yapısı ve sınırlı temsil kapasitesi nedeniyle özellikle küçük ölçekli ve birbirine yakın konumlanmış nesnelerin tespitinde performans kısıtları ortaya çıkmıştır. Bu sınırlamaları gidermek amacıyla geliştirilen YOLOv2, Darknet-19 omurga mimarisini temel almış; anchor (çapa) kutularının entegrasyonu ile konum tahmin doğruluğunu artırmış ve Batch normalizasyonu kullanımı sayesinde eğitim sürecini daha kararlı ve hızlı hale getirmiştir [75]. Ayrıca,

çok ölçekli eğitim stratejileri ve hiyerarşik sınıflandırma yaklaşımı ile tek bir model üzerinden 9000’den fazla sınıfın tanınabilmesini hedeflemiş ve bu yönüyle YOLO9000 adıyla da bilinir. Bu gelişimi izleyen YOLOv3, daha derin ve güçlü bir omurga olan Darknet-53 mimarisini benimsemiş ve çok ölçekli tespit yaklaşımını etkin biçimde kullanarak üç farklı çözünürlükte tahmin üretebilen bir yapı sunmuştur [76]. Özellik Piramit Ağları’ndan esinlenen bu tasarım, özellikle küçük nesnelerin ve düşük belirginliğe sahip yapıların tespitinde önemli performans artışları sağlamıştır. Eğitim ve mimari optimizasyonlara odaklanan YOLOv4, CSPDarknet53 omurgası, Mosaic veri artırma, CIOU kayıp fonksiyonu ve çeşitli düzenleyici teknikleri bir araya getirerek, “Bag of Freebies” ve “Bag of Specials” kavramları altında hız ve doğruluk arasındaki dengeyi üst seviyeye taşımıştır [77]. Aynı yıl tanıtılan YOLOv5, Ultralytics tarafından geliştirilmiş olup Darknet tabanlı altyapıdan PyTorch tabanlı bir mimariye geçişi temsil etmektedir. AutoAnchor, SPPF (Spatial Pyramid Pooling Fast) katmanları ve farklı ölçeklerde model varyantları (s, m, l, x) ile hem araştırma hem de endüstriyel uygulamalar için esnek ve erişilebilir bir yapı sunmuştur [78]. YOLOv6, RepVGG tabanlı EfficientRep omurgası ile Rep-PAN (Re-parameterized Path Aggregation Network) boyun mimarisini birleştirerek, gerçek zamanlı uygulamalar için yüksek çıkarım hızı ve düşük gecikme süresi sağlamayı hedeflemektedir. [79].


YOLO’nun evrimsel sürecin önemli bir kilometre taşı olan YOLOv7, E-ELAN (Extended Efficient Layer Aggregation Network) mimarisi sayesinde ağ derinliği boyunca bilgi akışını optimize etmiş; farklı derinliklerde öğrenilen özniteliklerin daha etkin biçimde birleştirilmesini sağlayarak hem doğruluk hem de hız açısından önemli kazanımlar sunmuştur. Yayımlandığı dönemde, gerçek zamanlı nesne tespitinde literatürdeki en güçlü modellerden biri olarak rapor edilmiştir [80].

Yeni nesil sürümlerle birlikte YOLO ailesi, yalnızca tespit doğruluğunu değil, aynı zamanda görev çeşitliliğini de genişletmiştir. YOLOv8, anchor-free (çapa kutusuz) tespit yaklaşımını benimseyerek C2f (Cross Stage Partial with fused features – birleştirilmiş özellikli kısmi çapraz katman) modülü ile bağlamsal özellik birleşimini güçlendirmiş; nesne tespitine ek olarak segmentasyon (bölütleme), poz kestirimi (pose estimation) ve yönlendirilmiş sınırlayıcı kutu (Oriented Bounding Box – OBB) tespiti gibi çoklu görevleri destekler hale gelmiştir [81]. YOLOv9, derin ağlarda ortaya çıkan bilgi darboğazı (information bottleneck) problemini azaltmayı hedefleyen PGI (Programmable Gradient Information – Programlanabilir Gradyan Bilgisi) ve GELAN

(Generalized Efficient Layer Aggregation Network – Genelleştirilmiş Verimli Katman Birleştirme Ağı) mimarisi ile daha verimli ve kararlı bir öğrenme süreci sunmuştur [82]. Bu yaklaşımı izleyen YOLOv10, klasik NMS (Non-Maximum Suppression – Maksimum Olmayan Bastırma) adımını ortadan kaldıran ikili etiket atama (dual label assignment) stratejisi sayesinde çıkarım gecikmesini azaltmış ve gerçek zamanlı performansı daha ileri bir seviyeye taşımıştır [83]. Aynı dönemde geliştirilen YOLO11, C3k2 ve C2PSA (Cross-Stage Partial with Position Sensitive Attention - Konum Duyarlı Uzamsal Dikkat) modülü ile özellikle küçük, yoğun ve üst üste binen nesnelerin ayrıştırılmasında daha dengeli sonuçlar üretmişti [84]. En güncel sürüm olan YOLOv12 ise A2 (Area Attention – Alan Tabanlı Dikkat) ve FlashAttention (Hızlandırılmış Dikkat Mekanizması) kullanarak bellek verimliliğini artıran, dikkat odaklı (attention-centric) bir mimari sunmuş ve YOLO ailesinin modern derin öğrenme eğilimleriyle uyumunu pekiştirmiştir [85].

Geliştirilen sistemde, fındıkların sınıflandırma işlemi için YOLOv7 [80] derin öğrenme yöntemi kullanılmıştır. Literatürde, sınırlayıcı kutu tabanlı derin öğrenme yöntemleri arasında YOLOv7 hem yüksek doğruluk hem de hızlı işlem süresi açısından öne çıkan yöntemlerden biridir [86]. Ayrıca, YOLOv7'nin çapa (anchor) tabanlı bir yöntem olması, onu tercih edilen bir çözüm haline getirmiştir; bu sayede DCIoU ve Komşuluk İlişki Algoritması gibi yöntemlerin çapa tabanlı mimarilerde de uygulanabilirliği sağlanabilmektedir.

YOLOv7'nin mimarisi Şekil 2.5.'te sunulmuştur. Model, giriş görüntüsünden ayırt edici özniteliklerin çıkarılmasını sağlayan omurga (backbone), bu öznitelikleri farklı ölçeklerde birleştirerek nesnelerin çeşitli boyutlarda algılanmasına olanak tanıyan boyun (neck) ve elde edilen özellikler üzerinden sınırlayıcı kutu konumları, nesne varlık olasılığı ve sınıf tahminlerini üreten kafa (head) olmak üzere üç ana bölümden oluşmaktadır. Omurga yapısında kullanılan E-ELAN (Extended Efficient Layer Aggregation Network – Genişletilmiş Verimli Katman Birleştirme Ağı), ağ derinliği boyunca bilgi kaybını azaltmayı hedeflerken; boyun bölümünde yer alan PAN (Path Aggregation Network – Yol Birleştirme Ağı), çok ölçekli özelliklerin etkin biçimde bütünleştirilmesini sağlamaktadır. Optimize edilmiş kafa yapısı sayesinde YOLOv7, yüksek doğruluk ile gerçek zamanlı çıkarım performansını dengeli bir şekilde sunmaktadır.



Şekil 2.5. YOLOv7 mimarisi [87].

YOLOv7 mimarisi, giriş görüntüsünü eşit boyutlu bir ızgaraya böler ve her bir hücrede nesne tespitine yönelik sınırlayıcı kutular oluşturur. Her kutu, içinde nesne bulunma olasılığı ile ilişkilendirilir ve bir Güven Skoru (Confidence Score) hesaplanır. Güven Skoru, ilgili kutu içindeki nesnenin model tarafından tahmin edilen nesne ile ne kadar benzer olduğunu yüzde olarak ifade eder ve sınırlayıcı kutuların seçiminde belirleyici rol oynar. Her kutu ayrıca nesnenin sınıf tahminini de içerir; böylece YOLOv7 hem nesneyi tespit eder hem de ait olduğu kategoriye sınıflandırır. Sistem, nesne koordinatlarını ve sınıf olasılıklarını aynı anda tahmin ederek tek geçişte (single-shot) nesne tespiti gerçekleştirir.

Eğitim sürecinde, model kayıp fonksiyonları aracılığıyla sınırlayıcı kutu konum hatası, sınıf tahmini hatası ve Güven Skoru hatasını minimize edecek şekilde optimize edilir. YOLOv7'nin hızlı ve doğru tahmin yeteneği, yüksek çözünürlüklü X-Işını görüntülerinde küçük kusurların belirlenmesi açısından oldukça önemlidir. Yüksek çözünürlüklü X-Işını görüntülerinde genellikle küçük boyutlu ve belirsiz sınır çizgilerine sahip kusurlar görülür. YOLOv7'nin çok ölçekli tespit mimarisi, bu kusurların net biçimde işaretlenmesini sağlayarak kalite değerlendirme sürecinde önemli bir doğruluk artışı sunmaktadır.

3. SINIRLAYICI KUTU REGRESYON YÖNTEMLERİ VE ÖNERİLEN DCIOU METRİĞİ

Nesne tespiti, bilgisayarlı görme alanında uzun süredir araştırmacıların üzerinde çalıştığı temel problemlerden biridir. Bu problem, bir görüntüdeki nesnelerin konumlarının ve türlerinin doğru biçimde belirlenmesini amaçlamakta olup, derin öğrenme tabanlı yaklaşımların gelişmesiyle birlikte önemli ölçüde ilerleme kaydetmiştir [88]. Derin öğrenme temelli nesne tespit sistemlerinde, modelin performansını belirleyen en kritik aşamalardan biri, görüntüdeki nesnelerin konumlarını temsil eden sınırlayıcı kutuların doğru şekilde tahmin edilmesidir [89]. Bu tahmin süreci, genellikle sınırlayıcı kutu regresyonu olarak adlandırılan bir optimizasyon problemiyle ifade edilir ve modelin uzamsal doğruluğunu doğrudan etkileyen temel bir bileşendir [90]. Sınırlayıcı kutu regresyonu, modelin tahmin ettiği kutular ile gerçek nesne konumları arasındaki farkın en aza indirilmesi prensibine dayanır. Bu amaçla, derin öğrenme mimarilerinde kayıp fonksiyonları, modelin tahmin performansını değerlendiren ve parametre güncellemelerini yönlendiren temel ölçütler olarak kullanılır.

Derin öğrenme modelinin başarısı, kullanılan regresyon kayıp fonksiyonunun yapısına ve bu fonksiyonun öğrenme sürecini yönlendirme gücüne doğrudan bağlıdır. Regresyon kayıp fonksiyonları, modelin tahmin ettiği sınırlayıcı kutular ile gerçek kutular arasındaki farkı nicel olarak ifade ederek, modelin parametrelerinin nasıl güncelleneceğini belirleyen temel ölçütlerdendir. Başka bir ifadeyle, kayıp fonksiyonu modelin öğrenme sürecinin pusulası niteliğindedir; çünkü eğitim modeli her iterasyonda bu fonksiyonu en aza indirmeye çalışarak daha doğru tahminler üretmeyi amaçlar. Bu nedenle kayıp fonksiyonunun doğru biçimde tasarlanması, modelin yakınsama hızını, genel doğruluğunu ve genelleme yeteneğini doğrudan etkileyen önemli bir faktördür.

Nesne tespiti problemlerinde yer alan kritik bileşenlerden biri olan sınırlayıcı kutu regresyonu, aynı zamanda modelin tahmin ettiği kutuların gerçek nesne konumlarıyla örtüşme düzeyini ölçerek konum doğruluğunu artırmayı amaçlayan bir optimizasyon sürecini de gerçekleştirir. Derin öğrenme modellerinde regresyon kaybı, tahmin edilen

kutuların geometrik parametreleri olan merkez koordinatları, genişlik, yükseklik ve en-boy oranı gibi değişkenlerin gerçek kutu ile olan farkını nicel olarak ifade eder. Model, her eğitim iterasyonunda bu farkı en aza indirerek nesnenin uzamsal konumunu daha doğru biçimde temsil etmeyi öğrenir. Dolayısıyla regresyon kaybı, yalnızca konum hatalarını azaltmakla kalmaz; aynı zamanda modelin genel öğrenme dinamiklerini doğrudan etkileyen bir unsur olarak öne çıkar.

Regresyon kaybının tanımı ve biçimi, modelin yakınsama kararlılığı ve genelleme performansı üzerinde belirleyici bir etkiye sahiptir. Geleneksel olarak kullanılan norm tabanlı kayıp fonksiyonları (L1, L2, Smooth L1 vb.), kutuların koordinat farklarını doğrudan minimize ederek hata geri yayılım sürecini basitleştirir [91]. Ancak bu yaklaşımların çeşitli sınırlılıkları bulunmaktadır. Norm tabanlı yöntemler, büyük ölçekli nesnelerin yerleştirme hatalarını küçük ölçekli nesnelere kıyasla daha yüksek ceza ile değerlendirdiğinden, regresyon kaybı dengesizliğine neden olmaktadır. Ayrıca, bu tür kayıp fonksiyonlarının simetrik yapısı, tahmin edilen sınırlayıcı kutular belirli simetrik ilişkiler sergilediğinde regresyon kaybının değişmeden kalmasına yol açarak modelin konum duyarlılığını azaltmaktadır [92]. Bununla birlikte, norm tabanlı kayıplar kutular arasındaki geometrik örtüşme oranını dikkate almadıkları için, aynı koordinat farkına sahip ancak farklı konumsal örtüşme düzeyleri bulunan kutuları eşit şekilde cezalandırır. Bu durum, özellikle nesne sınırlarının hassas biçimde belirlenmesinin kritik olduğu senaryolarda model performansını sınırlayıcı bir etki oluşturmaktadır.

Bu sınırlamaları gidermek amacıyla önerilen IoU tabanlı regresyon kayıpları (Intersection over Union, GIoU, DIoU, CIoU vb.) tahmin kutusu ile gerçek kutu arasındaki örtüşme oranını doğrudan optimizasyon kriteri olarak kullanır [59]. Böylece, modelin yalnızca koordinat farklarını değil, aynı zamanda kutuların uzamsal hizalamasını da öğrenmesi sağlanır. IoU tabanlı sınırlayıcı kutu regresyon yöntemleri eğitim modelinin nesne sınırlarına daha duyarlı hale gelmesini ve farklı boyutlardaki nesnelerde daha tutarlı sonuçlar üretmesini sağlar [91].

Sınırlayıcı kutu regresyon kaybı, nesne tespitinde yalnızca konum tahmini doğruluğunu değil, aynı zamanda modelin genel öğrenme performansını da belirleyen temel bir bileşendir. Doğru tanımlanmış bir regresyon kaybı fonksiyonu, modelin nesne sınırlarını daha hassas biçimde öğrenmesine, konum tahminlerinde kararlılığın artmasına ve genel tespit başarısının iyileşmesine doğrudan katkı sağlar.

Bu nedenle, kayıp fonksiyonları yalnızca bir hata ölçütü değil, aynı zamanda modelin güncelleme yönünü belirleyerek öğrenme sürecinin stratejik biçimde şekillenmesini sağlayan temel bir mekanizma olarak değerlendirilmektedir. Doğru tanımlanmış bir kayıp yapısı, parametre güncellemelerinin daha tutarlı gerçekleşmesine zemin hazırlayarak modelin uzamsal temsil gücünü ve genel tespit başarımını dolaylı olarak etkilemektedir.

Nesne tespitinde temel amaç; girdi görüntüdeki hedefleri keşfetmek, sınıflandırmak ve ilgili her bir örnek için konum bilgisi içeren sınırlayıcı kutular üretmektir. Bu çerçevede sınırlayıcı kutu regresyonu, öngörülen kutuların koordinat ve boyutlarının optimize edildiği kritik aşamayı oluşturmaktadır. Dolayısıyla yerelleştirmenin doğruluğunu artırmaya yönelik olarak, regresyon adımının matematiksel formülasyonunun iyileştirilmesi model performansına doğrudan katkı sağlamakta; bu bağlamda özellikle sınır kutusu uyumu, merkez uzaklığı ve oran tutarlılığı gibi unsurların modellenmesi, yöntemlerin çıktı kalitesinin belirleyici unsurlarından biri hâline gelmektedir.

Literatürde ve sınırlayıcı kutu tabanlı nesne tanıma dedektörlerinde en yaygın kullanılan yöntemlerden biri, kutular arasındaki örtüşme oranını ölçen birleşim üzerindeki kesişim (Intersection over Union- IoU) metriğidir. IoU, sınırlayıcı kutu regresyonunu nicel olarak değerlendirmek için basit ve etkili bir ölçüt sunmasına rağmen, optimizasyon sürecinde bazı sınırlılıkları nedeniyle yavaş yakınsama ve hatalı regresyon sonuçlarına yol açabilmektedir. Özellikle, iki nesne arasında hiçbir örtüşme bulunmadığında veya bir kutu diğerini tamamen kapsadığında, IoU türevi sıfırdır ve bu durum kayıp fonksiyonunun gradyanını ortadan kaldırır. Bu durum, IoU'nun nesneler arasındaki konumsal ilişkiyi doğru şekilde yansıtmamasını engeller ve optimizasyon sürecine katkıda bulunmasını sınırlar [67]. Bu da IoU'nun nesneler arasındaki konumsal ilişkileri yeterince hassas yansıtamaması nedeniyle regresyon kaybının etkinliğini sınırlamakta ve yakınsama sürecinde yavaşlama ile hatalı regresyon sonuçlarına yol açmaktadır.

Bu sınırlılıkları aşmak amacıyla literatürde çeşitli IoU türevli kayıp fonksiyonları geliştirilmiştir. GIoU (Generalized IoU), IoU'nun örtüşmeyen kutular için yetersiz kaldığı durumlara kısmi bir çözüm sunar; tahmin edilen ve hedef kutuları kapsayan en küçük kutuyu dikkate alarak kayıp fonksiyonuna ek bir ceza terimi ekler. Bu sayede, tamamen örtüşmeyen kutular için gradyan bilgisi sağlanarak optimizasyon süreci

ilerleyebilir. Ancak GIoU, hâlen bazı durumlarda yavaş yakınsama ve hatalı regresyon problemlerini tamamen ortadan kaldıramamaktadır; özellikle çok küçük veya çok büyük nesneler ile karmaşık sahnelerde sınırlı performans göstermektedir.


Buna karşılık, DIOU (Distance-IOU) tahmin edilen kutu ile hedef kutu arasındaki merkez noktası mesafesini normalleştirerek kayıp fonksiyonuna dahil eder. Bu yaklaşım, yalnızca örtüşme oranına değil, aynı zamanda kutular arasındaki konumsal uzaklığa odaklanarak, regresyon sürecinde daha hızlı ve kararlı bir yakınsama sağlar. CIOU (Complete-IOU) ise regresyon kaybını hesaplamada üç temel geometrik bileşeni birleştirir: örtüşme oranı, merkez mesafesi ve kutuların en-boy oranı. Böylece model hem konum hem boyut hem de şekil açısından daha hassas tahminler yapabilir; bu da genel nesne tespit performansını artırır.

Ek olarak, Focal EIOU [59], regresyon kaybında küçük hataların ağırlığını artırarak yerleştirme doğruluğunu ve yakınsama hızını iyileştirmeyi amaçlayan bir kayıp fonksiyonudur. Bu yöntem, özellikle veri setlerinde sınıf veya boyut dengesizliklerinin bulunduğu durumlarda performans avantajı sağlar. Güncel literatürde önerilen SIOU (Scale-Sensitive IOU) [93] ve LCornerIoU [94] gibi yöntemler ise geometrik hassasiyeti daha da artırmayı hedefler; SIOU, kutuların açısal eğimlerini ve yönelimlerini hesaba katarak regresyonu optimize ederken, LCornerIoU köşe noktalarının konum doğruluğunu doğrudan iyileştirmeye odaklanmaktadır.

Buna rağmen, literatürde giderek artan sayıda IoU tabanlı sınırlayıcı kutu regresyon kaybı önerilmiş olmasına karşın, optimizasyon sürecinde hâlen tahmin edilen kutular ile gerçek kutular arasındaki boşluk önemli bir sorun olarak varlığını sürdürmektedir. Bu boşluk, özellikle küçük nesneler, yoğun veya karmaşık sahneler içeren veri setlerinde nesne yerleştirme doğruluğunu sınırlayan kritik bir faktör olarak değerlendirilmektedir. Bu durum, hâlen sınırlayıcı kutu regresyon kayıplarının geliştirilmesine yönelik araştırmaların literatürde yoğun bir şekilde devam etmesine yol açmaktadır.

Sınırlayıcı kutu regresyonları nesne dedektörleri tarafından gerçek kutu (ground truth (b^g)) ve tahmin kutuları (prediction (b^p)) arasında hesaplanır. Şekil 3.1.'de b^g , b^p ve b^e (kapsayıcı kutu (enclosing box)) kutuları gösterilmiştir. Burada b^g gerçek kutu merkezi, b^p tahmini kutu merkezi, b^e ise kapsayıcı kutunun merkezi olarak tanımlanmıştır. Bu merkezler, sınırlayıcı kutuların konumlarını nicel olarak ifade

etmek ve regresyon kaybını hesaplamak için temel referans noktaları olarak kullanılmaktadır. Bunlara ek olarak; b_d^g gerçek kutu köşegen uzunluğunu (diagonal uzunluk), b_d^p tahmin kutusunun köşegen uzunluğu, b_e^p kapsayıcı kutuya ait köşegen uzunluğunu temsil etmektedir.



Şekil 3.1. Gerçek, tahmini ve kapsayıcı kutular ile kutularda kullanılan parametreler.

Sınırlayıcı kutular dikdörtgen şeklindedir ve matematiksel olarak (x, y, w, h) biçiminde ifade edilmektedir. Bu ifadede x ve y kutunun koordinat düzlemindeki konumunu, w ve h ise kutunun genişlik ve yüksekliğini temsil etmektedir. Bu parametreler, regresyon kaybının hesaplanmasında hem konum hem de boyut doğruluğunun değerlendirilmesini sağlar. Ayrıca, kapsayıcı kutu b^e , tahmin edilen ve gerçek kutunun her ikisini de içine alan en küçük sınır kutusu olacak şekilde tanımlanmakta, IoU ve türevleri gibi örtüşme tabanlı kayıp fonksiyonlarının hesaplanmasında referans olarak kullanılmaktadır.

Bu yapı, sınırlayıcı kutu regresyonunda konumsal hassasiyetin artırılmasına, kutular arasındaki geometrik ilişkilerin değerlendirilmesine ve dolayısıyla modelin yerleştirme performansının optimize edilmesine olanak tanımaktadır. Özellikle IoU tabanlı ve mesafe tabanlı kayıp fonksiyonları, bu parametreleri kullanarak tahmin edilen kutuların gerçek kutulara olan yakınlığını nicel olarak ölçer ve regresyon sürecinde geri yayılımın etkin bir şekilde uygulanmasını sağlar.

3.1. Birleşim üzerindeki Kesişim

Birleşim üzerindeki kesişim (IoU) nesne tespitinde gerçek kutular (b^g) ve hedef kutular (b^p) arasındaki örtüşme bölgesini değerlendirmek için kullanılan temel bir metriktir. IoU, temelde Jaccard indeksinden türetilmiş bir ölçüt olup, iki küme

arasındaki benzerliği hesaplamak için kullanılan bu klasik istatistiksel yöntem, nesne tespit bağlamına sınırlayıcı kutular aracılığıyla uyarlanmıştır.

IoU, negatif olmama, özdeşlik ve simetri gibi matematiksel özelliklere sahip bir benzerlik ölçütü olarak öne çıkar ve bu nedenle kayıp fonksiyonları tasarımında güvenilir bir referans olarak kullanılmaktadır. Özellikle, IoU'nun ölçek bağımsızlığı, nesnelerin boyutlarının değişmesi durumunda, kutular arasındaki uzamsal örtüşme oranının sabit kalmasını temin eder. Bu özellik, farklı boyutlardaki nesnelerin karşılaştırılmasını kolaylaştırarak, regresyon kaybının boyut bağımsız bir biçimde hesaplanmasına olanak tanır.

IoU'nun genel formülasyonu denklem (3.1)'de verilmiş olup, tahmin edilen ve gerçek kutuların kesişim alanının birleşim alanına oranlanması esasına dayanmaktadır. IoU kaybı ise bu formülasyonun matematiksel karşılığı olarak (3.2)'de belirtilmiştir

$$IoU = \frac{(b^g \cap b^p)}{(b^g \cup b^p)} = \frac{I}{U} \quad (3.1)$$

$$L_{IoU} = 1 - IoU \quad (3.2)$$

IoU benzerlik ölçütü, doğrudan optimizasyon sürecinde kullanılamadığından, matematiksel olarak kayıp fonksiyonuna dönüştürülmesi gerekir ((3.2). Bu dönüşüm sayesinde fonksiyon, regresyon optimizasyonunda doğrudan uygulanabilir hâle gelir ve modelin tahminleri ile gerçek kutular arasındaki farkın minimize edilmesi sağlanır. Bu süreçte, sınırlayıcı kutuların sayısal ve sistematik olarak temsil edilmesi kritik bir adımdır; bu nedenle her bir sınırlayıcı kutu, bir görüntüde dört boyutlu bir vektör (x , y , w , h) olarak modellenir (denklem (3.3). Burada x ve y kutunun koordinat düzlemindeki konumunu, w ve h ise kutunun genişlik ve yüksekliğini temsil etmektedir.

$$b = (x, y, w, h) \quad (3.3)$$

Bu dört boyutlu vektör temsili, IoU'nun hesaplanabilmesi için temel bir gerekliliktir. IoU, gerçek kutu (b^g) ve tahmin edilen kutu (b^p) arasındaki örtüşme oranını ölçer ve matematiksel olarak kesişim alanının birleşim alanına oranı şeklinde ifade edilir. Kesişim ($\cap$) ve birleşim ($\cup$) alanlarının hesaplanması, sınırlayıcı kutuların bu dört

boyutlu vektör temsili üzerinden türetilir. Dolayısıyla IoU, sınırlayıcı kutuların sayısal modellemesinden türetilmiş bir ölçüt olarak değerlendirilir.

IoU yalnızca örtüşme oranını değil, aynı zamanda kutuların konum, boyut ve geometrik ilişkilerini de dikkate alacak şekilde optimizasyon sürecine entegre edilmesi, modelin sınırlayıcı kutu regresyonunda daha hassas tahminler gerçekleştirmesine ve yakınsama sürecinin kararlılığının artmasına olanak tanır. Bu bağlamda IoU kaybının türevi, regresyon sırasında geri yayılım algoritması tarafından kullanılmak üzere sınırlayıcı kutu parametreleri (b) açısından hesaplanabilir ve denklem (3.4)'de gösterildiği üzere lokalizasyon doğruluğunu optimize etmek için temel bir mekanizma olarak işlev görür.

$$\frac{\partial L_{IoU}}{\partial b} = \frac{\partial \left(1 - \frac{1}{U}\right)}{\partial b} \quad (3.4)$$

IoU gerçek sınırlayıcı kutu (b^g) ve ile tahmin edilen kutu (b^p) arasındaki örtüşme oranını değerlendirmede yaygın olarak kullanılan temel bir ölçüt olmasına rağmen, optimizasyon sürecinde belirli yapısal sınırlılıklara sahiptir. Özellikle, iki kutu arasında herhangi bir kesişim alanı bulunmadığında ($|b^g \cap b^p| = 0$) IoU değeri sıfıra eşit olur (denklem (3.1)) ve bu durumda kayıp fonksiyonunun türevi de sıfırlanır. Bu durum, geri yayılım (backpropagation) sürecinde gradyan bilgisinin kaybolmasına (gradient vanishing) neden olur. Gradyanların sıfıra yaklaşması, modelin parametrelerinin güncellenmesini imkânsız hâle getirir ve dolayısıyla öğrenme süreci durma noktasına gelir. Bu problem, özellikle erken eğitim aşamalarında tahmin edilen kutuların gerçek nesnelerle çakışmadığı durumlarda sıklıkla görülür ve modelin yerelleştirme (localization) kabiliyetinin gelişmesini ciddi biçimde engeller.

Buna ek olarak, kutulardan birinin diğerini tamamen kapsadığı durumlarda IoU değeri yapay olarak yüksek kalabilmektedir. Ancak bu yüksek IoU değeri, modelin tahmin ettiği kutunun nesneyi gerçekten doğru biçimde konumlandığı anlamına gelmez; çünkü kapsama oranı yüksek olsa da kutu kenarları ile nesnenin sınırları arasında hâlâ belirgin farklar bulunabilir. Bu durumda model, yüksek IoU değerini yanlış bir şekilde doğru tahmin olarak yorumlayarak hatalı konumlandırmaları cezalandırmaz. Böylece modelin hata sinyali (loss gradient) zayıflar ve ağı, konum doğruluğunu artıracak yönde öğrenme gerçekleştiremez.

IoU metriği yalnızca örtüşme alanına dayalı bir ölçüm yaptığı için, kutuların göreceli konumlarını, merkezler arası mesafeyi veya kutuların boyut ve orantısal ilişkilerini hesaba katmaz. Bu yapısal sınırlılıklar, özellikle örtüşmeyen veya kısmen örtüşen kutuların bulunduğu senaryolarda, modelin yakınsama hızını azaltır, yerelleştirme doğruluğunu düşürür ve optimizasyon sürecinin kararlılığını olumsuz etkiler.

Bu sorunların üstesinden gelmek amacıyla, literatürde IoU tabanlı kayıp fonksiyonlarının çeşitli genişletilmiş varyantları önerilmiştir. Özellikle GIoU, DIoU ve CIoU yaklaşımları, IoU metriğine ek ceza terimleri (P- Penalty) entegre edilerek geliştirilmiştir. Bu ceza terimleri, kutular arasındaki geometrik farkları, merkez mesafesini ve boyut oranlarını hesaba katarak yalnızca örtüşme oranını değil, konumsal düzeni ve yapısal benzerliği de değerlendirmeyi amaçlamaktadır. Bu sayede, örtüşme bulunmayan veya kısmi örtüşme durumlarında bile modelin kayıp fonksiyonu bilgi üretmeye devam eder. Söz konusu geliştirilmiş IoU tabanlı fonksiyonların genel biçimi denklem (3.5’de verilmiştir.

$$L_{iou-based} = 1 - IoU + P(b_i - \tilde{b}_i) \quad (3.5)$$

(3.5’de belirtilen $P(b_i - \tilde{b}_i)$ ifadesi IoU’nun göz ardı ettiği eksiklikleri cezalandırmak amacıyla kullanılır; bu terim merkezler arası uzaklık, en-boy oranı uyumsuzluğu veya diğer konumsal farklılıkları dikkate alarak tahminlerin geometrik doğruluğunu artırır. Böylece kayıp fonksiyonu yalnızca kutuların örtüşme oranına odaklanmakla kalmaz; aynı zamanda tahminlerin konumsal doğruluğunu ve geometrik uyumunu optimize ederek nesne tespit modelinin performansını artırır.

3.2. Genelleştirilmiş Birleşim Üzerinden Kesişim

GIoU kayıp fonksiyonu, IoU’nun yalnızca kesişim alanı üzerinden bilgi üreten doğasını genişleterek, kutuların birbirlerine göre mutlak konumsal düzenini de optimizasyona dâhil eden bir yaklaşımdır. Bu yaklaşımda hem tahmin edilen sınırlayıcı kutu hem de gerçek kutuyu bütünüyle içine alan minimum çevreleyici kutu (b^e) üzerinden yeniden tanımlanır ve IoU terimine bu çevresel alanın normatif büyüklüğüne bağlı ek bir ceza ifadesi eklenir; söz konusu ceza teriminin matematiksel formu denklem (3.6’da belirtilmiştir. Böylece model, sadece mevcut örtüşme miktarı üzerinden değil, iki kutunun mekânsal yakınlık ve kapsama düzeyinin “ne kadar idealden uzaklaştığı” üzerinden de geri besleme üretmiş olur. Bu özellik, özellikle

kesişimin olmadığı erken eğitim aşamalarında önemlidir; çünkü klasik IoU’nun türev üretmediği durumlarda bile GIoU, b^e boyutu üzerinden türevlenebilir kayıp üretmeye devam eder ve geri yayılım mekanizmasının durma noktasına gelmesini engelleyerek konum iyileştirme sürecini sürekli hale getirir. Bu genelleştirilmiş GIoU fonksiyonunun bütünsel biçimi denklem (3.7’de gösterilmiş olup, optimizasyon sürecinde kullanılan GIoU kayıp fonksiyonu ise denklem (3.8’de belirtilmiştir. Dolayısıyla GIoU, IoU’nun temel tanımını “sadece mevcut örtüşmenin değerlendirilmesinden”, “potansiyel örtüşme kapasitesinin de optimize edilmesine” doğru genişleten bir iyileştirme sunar.

$$P_{\text{GIoU}} = \frac{b^e - (b^g \cup b^p)}{b^e} \quad (3.6)$$

$$\text{GIoU} = \text{IoU} + P_{\text{GIoU}} \quad (3.7)$$

$$L_{\text{GIoU}} = 1 - \text{GIoU} \quad (3.8)$$

Bununla birlikte GIoU, tüm geometrik durumlar için yeterince ayrıştırıcı bir performans göstermez. Özellikle tahmin edilen kutu ile gerçek kutunun birinin diğerini tamamen kapsadığı durumlarda, b^e kutusu artık küçültülebilir bir alan içermez; dolayısıyla ceza terimi pratikte sabitlenir ve denklem (3.6’da tanımlanan ceza bileşeninden artık iyileştirici bilgi üretilemez hâle gelir. Bu noktada GIoU, davranışsal olarak tekrar salt IoU şeklinde çalışır ve görünürde yüksek IoU değerleri hâlâ üretilebildiği için, kutu kenar hizalama hataları cezalandırılmadan kalır. Sonuç olarak yüksek IoU değerleri model tarafından “başarılı tahmin” gibi algılansa da konumsal hizalama hataları devam edebilmektedir. Bu durum gradyan yüzeyinin doygunlaşmasına neden olur; modelin lokal hizalama duyarlılığı zayıflar ve optimizasyon kararlılığı düşer. Dolayısıyla GIoU, IoU’ya göre önemli bir genişletilmiş form sunmasına rağmen, ceza teriminin yalnızca b^e üzerinden tanımlanmış olması nedeniyle tam kapsama yapılarını ayrıştırma ve kenar hizalama duyarlılığı üretme noktasında hâlâ sınırlı bir ayırım gücüne sahiptir; bu yönü hâlen iyileştirilmesi gereken bir özellik olarak kalmaktadır.

3.3. Mesafe Kapsamlı Birleşim Üzerinden

DIoU (Distance Intersection over Union) yaklaşımı, IoU ve GIoU'nun yalnızca örtüşme alanına dayalı değerlendirme yaptıkları sınırlılıkları iyileştirmeyi hedefler. Bu yöntemde, tahmin edilen kutu ile gerçek kutu arasındaki örtüşme oranının yanı sıra, kutuların merkez noktaları arasındaki mesafe ($\rho(b_c^g, b_c^p)$) ve bu kutuları kapsayan en küçük dikdörtgensel çevre kutunun köşegen uzunluğunu da (b_d^e) da dikkate alan ek bir ceza terimi olarak kayıp fonksiyonuna dâhil edilir (denklem (3.9)). Merkezler arası mesafe, çevre kutunun köşegen uzunluğuna oranlanarak normalize edilir ve bu oran, tahmin edilen kutunun gerçek kutuya olan mekânsal uzaklığını doğrudan cezalandıracak şekilde kayıp fonksiyonuna eklenir. DIoU'nun genel fonksiyonu (3.10'da ve kayıp fonksiyonu ise denklem (3.11'de belirtilmiştir. Böylece DIoU, yalnızca mevcut örtüşmeye değil, aynı zamanda kutuların konumsal hizalanmasına dair bilgiyi de optimize sürecine dâhil eder. Bu yapı, IoU ve GIoU'nun türev üretememesi nedeniyle oluşan gradyan kaybolması sorununa alternatif bir çözüm sunar ve modelin yakınsama hızını ve konum doğruluğunu artırır. Kısaca, merkezler arası mesafe ve çevre kutu köşegen oranının ceza terimi olarak eklenmesi, DIoU'nun öğrenme sürecinde daha hassas ve sürekli bir geri besleme sağlamasını mümkün kılar.

$$P_{\text{DIoU}} = \frac{\rho^2(b_c^g, b_c^p)}{(b_d^e)^2} \quad (3.9)$$

$$\text{DIoU} = \text{IoU} + P_{\text{DIoU}} \quad (3.10)$$

$$L_{\text{DIoU}} = 1 - \text{DIoU} \quad (3.11)$$

Buna karşın, DIoU belirli geometrik konfigürasyonlarda hâlen sınırlılıklar göstermektedir. Özellikle tahmin edilen kutu ile gerçek kutunun merkezlerinin çakıştığı durumlarda, kutuların boyutları veya en-boy oranları farklı olsa bile DIoU değeri yüksek çıkabilmektedir. Bu durumda merkez mesafesine dayalı ceza terimi sıfırlanmakta ve kutu kenarlarının hizalama hataları yeterince yansıtılamamaktadır. Dolayısıyla, merkez konumu doğru olsa bile kutu sınırları gerçek nesne sınırlarından sapabilir ve model bu sapmaları “düşük hata” olarak değerlendirebilir. Ayrıca DIoU yalnızca merkezler arası uzaklığı ceza terimi olarak dahil ettiğinden, kutuların ölçek ve orantısal farklılıklarını doğrudan optimize etmez; bu sebeple özellikle uzun, dar veya oran bakımından asimetrik nesnelerde hassas çerçeve hizalaması açısından

yetersiz kalmaktadır. Sonuç olarak DIOU, GIOU'nun eksiklerini kısmen gideren bir yaklaşım olmakla birlikte, kutuların boyut ve şekil farklılıklarını modellemeye yönelik ek bileşenlere ihtiyaç duyan bir yöntem olarak değerlendirilebilir.

3.4. Tam Kapsamlı Birleşim Üzerinden

DIOU kaybı, yalnızca iki sınırlayıcı kutunun merkez noktaları arasındaki mesafeyi minimize etmeyi değil, aynı zamanda bu mesafenin kapsayıcı çevre kutusunun diyagonal (köşegen) uzunluğuna oranlanmış halini de doğrudan minimize etmektedir. Bu özellik, kutuların sadece örtüşme oranını değil, aynı zamanda mekânsal yakınlıklarını da optimize etmek için tasarlanmıştır. Ancak, iki kutunun merkez noktaları çakıştığında, ceza terimi sıfıra düşer. Bu durumda, DIOU kaybı IoU kaybına dönüşür.

CIOU yaklaşımı, DIOU'nun yalnızca merkezler arası mesafeyi minimize etme temelli optimizasyonunun belirli geometrik konfigürasyonlarda tek başına yetersiz kaldığı gerçeğini temel alarak geliştirilmiş bir çerçevedir. DIOU, merkezler arası öklid mesafesini normalize oran üzerinden ceza olarak eklediği için konumsal yakınlığı optimize edebilir; ancak kutuların boyut benzerliği, şekil uyumu ve en-boy oranı hakkında bilgi üretmez. Bu nedenle CIOU, DIOU'nun ceza terimini genişleterek kutuların genişlik-yükseklik oran uyumluluğunu da hesaba katar; böylece sadece örtüşme ve merkez hizalaması değil, kutuların geometrik uyumu da optimizasyon sürecine dâhil edilir. Bu kapsamda CIOU ceza bileşeni denklem (3.12'de verilmiştir. Bu ceza bileşeni, kutular arası en-boy oran tutarlılığını tanımlayan v terimi (denklem (3.13) ve bu oranın etkisini normalize eden α katsayısı (denklem (3.14) üzerinden formüle edilmiştir. Böylece CIOU, mesafeye dayalı cezanın ötesine geçerek kutu boyutlarının ve en-boy oranlarının da optimizasyon dinamiklerine etkili bir biçimde yansıtılmasını sağlar.

CIOU'nun genel fonksiyonel ifadesi denklem (3.15'de ve CIOU kayıp fonksiyonunun nihai biçimi denklem (3.16'da verilmiştir. Bu yapı sayesinde CIOU, yalnızca yakınsama hızını artırmakla kalmaz; aynı zamanda kenar hizalama doğruluğunu ve kutu şekli tutarlılığını da destekler. Özellikle IoU ve DIOU'nun erken eğitim aşamalarında gradyan bilgisi üretmekte sınırlı kaldığı veya merkezlerin çakıştığı durumlarda ceza terimi zayıfladığı için DIOU'nun IoU'ya geri düştüğü senaryolarda, CIOU hâlâ etkili hata sinyali üretebilir. Böylece CIOU, “konum- boyut- şekil” üçlüsünü

tek bir kayıp yapısı altında birleştirilerek daha bütünsel ve daha kararlı bir kutu regresyonu öğrenme süreci sağlar.

$$P_{CIoU} = \frac{\rho^2(b_c^g, b_c^p)}{(b_d^g)^2} + av \quad (3.12)$$

$$v = \frac{4}{\pi * \pi} \left(\arctan \frac{w^g}{h^g} - \arctan \frac{w^p}{h^p} \right)^2 \quad (3.13)$$

$$a = \begin{cases} 0, & \text{if IoU} < 0.5, \\ \frac{v}{(1 - \text{IoU}) + v}, & \text{if IoU} \geq 0.5 \end{cases} \quad (3.14)$$

$$CIoU = IoU + P_{CIoU} \quad (3.15)$$

$$L_{CIoU} = 1 - CIoU \quad (3.16)$$

CIoU'nun, DIoU'ya göre ek olarak en-boy oranı uyumluluğunu da optimize edebilmesi oldukça önemli bir iyileştirme sunmasına rağmen, bu avantajına karşın yetersiz kaldığı durumlar da bulunmaktadır. CIoU'da $\text{IoU} \geq 0.5$ durumunda (denklem (3.14) ceza puanının bir etkisi kalmayacak ve CIoU DIoU gibi davranacaktır. Bu durum, özellikle yüksek örtüşme oranı elde edildiğinde, kutuların en-boy oranı tutarsız olsa bile ceza teriminin kaybolmasına yol açar; dolayısıyla CIoU kutuların oran uyumluluğunu yeterli düzeyde optimize etmeyebilir. Başka bir ifadeyle, IoU yüksek olduğunda model, kutuların oran uyumsuzluğunu artık cezalamaz ve bu nedenle CIoU'nun en-boy oranı temelli iyileştirme yetkinliği belirli bir aralıkta etkisiz hale gelir.

IoU, GIoU, DIoU ve CIoU, literatürde ve sınırlayıcı kutu tabanlı dedektörlerde yaygın olarak kullanılan etkili sınırlayıcı kutu regresyon yöntemleridir; ancak bu yöntemler sahip oldukları belirli üstünlüklere rağmen, bazı durumlarda hâlâ yetersizlikler göstermektedir (Şekil 3.2.). Özellikle CIoU'nun cezasının IoU rejimine koşullu olması, şekil uyumsuzluğunun yüksek örtüşmede yeterince optimize edilememesine neden olmakta ve bu durum da özellikle ince, uzun veya en-boy oranı aşırı farklı nesne geometrilerinde konumsal hassasiyetin düşmesine yol açabilmektedir. Bu sınırlılık, daha gelişmiş ve geometrik ilişkileri daha açıklayıcı yeni IoU varyantlarının geliştirilmesine yönelik ihtiyacı doğuran temel motivasyonlardan biridir.

3.5. Merkezler Arası Mesafe Birleşim Üzerinden

CIoU'nun yüksek IoU rejiminde en-boy oranı ceza katkısının kaybolması ve DIoU'nun kutuların sadece iki merkez arasındaki tekil mesafe bilgisini kullanması nedeniyle bazı geometrik konfigürasyonlarda hâlâ sınırlılıklar üretmesi, literatürde daha açıklayıcı ve daha güçlü bir ceza formülasyonuna ihtiyaç olduğunu ortaya koymuştur.

$$P_{DCIoU} = \left(\frac{((\rho^2(b_c^g, b_c^e), \rho^2(b_c^p, b_c^e)))_{\max}}{\rho^2(b_c^g, b_c^e) + \rho^2(b_c^p, b_c^e) + \rho^2(b_c^g, b_c^p)} \right) \quad (3.17)$$

$$P_{DCIoU} = \left(\frac{(\rho^2(b_d^g, b_d^p))_{\min}}{(\rho^2(b_d^g, b_d^p))_{\max}} \right) * \lambda \text{ (Eğer merkezler eşitse, } (\lambda = 0.01)) \quad (3.18)$$

$$DCIoU = (IoU + P_{DCIoU})_{\text{normalize}} \quad (3.19)$$

$$L_{DCIoU} = 1 - DCIoU \quad (3.20)$$

Bu çalışma kapsamında, tüm bu eksiklikler göz önüne alınarak, sınırlayıcı kutu regresyon performansını iyileştirmek amacıyla DCIoU (Distance Centers Intersection over Union) adı verilen yeni bir metrik önerilmektedir. DCIoU'nun temel motivasyonu, yalnızca tahmin kutusu ile gerçek kutu merkezleri arasındaki mesafenin değil, ayrıca bu iki kutunun birleşim alanının minimum çevre kutusu merkezinin (b_c^e) de regresyon sürecine dahil edilmesidir. Böylece DCIoU ceza terimi, yalnızca iki kutunun birbirine ne kadar yakın olduğunu değil, aynı zamanda iki kutunun global uzamsal lokasyon hâkimiyetine göre nasıl konumlandığını da optimize edecek şekilde tasarlanmıştır. DCIoU'nun bu ceza formülasyonu denklem (3.17)'de verilmiştir.

Algoritma 1. DCIoU Algoritması.

Girdi: Tahmin b^p ve gerçek kutu b^g koordinatları: $b^g = (x^g y^g h^g w^g)$, $b^p = (x^p y^p h^p w^p)$

Çıktı: DCIoU

1. Kutuların koordinatlarını sol üst ve sağ alt köşeleri gösterecek şekilde standartlaştır:

$$b^g = (x_1^g, y_1^g, x_2^g, y_2^g), \quad b^p = (x_1^p, y_1^p, x_2^p, y_2^p), \quad b^c = (x_1^e, y_1^e, x_2^e, y_2^e)$$

(b^e , b^g ve b^p 'nin birleşiminin koordinatları)


2. b^g ve b^p alanlarını hesapla: $A^g = (x_2^g - x_1^g) \times (y_2^g - y_1^g)$, $A^p = (x_2^p - x_1^p) \times (y_2^p - y_1^p)$
3. b^g ve b^p kesişim ve birleşim alanlarını hesapla: $W_I = (\max(x_1^g, x_1^p) - \min(x_2^g, x_2^p))$, $H_I = (\max(y_1^g, y_1^p) - \min(y_2^g, y_2^p))$, $Inter = W_I \times H_I$, $Union = A^g + A^p - Inter$
4. $IoU = \frac{Inter}{Union}$
5. Eğer $b^g = b^p$: return dciou=1.0
6. Kutu merkezlerini hesapla: $box_center_x = (x_1 + x_2)/2$, $box_center_y = (y_1 + y)/2$, $b_c = (box_center_x, box_center_y)$
7. Kutu diagonal uzaklıkları hesapla: $b_d^g = |(x_1^g, y_1^g), (x_2^g, y_2^g)|$, $b_d^p = |(x_1^p, y_1^p), (x_2^p, y_2^p)|$
8. Eğer $box_center^g = box_center^p$: return DCIoU = $IoU + \frac{(\rho^2(b_d^g, b_d^p))_{\min}}{(\rho^2(b_d^g, b_d^p))_{\max}} \times \lambda$
9. DCIoU hesapla : $DCIoU = IoU + \frac{((\rho^2(b_c^g, b_c^e)), (\rho^2(b_c^p, b_c^e)))_{\max}}{\rho^2(b_c^g, b_c^e) + \rho^2(b_c^p, b_c^e) + \rho^2(b_c^g, b_c^p)}$
10. DCIoU değerini normalize et ve bitir: return nomalized_DCIoU

DCIoU yöntemi, önceki IoU tabanlı kayıp fonksiyonlarının örtüşme merkezli sınırlılıklarını aşmayı hedefleyen bir yaklaşım olup, DCIoU'nun algoritma işleyişi Algoritma 1'de verilmiştir. Hesaplama sürecinde, ilk adım olarak tahmin edilen kutu ile gerçek kutunun tamamen eşit olup olmadığı kontrol edilir; eğer kutular tamamen aynı ise DCIoU değeri 1 olarak atanır ve regresyon problemi çözülmüş sayılır. Kutular eşit değil ama merkezler eşit ise, iki kutunun köşegen mesafeleri oranının λ sabiti ile çarpımı ceza terimi olarak kullanılır (denklem (3.18)).

Kutular tamamen eşit değil ve merkezleri farklı ise, DCIoU mevcut IoU değerine ek olarak bir genel konum ceza terimi uygular. Bu ceza, birleşim kutusunun merkezi (b^e) referans alınarak hesaplanan iki mesafeden ($\rho(b_c^g, b_c^e)$) ve ($\rho(b_c^p, b_c^e)$) mesafe ölçümlerinden büyük olanının ($\rho(b_c^g, b_c^e)$), ($\rho(b_c^p, b_c^e)$) ve ($\rho(b_c^g, b_c^p)$) arası mesafelerinin toplam değerine oranı eklenir. Noktalar arası mesafeler hesaplanırken Öklid mesafesi

yöntemi kullanılır. DCIoU formülasyonunda, regresyon kaybına eklenen ceza terimi denklem (3.17’de açıkça tanımlanmıştır ve bu terim, kutuların konumsal doğruluğunu artırmak amacıyla merkezler arası mesafe ölçümlerini içerir. Genel DCIoU fonksiyonu denklem (3.19’da gösterilmiş olup, hem tahmin edilen kutu ile gerçek kutu arasındaki örtüşmeyi hem de bu kutuları kapsayan minimum çevre kutusunun merkezi üzerinden hesaplanan uzaklıkları dikkate alır.

Bu yaklaşım, yalnızca kutuların lokal hizalanmasını optimize etmekle kalmaz, aynı zamanda kutuların genel konum ilişkisini de hesaba katarak regresyon sürecinde daha güvenilir ve sürekli bir gradyan üretir. DCIoU’nun ham hesaplama sonucu denklem (3.17’deki formülasyon ile $(0, 1.5]$ aralığında değişkenlik gösterir; ancak denklem (3.19 ile bu değerler $(0, 1]$ aralığına normalize edilir. Bu normalizasyon işlemi, DCIoU’nun tüm sınırlayıcı kutu tabanlı nesne tanıma dedektörlerinde doğrudan ve tutarlı şekilde kullanılabilmesini sağlar. DCIoU kaybı denklem (3.20’de belirtilmiştir. Böylece DCIoU, IoU, GIoU, DIoU ve CIoU’nun örtüşme ve merkez bazlı geri besleme ile sınırlı kaldığı durumların aksine hem lokal merkez hizalanmasını hem de global konum ilişkilerini eş zamanlı olarak optimize eden IoU varyantı olarak öne çıkar. Bu yapı, modelin regresyon gradyanını daha kararlı hâle getirir, öğrenme sürecinde duraksamaları önler ve sınırlayıcı kutu tahminlerinin doğruluk ve hassasiyetini önemli ölçüde artırır.



Şekil 3.2. Farklı örtüşmelerde IoU, GIoU, DIoU ve DCIoU ölçümleri. (a) merkez noktaları ve en-boy oranları aynı olan birbirini kapsayan kutular. (b) Merkezleri farklı ancak en-boy oranları aynı olan kesişen kutular. (c) Merkezleri çakışan, yüksekliği aynı ancak genişliği farklı olan kutular. (d) Aynı merkez noktasına sahip ancak farklı en-boy oranlarına sahip kutular.

DCIoU yöntemi, klasik IoU ve türevlerinin yetersizliklerini aşarak sınırlayıcı kutu regresyonunda önemli avantajlar sunar. Öncelikle, yalnızca örtüşme alanını dikkate alan IoU ve GIoU'nun aksine, DClou kutuların merkez noktalarının ve kapsayan çevre kutunun merkezine olan mesafelerini de kayıp fonksiyonuna dahil ederek konumsal hassasiyeti artırır. Bu yaklaşım, özellikle kutuların kısmen örtüştüğü veya başlangıçta hiç örtüşmediği erken eğitim aşamalarında gradyan kaybolması sorununu önler ve modelin sürekli geri besleme almasını sağlar. Ayrıca, merkezler arası mesafe ve çevre kutu merkezine olan uzaklıkların ceza terimi olarak eklenmesi, modelin yalnızca lokal hizalamayı değil, küresel konum ilişkilerini de optimize etmesine imkân tanır. DClou'nun Öklid normu ile hesaplanan bu mesafe bileşenleri, tahmin edilen kutuların gerçek nesne sınırlarına daha tutarlı bir şekilde yaklaşmasını sağlar ve yakınsama sürecini hızlandırır. Böylece DClou, IoU, GIoU, DIoU ve CIoU'nun sağladığı örtüşme tabanlı geri besleme dışında, kutuların hem boyut hem de konum doğruluğunu eş zamanlı olarak iyileştiren bütünsel bir yaklaşım sunar. Özellikle Şekil 3.2.(a)'da gösterildiği gibi, sınırlayıcı kutuların merkez noktalarının ve en-boy oranlarının aynı olması ve bir kutunun diğerini tamamen kapsaması durumunda, GIoU, DIoU ve CIoU değerlerinin IoU seviyesine gerilediği gözlemlenmektedir. Şekil 3.2.(b) incelendiğinde, kutuların farklı merkezlere sahip olmalarına rağmen aynı en-boy oranına sahip olmaları nedeniyle CIoU'nun DIoU değerine gerilediği anlaşılmaktadır. Öte yandan, Şekil 3.2.(c)'de birbirini kapsayan kutuların merkezlerinin çakışması durumunda, DIoU'nun IoU seviyesine düştüğü görülmektedir. Benzer şekilde, Şekil 3.2.(d)'de aynı merkez noktasına sahip ancak farklı en-boy oranlarına sahip kutularda DIoU ve CIoU'nun IoU'ya benzer davranış sergilediği tespit edilmiştir.

Tüm senaryolarda, DClou ile elde edilen kayıp değerlerinin diğer yöntemlere kıyasla daha yüksek performans sergilediği görülmektedir. Bu durum, regresyon hatalarının etkili bir şekilde azaltılmasına ve özellikle zorluk derecesi yüksek vakalarda kayıp fonksiyonunun başarılı bir biçimde minimize edilmesine olanak sağlamaktadır.

4. TAHMİNİ SINIRLAYICI KUTULARIN BELİRLENMESİ VE ÖNERİLEN KOMLUŞUK İLİŞKİ ALGORİTMASI

Nesne tespiti sürecinde tahmini sınır kutularının (predicted bounding boxes) doğru ve tutarlı biçimde tanımlanması hem sınıflandırma doğruluğu hem de regresyon performansı üzerinde doğrudan belirleyici bir etkisi bulunmaktadır [95]. Tahmin edilen kutunun gerçek nesneyi ne kadar doğru temsil ettiği; konum, merkez koordinatları ve en-boy oranı gibi geometrik parametrelerin yüksek doğrulukla belirlenmesine bağlıdır. Bu bağlamda, tahmini kutuların doğru modellenmesi yalnızca IoU değerlerini arttırmakla kalmamakta, aynı zamanda modelin kayıp fonksiyonundan aldığı ceza miktarını da doğrudan azaltmaktadır. Tahmini kutulardaki hatalar, modelin öğrenme sürecinde hem lokalizasyon hem de sınıf ayrıştırma performansını negatif yönde etkilemekte; özellikle birbirine yakın konumlanan nesnelerde veya yüksek örtüşme gösteren durumlarda hatalı kutu üretimi, yanlış pozitif ve yanlış negatiflerin artmasına yol açabilmektedir [96]. Dolayısıyla, tahmini sınır kutularının başlangıç aşamasında mümkün olduğunca doğru biçimde belirlenmesi, sonraki aşamalarda uygulanacak eleme, filtreleme veya ilişkilendirme algoritmalarının etkinliğini belirleyen temel ön koşullardan biridir.

YOLOv7 mimarisinde tahmini sınır kutularının oluşturulması süreci, eğitim aşamasında görüntü üzerinde manuel olarak belirlenmiş gerçek kutu bilgilerinin modele referans olarak verilmesiyle başlar. Eğitim verisetinde her bir nesne için sağlanan gerçek kutu etiketleri (x , y , w , h ve cls (sınıf değerleri)) modelin öğrenmesi gereken temel geometrik hedefleri tanımlar. Bu etiketler, YOLOv7'nin çok ölçekli yapısı ile uyumlu hale getirilmek amacıyla normalleştirilir ve varsayılan olarak modelin ürettiği üç farklı çıkış düzeyine (80×80 , 40×40 , 20×20) yeniden ölçeklendirilir. Böylece her bir gerçek nesne, ilgili çözünürlük seviyesinde doğru uzamsal konuma karşılık gelen grid bölgesine yerleştirilmiş olur. Bu işlem, modelin öğrenme aşamasında hangi bölgelerde nesne bulunması gerektiğini ve bu nesnenin yaklaşık konum/boyut referansının nasıl olması gerektiğini açık biçimde tanımlayan temel başlangıç adımıdır. Gerçek kutuların doğru biçimde tanımlanması ve uygun çıkış ölçeğine doğru aktarılması; hem konum regresyonunun daha hızlı yakınsamasını

sağlamakta, hem de modelin sınırlayıcı kutu merkezlerini daha stabil öğrenmesine katkıda bulunmaktadır. Aksi durumda, yanlış veya belirsiz konumlandırılmış etiketler, modelin konum tahmini sürecini hatalı yönlendirerek lokalizasyon performansını düşürmekte ve eğitim süreci boyunca yanlış pozitif oranlarının artmasına sebep olabilmektedir.

YOLOv7’de gerçek kutuların uygun ölçeklere aktarılmasından sonra model, tahmin edilen kutular ile gerçek kutular arasındaki ilişkiyi kurmak amacıyla bir eşleme (matching) süreci uygular. Bu aşamada amaç; tahmini kutulardan hangilerinin gerçek nesne konumlarını temsil ettiği ve hangilerinin sadece zayıf aday olduğu bilgisini kesinleştirmektir. Bu belirleme yapıldıktan sonra eğitim sürecinin temel belirleyicilerinden biri olan regresyon kaybı devreye girer. Regresyon kaybı; tahmini kutu merkezi ile gerçek kutu merkezi arasındaki konumsal farkı, ayrıca genişlik-yükseklik gibi geometrik parametrelerdeki farklılıkları cezalandıran çekirdek bileşendir. Başka bir ifadeyle modelin sınır kutusunu “ne kadar doğru yerleştirdiğini” doğrudan sayısal olarak ölçen mekanizma bu bileşendir. Bu nedenle regresyon kaybının yapısı, lokalizasyon performansını belirleyen en kritik parametrelerden biri olarak kabul edilir. Literatürde bu amaçla IoU tabanlı farklı ceza fonksiyonları tanımlanmış olmakla birlikte, bu çalışma kapsamında özellikle merkez mesafesi duyarlılığı ve geometrik sapmaya karşı kararlılığı artırmak amacıyla regresyon bileşeninde DCIoU tabanlı bir yaklaşım önerilmiştir. Bu yaklaşım, klasik IoU temelli kayıpların özellikle merkez kayması senaryolarında yetersiz kaldığı durumlarda ek bir ayırt edicilik sağlamayı hedeflemekte ve modelin sınır kutularını daha hassas biçimde optimize etmesine katkıda bulunmaktadır.

YOLOv7’de tahmini kutular, giriş görüntüsünden çıkarılan çok ölçekli özellik haritalarına dayalı olarak oluşturulur. Modelde genellikle (varsayılan olarak) üç farklı ölçekten (80×80 , 40×40 , 20×20) tahminler üreterek toplam 25200 tahmini kutu oluşturur. Bu tahmini kutular, çok boyutlu bir tensör (tensor) olarak temsil edilir; yani tüm tahminler, konum, boyut, nesne varlığı ve sınıf olasılığı bilgilerini içerecek şekilde düzenli bir veri yapısında tutulur ve paralel hesaplamaya uygundur. Tensör yapısı genel olarak $[N, C]$ biçimindedir; burada $N= 25200$ tahmini kutuyu (varsayılan), C ise her kutuyu temsil eden değerlerin toplam sayısını gösterir ve şu şekilde oluşur: $[x, y, w, h, obj_skr, cls_1, cls_2, \dots, cls_n]$.

Tahmini kutuların oluşumu, her çıkış ölçeğinin grid boyutları ve her grid hücresine atanmış çapa sayısı ile belirlenir. YOLO’da kullanılan varsayılan 640×640 boyutlu bir giriş görüntüsü için;

- 80×80 grid ölçeğinde $\rightarrow$ 19200 tahmini kutu,
- 40×40 grid ölçeğinde $\rightarrow$ 4800 tahmini kutu,
- 20×20 grid ölçeğinde $\rightarrow$ 1200 tahmini kutu

Her bir tensör elemanı, tahmini kutunun geometrik ve sınıfsal bilgilerini içerir:

- x,y : Tahmini kutunun merkez koordinatları
- w,y : Tahmini kutunun genişlik ve yüksekliği
- obj_skr : Bu kutunun gerçek bir nesne içermesi olasılığı (0-1 arası). Pozitif ve negatif örneklerin belirlenmesinde ve güven skoru hesaplamasında kullanılır.
- cls_n :Tahmini kutunun belirli bir sınıfa ait olma olasılığı (0-1 arası); veri kümesindeki tüm sınıflar için olasılık dağılımını içerir.

Bu tensör yapısı, tahmini kutuların konum, boyut, nesne varlığı ve sınıf olasılığı açısından eksiksiz ve düzenli bir şekilde temsil edilmesini sağlar; ayrıca paralel hesaplamaya uygun olması, modelin sonraki eleme ve optimizasyon adımlarında hızlı ve verimli işlem yapılabilmesini mümkün kılar.

Modelin ürettiği çok sayıda tahmini kutunun büyük kısmı birbirleriyle örtüşür ve sıklıkla aynı nesneyi temsil eder; bu durum, post-processing (tahmini kutu oluşturma) aşamasında gereksiz tekrarların ve çakışan tahminlerin azaltılmasını zorunlu kılar. Bu amaçla sıklıkla kullanılan yöntemlerden biri Non-Maximum Suppression (NMS)’dir [97]. Klasik NMS yaklaşımında, her sınıfa ait tahmini kutular önce güven skoruna göre sıralanır; ardından en yüksek güven skorlu kutu seçilir ve bu kutu ile yüksek IoU değerine sahip diğer kutular eleme işlemine tabi tutulur. Bu yöntem, özellikle yoğun tahminlerin bulunduğu sahnelerde, çakışan kutular arasından yalnızca en güvenilir olanını koruyarak modelin tekilleştirilmiş ve temiz bir çıktı üretmesini sağlar.

Buna karşın klasik NMS bazı durumlarda sınırlıdır [98]. Özellikle birbirine yakın konumlanmış fakat farklı nesneleri içeren sahnelerde, iç içe geçmiş küçük nesnelerde veya yüksek nesne yoğunluğuna sahip karmaşık sahnelerde agresif eleme, gerçek pozitif kutuların yanlışlıkla silinmesine yol açabilir [99]. Bu tür durumlarda, IoU tabanlı eşik değeri yeterince esnek olmadığında, modelin doğru tahminleri kaybetme

olasılığı artar ve sonuç olarak hem lokalizasyon doğruluğu hem de sınıf tahmini performansı düşer. Özellikle küçük nesnelerin yoğun olduğu görüntülerde, kutular arasındaki küçük geometrik farklar göz ardı edildiğinde NMS'in hatalı eleme yapması, modelin genel tespit başarısını ciddi şekilde olumsuz etkileyebilir [100].

Ayrıca klasik NMS, yalnızca kutuların örtüşme oranını dikkate aldığı için, kutuların merkez uzaklığı, en-boy oranı veya kutu geometrisi gibi diğer önemli bilgileri ihmal eder. Bu da birbirine yakın fakat farklı nesneler için yapılan seçimlerin hassasiyetini azaltır ve küçük nesnelerin doğru şekilde korunmasını zorlaştırır. Doğru ve güvenilir post-processing (tahmini kutu seçme) uygulamaları, yalnızca en yüksek güven skorlu kutuyu seçmekle sınırlı kalmamalı; aynı zamanda kutuların konumsal ve geometrik ilişkilerini de değerlendirecek şekilde tasarlanmalıdır.

NMS işlemi, tahmini kutuların güven skoruna göre sıralanmasını ve belirlenen eşik değerinin altındaki tahminlerin elenmesini içerir. Ardından, kalan kutuların IoU değerleri hesaplanır ve belirlenen eşik değerini aşan kutular kaldırılır. Bu adım, tüm tahmini kutular için tekrarlanarak her nesne için yalnızca en güvenilir tahminlerin korunmasını sağlar. Ancak klasik NMS yalnızca örtüşme tabanlı eleme yaptığı için, yoğun sahnelerde veya iç içe geçmiş küçük nesnelerde bazı gerçek pozitifler yanlışlıkla silinebilir.

YOLOv7 modelinin ürettiği tensörlerde varsayılan olarak 25200 tahmini kutu yer alır. Bu kutuların bir kısmı çakışır, bir kısmı ise birbirinden bağımsızdır. NMS işlemi hem çakışan hem de çakışmayan kutular arasından en uygun tahmini kutuların seçilmesini sağlar; ancak klasik yaklaşım, yoğun tahminlerde hem işlem süresini artırabilir hem de doğru kutu seçiminde hatalara yol açabilir. Bu sorunları çözmek, işlem süresini optimize etmek ve en doğru kutuları seçmek amacıyla, K-Means algoritmasına dayalı "Komşuluk İlişki Algoritması" (Algoritma 2) önerilmiştir. Bu algoritma, tahmini kutuların konumsal ve geometrik ilişkilerini dikkate alarak daha tutarlı ve dengeli seçimler yapılmasını sağlar ve NMS ile entegre edilerek hem doğru pozitiflerin korunmasını hem de tahmini kutu seçimini optimize edilmesini mümkün kılar.

Geliştirilen Komşuluk İlişki Algoritması, K-Means tabanlı kümeleme yöntemi ile tahmini kutuların konumsal ilişkilerini analiz eder. Bu sayede sınır kutularının dağılımı, merkezi konumları ve yönleri dikkate alınarak daha dengeli ve tutarlı seçimler yapılır. NMS yalnızca en yüksek skorlu kutuyu korurken, Komşuluk İlişki

Algoritması komşu kutuların geometrik ve konumsal özelliklerini de değerlendirir. Sonuç olarak, yoğun nesne içeren sahnelerde yanlış eleme oranı azalır, tahmin edilen nesnelerin kaybolması önlenir ve işlem süresi optimize edilerek modelin verimliliği ve doğruluğu artırılır.

4.1. K-Means Algoritması

K-Means algoritması, makine öğrenmesi ve veri analizi alanında yaygın olarak kullanılan bir veri kümeleme (clustering) yöntemidir [101]. Kümeleme, veriyi önceden belirlenmiş sınıflar veya etiketler olmadan, benzer özelliklere sahip gruplar hâline getirme işlemidir. Bu yaklaşım gözetimsiz öğrenme (unsupervised learning) kategorisine girer ve veri noktalarının doğal dağılımını temel alır [102]. Kısacası, kümeleme algoritmaları veriyi benzerlik ve farklılıklarına göre organize eder, her kümenin kendi içinde homojen, kümeler arası ise heterojen olmasını sağlar.

K-Means algoritması, verilen veri setini k sayıda kümeye ayırarak çalışır ve temel adımları şunlardır:

1. Küme Sayısının Belirlenmesi (k): Veri setinde oluşturulacak küme sayısı önceden belirlenir; bu seçim, veri yapısına veya uygulamanın amacına bağlıdır.
2. Başlangıç Küme Merkezlerinin Belirlenmesi: Rastgele veya belirli bir stratejiye göre k adet başlangıç merkezi (centroid) seçilir. Bu merkezler, veri noktalarının hangi kümeye atanacağını belirleyen referans noktalarıdır.
3. Veri Noktalarının Küme Ataması: Her veri noktası, kendisine en yakın küme merkezine atanır. Benzerlik genellikle Öklidyen mesafe veya diğer uygun metrikler ile ölçülür.
4. Merkezlerin Güncellenmesi: Her kümedeki veri noktalarının ortalaması alınarak yeni merkezler hesaplanır; bu merkezler artık kümenin temsilcisi hâline gelir.
5. İteratif Güncelleme: Veri noktalarının kümelere atanması ve merkezlerin güncellenmesi adımları, merkezler stabilize olana veya belirlenen iterasyon sayısına ulaşılan kadar tekrarlanır.

Bu süreç sonunda veri noktaları, özelliklerine göre kümelenmiş olur; yani birbirine benzer noktalar aynı kümede, birbirinden farklı noktalar farklı kümelere toplanır. K-Means algoritması, özellikle yoğun veya karmaşık veri setlerinde veri dağılımını anlamak, örüntüleri tespit etmek ve analizleri kolaylaştırmak için etkili bir yöntemdir.


Nesne tespiti bağlamında ise K-Means, YOLOv7 gibi derin öğrenme modellerinde tahmini sınır kutularının oluşturulması ve optimize edilmesinde kullanılabilir. Tahmini kutular, başlangıçta çok sayıda ve düzensiz şekilde üretilir; K-Means algoritması, bu kutuları konumsal ve boyut özelliklerine göre kümelendirerek daha homojen ve dengeli bir dağılım sağlar. Böylece, post-processing aşamasındaki Non-Maximum Suppression (NMS) sürecinde, her küme içerisinde en uygun ve temsilci kutuların seçilmesi mümkün olur. Bu yaklaşım, tahmini kutular arasında doğru seçim yapılmasını sağlar ve işlem süresini optimize ederek modelin doğruluk ve verimliliğini artırır.

4.2. Komşuluk İlişki Algoritması

Tez kapsamında önerilen Komşuluk İlişki Algoritması, nesne tespitinde kullanılan tahmini sınırlayıcı kutularının seçiminde ve tespit edilen nesnelerin bölgesel segmentasyonu için önerilen yeni bir yaklaşımdır. Algoritma, yalnızca modelin tahmin ettiği kutulara bağlı kalmayıp; X-Işını görüntüleri üzerinde uygulanan ön işleme aşamalarından elde edilen görüntüleri veri girişi olarak kullanır. Bu görüntüler üzerinde K-Means kümeleme yöntemi ile gruplanarak “ön-aday sınırlayıcı kutular” oluşturulur. Bu ön-aday kutular daha sonra NMS sürecini yönlendiren referans bölgeler olarak kullanılır; böylece NMS’te yalnızca IoU skoruna bağlı kutu eleme değil, aynı zamanda bölgesel komşuluk yoğunluklarına dayalı bir kutu seçme stratejisi uygulanır. Bu yaklaşım, aynı bölgede yoğunlaşmış tahmini kutuların daha tutarlı biçimde gruplanmasını, gerçek nesne bölgelerinin korunmasını ve tespit edilen bölge içinde daha doğru segmentasyon bölgesi tanımlanmasını sağlar. Komşuluk İlişki Algoritması ile gerçekleştirilen segmentasyon işlemi, YOLOv7’nin ürettiği sınırlayıcı kutu tahminlerini doğrudan kullanarak bölge-bazlı ayrıştırma yapılmasını mümkün kılan yeni bir kullanım yöntemidir. Bu yaklaşımda, herhangi bir ek segmentasyon ağına veya mask üretim modeline ihtiyaç duyulmadan; yalnızca YOLOv7’nin sınırlayıcı kutu çıktılarından ve bu kutuların birbirleriyle olan komşuluk ilişkilerinden yararlanılarak ilgili bölgenin sınırları belirlenmekte ve nesnenin bulunduğu alana karşılık gelen bölgesel ayırım mantıksal olarak tanımlanmaktadır. Böylece sınırlayıcı kutu tabanlı tahminler, sadece sınırlayıcı kutu seçimine değil aynı zamanda nesneyi temsil eden anlamlı bölgenin çıkarımına da katkı sağlamaktadır.

Komşuluk ilişki algoritması süreci, öncelikle giriş görüntülerini 2 boyutlu (2D) matrisler hâline dönüştürmekle başlar. Bu matrislerde her bir eleman, ilgili pikselin yoğunluk değerini temsil eder; böylece görüntüdeki her nokta sayısal bir değerle ifade edilmiş olur. Bu adım, ham görüntü verilerinin sayısal olarak işlenmesini mümkün kılar ve algoritmanın sonraki aşamalarında uygulanacak olan kümeleme, komşuluk taraması ve sınır tespiti gibi işlemler için temel veri yapısını sağlar.

Matris elde edildikten sonra algoritma, görüntüdeki pikselleri benzer yoğunluk değerlerine sahip kümelerle ayırmak amacıyla K-Means algoritmasını uygular. Bu çalışmada, K-Means yöntemi 5 küme ($K=9$) kullanılarak uygulanmıştır. Bu işlem sırasında, matrisin her bir elemanı belirlenen beş kümeden birine atanır ve her piksel, ait olduğu kümenin etiketini alır (Şekil 4.1.). $K=9$ seçimi, görüntüdeki farklı yoğunluk bölgelerini yeterli hassasiyetle ayırtmak ve hem önemli nesne bölgelerini hem de arka plan farklılıklarını temsil etmek amacıyla yapılmıştır. Kümeleme süreci, piksellerin yoğunluk değerlerine göre gruplandırılmasını sağlayarak, görüntüdeki yapısal ve yoğunluk temelli bilgilerin düzenli bir biçimde temsil edilmesine imkân tanır. Ayrıca, bu kümeler ilerleyen aşamalarda komşuluk ilişkilerinin belirlenmesi ve tahmini sınırlayıcı kutuların oluşturulmasında referans noktası olarak kullanılır.



Şekil 4.1. 2D X-Işını görüntüsünün matris formuna dönüştürülmesi.

Matris oluşturulduktan sonra K-Means kümeleme işlemi sonucunda her piksele atanmış olan küme etiketlerini içeren 2 boyutlu matrisin her bir elemanı için sistematik bir tarama işlemi yapılır. Tarama işlemi, matrisin sol-üst köşesinden başlamakta ve tüm hücreler sırasıyla ziyaret edilmektedir. Her piksel merkezi referans noktası olarak kabul edilir ve bu referans piksel için 8 yönlü (Şekil 4.2.(a)) komşuluk yaklaşımı uygulanır. Bu kapsamda, merkez pikselin üst, alt, sağ, sol ve çapraz yönlerde bulunan toplam sekiz komşu pikseli kontrol edilir.


Komşu piksellerden herhangi birinin küme etiketi, merkez pikselin küme değeri ile eşleşiyorsa, her iki pikselin koordinat bilgisi komşuluk ilişkilerini tutan tensör verisinde saklanır. Böylece, yalnızca aynı kümeden gelen pikseller bir araya getirilmekle kalmaz, aynı zamanda bu kümelerin uzamsal sürekliliği de korunmuş olur. Bu süreçte amaç, sadece yoğunluk benzerliğini temel alan küme etiketleri değil, aynı zamanda gerçekte piksel bazında birbirine temas eden veya birbirine yakın konumlanan yapıların belirlenmesidir. Bu nedenle algoritma, bağlantısallığı değerlendirirken yalnızca değer benzerliğine değil, pozisyon ilişkisine de dikkat eder.

Tarama esnasında tekrar işlem yapılmasını engellemek için kontrolü tamamlanan piksellerin matris değerleri -1 olarak güncellenir. Bu mekanizma hem gereksiz döngülerin oluşmasını engeller hem de algoritmanın zaman karmaşıklığını düşürür; çünkü aynı piksel ilerleyen tarama adımlarında tekrar işlenmez. Bu yaklaşım ile her küme, kendi içerisinde yalnızca bir kez işlenir ve olası çakışmalar ortadan kaldırılır.

Tüm piksellerin taranmasının ardından, her küme için oluşturulmuş olan tensör yapısı dolmuş olur. Bu tensör içinde, kümeye ait tüm piksel koordinatları homojen, düzenli ve tekrar içermeyen bir biçimde depolanır. Bu tensör yapısı, bir sonraki aşamada her küme yapısının geometrik sınırlarının (minimum x, maksimum x, minimum y, maksimum y) belirlenmesinde doğrudan kullanılır. Böylece komşuluk ilişkisi algoritması hem segmentasyon hem de sınırlayıcı kutu tahmininin ilk temel veri kaynağını oluşturan uzamsal olarak organize edilmiş bir yoğunluk temelli koordinat kümesi üretmiş olur.

Kümeler ve komşuluk ilişkileri tensör yapısında kayıt altına alındıktan sonra, algoritmanın bir sonraki aşaması her küme için uzamsal sınırların belirlenmesidir. Bu kapsamda, tensörde yer alan her bir küme elemanına ait piksel koordinatları ayrı ayrı analiz edilerek, ilgili kümenin minimum ve maksimum x ve y koordinatları hesaplanır. Bu minimum ve maksimum değerleri, kümenin görüntü düzlemindeki en uç noktalarını ifade ettiği için, doğrudan tahmini sınırlayıcı kutuların geometrik sınırlarını oluşturmada temel parametre olarak kullanılmaktadır. Böylece her küme için, kümenin gerçek uzamsal yayılımını temsil eden dikdörtgensel bir sınır kutusu oluşturulmuş olur. Bu yaklaşım, hem nesnenin segmentasyon bazlı uzamsal kapsama alanını tanımlamakta hem de sonraki tespit ve analiz adımlarının standart bir kutu yapısı üzerinden yürütülebilmesini sağlamaktadır.

Bununla birlikte, X-Işını tabanlı görüntüleme sistemlerinde ortam gürültüsü, düşük yoğunluk bölgeleri veya sensöre bağlı parazit piksel kümeleri, gerçek nesnenin temsil edilmediği küçük kümelerin oluşmasına yol açabilmektedir. Bu tür kümeler, sınır kutusu oluşturma aşamasında hatalı kutuların üretilebilmesine zemin hazırlayacağı için çalışmada belirli bir eşik değeri (threshold) tanımlanmıştır. Bu eşik kontrolü tensör oluşturma aşamasında uygulanmakta olup, belirlenen piksel sayısının altında kalan küçük kümelere ait koordinatlar tensöre işlenmemekte ve süreçten tamamen elimine edilmektedir. Komşuluk ilişki algoritmasının tüm adımları, algoritma akışı olarak Algoritma 2’de sunulmuştur. Böylece sınırlayıcı kutu üretim süreci, başlangıçtan itibaren yalnızca anlamlı, nesne potansiyeli taşıyan kümelere uygulanır. Bu yaklaşım sistemin hem hesaplama verimliliğini yükseltmekte hem de sınır kutusu tahminlerinin nesnesel doğruluğunu artırmaktadır.



Şekil 4.2. Komşuluk ilişki algoritması adımları. (a) Komşuluk ilişki algoritması yönleri, (b) kümelenmiş X-Işını fındık matris formu görüntüsü, (c) kontrol matrisi uygulanmış görüntü, (d) komşuluk ilişki algoritması tensör yapısı.


Şekil 4.2. Komşuluk ilişki algoritması adımlarında komşuluk ilişki algoritmasının temel iş akış adımları örnek bir X-Işını fındık görüntüsü üzerinde gösterilmektedir. İlk görsel (Şekil 4.2.(a)) bir pikselin komşuluk kontrol yönlerini ifade etmektedir; merkezdeki piksel referans alınarak, 8 yönlü (üst, alt, sağ, sol ve çapraz yönler) komşuluk ilişki analizi gerçekleştirilir. Bu yönsel komşuluk taraması, piksellerin yalnızca yoğunluk benzerliği ile değil, aynı zamanda uzamsal süreklilik ile de ilişkilendirilmesini mümkün kılmaktadır.

Şekil 4.2. Komşuluk ilişki algoritması adımları(b)’de K-Means yöntemi (K=9) kullanılarak kümelere ayrılmış X-Işını fındık görüntüsünü göstermektedir. Bu aşamada her piksel ait olduğu küme etiketini almış olup, farklı yoğunluk bölgeleri

farklı renklerle temsil edilmiştir. Kümeleme ile elde edilen bu dağılım, komşuluk analizi için referans oluşturmaktadır.

Şekil 4.2. Komşuluk ilişki algoritması adımları(c)'de, komşuluk taramasının uygulanmış hâli gösterilmektedir. Algoritma, her piksel için tüm komşuları kontrol etmekte, aynı küme değerine sahip olan piksellerin koordinatlarını ilgili tensör yapısına eklemektedir. Tekrar taramanın önüne geçebilmek için, kontrol edilen pikseller -1 değeri verilerek işaretlenmiştir. Böylece hem işlem maliyeti azaltılmış hem de her pikselin yalnızca bir kez dikkate alınması sağlanmıştır.

Şekil 4.2. Komşuluk ilişki algoritması adımları(d)'de ise, her küme için oluşturulan komşuluk tensörünün genel yapısını ifade etmektedir. Bu tensör yapısında, aynı küme içerisindeki piksellere ait koordinat değerleri (x_1, y_1, x_2, y_2) şeklinde sıralı biçimde kaydedilir. Bu tensör, sınırlayıcı kutuların oluşturulmasında temel veri kaynağı olarak kullanılmıştır. Bununla birlikte, X-Işını görüntülerinde meydana gelebilecek ortam gürültüsünün sınırlayıcı kutu oluşumuna olumsuz etkilerini en aza indirmek amacıyla, çok küçük kümelerin göz ardı edilmesini sağlayan bir eşik değeri (threshold) tanımlanmıştır. Bu yaklaşım, ortam gürültüsünden kaynaklanan hatalı sınırlayıcı kutuların oluşumunu engelleyerek sistemin görüntüleme performansını hem daha verimli hem de daha güvenilir bir şekilde optimize etmektedir. Son olarak tensör içindeki her küme noktaları sınır değerlerinden hedef sınırlayıcı kutu noktaları oluşturulur (Şekil 4.3.).



Şekil 4.3 Komşuluk ilişki algoritması ile sınırlayıcı kutu oluşumu. (a) X-Işını görseli, (b) ön işleme yapılmış görüntü, (c) eşik değeri kullanmadan oluşan sınırlayıcı kutular, (d) eşik değeri kullanarak oluşan sınırlayıcı kutular.

Önerilen komşuluk ilişki algoritması ile sınır kutularının daha doğru ve verimli bir şekilde belirlenmesine katkı sağlamaktadır.

Algoritma 2. Komşuluk İlişki Algoritması.

Girdi: Ön işleme aşamasından gelen görüntü

Çıktı: Tensör

1. Görüntülerin Tensör Formatına Dönüşümü:
 - Ön işleme ile elde edilen görüntüleri tensör formatında 2 boyutlu (2B) matrislere dönüştür.
2. K-Means Kümeleme İşlemi
 - Piksel değerlerine göre matris üzerinde K-Means yöntemiyle kümeleme işlemini gerçekleştir. (k=9)
 - Her bir piksele ait olduğu küme değerini ata.
3. Komşuluk Kontrolü Başlat
 - Matrisin ilk elemanından başla.
 - Matrisin ilk elemanından başlayarak, elemanın tüm yönlü komşuları (üst, alt, sağ, sol ve çapraz) kontrol et.
 - Her bir komşu eleman için:
 - Aynı kümeye ait olup olmadığını kontrol et.
 - Eğer aynı kümeye aitse, listeye eklenir ve onun komşularını da kontrol et.
 - İşlenen elemanların tekrar kontrol edilmemesi için bir kontrol matrisi oluştur ve kontrol edilen elemanlara bu matriste -1 değerini ata.
 - Aynı kümeye ait piksel koordinatlarını ve küme değerlerini tensör içinde sakla. (Şekil 4.2.(d))
4. Tüm Elemanları İşle
 - Matrisin tüm elemanları kontrol edilene kadar Adım 3'ü tekrarla.
5. Sınırlayıcı kutuları oluştur

Komşuluk ilişki algoritması sonucunda elde edilen tahmin kutuları, YOLO mimarisinde NMS algoritması kapsamında işlenmektedir. NMS algoritması, tahmin edilen sınırlayıcı kutuları öncelikle güven skoru (confidence score) değerlerine göre sıralamakta ve belirlenen eşik değerinin altında kalan kutuları elemektedir. Eşik değerinin üzerinde kalan kutular ile komşuluk ilişkisi algoritmasından elde edilen kutular arasında, önerilen DCIoU yöntemi kullanılarak benzerlik hesaplaması yapılır. Bu hesaplama, kutuların konum ve boyut ilişkilerini dikkate alarak çakışma durumlarını belirlemekte ve IoU eşik değerinin üzerindeki benzeşim gösteren kutular

NMS algoritmasının nihai çıktı kutuları olarak seçilmektedir. Bu işlem, nesne tespitinde sıkça karşılaşılan örtüşen tahmin kutularının sayısını önemli ölçüde azaltmakta ve en uygun sınırlayıcı kutuların seçilmesini sağlamaktadır.

Nihai çıktı kutuları belirlendikten sonra, komşuluk ilişki algoritmasından elde edilen tensör yapısı kullanılarak segmentasyon işlemi gerçekleştirilir. Tensör, her küme içerisindeki piksellerin koordinatlarını düzenli ve tekrar içermeyen bir biçimde içerdiğinden, her nesnenin görüntü düzlemindeki piksel bazlı dağılımını doğru şekilde temsil etmektedir. Bu yapı sayesinde, yalnızca sınırlayıcı kutu ile sınırlı kalmayan, nesnelerin gerçek uzamsal yayılımı ve şekli segmentasyon sonuçlarına yansıtılmaktadır. Komşuluk tensörünün kullanımı, örtüşen veya birbirine yakın nesnelerin ayrımını kolaylaştırmakta ve segmentasyon çıktılarının daha tutarlı, anlamlı ve güvenilir olmasını sağlamaktadır. Böylece model hem konumsal hem de piksel düzeyinde detaylı sonuçlar üretmektedir.

5. DENEYSEL ÇALIŞMALAR VE TARTIŞMA

5.1. DCIoU Simülasyon Testleri


Önerilen DCIoU kayıp fonksiyonunun etkinliği iki aşamalı deneysel yapı ile değerlendirilmiştir. İlk aşamada, literatürde IoU tabanlı kayıp fonksiyonlarının karşılaştırılmasında yaygın olarak kullanılan Zheng vd. [69] ve Su vd. [103] çalışmalarında yer alan sentetik simülasyon testleri temel alınmıştır. Bu aşamanın amacı, farklı kayıp fonksiyonlarının kontrollü koşullar altında yakınsama özelliklerini doğrudan karşılaştırmak ve DCIoU'nun optimizasyon davranışını teorik düzlemde incelemektir. İkinci aşamada ise IoU metriklerinin gerçek veri üzerindeki performansı değerlendirilmiş; bu doğrultuda X-Işını fındık veri seti ile COCO-128 veri seti kullanılarak yürütülen YOLOv7 eğitim sonuçları karşılaştırılmıştır. Böylece hem sentetik hem de gerçek veri ortamlarında DCIoU'nun performans tutarlılığı analiz edilmiştir.

Zheng ve diğerleri [69] tarafından sunulan ilk simülasyon senaryosu temel alınarak, IoU, GIoU, DIoU, CIoU ve önerilen DCIoU kayıp fonksiyonlarının regresyon performansları karşılaştırılmıştır. Bu yapılandırmada, simülasyonun başlangıç koşulları tüm kayıp fonksiyonları için aynı olacak şekilde standartlaştırılmıştır. Hedef kutu, (0.5, 0.5) koordinatında merkezlenmiş, alanı 1/32 olarak belirlenmiş ve 1:4, 1:3, 1:2, 1:1, 2:1, 3:1 ve 4:1 olmak üzere toplam yedi farklı en-boy oranı ile tasarlanmıştır. Bu sayede simülasyon yalnızca konumlandırma hatalarına değil, aynı zamanda oran tutarlılığı problemlerine de duyarlı hâle getirilmiştir.

Karşılaştırılacak sınır kutuları ise aynı merkez etrafında konumlandırılmıştır. (0.5, 0.5) merkezli ve 0.5 birim yarıçaplı dairesel bir bölgede eşit aralıklarla 5.000 sınırlayıcı kutu örneklenmiş, böylece kutuların hem hedefe yakın hem de uzak konumlarda farklı mesafe gradyanları üretmesi sağlanmıştır. Her kutu üzerine 7 farklı ölçek (1/32, 1/24, 3/64, 1/16, 1/12, 3/32 ve 1/8) ve 7 farklı en-boy oranı kombinasyonu uygulanarak toplam 5000 sınırlayıcı kutu yerleştirilmiştir. Bu yapılandırma, farklı ölçek ve en-boy oranı kombinasyonlarının üretebileceği regresyon sapmalarını sistematik olarak kapsamaktadır ve her sınır kutusu hedef kutu ile eşleştirilmiştir. Sonuç olarak, toplam

1.715.000 ($7 \times 7 \times 7 \times 5.000$) bağımsız regresyon örneği elde edilmiştir (Şekil 5.1. (a)).

Simülasyon sırasında optimizasyon Adam algoritması ile gerçekleştirilmiş, öğrenme oranı 0.01 olarak belirlenmiş ve model 120 adım boyunca güncellenmiştir. Elde edilen sonuçlar Şekil 5.1. (b)'de gösterilmektedir. Bulgular, IoU kaybının en yavaş düşüşü sergilediğini ve belirli bir noktadan sonra optimizasyonun duraksadığını göstermektedir. GIoU kaybı, IoU'ya kıyasla daha iyi bir yakınsama eğilimi gösterse de kayıp değerleri hâlâ yüksek seviyelerde seyretmektedir. DIoU ve CIoU kayıpları daha hızlı bir düşüş eğilimi sergileyerek IoU ve GIoU'ya göre daha etkili bir performans ortaya koymuştur. En hızlı yakınsayan fonksiyonun DCIoU olduğu gözlemlenmiş ve diğer yöntemlere kıyasla çok daha erken düşük kayıp değerlerine ulaşmıştır. Bu sonuçlar, özellikle nesne tespiti probleminde sınır kutusu regresyonunun kritik olduğu durumlarda, DCIoU'nun en etkili kayıp fonksiyonu olarak öne çıktığını göstermektedir.




Şekil 5.1. (a) Simülasyon için oluşturulan sınırlayıcı kutu regresyon örnekleri, (b) Sınırlayıcı kutuların IoU, GIoU, DIoU, CIoU ve DCIoU için regresyon sonuçlarının grafiksel gösterimi.

Diğer simülasyon çalışmasında [103], IoU, GIoU, DIoU, CIoU ve önerilen DCIoU kayıp fonksiyonlarının optimizasyon davranışlarını doğrudan karşılaştırmak amacıyla tahmin kutusunun konumu iteratif gradyan inişi (gradient descent) yaklaşımı ile güncellenmiştir. Bu yapılandırmada tahmin kutusu her iterasyonda $B^t = (x^t, y^t, w^t, h^t)$ ile temsil edilmekte, bir önceki iterasyona ait kutu parametreleri $B^{t-1} = (x^{t-1}, y^{t-1}, w^{t-1}, h^{t-1})$ üzerinden ilgili regresyon kaybının gradyanı

∇B^{t-1} hesaplanarak güncelleme adımı uygulanmaktadır. Böylece kutunun hem merkez koordinatları hem de genişlik-yükseklik parametreleri, seçilen kayıp fonksiyonunun eğim bilgisine (slope information) göre eşzamanlı olarak optimize edilmektedir.

Bu deneysel düzenek, IoU tabanlı kayıp fonksiyonlarının yalnızca statik değer karşılaştırması üzerinden değil; dinamik optimizasyon süreci içerisindeki davranışlarının da gözlenebilmesini sağlamaktadır. Özellikle, farklı kayıp fonksiyonlarının benzer başlangıç koşullarında ne kadar hızlı yakınsadığı, hangi yöntemin ters gradyan alanlarında daha düşük osilasyon ürettiği, optimizasyonun hangi noktada kararlı bölgeye geçiş yaptığı ve hangi fonksiyonun optimum bölgede daha stabil seyrettiği gibi metrikler bu simülasyon aracılığıyla belirlenebilmektedir. Bu nedenle bu tasarım, salt performans skoru karşılaştırmasının ötesinde, kayıp fonksiyonlarının öğrenme dinamiklerini, eğim duyarlılıklarını ve iterasyon boyunca davranış kararlılıklarını doğrudan ortaya koyan analitik bir değerlendirme niteliği taşımaktadır.

Simülasyon toplam 200 iterasyon boyunca gerçekleştirilmiş ve her fonksiyon aynı başlangıç kutusundan başlatılarak eşit koşullar altında değerlendirilmiştir. Böylece elde edilen yakınsama eğrileri yalnızca fonksiyonun kendi iç formülasyonundan kaynaklanan farkları yansıtmaktadır. Bu tasarım, farklı IoU tabanlı yaklaşımların optimize edilebilirlik derecelerini, yani “hangi kayıp fonksiyonu gerçekten daha iyi öğrenebilir?” sorusunu doğrudan ortaya koymayı amaçlamaktadır.



Şekil 5.2. IoU, GIoU, DIoU, CIoU ve DCIoU için 50, 100, 150 ve 200 iterasyonda kutu optimizasyon davranışları. Mavi kutu gerçek kutuyu, kırmızı kutu tahmin kutusunu yeşil kutu ise örtüşme kutusunu temsil etmektedir.

Şekil 5.2.'de sunulan bulgular, IoU, GIoU, DIoU, CIoU ve DCIoU metriklerinin iterasyon sayısının artmasıyla birlikte tahmin kutularının hedef kutuya kademeli olarak yakınsadığını göstermektedir. Bununla birlikte her yöntemin farklı yakınsama karakteristikleri sergilediği ve 200 iterasyon sonunda DCIoU'nun diğer metriklerle kıyasla daha düşük hata seviyesine ve daha yüksek konumlandırma doğruluğuna ulaşabildiği gözlemlenmiştir. Bu sonuç, DCIoU'nun optimizasyon sürecinde daha etkin yakınsama sağlayabildiğini ve nesne tespiti benzeri sınır kutusu regresyonu içeren uygulamalarda daha güvenilir bir kayıp fonksiyonu olarak değerlendirilebileceğini ortaya koymaktadır.

Bu iki simülasyon değerlendirmesi sonucunda genel olarak elde edilen bulgular, DCIoU yönteminin IoU, GIoU, DIoU ve CIoU yöntemlerine kıyasla kayıp fonksiyonu optimizasyonu açısından daha avantajlı bir davranış sergilediğini ortaya koymaktadır. DCIoU'nun temel üstünlüğü, kutu merkezleri arasındaki konum farklılıklarını

yalnızca bir uzaklık ceza terimi ile değil; ayrıklaştırılmış ve merkez odaklı bir optimizasyon mekanizması üzerinden modellenmesidir. CIoU ve DIoU yöntemleri genişlik ve yükseklik parametrelerini merkez uzaklığı ile birlikte kullanan bir yapı sunmakla birlikte, merkez konum diferansiyelini DCIoU kadar ayrıntılı bir şekilde bağımsızlaştırmamaktadır. DCIoU ise merkez koordinatları arasındaki mesafeyi doğrudan ana optimizasyon eksenine getirerek regresyon uzayında daha hassas bir çözünürlük sağlar. Bu durum özellikle kutuların birbirine yakın konumlandığı, minimal çakışma değerlerine sahip olduğu veya nesnenin çerçeve içerisinde küçük alan kapladığı senaryolarda daha belirgin hale gelmektedir.

Buna ek olarak, DCIoU'nun kutu boyutları ve en-boy oranı değişimlerine olan duyarlılığı CIoU ve DIoU'ya kıyasla daha etkilidir. Bu sayede; regresyon parametrelerinin (w, h) güncellemelerinde oluşan sapma hızla telafi edilmekte, optimizasyon süreci daha istikrarlı bir şekilde düşük hata bölgelerine yönlendirilmektedir. Ayrıca GIoU, kesişim dışı bölgeleri hesaba katma açısından önemli bir katkı sunmasına rağmen, merkez sapması düşük fakat boyut uyumsuzluğunun belirgin olduğu durumlarda yeterli ayrıştırma gücüne sahip değildir. DCIoU ise hem merkez pozisyonu hem kutu boyutu hem de oran optimizasyonunu aynı anda daha sıkı biçimde kontrol eden bir yapıda çalıştığı için, GIoU'nun bu sınırlı düzeltme etkisini aşabilmektedir.

Tüm bu değerlendirmeler ışığında, DCIoU'nun kayıp fonksiyonu uzayında daha hızlı yakınsama, daha düşük regresyon sapması ve daha yüksek konumlandırma doğruluğu sağladığı görülmektedir. Dolayısıyla, DCIoU yöntemi hem eğitim sürecinin optimizasyon stabilitesi hem de nihai nesne kutusu hizalama performansı açısından IoU tabanlı diğer kayıp fonksiyonlarına göre daha üstün bir davranış sergilemektedir.

5.2. DCIoU Performans Testi

DCIoU'nun simülasyon temelli analizlerle hizalama duyarlılığı ve kayıp fonksiyonu optimizasyonundaki üstünlüğü teorik düzlemde gösterilmiş ve daha başarılı olduğu gözlemlenmiştir. Bununla birlikte, önerilen yaklaşımın yalnızca simülasyon ortamında değil, gerçek dünya koşullarında da etkisini sürdürebildiğinin doğrulanması da oldukça önemlidir. Bu nedenle, bu bölümde geliştirilen fındık kalite belirleme sisteminin gerçek görüntüler üzerinde kusurlu fındıkları tespit etme başarısı değerlendirilmiş ve yöntemin farklı veri setlerinde de tutarlı performans sergileyip

sergilemediği incelenmiştir. Bu kapsamda, X-Işını fındık veri seti uygulama veri seti olarak sistemde doğrudan kullanılmış; COCO-128 veri seti ise genel amaçlı ve farklı nesne kompozisyonları içeren harici bir veri seti olarak seçilmiştir. Böylece, DCIoU'nun yalnızca fındık kusur tespitindeki özgül başarısı değil, aynı zamanda farklı veri dağılımlarında da genelleme yeteneğini koruyabildiği deneysel olarak ortaya konmuştur.

Bu çalışma, GPU hızlandırmalı hesaplamaları destekleyen bir bilgisayar sistemi üzerinde gerçekleştirilmiştir. Kullanılan donanım bileşenleri; 32 GB DDR5 RAM, Intel Core i7-13700HX işlemci ve 12 GB bellek kapasitesine sahip NVIDIA GeForce RTX 4070 grafik işlem biriminden oluşmaktadır. Grafik işlem biriminin sunduğu paralel hesaplama yetenekleri, derin öğrenme tabanlı modellerin eğitimi sırasında yoğun hesaplama gerektiren işlemlerin etkin ve hızlı bir şekilde gerçekleştirilmesine olanak sağlamıştır.

Yazılım tarafında, CUDA 12.1 desteği ile derlenmiş PyTorch 2.5.1 sürümü kullanılmış olup, nesne tespit işlemleri YOLOv7 mimarisi temel alınarak gerçekleştirilmiştir. Bu donanım ve yazılım yapılandırması, modelin eğitimi sürecinde hesaplama verimliliğini artırmış ve daha kararlı bir öğrenme sürecinin elde edilmesine katkı sağlamıştır. GPU tabanlı donanım altyapısı, modelin hem eğitim hem de çıkarım süreleri üzerinde doğrudan etkili olmuştur. NVIDIA GeForce RTX 4070 grafik işlem birimi, YOLOv7 mimarisinde yer alan evrimsel katmanların paralel olarak hesaplanmasına olanak tanıyarak, eğitim süresinin CPU tabanlı sistemlere kıyasla önemli ölçüde azalmasını sağlamıştır. Ayrıca 12 GB GPU belleği, eğitim sırasında daha dengeli batch size değerlerinin kullanılmasına imkân vererek modelin daha stabil bir şekilde yakınsamasına katkı sunmuştur.

YOLOv7, tek aşamalı nesne tespit mimarileri arasında yer alan ve gerçek zamanlı uygulamalar için yüksek doğruluk ve hız sunmayı hedefleyen derin öğrenme tabanlı bir modeldir. Bu çalışmada, YOLOv7'nin omurga yapısında E-ELAN mimarisi kullanılmıştır. E-ELAN, ağ derinliği boyunca bilgi akışını etkin biçimde düzenleyerek farklı katmanlarda öğrenilen özniteliklerin daha verimli bir şekilde birleştirilmesini sağlamaktadır. Bu yapı, gradyan yayılımını dengeli hale getirerek eğitim sürecinin kararlılığını artırmakta ve modelin temsil gücünü yükseltmektedir. Ayrıca, çok ölçekli nesnelerin daha başarılı bir şekilde algılanabilmesi amacıyla, YOLOv7 mimarisinde

yeniden tasarlanmış özellik birleştirme ve yol toplama yapıları kullanılarak farklı çözünürlüklerdeki öznetelik haritaları etkili biçimde bütünleştirilmiştir.


Tablo 5.1. YOLOv7 eğitiminde kullanılan hiperparametreler.

Parametre	Değer
Giriş Görüntü Boyutu	640 × 640
Batch Size	32
Başlangıç Öğrenme Oranı (Learning Rate)	0.01
Momentum	0.937
Weight Decay	0.0005
Kayıp Fonksiyonu (BBox Regresyonu)	IoU, GIoU, DIoU, CIoU ve DCIoU

Model eğitimi sırasında kullanılan temel hiper-parametreler Tablo 5.1’de verilmiştir. Giriş görüntü boyutu 640×640 olarak belirlenmiş ve batch size (her bir eğitim adımında modele aynı anda sunulan örnek sayısı) değeri 32 olarak kullanılmıştır. Eğitim sürecinde başlangıç öğrenme oranı (learning rate) 0.01, momentum (önceki gradyan bilgisini kullanarak öğrenme sürecini hızlandıran katsayı) değeri 0.937 ve weight decay (aşırı öğrenmeyi azaltmaya yönelik ağırlık cezalandırma katsayısı) değeri 0.0005 olarak ayarlanmıştır. Bu parametreler, modelin eğitim sürecinde kararlı bir şekilde yakınsamasını sağlamış ve hesaplama verimliliği ile algılama doğruluğu arasında dengeli bir performans elde edilmesine katkı sunmuştur. Sınırlayıcı kutu regresyonu aşamasında, IoU tabanlı kayıp fonksiyonları (IoU, GIoU, DIoU, CIoU ve önerilen DCIoU) kullanılarak tahmin edilen kutular ile gerçek kutular arasındaki geometrik örtüşme doğrudan optimize edilmiştir.

X-Işını fındık veri seti ile COCO-128 veri seti, YOLOv7’nin güncel sürümü PyTorch kullanılarak eğitilmiştir. X-ışını fındık veri setindeki görüntülerin %80’i eğitim, %20’si test aşamasında kullanılmıştır. Fındık kusur tespiti uygulaması kapsamında model 150 iterasyon boyunca eğitilmiştir. Buna ek olarak, daha geniş kapsamlı nesne tespiti performansını değerlendirmek amacıyla COCO-128 veri seti kullanılmış ve bu

veri seti üzerinde model 200 iterasyon süresince eğitilmiştir. Eğitim sürecinde erken durdurma (early stopping) mekanizması uygulanmamış olup, eğitim boyunca yakınsamanın istikrarlı bir şekilde sürdüğü ve önceden belirlenen iterasyon sayısının tamamının etkin biçimde kullanıldığı gözlemlenmiştir. Bu süreçte hem sınıflandırma hem de nesne konumlandırma (bounding box regression) kayıpları, YOLOv7’de IoU tabanlı kayıp fonksiyonlarıyla birlikte kullanılmış ve önerilen DCIoU fonksiyonu regresyon bileşenine entegre edilerek optimizasyonun etkinliği artırılmıştır.



Şekil 5.3. X-Işını Fındık Görüntülerinde IoU, GIoU, DIoU, CIoU ve DCIoU kayıp fonksiyonları için elde edilen karmaşıklık (confusion) matrisleri

Şekil 5.3.’de X-ışını fındık görüntüleri üzerinde gerçekleştirilen eğitim sürecinde IoU, GIoU, DIoU, CIoU ve DCIoU kayıp fonksiyonları kullanılarak elde edilen karmaşıklık (confusion) matrisleri gösterilmiştir. Tüm IoU tabanlı kayıp fonksiyonları için elde edilen karmaşıklık matrisleri incelendiğinde, diyagonal elemanların baskın olması YOLOv7 modelinin Kusurlu, Az Kusurlu ve Kusursuz sınıflarını genel olarak yüksek

doğrulukla ayırt edebildiğini göstermektedir. Bununla birlikte, kullanılan kayıp fonksiyonuna bağlı olarak sınıflar arasındaki karışma oranlarında belirgin bazı farklılıklar gözlenmiştir. Yalnızca örtüşme oranını temel alan IoU kayıp fonksiyonunda, özellikle Kusurlu ve Az Kusurlu sınıfları arasında daha yüksek bir karşılık meydana gelmiştir. Bu durum, IoU'nun sınırlayıcı kutular arasındaki konumsal mesafe ve geometrik farklılıkları doğrudan dikkate almamasından kaynaklanmaktadır. GIoU kayıp fonksiyonunun kullanılmasıyla birlikte, kapsayıcı alan bilgisinin optimizasyona dahil edilmesi sayesinde sınıflandırma performansında kısmi bir iyileşme sağlanmış ve özellikle Az Kusurlu sınıfına ait doğru tahmin oranlarında artış gözlemlenmiştir. DIoU kayıp fonksiyonunda merkez noktaları arasındaki uzaklığın hesaba katılması, nesnelerin konumsal olarak daha hassas biçimde yerleştirilmesine olanak tanımış, Kusurlu ve Az Kusurlu sınıfları arasındaki karışmayı belirgin ölçüde azaltmıştır. CIoU ile birlikte en-boy oranı tutarlılığının da kayıp fonksiyonuna dahil edilmesi, sınırlayıcı kutuların geometrik uyumunu daha da güçlendirmiş ve sınıflar arası ayrımın daha net hale gelmesini sağlamıştır. DCIoU kayıp fonksiyonu ise örtüşme oranı, merkez uzaklığı ve geometrik uyum bileşenlerini daha etkin biçimde optimize ederek, tüm sınıflar için en yüksek ve en dengeli diyagonal değerlere sahip karmaşıklık matrislerini üretmiştir. Bu sonuçlar, özellikle görsel olarak birbirine yakın özellikler sergileyen Kusurlu ve Az Kusurlu sınıflarının ayrımında DCIoU'nun daha tutarlı ve güvenilir bir performans sunduğunu ortaya koymaktadır. Genel olarak elde edilen bulgular, DCIoU kayıp fonksiyonunun YOLOv7 tabanlı nesne tespit sisteminde sınıflar arası karışmayı en aza indirerek algılama doğruluğunu artırmada daha etkili bir yaklaşım olduğunu göstermektedir.

Modelin performans değerlendirmesinde beş temel metrik kullanılmıştır: Kesinlik, duyarlılık, $mAP@50$, $mAP@0.5:0.95$ ve F-1 skoru. Bu metrikler, modelin nesne tespiti doğruluğunu, duyarlılığını ve genel tahmin başarımını kapsamlı bir şekilde değerlendirmek amacıyla tercih edilmiştir.

Kesinlik ((5.1), modelin tespit ettiği nesneler arasında doğru sınıflandırılanların oranını gösterir. Burada doğru pozitif, model tarafından doğru tespit edilen nesneleri, yanlış pozitif ise model tarafından hatalı tespit edilen nesneleri ifade etmektedir. Yüksek kesinlik değeri, modelin yanlış pozitif üretme oranının düşük olduğunu göstermektedir.

Duyarlılık ((5.2), veri setindeki gerçek nesneler arasında doğru şekilde tespit edilenlerin oranını ifade eder. Bu bağlamda yanlış negatif (False Negative, FN), modelin tespit edemediği gerçek nesneleri göstermektedir. Yüksek duyarlılık değeri, modelin nesneleri kaçırmadan doğru şekilde algıladığını ifade eder.

mAP@50 ((5.3), tüm sınıflar için IoU eşik değeri 0.5 kabul edilerek hesaplanan ortalama kesinlik değeridir ve nesne tespit doğruluğunun genel bir özetini sunar.

mAP@50:95 ((5.4) ise farklı IoU eşik değerleri (0.5'ten 0.95'e kadar, 0.05 adımlarla) kullanılarak hesaplanan ortalama mAP değeridir ve modelin hem sıkı hem de gevşek eşik koşullarında genel performansını göstermektedir.

F1-skoru (denklem 5.5), kesinlik ve duyarlılık metriklerinin harmonik ortalamasını ifade eden birleşik bir performans ölçütüdür. Bu metrik, modelin hem yanlış pozitifleri minimize etme hem de gerçek nesneleri kaçırmadan tespit edebilme yeteneğini aynı anda değerlendirmeyi amaçlar. Kesinlik ve duyarlılık değerleri arasında bir denge kurulmasını sağladığı için, özellikle sınıf dağılımının dengesiz olduğu veri setlerinde model performansının daha güvenilir bir göstergesi olarak kabul edilmektedir.

Denklemlerde (denklem (5.1, (5.2, (5.3, (5.4, denklem 5.5), TP (True Positive) doğru pozitifleri, TN (True Negative) doğru negatifleri, FP (False Positive) yanlış pozitifleri ve FN (False Negative) yanlış negatifleri ifade etmektedir. Ayrıca AP_i ifadesi, i sınıfı için belirli bir IoU eşik değerinde hesaplanan Average Precision (ortalama kesinlik) değerini göstermektedir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (5.1)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (5.2)$$

$$\text{mAP50} = \frac{1}{N} \sum_{i=1}^N AP_i^{\text{IoU} \geq 0.50} \quad (5.3)$$

$$\text{mAP50: 95} = \frac{1}{N} \sum_{i=1}^N \frac{1}{10} AP_i^{0.5 \leq \text{IoU} \leq 0.95} \quad (5.4)$$

$$F - 1 \text{ Score} = 2 \times \frac{\text{Precision} + \text{Recall}}{\text{Precision} \times \text{Recall}} \quad (5.5)$$

Bu metrikler birlikte kullanılarak, önerilen DCIoU tabanlı fındık kalite belirleme sistemi ve COCO-128 veri seti üzerindeki YOLOv7 modelinin nesne tespit ve konumlandırma doğruluğu hem sınıf bazlı hem de genel tespit performansı açısından kapsamlı bir şekilde değerlendirilmiştir.

Tablo 5.2. X-Işını Fındık ve COCO- 128 verisetlerinin IoU, GIoU, DIoU ve DCIoU kullanarak performans değerlendirme tablosu.

Veri Seti	Metrik	Kesinlik	Duyarlılık	mAP@50	mAP@50: 95	F-1 Skoru
X-Işını Fındık Veriseti	IoU	0.8872	0.8746	0.9175	0.7815	0.8885
	GIoU	0.9135	0.8765	0.9213	0.7886	0.9091
	DIoU	0.9248	0.8965	0.9253	0.7893	0.9199
	CIoU	0.9316	0.9190	0.9268	0.7904	0.9279
	DCIoU	0.9448	0.9360	0.9373	0.7901	0.9425
COCO-128 Veriseti	IoU	0.8924	0.8694	0.9428	0.7551	0.8808
	GIoU	0.8988	0.8714	0.9475	0.7576	0.8849
	DIoU	0.9213	0.9025	0.9512	0.7610	0.9062
	CIoU	0.9240	0.9080	0.9573	0.7742	0.9104
	DCIoU	0.9348	0.9216	0.9632	0.7860	0.9274

Tablo 5.2’de YOLOv7 mimarisi kullanılarak gerçekleştirilen eğitimlerin sonuçlarını, hem X-Işını fındık veri seti hem de COCO-128 veri seti üzerinde göstermektedir. Bu sonuçlar, modelin kesinlik, duyarlılık, mAP@50, mAP@50:95 ve F-1 skoru metrikleri üzerinden kapsamlı bir performans değerlendirmesi sunmaktadır. Elde edilen bulgular,

önerilen DCIoU kayıp fonksiyonunun her iki veri setinde de diğer IoU tabanlı yöntemlere göre belirgin bir üstünlük sağladığını ortaya koymaktadır.

X-Işını fındık veri seti üzerinde gerçekleştirilen eğitimlerde, DCIoU yöntemi 0.9448 kesinlik, 0.9360 duyarlılık, 0.9373 mAP@50 ve 0.9425 F-1 skoru değerleri ile en yüksek doğruluk oranlarını sağlamış, ayrıca 0.7901 mAP@50:95 değeri ile farklı IoU eşiklerinde de istikrarlı ve rekabetçi bir performans göstermiştir. Bu bulgular, DCIoU'nun özellikle fındık kusur tespitinde nesnelerin merkez ve boyut optimizasyonunu daha hassas bir şekilde gerçekleştirdiğini ve modelin yanlış pozitif ve yanlış negatif oranlarını etkili biçimde minimize ettiğini göstermektedir. Yüksek kesinlik değeri, modelin hatalı sınıflandırmaları düşük seviyede tuttuğunu, yüksek duyarlılık ise gerçek kusurlu fındıkları kaçırmadan başarılı bir şekilde tespit ettiğini doğrulamaktadır.

COCO-128 veri seti üzerinde yapılan eğitimlerde ise DCIoU, 0.9348 kesinlik, 0.9216 duyarlılık, 0.9632 mAP@50, 0.7860 mAP@50:95 ve 0.9274 F-1 skoru değerleri ile tüm metrikler arasında en yüksek performansı elde etmiştir. Bu sonuçlar, DCIoU'nun yalnızca belirli bir uygulama veya veri setine özgü olmadığını, farklı nesne türleri ve dağılımlarına sahip veri setlerinde de tutarlı ve güvenilir bir optimizasyon sağladığını göstermektedir. Özellikle mAP@50:95 değerindeki yüksek performans, modelin farklı IoU eşiklerinde de güçlü bir konumlandırma hassasiyetine sahip olduğunu ortaya koymaktadır.

Genel olarak, hem X-Işını fındık hem de COCO-128 veri setlerinde elde edilen sonuçlar, DCIoU'nun nesne tespiti sürecinde kesinlik, duyarlılık ve mAP gibi kritik performans göstergelerinde diğer IoU tabanlı metriklerle kıyasla üstünlük sağladığını açıkça ortaya koymaktadır. Bu bulgular, DCIoU'nun kutu hizalama hassasiyeti, regresyon kaybı optimizasyonu ve genel model doğruluğu açısından daha verimli ve güvenilir bir yaklaşım olduğunu desteklemektedir. Ayrıca, DCIoU'nun farklı veri dağılımlarında da genelleme kapasitesini koruyarak, hem özel (fındık kusuru tespiti) hem de genel amaçlı nesne tespiti uygulamalarında başarılı bir performans sunduğu deneysel olarak da doğrulanmıştır.

Özellikle önerilen fındık kalite belirleme sisteminde, DCIoU'nun sağladığı hassas kutu hizalama ve hızlı yakınsama özellikleri, kusurlu fındıkların daha doğru ve güvenilir bir şekilde tespit edilmesini sağlamaktadır. Bu da sistemin kalite

değerlendirme doğruluğunu artırmakta ve hatalı sınıflandırmaların (FP/FN) azalmasına katkıda bulunmaktadır. Sonuç olarak, DCIoU tabanlı yaklaşım, önerilen fındık kalite belirleme sisteminde yalnızca tespit doğruluğunu yükseltmekle kalmayıp, sistemin genel verimliliğini ve güvenilirliğini de artırarak, üretim süreçlerinde daha etkili ve tutarlı bir kalite kontrol mekanizması sunmaktadır.

5.3. Komşuluk İlişkisi Algoritması Testi


Komşuluk İlişkisi Algoritması, modelin tahmin performansını optimize etmek amacıyla uygulanmıştır. Algoritma, özellikle X-Işını görüntülerinden elde edilen verilerde, fındık çekirdeklerinin veya kusurlu bölgelerin doğru biçimde sınırlandırılmasını sağlayarak sınırlayıcı kutuların konumsal tutarlılığını ve doğruluğunu güçlendirmektedir. Bu kapsamda, model tarafından üretilen tahmini sınırlayıcı kutular arasından en uygun olanların seçimi, piksel düzeyinde tanımlanan komşuluk ilişkileri temelinde gerçekleştirilmektedir. Her bir pikselin komşuluk bağlantıları ve ait olduğu küme bilgileri, tensör yapısı içerisinde organize edilerek aynı nesneye ait piksellerin uzamsal sürekliliğini koruyacak biçimde işlenmektedir. Böylece oluşturulan tensör yapısı, yalnızca sınırlayıcı kutuların geometrik bütünlüğünü sağlamakla kalmayıp, aynı zamanda modelin gürültü kaynaklı veya örtüşen tahminleri daha etkin biçimde ayırt etmesine olanak tanımaktadır.

Bu süreç, modelin yalnızca yüksek IoU skorlarına sahip kutuları değerlendirmesini değil, aynı zamanda yoğunluk benzerliği ve uzamsal ilişki tutarlılığı yüksek olan kutuların da öncelikli olarak seçilmesini mümkün kılar. Böylece, tahminlerin doğruluk ve güvenilirlik bakımından dengelenmesi sağlanır. Komşuluk ilişki algoritması, modelin hatalı veya gereksiz kutuları (gürültü kaynaklı veya kısmi örtüşme içeren kutular) filtrelemesine yardımcı olurken, gerçek nesne bölgelerini temsil eden kutuların öne çıkarılmasına katkı sağlamaktadır.

Ayrıca, algoritmanın çıktısı olarak elde edilen tensör yapısı segmentasyon sürecinde doğrudan kullanılmakta ve hedef sınırlayıcı kutu içerisinde piksel düzeyinde bölütleme işleminin etkin biçimde yürütülmesine olanak tanımaktadır. Bu yapı sayesinde model, yalnızca nesne tespiti açısından değil, aynı zamanda tespit edilen nesne bölgelerinin iç yapısının ayrıştırılmasında da daha yüksek bir başarımla sergilemektedir. Dolayısıyla Komşuluk İlişkisi Algoritması, segmentasyon

performansı bakımından sistemin bütünsel doğruluğunu artıran tamamlayıcı bir bileşen olarak deneysel süreçte önemli bir rol üstlenmektedir.





Şekil 5.4. Farklı örnekler için fındık kusur gösterimi. (a) YOLOv7 ile kusur tespiti, (b) DCIoU ve Komşuluk ilişkisi algoritması ile kusur tespiti, (c) DCIoU ve Komşuluk ilişkisi algoritması ile kusur segmentasyonu.

Fındık görüntülerinde kusurlu, az kusurlu ve kusursuz sınıflandırma işlemleri, X-Işını veri seti kullanılarak YOLO v7 modeli ile gerçekleştirilmiş olup hem nesne tanıma hem de segmentasyon süreçleri uygulanmıştır. Bu çalışmada, farklı yöntemlerin etkinliği Şekil 5.4.'te karşılaştırmalı olarak sunulmaktadır. Şekil 5.4.(a), yalnızca YOLO v7 modelinin kullanıldığı temel kusur tespit yaklaşımını; Şekil 5.4.(b), geliştirilmiş DCIoU ve Komşuluk İlişkisi Algoritması ile iyileştirilmiş kusur tespitini; Şekil 5.4.(c) ise bu iki yönteme ek olarak segmentasyon işleminin uygulandığı aşamayı göstermektedir.

Şekil 5.4.(a) sütununda, YOLO v7 modeli tek başına kullanıldığında, model bazı kusurları tespit edebilmekle birlikte özellikle küçük veya kısmi kusurlarda sınırların doğru belirlenemediği gözlemlenmiştir. Bu durum, YOLO v7'nin temel olarak nesne tanıma odaklı çalışmasından kaynaklanmakta olup, sınır doğruluğunun sınırlı kalmasına neden olmaktadır. Söz konusu yaklaşım, kusur tespiti açısından temel bir referans oluşturmasına rağmen, segmentasyon ve uzamsal ilişki analizine dayalı hassas ölçümler açısından yetersiz kalmaktadır.

Şekil 5.4.(b) sütununda, DCIoU ve Komşuluk İlişkisi Algoritması'nın entegrasyonu ile modelin kusur tespit doğruluğunun belirgin şekilde artırıldığı görülmektedir. Bu yaklaşım, yalnızca nesne varlığını tespit etmekle kalmayıp, aynı zamanda kusur bölgelerinin boyut ve konum bilgilerini daha hassas biçimde belirlemektedir. Özellikle küçük ve örtüşen kusurların ayrıştırılmasında klasik YOLO v7'ye göre daha yüksek doğruluk oranları sağlanmakta ve yanlış pozitif veya eksik tespitlerin sayısı azaltılmaktadır. Bu durum, modelin uzamsal sürekliliği ve piksel bazlı doğruluğu koruma kapasitesinin artırılması ile doğrudan ilişkilidir.

Şekil 5.4.(c) sütununda ise, önerilen algoritmanın segmentasyon ile desteklenmiş hali gösterilmektedir. Segmentasyon süreci, kusurlu bölgelerin yalnızca varlığını değil, aynı zamanda boyutu, şekli ve kesin konumunu da detaylı biçimde ortaya koymaktadır. Bu sayede, kalite kontrol açısından kritik öneme sahip kusur tespiti daha güvenilir ve tekrarlanabilir bir hâle gelmektedir. Görsellerde yer alan tahmin değerleri, DCIoU ve Komşuluk İlişkisi Algoritması ile segmentasyon destekli yöntemin, YOLO v7'ye kıyasla hem doğruluk hem de hassasiyet açısından üstün performans sergilediğini açıkça ortaya koymaktadır.

Görseller üzerinde yer alan tahmin değerleri, geliştirilen yöntemin (Şekil 5.4.(b) ve Şekil 5.4.(c)) YOLO v7'ye kıyasla daha yüksek doğruluk oranlarına sahip olduğunu göstermektedir. Segmentasyon işlemi ile desteklenen yöntem, kalite kontrol süreçlerinde daha güvenilir ve hassas bir kusur tespit süreci sağlamaktadır. Elde edilen sonuçlar, geliştirilen DCIoU ve Komşuluk İlişkisi Algoritması'nın, yalnızca nesne tanıma açısından değil, aynı zamanda segmentasyon doğruluğu açısından da üstün bir performans sergilediğini ortaya koymaktadır.

Tez kapsamında segmentasyon işlemi, klasik yöntemlerin aksine, ayrı bir etiketleme veya manuel segmentasyon adımı gerektirmemektedir. Bunun yerine, Komşuluk İlişkisi Algoritması tarafından oluşturulan tensör yapısı doğrudan kullanılarak, nesne tespitinden segmentasyon benzeri hassas sonuçlar elde edilmektedir. Tensör yapısı, her bir pikselin ait olduğu küme ve komşuluk ilişkilerini kapsamlı bir şekilde temsil etmektedir (Şekil 4.3.(c)); böylece fındık üzerindeki kusurlu ve kusursuz bölgelerin sınırları, ek bir işlem veya etiketleme olmadan belirlenebilmektedir. Bu yaklaşım, yalnızca nesne varlığını tespit etmekle kalmayıp, aynı zamanda piksel düzeyinde bölge ayrıştırması sağlayarak kusurların boyutu, şekli ve konumunu yüksek doğrulukla belirlemeye olanak tanımaktadır.

Söz konusu yöntem, geleneksel segmentasyon tekniklerinden farklı olarak, veri ön işleme ve manuel etiketleme gereksinimini ortadan kaldırmakta, böylece işlem maliyetini ve süresini önemli ölçüde azaltmaktadır. Ayrıca, nesne tespitinden doğrudan elde edilen segmentasyon çıktıları, kalite kontrol süreçlerinde hem nicel hem de nitel analiz yapılabilmesine imkân sağlamaktadır. Örneğin, kusurlu bölgelerin oranı, alanı ve dağılımı otomatik olarak hesaplanabilir; bu da sistemin doğruluk, güvenilirlik ve tekrarlanabilirliğini artırmaktadır. Dolayısıyla, Komşuluk İlişkisi Algoritması'nın bu yeteneği, fındık kalite kontrolünde hem pratik hem de teorik açıdan yenilikçi bir çözüm sunmakta ve literatürde segmentasyon işleminin nesne tespitinden türetildiği özgün bir yaklaşım olarak değerlendirilmektedir.

Bu yaklaşımın fındık kalite belirleme sistemine sağladığı en önemli katkı, kusurlu ve az kusurlu bölgelerin yalnızca varlığını değil, aynı zamanda boyut, şekil ve uzamsal dağılımını da ayrıntılı bir şekilde ortaya koyabilmesidir. Segmentasyon çıktıları sayesinde, sistem her bir fındığın yüzeyindeki kusurların oranını ve dağılımını otomatik olarak analiz edebilmekte; böylece fındıklar kusurlu, az kusurlu veya kusursuz olarak daha güvenilir bir şekilde sınıflandırılabilir. Bu detaylı veri,

kalite kontrol süreçlerinde daha hassas kararların alınmasına, ürün sınıflandırmasının doğruluğunun artırılmasına ve üretim zincirinde kalite standartlarının etkin bir biçimde uygulanmasına olanak tanımaktadır. Ayrıca, segmentasyon tabanlı analizler, sistemin tekrarlanabilirliğini ve güvenilirliğini artırarak, manuel gözlem veya subjektif değerlendirmelerin yol açabileceği hataları minimize etmektedir. Dolayısıyla, Komşuluk İlişkisi Algoritması'ndan türetilen segmentasyon çıktıları, fındık kalite belirleme sisteminde hem operasyonel verimliliği artıran hem de ölçülebilir ve objektif değerlendirmeye imkân sağlayan kritik bir araç olarak işlev görmektedir.

5.4. Fındık Kalite Belirleme Sisteminin Karşılaştırmalı Performans Analizi

Tarım ürünlerinin sınıflandırılmasında teknolojik yöntemlerin kullanılması hem verimlilik hem de kalite yönetimi açısından önemli avantajlar sağlamaktadır. Teknoloji tabanlı yöntemler sayesinde tarımsal ürünlerin fiziksel ve kimyasal özellikleri ile kalite kriterleri daha doğru ve güvenilir bir biçimde belirlenebilmekte, bu da üretim süreçlerinin iyileştirilmesine ve ürünlerin piyasa değerinin artırılmasına katkı sunmaktadır. Literatürde fındık sınıflandırmasına yönelik birçok çalışma yer almakta olup, bu çalışmalar genellikle kabuklu veya kabuksuz fındıkların genel sınıflandırılması üzerine odaklanmıştır.

Kayakuş ve arkadaşları [45], fındıkların mekanik özellikleri ve deformasyon enerjisine dayalı olarak, optik sensörler ve makine öğrenmesi yöntemlerini kullanarak kabuklu ve kabuksuz fındıkları genel olarak sınıflandırmıştır. Ancak bu çalışmada, bölgesel kusur tespiti yapılmamış ve derin öğrenme tabanlı bir analiz gerçekleştirilmemiştir. Buna karşılık, bu tez kapsamında gerçekleştirilen çalışmada fındık üzerindeki kusurlar derin öğrenme yöntemleriyle bölgesel olarak tespit edilmekte ve detaylı şekilde sınıflandırılmaktadır. Böylece kalite kontrol süreçlerine doğrudan katkı sağlanmaktadır.

Erbaş ve arkadaşları [49] tarafından yürütülen bir başka çalışmada, AlexNet mimarisi kullanılarak yapay zekâ tabanlı bir fındık kalite sınıflandırma sistemi geliştirilmiştir. Ancak bu çalışmada fındıklar yalnızca genel kalite kategorilerine ayrılmış, kusur tespiti veya bölgesel analiz gibi ayrıntılı işlemler uygulanmamıştır. Dönmez ve arkadaşları [52] ise farklı bölgelerde yetiştirilen fındık çeşitlerini derin öğrenme tabanlı BigTransfer (BiT) modelleriyle sınıflandırmıştır. Bu çalışma, derin öğrenme

modellerinin kalite kontrol süreçlerindeki etkinliğini göstermiş olsa da, kusur bölgesinin konumuna ve boyutuna ilişkin detaylı analizler içermemektedir.

Ünal ve Aktaş [51], fındık endüstrisinde kullanılan ayırma sürecinde EfficientNet ve InceptionV3 gibi gelişmiş derin öğrenme mimarilerini kullanarak tam çekirdek, hasarlı çekirdek, kabuk ve küçük boyutlu fındık sınıflarını başarıyla ayırt etmişlerdir. Ancak bu çalışmada da odak noktası genel sınıf ayrımı olup, kusurların bölgesel tespiti üzerinde durulmamıştır. Bu tez kapsamında önerilen model ise yalnızca kusur türlerini belirlemekle kalmayıp, aynı zamanda bu kusurların fındık çekirdeği üzerindeki konumlarını da hassas biçimde belirleyebilmektedir. Bu özellik, kalite kontrol ve otomasyon süreçlerinde çok daha ayrıntılı ve güvenilir bir değerlendirme sağlamaktadır.

Literatürde yer alan çalışmaların büyük bir kısmı, fındık çeşitlerinin sınıflandırılmasına odaklanmakta olup, kusur tespiti veya segmentasyon temelli analizlere daha az yer verilmiştir. Çoğu çalışmada RGB kameralar kullanılmış ve görüntü işleme temelli yaklaşımlar tercih edilmiştir. Tahribatsız görüntüleme tekniklerinden biri olan X-Işını görüntüleme ise oldukça sınırlı sayıda çalışmada uygulanmıştır. Örneğin Khosa ve arkadaşları [56], X-Işını görüntülerini ve geleneksel görüntü işleme yöntemlerini kullanarak fındıkların otomatik tespit ve sınıflandırmasını gerçekleştirmiştir. Ancak bu çalışma, derin öğrenme tabanlı yöntemleri içermemekte ve bölgesel kusur tespiti açısından sınırlı kalmaktadır. Bu bağlamda, bu tez çalışması X-Işını görüntüleme ile derin öğrenme yöntemlerini birleştirerek fındıklardaki kusurların bölgesel tespiti ve ayrıntılı görselleştirilmesini sağlaması bakımından literatüre yenilikçi bir katkı sunmaktadır.

Tablo 5.3. Önerilen fındık kalite belirleme sisteminin literatürdeki farklı çalışmalarla karşılaştırılması.

Kaynak	Görüntüleme Yöntemi	Görüntü Sayısı	Sınıf Sayısı	Sınıflandırma Türü	Yöntem	Segmentasyon
(Taner ve arkadaşları [46])	RGB Kamera	4250	17	Genel Fındık Sınıflandırması	Lprtnr lı, VGG16, VGG19, ResNet50 ve InceptionV3	YOK
(Gencturk ve arkadaşları [50])	RGB Kamera	3627	3	Genel Fındık Sınıflandırması	InceptionV3 + ResNet50	YOK
(Ünal ve Aktaş [51])	RGB Kamera	2094	4	Kusur Sınıflandırması (Tüm Fındık)	InceptionV3 ve EfficientNe	YOK
(Dönmez ve arkadaşları [52])	RGB Kamera	3627	3	Genel Fındık Sınıflandırması	BigTransfer (BiT)-M R50 × 1, BiT-M R101 × 3 ve BiT-M R152 × 4	YOK
(Maier ve arkadaşları [104])	Optik Sensörler	-	2	Kusur Sınıflandırması (Tüm Fındık)	Makine öğrenme methotları	YOK

Tablo 5.4. (Devamı) Önerilerin fındık kalite belirleme sisteminin literatürdeki farklı çalışmalarla karşılaştırılması

Kaynak	Görüntüleme Yöntemi	Görüntü Sayısı	Sınıf Sayısı	Sınıflandırma Türü	Yöntem	Segmentasyon
(Khosa ve Pasero [56])	X-Işını	788	3	Kusur Sınıflandırması (Tüm Fındık)	Görüntü İşleme (Özellik Çıkarımı)	YOK
77 (Kayakuş ve arkadaşları [45])	Fındık mekanik özellikleri	120	2	Genel Fındık Sınıflandırması	Makine Öğrenme Methotları	YOK
(Erbaş ve arkadaşları [49])	RGB Kamera	461	5	Kusur Sınıflandırması (Tüm Fındık))	AlexNet	YOK
Bizim çalışmamız	X-Işını	1320	3	Kusur Sınıflandırması (Bölgesel)	YOLOv7	VAR

Tablo 5.3'te özetlenen karşılaştırmalar incelendiğinde, mevcut çalışmaların büyük bir kısmının tür tanımlama veya genel kusur sınıflandırması üzerine yoğunlaştığı; segmentasyon temelli derinlemesine bir analiz sunmadığı görülmektedir. Literatürde yaygın olarak kullanılan VGG16, ResNet50, InceptionV3, BiT gibi derin öğrenme mimarileri veya geleneksel makine öğrenmesi yöntemleriyle elde edilen sonuçlar, genellikle sınıf bazlı genel değerlendirmelerle sınırlıdır. Buna karşılık, bu tez kapsamında geliştirilen sistem, X-Işını görüntüleme teknikleriyle desteklenen YOLOv7 tabanlı bir yapı kullanarak fındıklarda yerel kusur tespiti ve segmentasyon işlemlerini bütünleşik bir şekilde gerçekleştirmektedir. Böylece, her bir fındık çekirdeği üzerindeki kusurların konum, boyut ve şekil bilgileri yüksek doğrulukla belirlenebilmekte ve kalite kontrol süreci çok daha detaylı bir biçimde yürütülebilmektedir.

Sonuç olarak, fındık kalitesinin değerlendirilmesinde yalnızca kusurların varlığını belirlemek yeterli olmayıp, kusurların türü, büyüklüğü ve yayılım oranının da doğru şekilde tespit edilmesi büyük önem taşımaktadır. X-Işını görüntüleme ile derin öğrenme tabanlı analizlerin bir arada kullanılması, fındık kusurlarının daha hassas, hızlı ve güvenilir biçimde belirlenmesine olanak tanımaktadır. Güncel literatürde bu iki yöntemi bütünleştiren çalışmalar oldukça sınırlı olup, bu tez çalışması bu alandaki boşluğu doldurarak fındık kalite değerlendirmesinde hem akademik hem de endüstriyel açıdan yüksek performanslı ve özgün bir çözüm sunmaktadır.

6. SONUÇLAR

Bu tez çalışmasında, fındık kalite kontrol süreçlerinde yüksek doğruluk, tekrarlanabilirlik ve otomasyon sağlamak amacıyla X-Işını görüntüleme temelli, derin öğrenme destekli bir fındık kalite belirleme sistemi önerilmiştir. Fındık randımanı belirleme işlemleri, geleneksel olarak hasat sonrası ürünlerin alım merkezlerinde, çoğunlukla uzman gözlemleri temel alınarak gerçekleştirilmektedir. Ancak bu yöntemler, insan faktörüne bağlı olmaları nedeniyle subjektif değerlendirme hatalarına açıktır ve özellikle gözle tespit edilmesi güç olan iç kusurların belirlenmesini sınırlamaktadır. Bu durum, fındığın depolama süresi, endüstriyel kullanım alanları ve adil fiyatlandırma gibi kritik parametreleri doğrudan etkilemektedir. Fındıkta görülen kusurlar, yetiştirme koşulları ve üretim alanına bağlı olarak yıllık %1 ile %15 arasında değişim göstermekte olup, FAOUN verilerine göre yılda 1 milyon tonun üzerinde fındık üretimi yapıldığında 10.000 ton ile 150.000 ton arasında kusurlu ürün oluşabilmektedir. Bu nedenle, kusurların hassas ve doğru bir şekilde tespit edilmesi hem randıman hesaplamalarının doğruluğu hem de endüstriyel kalite kontrol süreçlerinin etkinliği açısından büyük önem taşımaktadır. Önerilen sistem, mevcut tüm kusurları otomatik ve yüksek doğrulukla tespit ederek, geleneksel yöntemlerin yetersiz kaldığı süreçleri standardize etmekte ve kalite kontrol, üretim ve pazarlama aşamalarında güvenilir veri temelli karar alınmasına olanak sağlamaktadır.

Tez kapsamında oluşturulan X-Işını fındık veri seti, Samsun, Ordu ve Giresun illerinden toplanan en yaygın beş farklı fındık türünü içeren toplam 1320 etiketli görüntüden oluşmaktadır. Veri seti, fındık çekirdeğinin iç yapısını ve olası kusurları doğru biçimde temsil edecek şekilde özenle hazırlanmış; her bir kusur bölgesi piksel düzeyinde ayrıntılı olarak etikenlendirilmiştir. Etiketleme süreci, hem bölgesel kusur tespitinde yüksek doğruluk elde edilmesine hem de geliştirilen yöntemlerin nesne tespiti ve segmentasyon performanslarının güvenilir bir biçimde değerlendirilmesine önemli katkı sağlamıştır. X-Işını tabanlı fındık kusur veri setinin literatürde ve açık kaynaklarda sınırlı olması, oluşturulan veri setini içerdiği çeşitlilik, kapsam ve ayrıntılı etiketleme yapısı açısından önemli bir kaynak hâline getirirken; aynı zamanda tez kapsamında geliştirilen modellerin doğrulanmasını ve gelecekteki akademik

alışmalar ile endüstriyel kalite kontrol uygulamalarında kullanılabilir olmasını sağlayarak alışmanın genel değeriini güçlendirmektedir.

Veri setindeki X-Işını görüntülerinin ön işleme aşamaları, modelin doğruluk ve hassasiyet performansını doğrudan etkilemiştir. Otsu filtreleme ile fındık çekirdeğinin alanları başarıyla tespit edilirken, CLAHE, Gauss Blur ve Anisotropic Diffusion filtreleri kullanılarak kusur alanlarının öne çıkarılması sağlanmıştır. Bu işlemler sayesinde görüntülerdeki gürültü önemli ölçüde azaltılmış, kontrast iyileştirilmiş ve nesne belirginliği artırılmıştır. Özellikle küçük, kısmi veya örtüşen kusurların doğru şekilde tespit edilmesinde bu ön işleme adımları kritik bir rol oynamış; modelin eğitim sürecine daha temiz ve optimize edilmiş veri girişi sunarak, fındık kusur tespitinde genel doğruluk ve güvenilirliği artırmıştır.

Önerilen fındık kalite belirleme sisteminde, nesne tespitinde sınırlayıcı kutu regresyonunun model performansı üzerindeki etkisi ayrıntılı olarak incelenmiştir. Bu kapsamda, YOLOv7 mimarisinde kullanılan IoU tabanlı kayıp fonksiyonlarının optimizasyon davranışları analiz edilmiştir. Elde edilen bulgular, klasik IoU ve norm tabanlı kayıpların örtüşme olmayan durumlarda yeterli gradyan üretmediğini ve yüksek örtüşmede konumsal ve geometrik hataları yeterince cezalandıramadığını göstermiştir. GIoU, DIoU ve CIoU gibi genişletilmiş IoU türevleri bu eksiklikleri kısmen gidermiş olsa da özellikle merkez akışması, tam kapsama ve yüksek IoU senaryolarında ceza terimlerinin etkisinin zayıfladığı ve optimizasyon sürecinin yeniden klasik IoU davranışına yakınsadığı gözlemlenmiştir. Bu sınırlılıklardan hareketle, alışmada DCIoU kayıp fonksiyonu önerildi. DCIoU, tahmin edilen kutu, gerçek kutu ve bu kutuları kapsayan minimum çevre kutunun merkezleri arasındaki mesafeleri birlikte dikkate alarak regresyon sürecine hem yerel hem de konumsal bilgiyi entegre eden bir optimizasyon çerçevesi sunmaktadır. Bu sayesinde DCIoU önceki yöntemlerin yetersiz kaldığı durumlarda dahi sürekli ve anlamlı gradyan üretmeyi başararak yakınsama kararlılığını artırmakta ve sınırlayıcı kutu tahminlerinin konum doğruluğunu daha hassas biçimde optimize etmektedir. Gerçekleştirilen simülasyon testleri ve eğitim sonuçları, DCIoU'nun diğer IoU tabanlı kayıp fonksiyonlarına kıyasla daha hızlı yakınsama sağladığını, daha düşük regresyon hatası ürettiğini ve iteratif öğrenme sürecinde daha kararlı bir optimizasyon davranışı sergilediğini açıkça ortaya koymuştur.

YOLOv7 modelinin eğitim sonuçlarına ait karmaşıklık matrisleri incelendiğinde, modelin kusurlu, az kusurlu ve kusursuz sınıflarını genel olarak yüksek doğrulukla ayırt edebildiği görülmektedir. Bununla birlikte, sınıflar arasındaki karışmanın ağırlıklı olarak kusurlu ve az kusurlu sınıfları arasında gerçekleştiği tespit edilmiştir. Yalnızca örtüşme oranını temel alan IoU kayıp fonksiyonu kullanıldığında, bu iki sınıf arasında belirgin yanlış sınıflandırmalar oluşmuştur. Önerilen DCIoU kayıp fonksiyonu, konumsal ve geometrik bileşenleri dengeli biçimde optimize etmiş; sınıflar arası karışmayı minimize ederek daha kararlı ve güvenilir bir sınıflandırma başarımı sağlamıştır. Bu durum, DCIoU'nun görsel olarak benzer kusur seviyelerinin ayrıştırılmasında daha ayırt edici olduğunu göstermektedir.

DCIoU yönteminin gerçek dünya koşullarındaki etkinliğini değerlendirmek amacıyla, IoU, GIoU, DIoU, CIoU ve önerilen DCIoU kayıp fonksiyonları YOLOv7 mimarisi içerisine ayrı ayrı entegre edilmiş; bu yapı X-Işını fındık veri seti ve COCO-128 veri seti üzerinde eğitilerek ilgili performans metrikleri üzerinden karşılaştırmalı olarak analiz edilmiştir. Elde edilen sonuçlar, DCIoU'nun kesinlik, duyarlılık, $mAP@0.5$, $mAP@0.5:0.95$ ve F1-skoru gibi temel performans metriklerinde tutarlı ve belirgin iyileştirmeler sağladığını ortaya koymuştur. Özellikle X-Işını fındık görüntülerinde, görsel olarak birbirine yakın özellikler sergileyen kusur sınıflarının ayırımında DCIoU'nun daha dengeli ve güvenilir bir performans sunduğu gözlemlenmiştir. COCO-128 veri seti üzerinde elde edilen bulgular ise, önerilen yöntemin farklı nesne dağılımlarına sahip veri setlerinde de genelleme yeteneğini koruduğunu doğrulamaktadır.

Çalışmanın diğer temel katkısı olan Komşuluk İlişki Algoritması, nesne tespitinde kullanılan sınırlayıcı kutuların seçimi ve bu kutulardan bölgesel segmentasyon bilgisinin elde edilmesine yönelik yenilikçi bir yaklaşım sunmaktadır. Bu süreçte yoğunluk benzerliği ve uzamsal süreklilik birlikte değerlendirilmekte; anlamlı kümeler tensör yapısı içerisinde organize edilerek hem gürültü kaynaklı küçük kümeler elimine edilmekte hem de gerçek nesne bölgelerinin geometrik sınırları daha doğru biçimde tanımlanmaktadır. Komşuluk İlişki Algoritması'nın NMS sürecine entegrasyonu ile, yalnızca IoU değerine dayalı klasik kutu eleme yaklaşımının ötesine geçilmiş; DCIoU tabanlı benzerlik ölçümü ve bölgesel yoğunluk bilgisi kullanılarak daha tutarlı ve optimal sınırlayıcı kutular seçilmiştir. Böylece, örtüşen veya birbirine yakın tahmin kutularının filtrelenmesi etkin biçimde gerçekleştirilirken, gerçek nesne

bölgelerinin korunması sağlanmıştır. Algoritmanın en dikkat çekici yönlerinden biri, herhangi bir ek segmentasyon ağına veya manuel etiketleme sürecine ihtiyaç duymadan, nesne tespit çıktılarından piksel düzeyinde segmentasyon benzeri sonuçlar üretebilmesidir. Segmentasyon çıktıları yalnızca nesne varlığını değil, aynı zamanda kusurların boyut, şekil ve konum dağılımını da hassas biçimde ortaya koyarak kalite kontrol sürecinde daha güvenilir, tekrarlanabilir ve veri odaklı kararlar alınmasını sağlamaktadır. Bu yaklaşım, literatürde nesne tespitinden türetilen segmentasyon yöntemlerine özgün bir katkı sunmakta ve manuel segmentasyon maliyetini ortadan kaldırarak pratik bir çözüm sağlamaktadır.

Geliştirilen sistem ile, fındıklardaki kusurlu ve az kusurlu bölgelerin boyut, şekil ve uzamsal dağılımı detaylı bir şekilde ortaya konulabilmekte; kalite kontrol süreçlerinde daha hassas ve standartlara uygun kararlar alınmakta, üretim zincirinde kalite standartlarının etkin uygulanması mümkün hale gelmektedir. Ayrıca, sistemin tekrarlanabilirliği ve güvenilirliği, manuel gözlem veya subjektif değerlendirmelerden kaynaklanabilecek hataları minimize ederek endüstriyel süreçlerde kalite kontrolün standardizasyonuna önemli katkı sağlamaktadır. Deneysel sonuçlar, yalnızca YOLOv7 kullanılan temel yaklaşıma kıyasla, DCIoU ve Komşuluk İlişki Algoritması ile desteklenen sistemin hem nesne tespit doğruluğu hem de segmentasyon hassasiyeti açısından belirgin üstünlük sağladığını göstermektedir. Sonuç olarak bu tez, fındık kalite kontrolü özelinde geliştirilen yöntemler aracılığıyla, nesne tespiti literatürüne yeni bir kayıp fonksiyonu ve nesne tespitinden segmentasyon bilgisi türetebilen özgün bir algoritma kazandırmaktadır. Önerilen yaklaşım, yalnızca fındık kalite belirleme uygulamaları için değil; X-Işını görüntüleme, endüstriyel kalite kontrol ve benzer nesne tespit problemleri için de genellenebilir bir yapı sunmaktadır.

Literatürdeki mevcut çalışmaların çoğunlukla fındıkların genel sınıflandırılması veya kusur varlığının tespitine odaklandığı ve segmentasyon temelli yerel analizlere sınırlı yer verdiği görülmektedir. Bu tez kapsamında geliştirilen sistem ise X-Işını görüntüleme ile YOLOv7 tabanlı derin öğrenme yöntemlerini bütünleştirerek, fındık çekirdeklerindeki kusurların türünü, konumunu ve boyutunu yüksek doğrulukla belirleyebilmektedir. Böylece kalite kontrol sürecinde yalnızca kusur varlığının tespiti değil, kusurların ayrıntılı analizi de mümkün hale gelmekte ve süreçler hem daha güvenilir hem de otomasyona uygun bir biçimde yürütülebilmektedir. Bu yaklaşım,

literatürdeki sınırlılıkları aşarak hem akademik hem de endüstriyel açıdan fındık kalite değerlendirmesinde yenilikçi ve yüksek performanslı bir çözüm sunmaktadır.

İlerleyen çalışmalarda, sistemin kapasitesini ve uygulanabilirliğini artırmak amacıyla çoklu sensör entegrasyonu ile veri çeşitliliğinin artırılması, üç boyutlu modellerin geliştirilmesi ile fındıkların ağırlık tahminleri ve randıman ölçümlerinde tamamen dijital yöntemlerin kullanılmasının sağlanması öngörülmektedir. Bu tür geliştirmeler, endüstriyel kalite kontrol süreçlerinin daha hassas, verimli ve otomatik hâle gelmesine katkı sağlayacaktır. Ayrıca, Transformer veya hibrit derin öğrenme mimarileri ve ileri düzey hiperparametre optimizasyonları ile model performansının artırılması, farklı endüstriyel veri setleri üzerinde genelleştirilebilirliğin test edilmesi ve büyük ölçekli üretim hatlarında gerçek zamanlı kullanım potansiyelinin değerlendirilmesi mümkün olacaktır. Bu yaklaşım, yalnızca fındık kalite kontrolü için değil, diğer tarımsal ürünlerin sınıflandırma ve kalite değerlendirme sistemlerine adaptasyon potansiyelini de güçlendirerek, gelecekteki araştırmalar ve endüstriyel uygulamalar için önemli bir temel oluşturacaktır.

Sonuç olarak, bu tez çalışması, X-Işını görüntüleme ve derin öğrenme temelli analizleri birleştirerek fındık kalite belirlemede hassas, hızlı ve güvenilir bir sistem geliştirmiş; literatüre hem akademik hem de endüstriyel açıdan özgün ve yüksek performanslı bir katkı sunmuştur. Sistem, yalnızca tespit doğruluğunu artırmakla kalmayıp, üretim süreçlerinde otomasyon, veri tabanlı karar mekanizmaları ve kalite kontrol verimliliğini de önemli ölçüde geliştirmektedir.



KAYNAKLAR

- [1] Food and Agriculture Organization of the United Nations (2023). FAOSTA. <https://www.fao.org/faostat/en/#data/QCL/> adresinden 24 Kasım 2025 tarihinde alınmıştır.
- [2] Król, K., & Gantner, M. (2020). Morphological Traits and Chemical Composition of Hazelnut from Different Geographical Origins: A Review. *Agriculture*, 10(9), 375. <https://doi.org/10.3390/agriculture10090375>
- [3] Silvestri, C., Bacchetta, L., Bellincontro, A. and Cristofori, V. (2020), Advances in cultivar choice, hazelnut orchard management, and nut storage to enhance product quality and safety: an overview. *Journal of Science of Food and Agriculture*, 101(1), 27-43. <https://doi.org/10.1002/jsfa.10557>
- [4] Kılıç Topuz, B., Kılıç, O., Boz, İ., Aydın Eryılmaz, G. (2019). Türkiye’de fındık üretim alanlarının daraltılması politikası. *Akademik Ziraat Dergisi*, 8(1), 141-148. <https://doi.org/10.29278/azd.594060>
- [5] Wani, I.A., Ayoub, A., Bhat, N.A., Dar, A.H., Gull, A. (2020). Hazelnut (1. Baskı, ss. 559-572). *Antioxidants in Vegetables and Nuts - Properties and Health Benefits*. Springer Singapore. https://doi.org/10.1007/978-981-15-7470-2_29
- [6] Karaosmanoğlu, H. (2022). Lipid characteristics, bioactive properties, and mineral content in hazelnut grown under different cultivation systems. *Journal of Food Processing and Preservation*, 46(7). e16717. <https://doi.org/10.1111/jfpp.16717>
- [7] Yaman, M., Balta, M. F., Karakaya, O., Kaya, T., Necas, T., Yildiz, E., & Dirim, E. (2023). Assessment of Fatty Acid Composition, Bioactive Compounds, and Mineral Composition in Hazelnut Genetic Resources: Implications for Nutritional Value and Breeding Programs. *Horticulturae* 2023, 9(9), 1008. <https://doi.org/10.3390/horticulturae9091008>
- [8] Bencresciuto, G. F., Carnevale, M., Paris, E., Gallucci, F., Santangelo, E., & Migliori, C. A. (2025). A Sustainable Alternative for Cosmetic Applications: NADES Extraction of Bioactive Compounds from Hazelnut By-Products. *Sustainability*, 17(4), 1516. <https://doi.org/10.3390/su17041516>
- [9] Valeriano T, Fischer K, Ginaldi F, Giustarini L, Castello G and Bregaglio S (2022) Rotten Hazelnuts Prediction via Simulation Modeling-A Case Study on the Turkish Hazelnut Sector. *Front. Plant Sci.*, 13. 766493. <https://doi.org/10.3389/fpls.2022.766493>
- [10] Bak, T., & Karadeniz, T. (2021). Effects of Branch Number on Quality Traits and Yield Properties of European Hazelnut (*Corylus avellana* L.). *Agriculture*, 11(5), 437. <https://doi.org/10.3390/agriculture11050437>

- [11] Karakaya, O., Yaman, M., Balta, F., Yilmaz, M. & Fikret, M. F. (2022). Assessment of genetic diversity revealed by morphological traits and ISSR markers in hazelnut germplasm (*Corylus avellana* L.) from Eastern Black Sea Region, Turkey. *Genet Resour Crop Evol*, 70, 525–537. <https://doi.org/10.1007/s10722-022-01444-0>
- [12] Spataro, F., Rosso, F., Genova, G., & Caligiani, A. (2024). Untargeted UHPLC-HRMS as a new tool for the detection of rotten defect markers in hazelnuts of different origins. *Microchemical Journal*, 197, 109743. <https://doi.org/10.1016/j.microc.2023.109743>
- [13] Squara, S., Stilo, F., Cialie Rosso, M., Liberto, E., Spigolon, N., Genova, G., Castello, G., Bicchi, C., & Cordero, C. (2022). *Corylus avellana* L. aroma blueprint: Potent odorants signatures in the volatilome of high quality hazelnuts. *Frontiers in Plant Science*, 13, 840028. <https://doi.org/10.3389/fpls.2022.840028>
- [14] Ayyildiz, E., Yildiz, A., Taskin, A., & Ozkan, C. (2023). An interval valued Pythagorean fuzzy AHP integrated quality function deployment methodology for hazelnut production in Turkey. *Expert Systems with Applications*, 231, 120708. <https://doi.org/10.1016/j.eswa.2023.120708>
- [15] Bostan, S. Z. (2019). Fındıkta kabuklu ve iç meyve kusurları. *Akademik Ziraat Dergisi*, 8(Özel Sayı), 157-166. <https://doi.org/10.29278/azd.644005>
- [16] Saruhan, İ., & Şen, M. (2016). Emici böcekler (Hemiptera: Pentatomidae, Coreidae ve Acanthosomatidae)'in farklı fındık (*Corylus avellana* L.) çeşitlerindeki lekeli iç zararının belirlenmesi. *Anadolu Tarım Bilimleri Dergisi*, 31(3), 337-344. <https://doi.org/10.7161/omuanajas.269986>
- [17] Hamidi, R., Toillon, J., & Thomas, M. (2022). Underestimated Damage Caused by the European Hazelnut Weevil, *Curculio nucum* (Curculionidae). *Agronomy*, 12(12), 3059. <https://doi.org/10.3390/agronomy12123059>
- [18] Kan, E., Akgün, M., & Turan, A. (2024). Kahverengi Kokarca [*Halyomorpha halys* Stal (Hemiptera: Pentatomidae)] Zararının Fındığın Fiziksel Özellikleri Üzerine Etkisi, *Karadeniz Fen Bilimleri Dergisi*, 14(3), 1654-1664. <https://doi.org/10.31466/kfbd.1462141>
- [19] Bak, T., & Karadeniz, T. (2021). Effects of Branch Number on Quality Traits and Yield Properties of European Hazelnut (*Corylus avellana* L.). *Agriculture*, 11(5), 437. <https://doi.org/10.3390/agriculture11050437>
- [20] OECD, (2011). Inshell Hazelnuts and Hazelnut Kernels, International Standards for Fruit and Vegetables. OECD Publishing, Organisation for Economic Co-Operation and Development. <https://doi.org/10.1787/9789264166721-en-fr>
- [21] United Nations Economic Commission for Europe. (2010). UNECE standard DDP-04 concerning the marketing and commercial quality control of hazelnut kernels. https://unece.org/fileadmin/DAM/trade/agr/standard/dry/dry_e/04HazelnutKernels_e.pdf adresinden 25 Kasım 2025 tarihinde alınmıştır.

- [22] Bostan, S. Z., & İşbakan, H. (2020). Fındıkta bitki morfolojik özellikleri ile verim ve meyve kalite özellikleri arasındaki ilişkiler. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 10(1), 32-45.
- [23] Romero-Aroca, A., Rovira, M., Cristofori, V., & Silvestri, C. (2021). Hazelnut Kernel Size and Industrial Aptitude. *Agriculture*, 11(11), 1115. <https://doi.org/10.3390/agriculture11111115>
- [24] Yılmaz, S. M., Kaman, S. Ç., & Güler, E. (2025). Hazelnut Kernel Percentage Calculation System with DCIoU and Neighborhood Relationship Algorithm. *Processes*, 13(8), 2414. <https://doi.org/10.3390/pr13082414>
- [25] Turan, A. (2023). Alım Noktalarına Gelen Fındık Meyvelerinde Bazı Özelliklerin Belirlenmesi: Giresun Örneği. *Akademik Ziraat Dergisi*, 12(Özel Sayı), 99-108. <https://doi.org/10.29278/azd.1355568>
- [26] Camardo Leggieri, M., Arciuolo, R., Chiusa, G., Castello, G., Spigolon, N., & Battilani, P. (2022). DEFHAZ: A Mechanistic Weather-Driven Predictive Model for Diaporthe eres Infection and Defective Hazelnut Outbreaks. *Plants*, 11(24), 3553. <https://doi.org/10.3390/plants11243553>
- [27] Sezer, A., & Şahin, S. (2022). Fındıkta Külleme Hastalığının Uzun Süreli Depolamada Bazı İç Bozuklukları ve Kalite Parametrelerine Etkisi. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 12(2), 179-188. <https://doi.org/10.54370/ordubtd.1207968>
- [28] Pannico, A., Schouten, R. E., Basile, B., Romano, R., Woltering, E. J., & Cirillo, C. (2015). Non-destructive detection of flawed hazelnut kernels and lipid oxidation assessment using NIR spectroscopy. *Journal of Food Engineering*, 160, 42–48. <https://doi.org/10.1016/j.jfoodeng.2015.03.015>
- [29] Mahanti, N. K., Pandiselvam, R., Kothakota, A., Ishwarya S., P., Chakraborty, S. K., Kumar, M., & Cozzolino, D. (2022). Emerging non-destructive imaging techniques for fruit damage detection: Image processing and analysis. *Trends in Food Science & Technology*, 120, 418–438. <https://doi.org/10.1016/j.tifs.2021.12.021>
- [30] Abasi, S., Minaei, S., Jamshidi, B., & Fathi, D. (2018). Dedicated non-destructive devices for food quality measurement: A review. *Trends in Food Science & Technology*, 78, 197–205. <https://doi.org/10.1016/j.tifs.2018.05.009>
- [31] Ropodi, A. I., Panagou, E. Z., & Nychas, G.-J. E. (2016). Data mining derived from food analyses using non-invasive/non-destructive analytical techniques; Determination of food authenticity, quality & safety in tandem with computer science disciplines. *Trends in Food Science & Technology*, 50, 11–25. <https://doi.org/10.1016/j.tifs.2016.01.011>
- [32] El-Mesery, H. S., Mao, H., & Abomohra, A. E.-F. (2019). Applications of Non-destructive Technologies for Agricultural and Food Products Quality Inspection. *Sensors*, 19(4), 846. <https://doi.org/10.3390/s19040846>
- [33] Zhou, L., Zhang, C., Qiu, Z., & He, Y. (2020). Information fusion of emerging non-destructive analytical techniques for food quality authentication: A survey. *TrAC Trends in Analytical Chemistry*, 127, 115901. <https://doi.org/10.1016/j.trac.2020.115901>

- [34] Aslam, R., Sharma, S.R., Kaur, J., ve Panayampadan, A. S. (2023). A systematic account of food adulteration and recent trends in the non-destructive analysis of food fraud detection. *Food Measure*, 17, 3094–3114. <https://doi.org/10.1007/s11694-023-01846-3>
- [35] Anjali, Jena, A., Bamola, A., Mishra, S., Jain, I., Pathak, N., Sharma, N., Joshi, N., Pandey, R., Kaparwal, S., Yadav, V., Gupta, A., Jha, A., Bhatt, S., Kumar, V., Naik, B., Rustagi, S., Preet, M., Akhtar, S. (2024). State-of-the-art non-destructive approaches for maturity index determination in fruits and vegetables: principles, applications, and future directions. *Food Prod Process and Nutr*, 6, 56. <https://doi.org/10.1186/s43014-023-00205-5>
- [36] Corona, P., Frangipane, M. T., Moschetti, R., Lo Feudo, G., Castellotti, T., & Massantini, R. (2021). Chestnut Cultivar Identification through the Data Fusion of Sensory Quality and FT-NIR Spectral Data. *Foods*, 10(11), 2575. <https://doi.org/10.3390/foods10112575>
- [37] Sanchez, P. D. C., Hashim, N., Shamsudin, R., & Mohd Nor, M. Z. (2020). Applications of imaging and spectroscopy techniques for non-destructive quality evaluation of potatoes and sweet potatoes: A review. *Trends in Food Science & Technology*, 96, 208–221. <https://doi.org/10.1016/j.tifs.2019.12.027>
- [38] Xia, Y., Xu, Y., Li, J., Zhang, C., & Fan, S. (2019). Recent advances in emerging techniques for non-destructive detection of seed viability: A review. *Artificial Intelligence in Agriculture*, 1, 35–47. <https://doi.org/10.1016/j.aiia.2019.05.001>
- [39] Xue, Q., Miao, P., Miao, K., Yu, Y., & Li, Z. (2022). X-ray-based machine vision technique for detection of internal defects of sterculia seeds. *Journal of Food Science*, 87, 3386–3395. <https://doi.org/10.1111/1750-3841.16237>
- [40] Kumar, A., Arnold, W. (2022). High resolution in non-destructive testing: A review. *Journal of Applied Physics*, 132(10), 100901. <https://doi.org/10.1063/5.0095328>
- [41] Say, D., Qaisar, S. M., Krichen, M., & Zidi, S. (2025). Artificial intelligence assisted non-destructive testing of welding joints: A review of techniques, X-ray image processing and applications. *Engineering Applications of Artificial Intelligence*, 160, 111792. <https://doi.org/10.1016/j.engappai.2025.111792>
- [42] Zehi, Z. B., Afshari, A., Noori, S. M. A., Jannat, B., & Hashemi, M. (2020). The effects of X-ray irradiation on safety and nutritional value of food: A systematic review article. *Current Pharmaceutical Biotechnology*, 21(10), 919–926. <https://doi.org/10.2174/1389201021666200219093834>
- [43] Islam, M., Bijjahalli, S., Fahey, T., Gardi, A., Sabatini, R. & Lamb, D. W. (2024). Destructive and non-destructive measurement approaches and the application of AI models in precision agriculture: a review. *Precision Agric*, 25, 1127–1180 (2024). <https://doi.org/10.1007/s11119-024-10112-5>
- [44] Zhu, L., Spachos, P., Pensini, E., & Plataniotis, K. N. (2021). Deep learning and machine vision for food processing: A survey. *Current Research in Food Science*, 4, 233–249. <https://doi.org/10.1016/j.crfs.2021.03.009>

- [45] Kayakuş, M., Kabas, O., Ünal, İ., Paçacı, S., & Dinca, M. N. (2024). Non-destructive prediction of hazelnut and hazelnut kernel deformation energy using machine learning techniques. *International Journal of Food Properties*, 27(1), 326–340. <https://doi.org/10.1080/10942912.2024.2317749>
- [46] Taner, A., Öztekin, Y. B., & Duran, H. (2021). Performance analysis of deep learning CNN models for variety classification in hazelnut. *Sustainability*, 13(12), 6527. <https://doi.org/10.3390/su13126527>
- [47] Wang, J., Lin, Y., Li, Q., Lu, Z., Qian, J., Dai, H., et al. (2024). Non-destructive detection and grading of chilling injury-induced lignification of kiwifruit using X-ray computer tomography and machine learning. *Computers and Electronics in Agriculture*, 218, 108658. <https://doi.org/10.1016/j.compag.2024.108658>
- [48] Vitale, A., Giaccone, M., Napolitano, A. G., Benedetta, F., Gargiulo L. & Mele G. (2025). Cimiciato defect detection in hazelnuts: CNN models applied on hazelnut kernels X-ray radiographs. *Computers and Electronics in Agriculture*, 22, 102072. <https://doi.org/10.1016/j.jafr.2025.102072>
- [49] Erbaş, N., Çınarar, G., & Kılıç, K. (2022). Classification of hazelnuts according to their quality using deep learning algorithms. *Czech Journal of Food Sciences*, 40(3), 240-248. <https://doi.org/10.17221/21/2022-CJFS>
- [50] Gençtürk, B., Arsoy, S., Taspınar, Y. S., & Köklü, M. (2024). Detection of hazelnut varieties and development of mobile application with CNN data-fusion feature-reduction-based models. *European Food Research and Technology*, 250, 97–110. <https://doi.org/10.1007/s00217-023-04369-9>
- [51] Ünal, Z. (2023). Classification of hazelnut kernels with deep learning. *Postharvest Biology and Technology*, 197, 112225. <https://doi.org/10.1016/j.postharvbio.2022.112225>
- [52] Dönmez, E., Kılıçarslan, S., & Diker, A. (2024). Classification of hazelnut varieties based on bigtransfer deep learning model. *European Food Research and Technology*, 250(5), 1433-1442. <https://doi.org/10.1007/s00217-024-04468-1>
- [53] Aydın, Ş., & Aldara, D. (2024). Microservices-based databank for Turkish hazelnut cultivars using IoT and semantic web technologies. *Concurrency and Computation: Practice and Experience*, 36(12), e8062. <https://doi.org/10.1002/cpe.8062>
- [54] Giraudo, A., Osella, C., Rinaldi, M., Ribotta, P. D., & Cucci, I. (2018). Development of an automated method for the identification of defective hazelnut kernels based on multivariate analysis. *Journal of Food Engineering*, 233, 56-63. <https://doi.org/10.1016/j.jfoodeng.2018.01.020>
- [55] Gadalla, O. A. A., & Öztekin, Y. B. (2023). Image processing and traditional machine learning based classification of Brown Marmorated Stink Bug (*Halyomorpha halys*) defected hazelnut. *Journal of Tekirdağ Agricultural Faculty*, 20(4), 784-798. <https://doi.org/10.33462/jotaf.1165105>
- [56] Khosa, I., & Pasero, E. (2014). Feature extraction in X-ray images for hazelnuts classification. *2014 International Joint Conference on Neural Networks (IJCNN)*, China, 2354-2360. <https://doi.org/10.1109/IJCNN.2014.6889661>

- [57] Kaur, R., & Singh, S. (2023). A comprehensive review of object detection techniques in precision agriculture. *Digital Signal Processing*, 132, 103812. <https://doi.org/10.1016/j.dsp.2022.103812>
- [58] Qian, X., Lin, S., Cheng, G., Yao, X., Ren, H., & Wang, W. (2020). Object Detection in Remote Sensing Images Based on Improved Bounding Box Regression and Multi-Level Features Fusion. *Remote Sensing*, 12(1), 143. <https://doi.org/10.3390/rs12010143>
- [59] Zhang, Y.-F., Ren, W., Zhang, Z., Jia, Z., Wang, L., & Tan, T. (2022). Focal and efficient IOU loss for accurate bounding box regression. *Neurocomputing*, 506, 146-157. <https://doi.org/10.1016/j.neucom.2022.07.042>
- [60] Zhang, X., Li, H., Meng, F., Song, Z., & Xu, L. (2022). Segmenting Beyond the Bounding Box for Instance Segmentation. *IEEE Transactions on Circuits and Systems for Video Technology*, 32(2), 704–714. <https://doi.org/10.1109/TCSVT.2021.3063377>
- [61] Shen, Y., Zhang, F., Liu, D., Pu, W., & Zhang, Q. (2022). Manhattan-distance IoU loss for fast and accurate bounding box regression and object detection. *Neurocomputing*, 500, 99-114. <https://doi.org/10.1016/j.neucom.2022.05.052>
- [62] Yuan, D., Shu, X., Fan, N., Chang, X., Liu, Q., & He, Z. (2022). Accurate bounding-box regression with distance-IoU loss for visual tracking. *Journal of Visual Communication and Image Representation*, 83, 103428. <https://doi.org/10.1016/j.jvcir.2021.103428>
- [63] Liu, C., Wang, K., Lu, H., Cao, Z., & Zhang, Z. (2022). Robust Object Detection with Inaccurate Bounding Boxes. *Computer Vision – ECCV 2022*, 13670, 53-69. https://doi.org/10.1007/978-3-031-20080-9_4
- [64] Vo, X.-T., & Jo, K.-H. (2021). Accurate bounding box prediction for single-shot object detection. *IEEE Transactions on Industrial Informatics*, 17(9), 5961–5971. <https://doi.org/10.1109/TII.2021.3138336>
- [65] Zhang, R., Di, Y., Lou, Z., Manhardt, F., Tombari, F., & Ji, X. (2022). RBP-Pose: Residual Bounding Box Projection for Category-Level Pose Estimation. *Computer Vision – ECCV 2022*, 13661, 655-672. https://doi.org/10.1007/978-3-031-19769-7_38
- [66] Yan, B., Zhang, X., Wang, D., Lu, H., & Yang, X. (2021). Alpha-Refine: Boosting Tracking Performance by Precise Bounding Box Estimation. *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 5285-5294. <https://doi.org/10.48550/arXiv.2012.06815>
- [67] Yu, J., Li, Y., Li, Q., Liu, Y., Shi, X., & Yan, J. (2016). UnitBox: An Advanced Object Detection Network. In *Proceedings of the 24th ACM international conference on Multimedia*. <https://doi.org/10.48550/arXiv.1608.01471>
- [68] Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 658–666. <https://doi.org/10.1109/CVPR.2019.00075>

- [69] Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R., & Ren, D. (2020). Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression. *Proceedings of the AAAI Conference on Artificial Intelligence*, 34(07), 12993-13000. <https://doi.org/10.1609/aaai.v34i07.6999>
- [70] Roboflow (2021, Eylül). COCO 128 Bilgisayar Görüşü Veri Seti. <https://universe.roboflow.com/team-roboflow/coco-128> adresinden 24 Kasım 2025 tarihinde alınmıştır.
- [71] Sinan, S., Sheet, M., Tan, T-S., Asari, M.A, Hitam, W.H.W., & Sia J.S.Y. (2022). Retinal disease identification using upgraded CLAHE filter and transfer convolution neural network. *ICT Express*, 8(1), 142-150. <https://doi.org/10.1016/j.ict.2021.05.002>
- [72] Flusser, J., Farokhi, S., Höschl, C., Suk, T., Zitová, B., & Pedone, M. (2016). Recognition of Images Degraded by Gaussian Blur. *IEEE Transactions on Image Processing*, 25(2), 790-806. <https://doi.org/10.1109/TIP.2015.2512108>
- [73] Ben Abdallah, M., Malek, J., Azar, A.T. et al. (2016). Adaptive noise-reducing anisotropic diffusion filter. *Neural Comput & Applic*, 27, 1273–1300. <https://doi.org/10.1007/s00521-015-1933-9>
- [74] Redmon, J., Divvala, S., Girshick, R., & Farhadi, F. (2016). You Only Look Once: Unified, Real-Time Object Detection. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, USA, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- [75] Redmon, J., & Farhadi, A. (2017). YOLO9000: Better, Faster, Stronger. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, USA, 6517-6525. <https://doi.org/10.1109/CVPR.2017.690>
- [76] Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. *arXiv*. <https://doi.org/10.48550/arXiv.1804.02767>
- [77] Bochkovskiy, A., Wang, C-Y., & Liao, H-Y.M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. *arXiv*. <https://doi.org/10.48550/arXiv.2004.10934>
- [78] Khanam, R. & Hussain, M. (2024). What is YOLOv5: A deep look into the internal features of the popular object detector. *arXiv*. <https://doi.org/10.48550/arXiv.2407.20892>
- [79] Li, C., Li, L., Jiang, H., Weng, K., Geng, Y., Li, L., Ke, Z., Li, Q., Cheng, M., Nie, W., Li, Y., Zhang, B., Liang, Y., Zhou, L., Xu, X., Chu, X., Wei, X. & Wei, X. (2022). YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications. *arXiv*. <https://doi.org/10.48550/arXiv.2209.02976>
- [80] Wang, C.-Y., Bochkovskiy, A. & Liao, H.-Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv*. <https://doi.org/10.48550/arXiv.2207.02696>
- [81] Reis, D., Kupec, J., Hong, J. & Daoudi, A. (2023). Real-Time Flying Object Detection with YOLOv8. *arXiv*. <https://doi.org/10.48550/arXiv.2305.09972>
- [82] Wang, C.-Y., Yeh, I.-H. & Liao, H.-Y. M. (2024). YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. *arXiv*. <https://doi.org/10.48550/arXiv.2402.13616>

- [83] Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J. & Ding, G. (2024). YOLOv10: Real-Time End-to-End Object Detection. *arXiv*. <https://doi.org/10.48550/arXiv.2405.14458>
- [84] Khanam, R. & Hussain, M. (2024). YOLOv11: An Overview of the Key Architectural Enhancements. *arXiv*. <https://doi.org/10.48550/arXiv.2410.17725>
- [85] Tian, Y., Ye, Q. & Doermann, D. (2025). YOLOv12: Attention-Centric Real-Time Object Detectors. *arXiv*. <https://doi.org/10.48550/arXiv.2502.12524>
- [86] Öztel, İ., Yolcu Öztel, G., & Akgün, D. (2022). A hybrid LBP-DCNN based feature extraction method in YOLO: An application for masked face and social distance detection. *Multimedia Tools and Applications*, 82(1), 1565–1583. <https://doi.org/10.1007/s11042-022-14073-7>
- [87] Alam, N. (5 Temmuz 2023). Understanding YOLOv7 Neural Network. Medium. <https://medium.com/@nahidalam/understanding-yolov7-neural-network-343889e32e4e> adresinden 24 Kasım 2025 tarihinde alınmıştır.
- [88] Qian, X., Wu, B., Cheng, G., Yao, X., Wang, W., & Han, J. (2022). Building a Bridge of Bounding Box Regression Between Oriented and Horizontal Object Detection in Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1-9. <https://doi.org/10.1109/TGRS.2023.3256373>
- [89] Ravi, N., Naqvi, S., & El-Sharkawy, M. (2022). BioU: An Improved Bounding Box Regression for Object Detection. *Journal of Low Power Electronics and Applications*, 12(4), 51. <https://doi.org/10.3390/jlpea12040051>
- [90] Qian, X., Jiang, Y., An, X., & Xu, X. (2020). Object detection in remote sensing images based on improved bounding box regression and multi-level features fusion. *Remote Sensing*, 12(1), 143. <https://doi.org/10.3390/rs12010143>
- [91] Sun, D., Yang, Y., Li, M., Yang, J., Meng, B., Bai, R., Li, L., & Ren, J. (2020). A Scale Balanced Loss for Bounding Box Regression. *IEEE Access*, 8, 108438-108448. <https://doi.org/10.1109/ACCESS.2020.3001234>
- [92] Wang, C., & Gong, X. (2022). Bounding box regression with balance for harmonious object detection. *Journal of Visual Communication and Image Representation*, 89, 103665. <https://doi.org/10.1016/j.jvcir.2022.103665>
- [93] Du, S., Zhang, B., Zhang, P., ve Xiang, P. (2021). An Improved Bounding Box Regression Loss Function Based on CIOU Loss for Multi-scale Object Detection. In *2021 IEEE 2nd International Conference on Pattern Recognition and Machine Learning (PRML)*, China, 92-98. <https://doi.org/10.1109/PRML52754.2021.9520717>
- [94] Wang, Q., ve Cheng, J. (2021) LCornerIoU: An Improved IoU-based Loss Function for Accurate Bounding Box Regression. In *2021 International Conference on Intelligent Computing, Automation and Systems (ICICAS)*, China, 377-383, <https://doi.org/10.1109/ICICAS53977.2021.00085>
- [95] Jiang, H., Zhang, X., & Xiang, S. (2023). Non-Maximum Suppression Guided Label Assignment for Object Detection in Crowd Scenes. *IEEE Transactions on Multimedia*, 26, 2207–2218. <https://doi.org/10.1109/TMM.2023.3293333>

- [96] Ge, L., & Dou, L. (2024). Non-Maximum Suppression for Rotated Object Detection During Merging Slices of High-Resolution Images. *IEEE Access*, 12, 149999–150007. <https://doi.org/10.1109/ACCESS.2024.3470815>
- [97] Hosang, J., Benenson, R., & Schiele, B. (2017). Learning non-maximum suppression. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 6469-6477. <https://doi.org/10.48550/arXiv.1705.02950>
- [98] Tang, X.-S., Xie, X., Hao, K., Li, D., & Zhao, M. (2022). A line-segment-based non-maximum suppression method for accurate object detection. *Knowledge-Based Systems*, 251, 108885. <https://doi.org/10.1016/j.knosys.2022.108885>
- [99] Son, S., & Song, B. C. (2025). NMS-KSD: Efficient Knowledge Distillation for Dense Object Detection via Non-Maximum Suppression and Feature Storage. *IEEE Access*, 13, 80723–80736. <https://doi.org/10.1109/ACCESS.2025.3567103>
- [100] Noh, K., Hong, S. K., Makonin, S., & Lee, Y. (2024). Enhancing Object Detection in Dense Images: Adjustable Non-Maximum Suppression for Single-Class Detection. *IEEE Access*, 12, 130253–130263. <https://doi.org/10.1109/ACCESS.2024.3459629>
- [101] Ikotun, A. M., Ezugwu, A. E., Abualigah, L., Abuhaija, B., & Heming, J. (2023). K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data. *Information Sciences*, 622, 178-210. <https://doi.org/10.1016/j.ins.2022.11.139>
- [102] Parlett-Pelleriti, C. M., Stevens, E., Dixon, D., & Linstead, E. J. (2022). Applications of unsupervised machine learning in autism spectrum disorder research: A review. *Review Journal of Autism and Developmental Disorders*, 10, 406–421. <https://doi.org/10.1007/s40489-021-00299-y>
- [103] Su, K., Cao, L., Zhao, B., Li, N., Wu, D., & Han, X. (2024). N-IoU: better IoU-based bounding box regression loss for object detection. *Neural Computing and Applications*, 36, 3049–3063. <https://doi.org/10.1007/s00521-023-09133-4>
- [104] Maier, G., Shevchyk, A., Flitter, M., Gruna, R., Längle, T., Hanebeck, U. D., & Beyerer, J. (2021). Motion-based visual inspection of optically indiscernible defects on the example of hazelnuts. *Computers & Electronics in Agriculture*, 185, 106147. <https://doi.org/10.1016/j.compag.2021.106147>



ÖZGEÇMİŞ

Ad-Soyad : Sultan Murat YILMAZ

ÖĞRENİM DURUMU:

- **Lisans** : 2013, Gazi Üniversitesi, Teknik Eğitim Fakültesi, Bilgisayar Sistemleri Öğretmenliği
- **Lisans** : 2020, Ondokuzmayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği
- **Yükseklisans** : 2019, Düzce Üniversitesi, Bilgisayar Mühendisliği, Bilgisayar Mühendisliği

TEZDEN TÜRETİLEN ESERLER:

- Yılmaz, S.M., Çakar Kaman, S. ve Güler, E. 2025. Hazelnut Kernel Percentage Calculation System with DCIoU and Neighborhood Relationship Algorithm, *Processes*, 13(8), 2414.

DİĞER ESERLER:

- Yılmaz, S.M. ve Çakar Kaman, S. 2023. Yeni Bir Dilimleme Yöntemi Kullanılarak El Yazısı Rakamlarının Tanınması ve Performans Değerlendirmesi, *Sivas Cumhuriyet Üniversitesi Mühendislik Fakültesi Dergisi*, 1(1), 38-47.
- Yılmaz, S.M. ve Şimşek M. 2025. Rule-based monitoring system for Internet of Things (IoT) device, *Artificial Intelligence Studies*, 2(1), 15-19.
- Yılmaz, S.M. (2022, 21-23, Kasım). Kalp Hastalığı Tahmininde Nesnelerin İnterneti Uygulaması. 2. *International Conference on Scientific Research*, Kırşehir, Turkey
- Yılmaz, S.M. ve Şimşek M. (2017, 12-14, Ekim). Rule-based monitoring system for internet of things (IoT) device. *International Symposium on Industry 4.0 and Applications (ISIA 2017)*, Karabük, Turkey

- Yılmaz, S.M. (2019). Nesnelerin İnterneti Cihazları İçin Kural Tabanlı Kontrol Sistemi Geliştirilmesi ve Uygulaması (Yüksek Lisans Tezi). *Düzce Üniversitesi, Fen Bilimleri Enstitüsü, Düzce.*

