

**T.C.
SAKARYA ÜNİVERSİTESİ
İŞLETME ENSTİTÜSÜ**

**BÖBREK TAŞI TÜRÜNÜN TESPİTİ İÇİN NESNE
TANIMLAMA
YÖNTEMLERİ İLE KARAR DESTEK SİSTEMİ
GELİŞTİRME ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

**Bahar ÇAKICI
ORCID: 0009-0001-3630-9777**

Enstitü Anabilim Dalı: Yönetim Bilişim Sistemleri

**Tez Danışmanı: Dr. Öğr. Üyesi Alpaslan KİBAR
ORCID: 0000-0002-6898-1736**

TEMMUZ-2026

Bahar AKICI tarafından hazırlanan “Böbrek Taşı Türünün Tespiti İçin Nesne Tanımlama Yöntemleri İle Karar Destek Sistemi Geliştirme Örneđi” başlıklı bu tez, 24/06/2026 tarihinde Sakarya Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliđi'nin ilgili maddeleri uyarınca yapılan Tez Savunma Sınavı sonucunda başarılı bulunarak, jürimiz tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Alpaslan KİBAR
Sakarya Üniversitesi

Jüri Üyeleri: Prof. Dr. Aykut Hamit TURAN
Sakarya Üniversitesi

Prof. Dr. Erman COŞKUN
Bahçeşehir Üniversitesi

 SAKARYA ÜNİVERSİTESİ	T.C. SAKARYA ÜNİVERSİTESİ İŞLETME ENSTİTÜSÜ TEZ SAVUNULABİLİRLİK VE ORJİNALLİK BEYAN FORMU	Sayfa: 1/1
Öğrencinin		
Adı Soyadı	:	Bahar Çakıcı
Öğrenci Numarası	:	Y239054008
Enstitü Anabilim Dalı	:	Yönetim Bilişim Sistemleri
Enstitü Bilim Dalı	:	Yönetim Bilişim Sistemleri
Programı	:	Yönetim Bilişim Sistemleri
Tezin Başlığı	:	Böbrek Taşı Türünün Tespiti İçin Nesne Tanımlama Yöntemleri İle Karar Destek Sistemi Geliştirme Örneği
Benzerlik Oranı	:	% 4
Sakarya Üniversitesi İşletme Enstitüsü Lisansüstü Tez Çalışması Benzerlik Raporu Uygulama Esaslarını inceledim. Enstitünüz tarafından Uygulama Esasları çerçevesinde alınan Benzerlik Raporuna göre yukarıda bilgileri verilen tez çalışmasının benzerlik oranının herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim. 21 / 05 / 2026 İmza Öğrenci		
Sakarya Üniversitesi İşletme Enstitüsü Lisansüstü Tez Çalışması Benzerlik Raporu Uygulama Esaslarını inceledim. Enstitünüz tarafından Uygulama Esasları çerçevesinde alınan Benzerlik Raporuna göre yukarıda bilgileri verilen öğrenciye ait tez çalışması ile ilgili gerekli düzenleme tarafıma yapılmış olup, yeniden değerlendirilmek üzere gsbttez@sakarya.edu.tr adresine yüklenmiştir. Bilgilerinize arz ederim. / / 20.... İmza Danışman		
Uygundur Danışman Unvanı / Adı-Soyadı: Tarih: / / 20.... İmza:		
☐ Kabul Edilmiştir ☐ Reddedilmiştir EYK Tarih ve No: / / 20.... /		Enstitü Birim Sorumlusu Onayı

ÖNSÖZ

Tez sürecinin her aşamasında değerli yönlendirmeleri, akademik katkıları ve sabrıyla yanımda olan danışmanım Dr. Öğr. Üyesi Alpaslan KİBAR'a en içten teşekkürlerimi sunarım. Çalışmam boyunca manevi desteklerini esirgemeyen değerli aileme ve bu süreçte yanımda olan tüm dostlarıma minnettarlığımı ifade etmek isterim.

Bahar ÇAKICI

24.06.2026

İÇİNDEKİLER

KISALTMALAR	iii
TABLOLAR	v
ŞEKİLLER	vi
ÖZET.....	vii
ABSTRACT	viii

GİRİŞ	1
-------------	---

BÖLÜM 1. KAVRAMSAL ÇERÇEVE.....	4
--	----------

1.1. Böbrek Taşı Hastalığı ve Koruyucu Hekimlik Önerileri.....	4
1.2. Tıbbi Görüntüleme ve Nesne Tespiti	5
1.3. Araştırmanın Konusu ve Kapsamı	6
1.4. Araştırmanın Amacı	7

BÖLÜM 2. LİTERATÜR TARAMASI.....	8
---	----------

2.1. Böbrek Taşı Hastalığı ve Klinik Önemi	8
2.1.1. Böbrek Taşı Türleri	8
2.1.1.1. Kalsiyum Oksalat.....	8
2.1.1.2. Ürik Asit.....	8
2.1.1.3. Sistin.....	9
2.1.1.4. Mikst	9
2.1.1.5. Kalsiyum Fosfat	9
2.2. Tıbbi Görüntü Analizinde Derin Öğrenme	10
2.3. Nesne Tespiti Yöntemleri.....	10
2.3.1. İki Aşamalı Dedektörler: R-CNN Ailesi	10
2.3.2. Tek Aşamalı Dedektörler: YOLO Ailesi.....	11
2.3.3. Transformer Tabanlı Dedektörler: DETR ve RT-DETR.....	11
2.4. Böbrek Taşı Tespitinde Derin Öğrenme Uygulamaları	11
2.5. Karar Destek Sistemleri ve Uzman Sistemler	12
2.6. Literatürdeki Boşluklar.....	13

BÖLÜM 3. YÖNTEM.....	14
-----------------------------	-----------

3.1. Araştırma Tasarımı.....	14
3.2. Veri Seti.....	14
3.2.1. Veri Seti Kaynağı ve Toplama Süreci	14

3.2.2. Ham Görüntülerin Hazırlanması ve Taş Kırpma İşlemi.....	15
3.3. Roboflow Platformu	17
3.3.1. Veri Seti Özellikleri.....	18
3.3.2. Veri Ön İşleme ve Artırma	18
3.4. Hesaplama Ortamı	20
3.4.1. Google Colab Platformu	20
3.4.2. Kaggle Platformu.....	21
3.5. Kullanılan Modeller	22
3.5.1. YOLOv8s.....	23
3.5.2. Faster R-CNN	27
3.5.3. RT-DETR	30
3.5.4. Transfer Öğrenme ve Early Stopping.....	34
3.5.5. Değerlendirme Metrikleri	35
BÖLÜM 4. ANALİZ VE BULGULAR.....	37
4.1. Doğrulama Seti Sonuçları	37
4.2. Test Seti Sonuçları.....	37
4.3. Sınıf Bazlı Analiz	38
4.4. Overfitting Analizi	40
4.5. Veri Dengesizliği Ve Sınıf Temsil Sorunu.....	40
4.6. Hasta Düzeyinde Veri Bölünme Sorunu	41
4.7. Karar Destek Uygulaması	42
SONUÇ VE ÖNERİLER.....	44
TERİMLER SÖZLÜĞÜ	50
KAYNAKÇA	54
EKLER.....	59
ÖZGEÇMİŞ.....	60

KISALTMALAR

ADAMW	: Adaptive Moment Estimation With Weight Decay
AP	: Average Precision
API	: Application Programming Interface
BT	: Bilgisayarlı Tomografi
CNN	: Convolutional Neural Network
COCO	: Common Objects In Context
CPU	: Central Processing Unit
CSP	: Cross Stage Partial Network
CUDA	: Compute Unified Device Architecture
CVPR	: Computer Vision And Pattern Recognition
DETR	: Detection Transformer
ESK	: Elektronik Sağlık Kaydı
EXIF	: Exchangeable Image File Format
FN	: False Negative
FP	: False Positive
FPN	: Feature Pyramid Network
FPS	: Frames Per Second
GAN	: Generative Adversarial Network
GB	: Gigabyte
GFLOPS	: Giga Floating Point Operations Per Second
GPU	: Graphics Processing Unit
HBYS	: Hastane Bilgi Yönetim Sistemi
IOU	: Intersection Over Union
KDS	: Karar Destek Sistemi
KVKK	: Kişisel Verilerin Korunması Kanunu
LR	: Learning Rate
MAP	: Mean Average Precision
MTA	: Maden Tetkik Ve Arama
NMS	: Non-Maximum Suppression
NVIDIA	: Grafik İşlemci
PAN	: Path Aggregation Network
REST	: Representational State Transfer
RESNET	: Residual Network

RG	: Resmî Gazete
RPN	: Region Proposal Network
RT-DETR	: Real-Time Detection Transformer
SEAH	: Sakarya Eğitim Ve Araştırma Hastanesi
SGD	: Stochastic Gradient Descent
SSD	: Single Shot Detector
STEPLR	: Step Learning Rate
TP	: True Positive
UA	: Ürik Asit
VRAM	: Video Random Access Memory
XAI	: Explainable Artificial Intelligence
YOLO	: You Only Look Once

TABLÖLAR

Tablo 1: Veri Seti Bölüm Dağılımı	18
Tablo 2: Veri Ön İşleme ve Artırma Adımları	18
Tablo 3: Kaggle Hesaplama Ortamı Özellikleri	22
Tablo 4: YOLOv8s Eğitim Parametreleri	23
Tablo 5: Faster R-CNN Eğitim Parametreleri	27
Tablo 6: RT-DETR Eğitim Parametreleri	31
Tablo 7: Early Stopping Sonuçları	34
Tablo 8: Doğrulama Seti Model Performans Karşılaştırması	37
Tablo 9: Test Seti Model Performans Karşılaştırması	37
Tablo 10: YOLOv8s Sınıf Bazlı mAP50 Sonuçları	38
Tablo 11: RT-DETR Sınıf Bazlı mAP50 Sonuçları	39
Tablo 12: Faster R-CNN Sınıf Bazlı mAP50 Sonuçları	39
Tablo 13: Val-Test mAP50 Karşılaştırması (Overfitting Göstergesi)	40

ŞEKİLLER

Şekil 1: Toplu Böbrek Taşı Görseli	14
Şekil 2: Roboflow Platformunda Dataset Oluşturma	17
Şekil 3: Kaggle Ortamında Model Eğitim Örnek Görseli	21
Şekil 4: YOLOv8s Eğitim Kodu Örneği	26
Şekil 5: YOLOv8s Confusion Matrix Grafikleri	27
Şekil 6: Faster R-CNN Eğitim Kodu Örneği	30
Şekil 7: RT-DETR Eğitim Kodu Örneği	33
Şekil 8: RT-DETR Confusion Matrix Grafikleri	34
Şekil 9: Hugging Face Spaces Platformunda Böbrek Taşı Analiz Örneği	42

ÖZET

Çakıcı, B. (2026). *Böbrek taşı türünün tespiti için nesne tanımlama yöntemleri ile karar destek sistemi geliştirme örneği* (Yayımlanmamış yüksek lisans tezi). Sakarya Üniversitesi.

Koruyucu hekimliğin özünde hastalıkları başlamadan önlemek ya da en azından yavaşlatmak yatar. Böbrek taşı, bu açıdan dikkat çekici bir örnek: hem dünya genelinde son derece sık görülüyor hem de tedavi edilmezse kronik böbrek yetmezliğine kadar gidebiliyor. Üstelik tedavi sonrasında nüks oranlarının yüksekliği, taşın türünün doğru belirlenmesini ve hastaya özel önleyici adımların planlanmasını gerekli kılıyor.

Bugünkü mevcut klinik süreçlerinde böbrek taşı örnekleri, kimyasal bileşimlerinin analizi için MTA'ya gönderilmek zorunda kalıyor ve bu süreçten elde edilen sonuçların yorumlanması ise hem zaman alıyor hem de hasta açısından ek bir mali yük oluşturuyor. Bu pratik güçlükler nedeniyle hastalar söz konusu süreci sıklıkla ihmal etmekte ve bu da koruyucu hekimlik tavsiyelerinin zamanında alınamamasına yol açmaktadır. Söz konusu boşluğu kapatmak amacıyla bu tezde, böbrek taşı görüntülerinden taş türünü otomatik olarak tespit eden ve koruyucu hekimlik önerileri sunan bir karar destek sistemi modeli geliştirilmesi hedeflenmiştir.

Elimizde hastalara ait toplu şekilde böbrek taşı görüntüleri vardı. Görüntülere kırpma işlemi uygulanarak 338 taş görüntüsü elde edilmiştir. 338 taş görüntüsünden 9 tanesi Roboflow görüntü kalitesinden dolayı reddetmiştir. Bu kapsamda beş farklı böbrek taşı türünü (kalsiyum oksalat, kalsiyum fosfat, ürik asit, sistin ve mikst) kapsayan 329 orijinal görüntüden oluşan bir veri seti kullanılmış. Veriler Roboflow platformu üzerinde %70-20-10 oranında eğitim, doğrulama ve test alt kümelerine ayrılmış ve sistematik veri artırma işlemlerine tabi tutulmuştur. Çalışma süresince kişisel sağlık verilerinin işlenmesinde 6698 sayılı KVKK'ya tam uyum sağlanmıştır. Nesne tespiti için birbirinden farklı mimariye sahip üç model seçildi: tek aşamalı dedektör YOLOv8s, iki aşamalı dedektör Faster R-CNN ve transformer tabanlı RT-DETR. Modellerin eğitimi Kaggle ortamında NVIDIA Tesla T4 GPU kullanılarak gerçekleştirildi. Performans karşılaştırması ise Precision, Recall, F1 skoru, mAP50 ve mAP50-95 metrikleri üzerinden yapıldı.

Analiz bulgular, her üç modelin de böbrek taşı türü tespitinde yüksek performans sergilediğini ortaya koymaktadır. Doğrulama setinde en yüksek performansı RT-DETR sergiledi (mAP50: %99.5, F1: %98.6). Test setinde ise Faster R-CNN mAP50'de %100'e ulaşarak mükemmel bir genelleme kapasitesi ortaya koydu ve F1 skorunda da %98.6 ile aynı düzeyde kaldı. Ama veri setinin az olmasından dolayı istatistiksel güvenilirlik sağlayamadı. RT-DETR'in hem doğrulama hem de test setinde aynı mAP50 değerini (%99.5) koruması, modelin daha önce görmediği verilere tutarlı biçimde uyum sağladığını gösteriyor. En iyi performanslı model olan RT-DETR, Hugging Face Spaces üzerinde web tabanlı bir karar destek sistemi olarak web arayüz üzerinden yayına alındı. Kullanıcılar bu uygulama aracılığıyla böbrek taşı görüntüsünü yükleyerek taş türü tahminine ve Türkçe tedavi önerilerine zaman sıkıntısı olmadan ulaşabileceklerdir. Bu sistem de hasta için önemli ölçüde zaman ve maliyet açısından avantaj sağlayacaktır.

Anahtar Kelimeler: Sağlıkta Yapay Zeka, Böbrek Taşı Türü Tespiti, Koruyucu Hekimlik Karar Destek Sistemi, Görüntü İşleme, Nesne Tespiti

ABSTRACT

Çakıcı, B. (2026). *Development of a decision support system using object detection methods for kidney stone type identification* (Unpublished master's thesis). Sakarya University.

Preventive medicine at its core lies in preventing diseases before they start or at least slowing them down. Kidney stones are a striking example in this regard: they are extremely common worldwide and can lead to chronic kidney failure if left untreated. Moreover, the high rate of recurrence after treatment makes it necessary to correctly identify the type of stone and plan personalized preventive measures for the patient.

In today's existing clinical processes, kidney stone samples have to be sent to the MTA for analysis of their chemical composition interpreting the results obtained from this process is both time-consuming and creates an additional financial burden for the patient. Due to these practical difficulties, patients often neglect the process, which results in not receiving preventive healthcare advice in a timely manner. In this thesis, the aim is to develop a decision support system model that automatically detects the type of kidney stone from kidney stone images and offers preventive medicine recommendations to close the gap.

We had collective kidney stone images of patients. By applying cropping to the images, 338 stone images were obtained. 9 of the 338 stone images were rejected due to Roboflow image quality. In this context, a dataset of 329 original images covering five different types of kidney stones (calcium oxalate, calcium phosphate, uric acid, cystine, and mixed) was used. The data was divided into 70-20-10 training, validation, and test subsets on the Roboflow platform and subjected to systematic data augmentation operations. Full compliance with Law No. 6698 on the Protection of Personal Data was ensured during the study. Three models with different architectures were selected for object detection: the single-stage detector YOLOv8s, the two-stage detector Faster R-CNN, and the transformer-based RT-DETR. The models were trained in the Kaggle environment using an NVIDIA Tesla T4 GPU. Performance comparison was made using Precision, Recall, F1 score, mAP50, and mAP50-95 metrics.

The analysis findings indicate that all three models exhibit high performance in identifying kidney stone types. RT-DETR demonstrated the highest performance on the validation set (mAP50: 99.5%, F1: 98.6%). On the test set, Faster R-CNN demonstrated excellent generalization capacity by reaching 100% in mAP50 and remained at the same level with 98.6% in the F1 score. However, due to the small size of the dataset, statistical reliability could not be ensured. RT-DETR's maintenance of the same mAP50 value (99.5%) on both the validation and test sets indicates that the model adapts consistently to data it has not seen before. The best-performing model, RT-DETR, has been deployed as a web-based decision support system on Hugging Face. Through this application, users can upload kidney stone images and receive stone type predictions and Turkish treatment recommendations without time constraints. This system will also provide significant time and cost advantages for the patient.

Keywords: Artificial Intelligence in Healthcare, Kidney Stone Type Detection, Preventive Medicine Decision Support System , Object Detection, Image Processing

GİRİŞ

Tıbbi görüntü analizi, yapay zeka ile sağlık alanının birleştiği bu alanda son on yılda görüntü teknolojilerindeki ilerleme ile hızlı gelişmeler kaydetmeye devam etmektedir. Derin öğrenme algoritmaları, başta evrimsel ağlar olmak üzere, tıbbi görüntülerin analizinde giderek daha yaygın bir alana sahip olmaktadır (Litjens vd., 2017). Böbrek taşı hastalığı ise hem toplumda ne kadar sık görüldüğü hem de tanı sürecindeki pratik kısıtlamalar nedeniyle yapay zeka destekli karar destek sistemleri için somut ve değerli bir uygulama alanı sunmaktadır.

Böbrek taşı hastalığı oldukça yaygın bir hastalık ve görülme oranı %14,8'e kadar çıkmaktadır ve artmaya devam etmektedir. İlk taş oluşumunun ardından beş yıl içinde tekrarlama ihtimali ise %50'ye ulaşabilmektedir (Khan vd., 2016). Böbrek taşı hastalığı, obstrüktif nefropati, üriner enfeksiyon ve kronik böbrek yetmezliği gibi ciddi komplikasyonlara yol açabilmektedir (Türk vd., 2022). "Hastalığın en kritik özelliği, uygun önlemler alınmadığı takdirde tekrarlama oranı 5 yılda %50'ye, 10 yılda ise %80–90'a ulaşmaktadır (Skolarikos vd., 2024). Bu yüksek tekrarlama riskinin yönetilebilmesi için taşın kimyasal bileşiminin belirlenmesi zorunludur çünkü farklı taş tiplerine özgü metabolik değerlendirme ve diyet tedavisi birbirinden belirgin biçimde farklılaşmaktadır (Pearle vd., 2014).

Bugün böbrek taşı örnekleri kimyasal bileşim analizi için MTA'ya gönderilmek zorundadır. Ne var ki bu süreç pratikte pek işlememektedir, uzun bekleme süreleri, ek mali yük ve transfer(lojistik) zorluklar nedeniyle hastalar çoğunlukla bu adımı atlamaktadır veya unutmaktadır ve sonuçta koruyucu hekimlik önerilerine zamanında ulaşamıyor. Bunun yanı sıra böbrek taşı hastalığının bireysel sağlık üzerindeki etkisi kadar, sağlık sistemleri üzerindeki ekonomik yükü de önemlidir. Taş oluşumunun önlenmesi, yalnızca hasta açısından yaşam kalitesini artırmakla kalmamakta, aynı zamanda tekrarlayan tedavi ve müdahale maliyetlerini azaltarak sağlık sistemine kayda değer bir tasarruf sağlamaktadır. Bu nedenle hastalığın yönetiminde tedavi kadar önleme de merkezi bir rol oynamaktadır. Bu sebeplerden dolayı bu boşluğun kapatılması hem bireysel hasta sağlığı hem de sağlık sisteminin uzun vadeli maliyet yönetimi açısından kritik öneme sahiptir.

Bu genel amaç doğrultusunda çalışma, aşağıdaki araştırma sorularına yanıt aramaktadır:

1. Birbirinden farklı mimari yaklaşımlara sahip nesne tespiti modelleri (tek aşamalı YOLOv8s, iki aşamalı Faster R-CNN ve transformer (dönüştürücü) tabanlı RT-DETR), beş sınıflı böbrek taşı türü tespitinde nasıl bir performans sergilemektedir ve hangi mimari yaklaşım bu göreve daha uygundur?
2. Model seçiminde yalnızca doğruluk metrikleri yeterli midir, yoksa tahmin hızı, genelleme tutarlılığı ve dağıtım uygunluğu gibi faktörler de klinik bir karar destek sistemi için belirleyici midir?
3. Daha önce böbrek taşı türü tespitinde uygulanmamış olan transformer tabanlı RT-DETR modeli, bu alanda geleneksel mimarilere kıyasla nasıl bir performans ve katkı sunmaktadır?
4. En iyi performansı sergileyen model, koruyucu hekimlik önerileri sunan, web tabanlı ve erişilebilir işlevsel bir karar destek sistemine dönüştürülebilir mi?

Bu tez, söz konusu pratik soruna yapay zekâ destekli bir çözüm önermektedir. Araştırmanın temel amacı, YOLOv8s, Faster R-CNN ve RT-DETR nesne tespiti modellerini böbrek taşı görüntüleri üzerinde eğiterek karşılaştırmalı olarak değerlendirmek ve en iyi performansı sergileyen modeli temel alan bir karar destek sistemi geliştirmektir. Bu sistem, böbrek taşı görüntüsünden otomatik taş türü tespiti, türe özgü koruyucu hekimlik önerileri ve web tabanlı erişim imkânı sunmaktadır. Sistemin hasta bakım kalitesini artırması, koruyucu hekimlik hizmetlerine talebi yükseltmesi ve harici laboratuvar ihtiyacını ortadan kaldırarak Analiz ve laboratuvar maliyetlerini önemli ölçüde azaltması beklenmektedir.

Tez, giriş ve sonuç bölümleri dışında dört ana bölümden oluşmaktadır. İlk bölüm kavramsal çerçeveye ayrılmış ve araştırma genel hatlarıyla anlatılmıştır. İkinci bölüm ise literatür taramasına ayrılmış: böbrek taşı hastalığının klinik önemi, tıbbi görüntü analizinde derin öğrenme uygulamaları, nesne tespiti modellerinin gelişim süreci ve karar destek sistemleri bu bölümün odak noktalarını oluşturuyor. Üçüncü bölümde araştırmanın yöntemi aktarılmaktadır. Veri seti, hesaplama altyapısı, modellerin mimarileri ve eğitim parametreleri ele alınmaktadır. Dördüncü bölümde analiz ve bulguları doğrulama seti, test seti ve sınıf bazlı analizler üzerinden anlatılmaktadır ve overfitting(ezberleme) riski de bu analiz sonuçlarından değerlendirilmektedir. Sonuç ve öneriler bölümünde ise çalışmanın temel bulguları açıklanıyor, literatürle karşılaştırma yapılıyor, çalışmanın

sınırlılıkları ele alınmakta ve gelecek arařtırmalara yönelik yapılabilecek öneriler paylaşılmaktadır.

BÖLÜM 1. KAVRAMSAL ÇERÇEVE

1.1. Böbrek Taşı Hastalığı ve Koruyucu Hekimlik Önerileri

Böbrek taşı hastalığı (nefrolitiazis), idrarda çözünmüş hâlde bulunan bazı minerallerin ve tuzların aşırı yoğunlaşarak böbrek içinde katı kristal yapılar oluşturması sonucu ortaya çıkan yaygın bir üriner sistem hastalığıdır. Görülme sıklığı toplumdan topluma değişmekle birlikte %14,8'e kadar çıkabilmekte ve giderek artmaktadır; ilk taş oluşumunun ardından beş yıl içinde tekrarlama ihtimali ise %50'ye ulaşabilmektedir (Khan vd., 2016). Tedavi edilmediği veya nüksü önlenmediği takdirde obstrüktif nefropati, üriner enfeksiyon ve kronik böbrek yetmezliği gibi ciddi komplikasyonlara yol açabilmektedir (Türk vd., 2022).

Böbrek taşının türünün doğru belirlenmesi, ürologların nükse yönelik tedaviyi kişiselleştirmesinin önündeki en temel adımıdır. Böbrek taşı türü doğru belirlenmediği takdirde hastaya uygulanacak tedavi etkili sonuçlar vermeyebilir. Koruyucu hekimliğin genel amacı, mevcut hastalığın oluşmasını/tekrarlamasını engellemek ve etkisini en aza düşürmektir. Bu amacın gerçekleşmediği durumlarda hastalığın ilerleyişini geciktirmek de koruyucu hekimliğin kapsamına alınabilmektedir. Tüm dünyada hayati risk oluşturabilen ve kişiler arasında yaygın olarak görülebilen böbrek taşı rahatsızlığı tedavi edilmezse kronik böbrek hastalıklarına neden olabilir ve dolayısıyla ölümcül bir etki oluşturabilir. Böbrek taşı hastalığının tedavi edildikten sonra tekrarlanma olasılığının da oldukça yüksek olduğu bilinmektedir. Bu hastalığın hekimler tarafından belirlenen uygun tedaviyle tekrarlanmasının önlenmesi için böbrek taşlarının türünün yani ana morfolojik grubunun belirlenmesi oldukça yüksek öneme sahiptir.

Nüks riskinin klinik yönetimi açısından metabolik değerlendirmenin önemi literatürde güçlü biçimde vurgulanmaktadır. Metabolik değerlendirmenin doğru şekilde uygulanması ve bu değerlendirmeye dayalı hedefe yönelik bir tedavi planının oluşturulması, böbrek taşı nüks riskini %90 oranına kadar azaltabilmektedir (Zirker, 2026). Ancak bu potansiyele rağmen klinik pratikte ciddi bir uygulama boşluğu bulunmaktadır. Aynı kaynağa göre semptomatik bir taş atağının ardından hastaların yalnızca %7,4'ü 6 ay içinde gerekli 24 saatlik idrar analizini tamamlayabilmekte, müdahalelerin metabolik riski gerçekten azaltıp azaltmadığını doğrulamak için tekrar test yaptıranların oranı ise %16 ile sınırlı kalmaktadır. Bu veriler, taş türünün ve altta yatan

riskin doğru ve erişilebilir biçimde belirlenmesine yönelik pratik çözümlerin klinik açıdan ne denli kritik olduğunu somut biçimde ortaya koymaktadır. Ülkemizde bu sürecin MTA'ya numune gönderimiyle yürütülmesi ise benzer bir erişilebilirlik sorununu daha da belirgin hâle getirmektedir.

1.2. Tıbbi Görüntüleme ve Nesne Tespiti

Tıbbi görüntüleme, hastanın vücut içindeki yapıları doğrudan görülebilir hâle getiren ve hekime tanı koyma sürecinde görsel bir kanıt sunan yöntemler bütünüdür; bilgisayarlı tomografi, röntgen, ultrason ve bu çalışmada olduğu gibi fotoğraf temelli görüntüler bu kapsama girer. Son yıllarda bu görüntülerin yorumlanması artık yalnızca insan gözüyle değil, derin öğrenme tabanlı algoritmalarla da desteklenmektedir. Bu algoritmalar görüntüdeki örüntüleri (doku, kenar, renk geçişi gibi görsel özellikleri) öğrenerek görüntüyü otomatik biçimde sınıflandırabilmekte veya içindeki nesneleri tespit edebilmektedir. Böylece hem tanı sürecinin hızlanması hem de göz yorgunluğu veya deneyim farkı gibi insan kaynaklı değişkenliğin azaltılması hedeflenmektedir.

Bu çalışmada kullanılan yöntem, görüntü sınıflandırmadan bir adım daha ileridedir. Nesne tespiti, bir görüntüdeki nesnelerin hem konumunu (bounding box) hem de sınıfını aynı anda belirleyen bir görevdir. Bir görüntüde yalnızca "bu bir taşır" demek yerine, taşın görüntü içindeki tam konumunu da işaretleyebilmesi, birden fazla nesnenin bulunduğu görüntülerde her birini ayrı ayrı ele alabilmesini sağlar. Böbrek taşı görüntülerinde taşın sınırlarının ve konumunun belirlenmesi hem görsel doğrulama hem de ileride otomatik ölçüm gibi ek işlevler için önem taşıdığından, bu çalışmada nesne tespiti yaklaşımı tercih edilmiştir.

Nesne tespiti alanında birbirinden farklı üç temel mimari yaklaşım bulunmaktadır ve bu çalışmada her yaklaşımdan güncel birer temsilci karşılaştırmalı olarak kullanılmıştır:

İki aşamalı dedektörler (Faster R-CNN): Önce görüntüde nesne içerebilecek aday bölgeleri belirler, ardından bu bölgeleri sınıflandırır. Bu iki adımlı yapı, özellikle küçük ve belirsiz nesnelerin tespitinde yüksek doğruluk sağlar; bu çalışmada yüksek doğruluk referansı sunması amacıyla kullanılmıştır.

Tek aşamalı dedektörler (YOLOv8s): Nesnenin yerini ve türünü tek bir ağ geçişiyle belirler ve bu sayede hızlıdır. YOLOv8s varyantı, hız ile doğruluk arasında dengeli bir

seenek sunması ve sınırlı veriyle ezberleme riskini azaltması nedeniyle bu alıřmaya dahil edilmiřtir.

Transformer tabanlı dedektörler (RT-DETR): Görüntünün bütününe bağlamıyla birlikte deęerlendirir ve elle tasarlanmış bazı bileřenlere ihtiya duymadan uçtan uca alıřabilir. Bu modelin böbrek tařı türü tespitine bildiđimiz kadarıyla ilk kez bu alıřmada uygulanması, arařtırmaya özgün bir katkı kazandırmaktadır.

Bu üç modelin birlikte seilmesi rastgele deęildir. Ama, birbirinden farklı mimari mantıklara sahip modellerin aynı veri seti üzerindeki performansını sistematik biimde karřılařtırarak böbrek tařı türü tespiti gibi sınırlı veriyle alıřılan bir tıbbi görevde hangi yaklaşımın daha uygun olduđunu ortaya koymaktır. Elde edilen tespit sonuçlarının nihai olarak klinik bir fayda sağlaması için ise bu sonuçların bir karar destek sistemine entegre edilmesi gerekmektedir. Bu sistem, tař türü tahminini kural tabanlı bir mantıkla birleřtirerek türe özgü koruyucu hekimlik önerileri sunabilecek biimde tasarlanmıřtır.

1.3. Arařtırmanın Konusu ve Kapsamı

Bu arařtırmanın konusunu, böbrek tařı görüntülerinden tař türünün nesne tespiti yöntemleriyle otomatik olarak belirlenmesi ve bu tespitin koruyucu hekimlik önerileri sunan bir karar destek sistemine dönüřtürölmesi oluřturmaktadır. alıřma, Sakarya Eđitim ve Arařtırma Hastanesi'nden elde edilen ve beř farklı böbrek tařı türünü (kalsiyum oksalat, kalsiyum fosfat, ürik asit, sistin ve mikst(karışık)) kapsayan görüntüler üzerinde yürütölmüřtür.

Arařtırmanın kapsamı, birbirinden farklı üç mimari yaklařıma sahip nesne tespiti modelinin (tek ařamalı YOLOv8s, iki ařamalı Faster R-CNN ve transformer tabanlı RT-DETR) aynı veri seti üzerinde eđitilmesi, standartlařtırılmış metrikler (mAP50, mAP50-95, Precision, Recall, F1) üzerinden karřılařtırılması ve en iyi performansı sergileyen modelin web tabanlı bir uygulamaya entegre edilmesiyle sınırlıdır. alıřma, modellerin yalnızca görüntü üzerinden tař türü tahmini yapmasına odaklanmakta olup tařın boyutu, yoğunluđu veya hastaya özgü klinik parametreler (yař, cinsiyet, kan/idrar tahlili sonuçları gibi) tespit sürecine dahil edilmemiřtir.

Geliřtirilen karar destek sistemi de kapsam bakımından sınırlıdır ünkü sistem, tař türü tahminine dayalı genel koruyucu hekimlik önerileri sunmakta, ancak bir hekim onay mekanizması içermemekte ve gerek klinik karar alma sürecinin yerini almamaktadır.

1.4. Araştırmanın Amacı

Bu tezin amacı, YOLOv8s, Faster R-CNN ve RT-DETR nesne tespiti modellerini böbrek taşı görüntüleri üzerinde eğiterek karşılaştırmalı biçimde değerlendirmek ve en iyi performansı sergileyen modeli temel alan, koruyucu hekimlik önerileri de sunabilen web tabanlı bir karar destek sistemi geliştirmektir. Böylece MTA sürecinin yarattığı zaman ve maliyet kaybına karşı, hızlı ve erişilebilir bir alternatif ortaya konması hedeflenmektedir.

Araştırmanın özgün katkıları şu başlıklar altında özetlenebilir:

- Türkiye klinik pratiğindeki MTA süreci sorununa yapay zekâ destekli pratik bir çözüm önermektedir.
- Beş sınıflı böbrek taşı veri seti üzerinde üç farklı nesne tespiti mimarisinin sistematik biçimde karşılaştırmaktadır.
- Transformer tabanlı RT-DETR modelinin böbrek taşı sınıflandırmasına bildiğimiz kadarıyla literatürde rastlanmamıştır.
- Geliştirilen modelin Hugging Face Spaces platformu üzerinde kalıcı bir web uygulaması olarak dağıtılmasını hedeflemektedir.
- KVKK'ya uygun veri işleme sürecinin tıbbi görüntü analizine entegre etmektedir.
- Sonuçların görüntülenmesi, raporlanması ve hastalara ulaştırılabilmesi için kullanıcı arayüzü geliştirilmiştir.

BÖLÜM 2. LİTERATÜR TARAMASI

2.1. Böbrek Taşı Hastalığı ve Klinik Önemi

Böbrek taşının türünün doğru belirlenmesi için önündeki en temel adım ürologların nüks yönelik tedaviyi kişiselleştirilebilmesidir. Parks ve Coe'ya (1996) göre böbrek taşı önlemenin ekonomik boyutunu incelemiş ve taş oluşumunun engellenmesinin sağlık sistemi açısından kayda değer mali tasarruf sağladığını ortaya koymuştur. Wong ve diğerleri (2016) ise sistematik bir derlemeyle böbrek taşıyla birlikte seyreden metabolik sendromları mercek altına almıştır. Peerapen ve Thongboonkerd'a (2023) göre taş önlemeye yönelik güncel stratejileri başta beslenme temelli olanları sistematik biçimde derlemiştir. Frassetto ve Kohlstadt'a (2011) göre nüksün büyük ölçüde taş tipine bağlı olduğuna dikkat çekerek tipe özgü önleme yaklaşımlarını tartışmıştır. İdrar yolu taşları, kimyasal bileşimlerine göre sınıflandırılmaktadır.

İdrar yolu taşları kimyasal bileşimlerine göre sınıflandırılmaktadır. Literatürde bildirilen verilere göre tüm böbrek taşların yaklaşık %80'i kalsiyum oksalat (CaOx) ve kalsiyum fosfattan (CaP) oluşur, %10'u struvit (ureaz enzimine sahip bakterilerin neden olduğu enfeksiyon sırasında oluşan magnezyum amonyum fosfat), %9'u ürik asitten (UA) ve kalan %1'i ise sistin veya amonyum asit ürik asitten oluşur (Coe vd., 2005). Bu çalışmada kullanılan veri seti beş böbrek taşı türünü kapsamaktadır: Kalsiyum Oksalat, Kalsiyum Fosfat, Ürik Asit, Sistin ve Mikst (karışık) taşlar çalışmada ele alınmıştır.

2.1.1. Böbrek Taşı Türleri

2.1.1.1. Kalsiyum Oksalat

Tüm böbrek taşlarının yaklaşık %80'ini oluşturan en yaygın kalsiyum bazlı taş türlerinden birisidir (Coe vd., 2005). Hiperoksalüri, hiperkalsüri ve hipositratüri temel risk faktörleridir. Yüksek oksalatlı besinlerden kaçınmak, bol sıvı tüketimi ve yeterli kalsiyum alımı koruyucu hekimlik önerileri arasında yer almaktadır. Kalsiyum içeren taşlar, organik kaynaklı taşların aksine, düz röntgen filmlerinde görüntülenebilmektedir.

2.1.1.2. Ürik Asit

Ürik asit taşları, pürinin metabolizması sonucu oluşan ürik asidin idrarda aşırı birikmesi veya idrar pH'nın kronik olarak düşmesi ($\text{pH} < 5,5$) ile meydana gelmektedir (Türk vd.,

2022). Taşların %5-10'unu oluşturan bu tür, gut hastalığı, diyabet ve obezite ile ilişkilidir (Wiederkehr ve Moe, 2011). Yaygın görülen taş türlerinden birisi olup genellikle kahverengi veya pas rengindedir ve düzgün yüzeylidir (Daudon vd., 2016). İdrar pH'nın alkalileştirilmesi yoluyla tıbbi tedaviyle eritebildiği bilinen tek taş türü olması nedeniyle doğru teşhis büyük önem taşımaktadır (Pearle vd., 2014).

2.1.1.3. Sistin

Sistin taşları, otozomal resesif geçiş gösteren sistinüri adlı nadir genetik bir bozukluk sonucu ortaya çıkmaktadır. Bu bozuklukta böbrek tübülleriindeki sistin taşıyıcı proteinlerini kodlayan genlerdeki mutasyonlar nedeniyle sistin aminoasidinin geri emilimi bozulmakta ve sistin idrarda aşırı miktarda atılmaktadır (Türk vd., 2022). Sistin taşları tüm taşların %1'inden azını oluşturur ve genellikle saf sistinden oluşur (Daudon vd., 2016). Sarı renkli ve düzgün, mumsu bir yapıya sahiptir. Altıgen şeklinde bir kimyasal yapıya sahiptir ve bu yönüyle diğer taşlardan ayırt edilebilir düzeydedir. Çok yüksek sıvı alımı ve potasyum sitrat tedavisi gerektirir ve genetik danışmanlık önerilir (Daudon vd., 2016).

2.1.1.4. Mikst

Mikst taşlar, birden fazla kimyasal bileşenin bir arada bulunduğu taşlardır. En sık karşılaşılan karışım taşları arasında kalsiyum oksalat ile kalsiyum fosfatın ya da kalsiyum oksalat ile ürik asidin bir arada bulunduğu formlar öne çıkmaktadır (Knoll vd., 2011; Türk vd., 2022). Bu tür taşların oluşması çoğunlukla birden fazla metabolik bozukluğun aynı anda var olduğuna işaret eder bu da hem tanıyı hem de tedavi planlamasını zorlaştırır (Pearle vd., 2014). Bu çalışmada mikst kategori, kalsiyum oksalat, kalsiyum fosfat ve ürik asit gibi bileşenlerden en az ikisini baskın oranda barındıran taş örneklerini kapsamaktadır.

2.1.1.5. Kalsiyum Fosfat

Ana bileşeni CaP olan, yani en az %50 CaP içeren taşlar, deneyimlerimize göre tüm serinin %8,6'sını ve kalsiyum taşlarının %21,7'sini oluşturmaktadır. CaP taşları, çoklu kristal formları nedeniyle oldukça heterojen bir gruptur (Daudon vd., 2016). Tedavide altta yatan metabolik bozukluğun giderilmesi ve asidik idrar ortamının sağlanması temel hedeflerdir. Bu taş türü, kalsiyum oksalat taşlarıyla karışık hâlde de bulunabilmektedir.

2.2. Tıbbi Görüntü Analizinde Derin Öğrenme

Krizhevsky ve diğerleri (2017) tarafından geliştirilen AlexNet, ImageNet yarışmasındaki dikkat çekici başarısıyla derin öğrenmeyi tıbbi görüntü analizinin gündemine taşımıştır. Litjens ve diğerleri (2017) bu alandaki uygulamaları kapsamlı biçimde incelemiş; radyoloji ve patoloji başta olmak üzere pek çok alanda derin öğrenme yöntemlerinin geleneksel yaklaşımları geride bıraktığını göstermiştir. He ve diğerleri (2016) tarafından önerilen ResNet ise artık bağlantı (residual connection) mekanizmasıyla çok katmanlı ağların eğitilmesinin önündeki en büyük engellerden birini aşmıştır ve bu sayede derin öğrenme tıbbi görüntü analizinde çok daha geniş bir kullanım alanı bulmuştur.

Yosinski ve diğerleri (2014), ImageNet gibi büyük veri setleri üzerinde önceden eğitilmiş nesnelerin tıbbi görüntüleme görevlerine başarıyla aktarılabildiğini gösterdi. Bu bulgu, etiketli verinin kısıtlı olduğu durumlarda transfer öğrenmenin ne denli kritik bir rol oynadığını açıkça ortaya koymuştur. Shorten ve Khoshgoftaar'a (2019) göre ise derin öğrenme için görüntü veri artırma yöntemlerini geniş bir perspektiften ele aldı ve geometrik dönüşümlerden renk uzayı manipülasyonlarına, oradan üretici çekişmeli ağlara (GAN) uzanan geniş bir teknik yelpazesini incelemiştir. Yapılan çalışmada özellikle de tıbbi görüntü analiz çalışmalarında veri setinin az veya erişiminin sınırlı olduğu zamanlarda veri artırmanın önemi tartışılmaz ve veri artırmanın en büyük avantajlarından birisi de modelin overfitting riskini en aza indirmesidir. Literatürde yerleşik kabul gören yaklaşıma göre veri artırma yalnızca eğitim setine uygulanmalıdır. Doğrulama ve test setleri ise modelin gerçek koşullardaki performansını tarafsız ve doğru ölçebilmek için orijinal görüntülerden oluşturulmalıdır.

2.3. Nesne Tespiti Yöntemleri

2.3.1. İki Aşamalı Dedektörler: R-CNN Ailesi

Girshick ve diğerleri (2014) tarafından önerilen R-CNN, derin evrişimli ağları bölge önerileriyle birleştiren ilk modern nesne tespiti mimarisi olarak iki aşamalı yaklaşımın temelini oluşturmuştur. Girshick (2015) tarafından geliştirilen Fast R-CNN, çok görevli kayıp fonksiyonu ve tek aşamalı eğitim stratejisiyle R-CNN'e kıyasla eğitimde 9 kat, test sürecinde ise 213 kat hız artışı sağlamıştır. Ren ve diğerleri (2015) tarafından önerilen Faster R-CNN, Region Proposal Network (RPN) aracılığıyla bölge önerisi üretimini tespit ağıyla paylaşılan evrişimsel özellikler üzerinde gerçekleştirerek bu hesaplama

maliyetini neredeyse sıfıra indirmiştir. Bu iki aşamalı yapı, küçük ve belirsiz nesnelerin tespitinde güçlü sonuçlar sunarken görece daha yüksek hesaplama maliyetine sahiptir.

2.3.2. Tek Aşamalı Dedektörler: YOLO Ailesi

Lin ve diğerleri (2017) tarafından geliştirilen Feature Pyramid Network (FPN), farklı ölçeklerdeki nesneleri daha etkin biçimde temsil eden çok ölçekli özellik piramidi yapısıyla iki aşamalı mimarilerin küçük nesne tespitindeki sınırlılıklarını önemli ölçüde gidermiştir. Redmon ve diğerleri (2016) tarafından önerilen YOLO (You Only Look Once), nesne tespitini tek bir sinir ağı geçişiyle gerçekleştirerek gerçek zamanlı uygulamalar için uygun bir hız-doğruluk dengesi sunmaktadır. Jocher ve diğerleri (2023) tarafından geliştirilen YOLOv8, çapa bağımsız (anchor-free) tespit başı, güncellenmiş C2f blokları ve gelişmiş veri artırma stratejileriyle YOLO serisinin en güncel versiyonunu temsil etmektedir. YOLOv8s varyantı 11,1 milyon parametre ve 28,4 GFLOPs hesaplama maliyetiyle hız ve doğruluk açısından dengeli bir seçenek sunmaktadır. YOLOv8'in resmi bir akademik makalesi bulunmamakta olup kaynak olarak Ultralytics yazılım deposu gösterilmektedir.

2.3.3. Transformer Tabanlı Dedektörler: DETR ve RT-DETR

Carion ve diğerleri (2020) tarafından önerilen DETR (Detection Transformer), transformer mimarisini nesne tespitine uyarlayan ve NMS gibi elle tasarlanmış bileşenleri ortadan kaldıran öncü bir uçtan uca tespit modelidir. Zhao ve diğerleri (2024) tarafından geliştirilen RT-DETR (Real-Time DETECTION TRAnsformer), hybrid encoder (hibrit kodlayıcı) yapısı ve IoU-aware query selection (sorgu seçimi) mekanizmasıyla DETR tabanlı mimarilerde gerçek zamanlı çıkarım hızına ulaşmıştır. RT-DETR-L, COCO val2017 üzerinde %53,0 AP ve T4 GPU'da 114 FPS performansı ile aynı ölçekteki YOLO modellerini hem hız hem doğruluk açısından geride bırakmıştır.

2.4. Böbrek Taşı Tespitinde Derin Öğrenme Uygulamaları

Derin öğrenme algoritmalarının görüntülerdeki karmaşık örüntüleri yakalayabilme kapasitesi, son yıllarda böbrek taşı türü tahminine olan ilgiyi belirgin biçimde artırmıştır. Abraham ve diğerleri (2022) tarafından gerçekleştirilen çalışmada böbrek hastalarını taş bileşeni ve idrar testi sonuçlarını kullanarak makine öğrenmesi yöntemlerinden XGBoost ve lojistik regresyon algoritmalarını kullanarak taş kompozisyonunun tahmini gerçekleştirilmiştir. XGBoost ile eğitilen model %71, lojistik regresyon ile eğitilen model

ise %91 doğruluk oranına ulaşmıştır. Bu sonuçların böbrek taşı hastaları için daha önce yönlendirilmiş tıbbi tedaviye yol gösterici olabileceği belirtilmiştir. El Beze ve diğerleri (2022), Inception V3 modelini XGBoost algoritmasıyla karşılaştırdı; Inception V3, taş türleri için %94 ile %99 arasında doğruluk oranı yakalayarak makine öğrenmesi tabanlı rakibini geride bırakmıştır. Lopez ve diğerleri (2021), derin evrişimli sinir ağları tabanlı yaklaşımlar (AlexNet, VGG19 ve Inception) ve geleneksel makine öğrenmesi yöntemleri (Rastsal Orman ve XGBoost) dahil olmak üzere beş sınıflandırma yöntemini karşılaştırmıştır. En iyi yöntem olarak Inception, dört sınıfta %98 ve %97 kesinlik ve duyarlılık değerlerine ulaşmıştır. Black ve diğerleri (2020) çalışmasında ise Deep CNN ve ResNet-101 modellerinin kombinasyonu kullanılmıştır.

Onal ve Tekgül'e (2022) göre farklı bir yol izleyerek akıllı telefon mikroskobu ve derin evrişimli sinir ağlarını bir araya getirdi ve bu kombinasyonla dört farklı böbrek taşı türünü sınıflandırabilen bir görüntü tanıma sistemi önerdi. Çalışma, akıllı telefon teknolojisinin yapay zeka ile buluşturulmasının hekimlerin karar süreçlerini destekleme potansiyeli taşıdığına da dikkat çekmektedir. Literatüre genel olarak bakıldığında, böbrek taşı türü tahminine yönelik çeşitli makine öğrenmesi ve derin öğrenme modellerinin geliştirildiği görülüyor. Ancak bu modelleri bir uzman sistemle tamamlayarak koruyucu hekimlik kapsamında türü inceleyip hekimlik bilgisi verebilen bir karar destek sistemi çalışmalarına henüz rastlanmamıştır.

Bununla birlikte literatürdeki çalışmaların büyük bölümü yalnızca taşın var olup olmadığını ya da boyutunu belirlemeye odaklanıyor o yüzden çok sınıflı taş türü tespitine yönelik çalışmalar ise oldukça az olduğu görülmektedir. Bu çalışma tam da bu boşluğu doldurmayı hedefliyor: beş farklı taş türünü kapsayan çok sınıflı bir sınıflandırma görevi, RT-DETR'nin böbrek taşı tespitine ilk kez uygulanması ve bir karar destek sistemiyle entegrasyon her üç boyutuyla da literatüre özgün bir katkı sunuyor.

2.5. Karar Destek Sistemleri ve Uzman Sistemler

Karar destek sistemleri (KDS), Turban ve diğerleri (2005) tarafından kapsamlı biçimde tanımlandığı üzere, karar vericilere karmaşık ve yapılandırılmamış problemlerin çözümünde yol gösteren bilgisayar tabanlı araçlardır. Tıbbi KDS'ler bu işlevi yapay zeka ve makine öğrenmesi yöntemlerini klinik veriyle birleştirerek yerine getirir. Tanı, tedavi planlaması ve hastalık yönetiminde hekimlere somut destek sağlar. Bu sistemlerin omurgasını bilgi tabanı, çıkarım motoru ve kullanıcı arayüzü oluşturur.

Shortliffe ve Cimino (2014) tarafından ele alınan kural tabanlı uzman sistemler, alan uzmanlarının bilgisini IF-THEN kuralları biçiminde kodlayarak otomatik çıkarım yapabiliyor. Şeffaflığı, açıklana bilirliği ve klinik pratiğe uyumu bu yaklaşımı tıbbi uygulamalarda cazip kılan başlıca özelliklerindendir. Bu tezde geliştirilen sistemde derin öğrenme tabanlı taş türü tespiti, kural tabanlı bir uzman sisteme entegre edilerek türe özgü koruyucu hekimlik önerileri otomatik olarak üretilmektedir.

Wolf ve diğerleri (2020) tarafından geliştirilen Hugging Face Transformers kütüphanesi, makine öğrenmesi modellerinin birleşik bir API aracılığıyla araştırmacılar ve uygulayıcılar tarafından erişilebilir hale getirilmesinde standart bir açık kaynak altyapısı sunmaktadır. Bu altyapı sayesinde mobil uygulama geliştirme, hastane bilgi sistemleri entegrasyonu ve klinik karar destek sistemlerine entegrasyon için kritik bir temel oluşturmaktadır.

2.6. Literatürdeki Boşluklar

Mevcut literatür incelendiğinde üç temel boşluk dikkat çekmektedir: (1) Böbrek taşı türü tespitine odaklanan çok sınıflı sınıflandırma çalışmalarının azlığı, (2) RT-DETR gibi güncel transformer tabanlı mimarilerin bu alana uygulanmaması, (3) Tespit modellerinin koruyucu hekimlik önerileri sunan bir karar destek sistemiyle entegre edilmemiş olması.

Bu çalışma; YOLOv8s, Faster R-CNN ve RT-DETR modellerini beş sınıflı böbrek taşı veri seti üzerinde sistematik biçimde karşılaştırarak ve en iyi performanslı modeli web tabanlı bir karar destek sistemine entegre ederek bu boşlukları kapatmayı hedeflemektedir. Türkiye klinik pratiğindeki MTA süreci sorununa pratik bir çözüm önerilmesi ise çalışmanın yerel özgünlüğünü oluşturmaktadır.

Bu çalışmada literatür taraması Google Scholar, PubMed, IEEE Xplore ve ScienceDirect veri tabanları kullanılarak gerçekleştirilmiştir. Tarama sürecinde kullanılan başlıca anahtar kelimeler şunlardır: "kidney stone detection deep learning", "nephrolithiasis artificial intelligence", "object detection medical imaging", "YOLOv8 medical image analysis", "Faster R-CNN object detection", "RT-DETR real-time detection transformer", "decision support system urology", "preventive medicine kidney stone" ve bunların Türkçe karşılıkları. İlk taramada ulaşılan yaklaşık 80 çalışma başlık ve özet düzeyinde incelenmiş ve konu ile doğrudan ilgili, metodolojik açıdan uyumlu 48 çalışma analiz edilerek teze dahil edilmiştir.

BÖLÜM 3. YÖNTEM

3.1. Araştırma Tasarımı

Bu tez, nicel bir araştırma deseni benimsemektedir. Araştırma; veri toplama ve ön işleme, model eğitimi ve değerlendirme, karar destek sistemi geliştirme ve dağıtım olmak üzere dört temel aşamadan oluşmaktadır. Nesne tespiti modellerinin karşılaştırmalı değerlendirmesi, standartlaştırılmış metrikler (mAP50, mAP50-95, Precision, Recall, F1) üzerinden gerçekleştirilmiştir. Araştırma modelinde veri seti üç modele (YOLOv8s, Faster R-CNN, RT-DETR) paralel olarak uygulanmış ve elde edilen sonuçlar bir karar destek sistemi çerçevesinde değerlendirilmiştir.

3.2. Veri Seti

Projede kullanılan veri seti 18 bireyden alınmış toplu taş görüntüleri ile kırpma işlemi uygulanarak 338 adet taş görüntüsü ile elde edilerek veri seti oluşturulmuş olup taş görüntülerini etiketleme, çoğaltma ve dışa aktarma için Roboflow ortamı kullanılmıştır.

3.2.1. Veri Seti Kaynağı ve Toplama Süreci

Şekil 1

Toplu Böbrek Taşı Görseli



Projede kullanılacak olan Şekil 1’de görüldüğü üzere böbrek taşı görüntü verileri kanunlar ve yönetmeliklere uygun olarak, Sakarya Eğitim ve Araştırma Hastanesi

(SEAH)’nden elde edilmiştir. Proje kapsamında hastalardan elde edilen böbrek taşına ilişkin analiz verilerinin yapay zeka kapsamında işlenmesi ve anonimleştirilmesi konusunda, Kişisel Verilerin Silinmesi, Yok Edilmesi veya Anonim Hale Getirilmesi Hakkında Yönetmelik (RG. 28.10.2017/30224) hükümleri uygulanacaktır. Yönetmeliğin "Kişisel verilerin anonim hale getirilmesi" başlıklı 10. maddesine göre, kişisel verilerin anonim hale getirilmesi, kişisel verilerin başka verilerle eşleştirilse dahi hiçbir surette kimliği belirli veya belirlenebilir bir gerçek kişiyle ilişkilendirilemeyecek hale getirilmesidir. Yönetmeliğin "Kişisel verilerin anonim hale getirilmesi" başlıklı 10. maddesine göre, kişisel verilerin anonim hale getirilmesi, kişisel verilerin başka verilerle eşleştirilse dahi hiçbir surette kimliği belirli veya belirlenebilir bir gerçek kişiyle ilişkilendirilemeyecek hale getirilmesidir. Proje kapsamında, elde edilen ve yapay zeka sistemine yüklenen analiz verilerinin anonim hale getirilmesinde verinin niteliği, büyüklüğü, çeşitliliği, güvenilirliği vb. gerekçeler ile doğru yöntem belirlenecektir (bkz. Kişisel Verilerin Silinmesi, Yok Edilmesi veya Anonim Hale Getirilmesi Rehberi, KVKK Yayınları, Ankara 2018, ss.15-35). Elde edilen taş görüntüleri için Etik Kurul Onayı alınmıştır ve ekler kısmında gösterilecektir.

Verilerin toplanacağı örneklem grubu veri setinde çeşitlilik olması açısından ürik asit, kalsiyum oksalat, kalsiyum fosfat, sistin, mikst gibi taş türü gruplarından yeterli sayıda görüntü bulundurulmasına özen gösterilecektir. SEAH’ta bulunan 18 bireyden alınmış 338 adet taş görüntüsü vardır. Böbrek taşı görüntüleri, başlangıçta birden fazla taşın bir arada bulunduğu toplu fotoğraflar şeklinde elde edilmiştir. Kırpma işlemleri uygulanarak 338 görüntüye ulaşılmıştır. Analize hazır hale getirilen böbrek taşı görüntülerinin taş türlerine dayalı olarak etiketlenmesi işleminde MTA’dan gelen sonuçlardan faydalanılacaktır.

3.2.2. Ham Görüntülerin Hazırlanması ve Taş Kırpma İşlemi

Bu çalışmada kullanılan böbrek taşı görüntüleri başlangıçta birden fazla taşın bir arada görüldüğü toplu fotoğraflardan oluşmaktadır. Çalışmada uygulanan kırpma işleminin, model eğitiminden ayrı ve ondan önce gerçekleştirilen bir veri hazırlama adımı olduğunu vurgulamak gerekmektedir. Ham görüntüleri doğrudan modele beslemek yerine, her taş ayrı ayrı kırparak bağımsız görüntüler elde etme yolu tercih edilmiştir. Bu karar iki temel gerekçeye dayanıyor: veri setinin çeşitliliğini artırmak ve modelin bireysel taş özelliklerini daha iyi kavramasını sağlamak. Bu hâliyle her görüntü birden çok ve farklı

türde taş içerebildiğinden, doğrudan model eğitime uygun değildir. Bu nedenle kırpma işlemi, Python ile yazılan özel bir betik aracılığıyla Jupyter Notebook ortamında gerçekleştirilmiştir (Kluyver vd., 2016). Kırpma işlemi tamamlandıktan sonra görüntüler veri artırma sürecine tabi tutulmuş ve ardından model eğitimi gerçekleştirilmiştir. Model eğitimi sırasında herhangi bir kırpma işlemi yapılmamıştır. Modeller yalnızca önceden hazırlanmış bu görüntüler üzerinde eğitilmiştir. Dolayısıyla kırpma, ham verinin analize uygun hâle getirilmesini sağlayan bir ön işleme adımı olarak değerlendirilmelidir; eğitim sürecinin bir parçası değildir. Bu hazırlık yönteminin doğal bir sonucu olarak, her görüntüde taş merkezi konumda ve çerçevenin büyük bölümünü kaplayacak biçimde yer almaktadır. Bu durum, modellerin taşın görüntü içindeki konumunu belirleme yükünü azaltarak öğrenme görevini büyük ölçüde tür ayırımına indirgemektedir. Söz konusu kontrollü görsel yapı, modellerin yüksek performans elde etmesine katkı sağlamaktadır.

İşlem dört aşamadan oluşmaktadır:

Taş Tespiti (detect_stones): Ham görüntüler önce gri tonlamaya çevrildi, ardından Gaussian bulanıklaştırma (GaussianBlur, 7×7 çekirdek) ile gürültü baskılanmıştır. Otsu eşikleme yöntemiyle ikili (binary) görüntü otomatik olarak türetilmiştir (Otsu, 1979). Morfolojik kapama ve açma işlemleriyle de nesne sınırları belirginleştirildi (Gonzalez ve Woods, 2018). Dış konturlar tespit edilerek her kontur için alan, dışbükey gövde (convex hull) tabanlı katılık (solidity), en boy oranı (aspect ratio) ve kenar konumu gibi geometrik özellikler hesaplanmıştır. Yalnızca belirlenen eşik değerlerini karşılayan konturlar geçerli taş adayları olarak kabul edilmiştir. Alan filtresi olarak görüntü alanının %0,3 ile %70'i arasında kalan nesneler, katılık değeri 0,25'in üzerinde olanlar ve en boy oranı 5,0'in altında kalanlar seçim kriterlerine dahil edilmiştir.

Kırpma ve Doğrulama (crop_contour / is_valid_crop): Geçerli bulunan her kontur için sınırlayıcı kutu (bounding box) koordinatlarına 15 piksellik dolgu (padding) eklenerek görüntü kırpılmış ve 224×224 piksel boyutuna yeniden ölçeklendirilmiştir. Kırpılan görüntüler, ortalama parlaklık ve koyu piksel oranı kriterleri açısından değerlendirilmiş ve fazla parlak veya yetersiz doku içeren görüntüler reddedilerek veri seti dışında bırakılmıştır.


Izgara Görselleştirmesi: Her taş türü için kırpılan görüntüler bir ızgara (grid) düzeninde birleştirilerek özet bir görsel oluşturulmuş ve çıktı klasörüne kaydedilmiştir.

Kırpma işlemi beş böbrek taşı türü üzerinde uygulanmıştır: Kalsiyum Oksalat, Kalsiyum Fosfat, Ürik Asit, Sistin ve Mikst. İşlem sonucunda toplam 338 bireysel taş görüntüsü başarıyla elde edilmiştir. Türler gere dağılım incelendiğinde Kalsiyum Oksalat türünden 137, Ürik Asit türünden 82, Sistin türünden 57, Kalsiyum Fosfat türünden 53 ve Mikst türünden 9 görüntü elde edildiği görülmektedir. Kırpma işlemi sonucunda elde edilen 338 görüntünün tamamı, betiğin kendi doğrulama adımından (parlaklık ve doku kontrolü) başarıyla geçmiştir. Mikst sınıfındaki yetersiz görüntü sayısı olduğundan dolayı mikst grubunun sonuçları daha ihtiyatlı şekilde yorumlanması gerekmektedir.

3.3. Roboflow Platformu

Şekil 2

Roboflow Platformunda Dataset Oluşturma



Roboflow, bilgisayarla görüntü projeleri için veri yönetimi, etiketleme, veri artırma ve dışa aktarma işlemlerini tek çatı altında sunan bulut tabanlı bir platformdur (Dwyer vd., 2022). Bu çalışmada ham böbrek taşı görüntüleri Şekil 2’de görüldüğü üzere Roboflow üzerinde etiketlendi, veri artırma uygulanmıştır ve YOLOv8 formatında dışa aktarılmıştır. Kişisel sağlık verilerinin işlenmesinde 6698 sayılı KVKK'ya uygunluk gözetilmektedir ve görüntüler anonimleştirilerek yalnızca taş morfolojisine odaklanan bir veri seti oluşturulmuştur.

3.3.1. Veri Seti Özellikleri

Tablo 1

Veri Seti Bölüm Dağılımı

Alt Küme	Orijinal Görüntü	Augmente Görüntü	Oran
Eğitim (Train)	230	2300	%70
Doğrulama (Val)	66	66	%20
Test	33	33	%10
Toplam	329	2399	%100

Çalışmada kullanılan veri seti, beş farklı böbrek taşı türünü kapsayan orijinal görüntülerden oluşmaktadır. Elde edilen ilk toplu görüntüler ile Python yardımı ile görüntülerdeki taşlara kırpma işlemi uygulanmıştır. Kırpma işlemi uyguladıktan sonra 338 orijinal görüntüye ulaşılmıştır. Roboflow ortamına data seti aktarırken platformun kendi otomatik kalite denetimi sonucunda 9 görüntüyü reddetmiştir. Roboflow, yükleme sırasında bozuk veya okunamayan dosyaları, birbirinin tıpatıp kopyası olan görüntüleri ve geçerli boyut ölçütlerini karşılamayan görüntüleri otomatik olarak filtrelemektedir (Dwyer vd., 2022). Roboflow platformu aracılığıyla %70-20-10 oranında eğitim, doğrulama ve test alt setlerine bölme uygulanmıştır ve beş sınıf için etiketleme yapılmıştır. Roboflow aracılığıyla veri artırma tekniği uygulanarak eğitim seti 230 görüntüden 2300 görüntüye çıkarılmıştır.

3.3.2. Veri Ön İşleme ve Artırma

Eğitim setine yönelik veri artırma işlemleri Tablo 2’deki gibi uygulanmıştır:

Tablo 2

Veri Ön İşleme ve Artırma Adımları

İşlem	Parametre	Uygulama Seti
Auto-Orient	EXIF meta verisi düzeltilmesi	Tümü
Resize	640×640 piksel (Stretch)	Tümü
Yatay/Dikey Aynalama	%50 olasılık	Yalnızca Train
90° Döndürme	CW, CCW, Ters	Yalnızca Train
Shear	±10° yatay/dikey	Yalnızca Train

Tablolar devamı

Parlaklık	$\pm\%25$ rastgele	Yalnızca Train
Gaussian Blur	0-1.5 piksel	Yalnızca Train
Salt & Pepper Gürültü	%1 piksel	Yalnızca Train
Augmentation Katsayısı	10x	Yalnızca Train

Tablo 2'de uygulanan veri ön işleme ve artırma adımları aşağıda açıklanmıştır. Bu adımların bir kısmı (Auto-Orient ve Resize) tüm veri setine uygulanırken, geri kalan artırma işlemleri yalnızca eğitim setine uygulanmıştır. Veri artırmanın yalnızca eğitim setine uygulanması, makine öğrenmesi literatüründe yerleşik bir standarttır (Shorten ve Khoshgoftaar, 2019). Doğrulama ve test setleri orijinal görüntülerden oluşturularak modelin gerçek dünya performansının ölçülmesi sağlanmıştır (Goodfellow vd., 2016).

Auto-Orient (Otomatik Yön Düzeltme): Dijital fotoğraflar, çekildikleri cihaza göre dosyanın içinde gizli bir yön bilgisi (EXIF meta verisi) taşır. Bu bilgi bazen görüntünün yanlış yönde (örneğin yan yatmış olarak) işlenmesine yol açar. Auto-Orient işlemi bu gizli yön bilgisini okuyup düzelterek tüm görüntülerin tutarlı biçimde, doğru yönde olmasını sağlar. Bu adım tüm sete uygulanmıştır çünkü amaç veriyi çeşitlendirmek değil, baştan tutarlı hâle getirmektir.

Resize (Yeniden Boyutlandırma): Modele verilen tüm görüntülerin aynı boyutta olması gerekir. Bu adımda her görüntü 640×640 piksel boyutuna getirilmiştir. Parantez içindeki "Stretch" (esnetme), görüntünün en-boy oranı korunmadan hedef boyuta doğrudan gerilerek uydurulduğu anlamına gelir. Bu boyut, üç modelin de standart çalışma çözünürlüğüyle uyumludur ve tüm sete uygulanmıştır.

Yatay/Dikey Aynalama: Bu işlem, görüntünün ayna görüntüsünü almaktadır; yani sağ-sol veya alt-üst ters çevrilmiş bir kopyasını üretir. Tablodaki "%50 olasılık", her eğitim görüntüsünün yarı yarıya ihtimalle aynalayacağı anlamına gelir. Bunun amacı, modelin bir taşı hangi yönden görürse görsün tanıyabilmesini sağlamaktır; çünkü bir taş ister düz ister ayna görüntüsü olsun aynı türdür.

90° Döndürme: Görüntü 90 derecelik açılarla döndürülür; tablodaki "CW, CCW, Ters" sırasıyla saat yönünde, saat yönünün tersine ve 180 derece döndürmeyi belirtir. Bu da modelin taşı farklı açılardan tanımasını öğretir. Taşların görüntüye yerleştirilme yönü sabit olmadığı için, bu çeşitlilik modelin yöne bağımlı kalmasını engeller.

Shear (Kaydırma/Eğme): Bu işlem, görüntüyü bir paralelkenar gibi hafifçe eğer; sanki görüntünün üst kenarı bir yöne, alt kenarı diğer yöne kaydırılmış gibidir. Tablodaki " $\pm 10^\circ$ yatay/dikey", bu eğmenin en fazla 10 derecelik bir açıyla yapıldığını gösterir. Bu hafif geometrik bozma, modelin taşları birebir aynı açıdan değil, küçük perspektif farklarıyla da tanıyabilmesini sağlar.

Parlaklık: Görüntünün aydınlık düzeyi rastgele biçimde artırılır veya azaltılır; tablodaki " $\pm 25\%$ ", parlaklığın en fazla yüzde 25 oranında değiştirildiğini belirtir. Gerçek hayatta fotoğraflar farklı ışık koşullarında çekilir; bu işlem modelin aydınlık ya da karanlık çekilmiş görüntülerde de aynı taşı tanıyabilmesini sağlar.

Gaussian Blur (Bulanıklaştırma): Görüntüye hafif bir bulanıklık eklenir; tablodaki "0-1.5 piksel" bu bulanıklığın şiddetini gösterir. Bu işlem, net olmayan veya düşük kaliteyle çekilmiş görüntülere karşı modeli dayanıklı hâle getirir; çünkü gerçek koşullarda her görüntü keskin olmayabilir.

Salt & Pepper Gürültü (Tuz-Biber Gürültüsü): Görüntüye rastgele dağılmış küçük siyah ve beyaz noktalar eklenir; bu noktalar tuz ve biber tanelerine benzediği için bu adı alır. Tablodaki "%1 piksel", görüntüdeki piksellerin yaklaşık yüzde birinin bu şekilde bozulduğunu belirtir. Bu işlem, görüntülerdeki olası teknik gürültüye karşı modeli dirençli kılar.

Augmentation Katsayısı (Artırma Katsayısı): Bu, her orijinal eğitim görüntüsünden kaç adet yeni varyasyon üretileceğini belirler. "10x" değeri, her görüntüden yukarıdaki işlemlerin farklı kombinasyonlarıyla 10 kat varyasyon oluşturulduğunu gösterir. Bu sayede eğitim seti 230 orijinal görüntüden 2300 görüntüye çıkarılmıştır. Amaç, sınırlı sayıdaki orijinal veriyi çoğaltarak modele daha fazla örnek sunmak ve ezberleme riskini azaltmaktır.

3.4. Hesaplama Ortamı

3.4.1. Google Colab Platformu

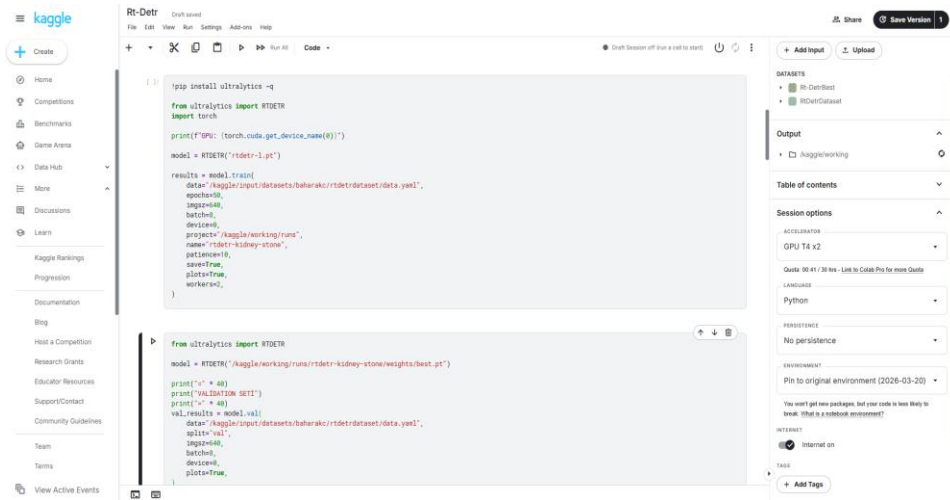
Modern derin öğrenme modelleri, eğitim sürecinde yüksek miktarda GPU belleği ve hesaplama gücü gerektirmektedir. RT-DETR-L modeli bu çalışmada yaklaşık 32.8 milyon parametre ve 108 GFLOPs hesaplama maliyetine sahipken, Faster R-CNN'nin ResNet-50-FPN omurgası da benzer düzeyde kaynak talep etmektedir. Tüketici sınıfı GPU'ların sahip olduğu 4-8 GB VRAM kapasitesi, bu modellerin eğitimi için yetersiz

kalmaktadır. CPU tabanlı hesaplamada ise eğitim süreçleri günlerce sürebilmektedir (LeCun vd., 2015). Bu sebeplerin getirdiği yük ile kişisel bilgisayar da eğitim tamamlanamamıştır. O yüzden ilk önce Google Colab ile eğitim yapmaya başlanmıştır fakat Google Colab de yetersiz kalmıştır. Google Colab araştırmacılara ücretsiz GPU erişimi sunan bulut tabanlı bir platformdur (Bisong, 2019, s. 59). Ancak YOLOv8s modeli Colab ortamında başarıyla eğitilirken, Faster R-CNN ve RT-DETR-L modellerinin eğitimi sırasında Colab'ın tahsis ettiği GPU'nun bellek kapasitesi yetersiz kalmış ve eğitim tamamlanamamıştır. Eğitim tamamlanamadığı için Kaggle ortamına geçiş yapılmıştır.

3.4.2. Kaggle Platformu

Şekil 3

Kaggle Ortamında Model Eğitim Örnek Görseli



Google Colab ortamında bellek kapasitesi yetersiz kalmış ve eğitim tamamlanamamıştır. Bu nedenle model eğitimleri Şekil 3'teki gibi Kaggle Notebooks ortamına taşınmıştır. Kaggle, Tesla T4 GPU (15 GB VRAM), haftalık 30 saat ücretsiz GPU kullanım süresi, veri setlerinin kalıcı olarak platforma yüklenmesi ve 'Save & Run All (Commit)' (Kaydet & Hepsini Çalıştır) özelliği ile notebook (not defteri) çıktılarının kalıcı saklanması avantajları sunmaktadır (Kaggle, 2024). Kaggle'ın dezavantajlarından birisi oturum sürelerinin 9 saat olmasıdır. 9 saatten fazla süren bir eğitim gerçekleşirse eğitim tamamlanamayacaktır.

Tablo 3*Kaggle Hesaplama Ortamı Özellikleri*

Model	Değer
Platform (RT-DETR, Faster R-CNN, YOLOv8)	Kaggle Notebooks
GPU	NVIDIA Tesla T4
GPU Belleği	15 GB VRAM
Python Sürümü	3.12.12
PyTorch Sürümü	2.10.0+cu128
CUDA Sürümü	12.8

3.5. Kullanılan Modeller

Bu çalışmada YOLOv8s, Faster R-CNN ve RT-DETR olmak üzere üç model kullanılmıştır. Bu üç modelin birlikte seçilmesi rastgele değildir; amaç, nesne tespiti alanındaki birbirinden farklı üç temel mimari yaklaşımı aynı veri seti üzerinde karşılaştırmaktır. Nesne tespiti modelleri çalışma biçimlerine göre üç ana gruba ayrılır ve bu çalışmada her gruptan güncel bir temsilci seçilmiştir. Böylece hangi mimari yaklaşımın böbrek taşı türü tespitinde daha başarılı olduğu sistematik biçimde değerlendirilebilmiştir.

YOLO ailesi, nesnenin yerini ve türünü tek bir adımda, tek bir ağ geçişiyle belirleyen tek aşamalı dedektörlerdir. En büyük avantajı hızdır bu sayede gerçek zamanlı uygulamalara uygundur. YOLOv8s, hız ile doğruluk arasında dengeli bir seçenek olduğu ve sınırlı veriyle ezberleme riskini azalttığı için tercih edilmiştir.

Faster R-CNN, nesne tespitini iki adımda gerçekleştirir: önce görüntüde nesne içerebilecek aday bölgeleri belirler, ardından bu bölgeleri sınıflandırır. Bu iki aşamalı yapının avantajı, özellikle küçük ve belirgin nesnelerin tespitinde yüksek doğruluk sağlamasıdır. Bu model, iki aşamalı yaklaşımın klasik ve güçlü bir temsilcisi olduğu, ayrıca yüksek doğruluk referansı sunduğu için karşılaştırmaya dahil edilmiştir.

RT-DETR, son yıllarda öne çıkan transformer mimarisini nesne tespitine uyarlayan güncel bir modeldir. Transformer yapısı sayesinde, görüntünün bütünü değerlendirilerek nesneleri bağlamlarıyla birlikte tanıyabilir. Bu modelin en büyük seçilmesindeki avantajı hız ile doğruluğu bir arada sunabilmesidir. Bu modelin böbrek taşı türü tespitine

bildiğimiz kadarıyla literatürde ilk kez bu çalışmada uygulanıyor olması ve böylece çalışmaya özgün bir katkı kazandırmasıdır.

Nesne tespiti literatüründe SSD, RetinaNet, EfficientDet ve DETR gibi başka modeller de bulunmaktadır. Ancak bu çalışmanın amacı mümkün olan tüm modelleri denemek değil, üç temel mimari yaklaşımı (tek aşamalı, iki aşamalı ve transformer tabanlı) güncel ve temsil gücü yüksek birer modelle karşılaştırmaktır. Seçilen üç model, kendi mimari ailelerinin güncel ve yaygın kabul görmüş temsilcileridir.

3.5.1. YOLOv8s

YOLOv8s (You Only Look Once version 8 - Small), Ultralytics tarafından 2023 yılında geliştirilen tek aşamalı bir nesne tespiti modelidir (Jocher vd., 2023). CSPDarknet omurgası, PAN-FPN boynu ve çapa bağımsız tespit başından oluşan YOLOv8s modeli, 11.1 milyon parametre, 130 katman ve 28.4 GFLOPs hesaplama maliyetiyle hız-doğruluk dengesi açısından pratik uygulamalar için uygundur. COCO veri seti üzerinde önceden eğitilmiş ağırlıklarla transfer öğrenme uygulanmıştır. YOLOv8 modellerini, NVIDIA Jetson, NVIDIA GPU'lar ve macOS sistemleri de dahil olmak üzere çok çeşitli cihazlarda, görüş modellerini çalıştırmak için açık kaynaklı bir Python paketi olan Roboflow Inference ile dağıtabilirsiniz (Jocher vd., 2023).

Tablo 4

YOLOv8s Eğitim Parametreleri

Parametre	Değer
Model	yolov8s.pt (COCO pretrained)
Epoch Sayısı	50 (32. epochta early stopping)
En İyi Epoch	22
Görüntü Boyutu	640×640
Batch Boyutu	16
Optimizer	AdamW (lr=0.001111, momentum=0.9)
Early Stopping Patience	10
Eğitim Süresi	~22 dakika

YOLOv8s Model Kullanımı

Model sıfırdan, hiçbir şey bilmeyen bir hâlde eğitilmemiştir. Bunun yerine, daha önce milyonlarca günlük fotoğraf üzerinde eğitilmiş hazır bir model (yolov8s.pt) başlangıç noktası olarak alınmıştır. Yani bu ne demek, bir model sıfırdan eğitilirse, kenar nedir, doku nedir, renk geçişi nedir bunların hepsini en baştan öğrenmek zorundadır. Bunu öğrenmek için de çok sayıda örnek gerekir, çünkü her temel kavramı görüntülerden tekrar tekrar görerek çıkarması gerekmektedir. Elinde az veri varsa bu mümkün olmaz; model temel görsel kuralları oturtamadan veri biter ve sonuç kötü olur. Bu yönetime transfer öğrenme denir ve bizim sadece yapmamız gereken böbrek taşlarını tanımayı öğretmektir. Bu yöntem, özellikle elimizdeki veri az olduğundan kritik önem taşır. Hazır modelin eğitildiği COCO veri seti 328.000 görüntü içerir (Lin vd., 2014), yani modelimiz çok güçlü bir başlangıçla işe başlamıştır. Ayrıca modelin "small" (küçük) boyutu bilinçli seçilmiştir. YOLOv8'in daha büyük versiyonları da vardır ama büyük modeller, az veriyle çalışırken veriyi ezberleme eğilimindedir. Küçük model bu riski azaltır ve hız ile doğruluk arasında dengeli bir seçim sunar (Jocher vd., 2023).

Tur Sayısı ve Erken Durdurma

Burada epochs(tur sayısı)=50 değeri "model tam 50 tur dönecek" anlamına gelmez. Bu sadece bir üst sınırdır, yani en fazla 50 tur demektir. Eğitimi asıl yöneten ayar patience(sabır)=10'dur. Bu ayar, model her turda doğrulama setinde sınanır ve eğer üst üste 10 tur boyunca hiçbir gelişme olmazsa eğitim kendiliğinden durur. Buna erken durdurma denir. Bu yapının amacı ezberlemeyi önlemektir. Bir model çok uzun süre eğitilirse, bir noktadan sonra veriyi anlamayı bırakıp ezberlemeye başlar. Erken durdurma tam bu dönüm noktasını yakalar ve en iyi sonucu veren modeli saklar (Goodfellow vd., 2016). Sonuçta bizim modelimiz 50 tura hiç ulaşmadan 32. turda durdu ve en iyi sonuç 22. turda elde edilmiştir. Yani 50 değeri, erken durdurmanın rahatça devreye girebileceği güvenli bir tavan görevi gördü.

Görüntü Boyutu

Bu ayar (imgsz=640), modele verilen her görüntünün boyutunu belirler. Bu sayı YOLOv8 için önerilen standart boyuttur (Jocher vd., 2023). Yeterince büyüktür, çünkü taşın yüzey dokusu ve kenar yapısı gibi ayırt edici ayrıntıları korur. Aynı zamanda kullandığımız GPU'nun belleğini zorlamayacak kadar da makuldür. Bu değer, veri hazırlama

aşamasında tüm görüntülere uygulanan 640×640 boyutlandırmayla da uyumludur böylece baştan sona aynı boyut korunmuştur.

Yığın Boyutu

Model, görüntüleri tek tek değil, gruplar hâlinde işler. Bu grubun büyüklüğüne yığın (batch) denir. Burada 16 seçildi yani model her seferinde 16 görüntüyü birlikte değerlendirdi. Bu sayı büyük ölçüde donanımla ilgili pratik bir karardır. YOLOv8s hafif bir model olduğu için GPU belleğine 16'lık grup sığabilmiştir. Bu değer, modelin kararlı öğrenmesini sağlayacak kadar büyük, belleği taşırmayacak kadar küçüktür. YOLOv8s'in 16'ya çıkabilmesi diğer modellerin yığın sayısına göre ne kadar verimli bir model olduğunu da göstermektedir.

Optimizer ve Öğrenme Hızı

Optimizer (Optimizasyon), modelin hatalarından nasıl ders çıkaracağını belirleyen yöntemdir. Öğrenme hızı (learning rate) ise modelin her adımda ne kadar büyük değişiklik yapacağını ayarlar. Çok büyük olursa model kararsızlaşır, çok küçük olursa öğrenme çok yavaşlar. Bu çalışmada optimizer elle seçilmedi çünkü Ultralytics otomatik modda veri setinin büyüklüğüne ve sınıf sayısına bakarak optimizer ile öğrenme hızını birlikte ayarlar. Elle ayar yapmak, deneme-yanılmayla onlarca eğitim çalıştırıp en iyi kombinasyonu aramayı gerektirir. Sınırlı GPU süresi olan (Kaggle'da haftalık 30 saat) bir çalışmada bu uzun bir süreçtir. Ultralytics yazılımı otomatik olarak AdamW yöntemini, 0,001111 öğrenme hızıyla seçti. AdamW, az veriyle bile kararlı sonuç veren güvenilir bir yöntemdir. Bu ayarların elle değil yazılım tarafından otomatik yapılmış olması, üç modelin de aynı tutarlı kurallarla eğitildiği ve sonuçların tekrarlanabilir olduğu anlamına gelir.

Şekil 4

YOLOv8s Eğitim Kodu Örneği

```
In [3]: !pip install ultralytics -q

from ultralytics import YOLO

model = YOLO("yolov8s.pt")


results = model.train(
    data="/kaggle/input/datasets/baharakc/kaggledataset/data.yaml",
    epochs=50,
    imgsz=640,
    batch=16,
    device=0,
    project="/kaggle/working/runs",
    name="yolov8s-kidney-stone",
    patience=10,
    save=True,
    plots=True,
    workers=2,
)
```

Diğer Ayarlar

Bu ayarlar modelin başarısını doğrudan etkilemez; eğitimin GPU üzerinde düzgün ve kayıt altında yürümesini sağlar. Device(cihaz)=0 eğitimi GPU'da çalıştırır (GPU bu tür hesaplamaları normal işlemciden çok daha hızlı yapar). Save=True eğitilen modeli diske kaydederek sonradan kullanılmasını sağlar. Plots(Arsalar)=True eğitim grafiklerini ve karmaşıklık matrisi gibi değerlendirme görsellerini otomatik üretir; bu çalışmada Bölüm 4'te kullanılan görseller bu sayede elde edilmiştir. Workers(İşçiler)=2 ise veriyi diskten okuyup modele aktaran paralel süreç sayısını belirler ve Kaggle'ın paylaşımlı ve sınırlı çekirdek sayısına sahip ortamında bellek taşması ve oturum kesintisi riskini azaltan güvenli bir tercihtir.

Şekil 5

YOLOv8s Confusion Matrix Grafikleri



3.5.2. Faster R-CNN

Faster R-CNN, ResNet-50-FPN omurgası üzerine inşa edilmiş iki aşamalı bir nesne tespiti mimarisidir (Ren vd., 2017). Region Proposal Network (RPN) ile aday bölgeler üretilerek ikinci aşamada sınıflandırma ve lokalizasyon gerçekleştirilmektedir. Bu mimaride sınıf sayısı, nesne sınıfları ile birlikte background (arka plan) sınıfı da dahil edilerek belirlenmektedir. Bu çalışmada 5 böbrek taşı türü ve 1 arka plan sınıfı olmak üzere toplam 6 sınıf tanımlanmıştır. Bu yaklaşım, Faster R-CNN'in iki aşamalı tespit mekanizmasının bir gereği olup RPN tarafından üretilen bölge önerilerinin nesne/arka plan ayırımına dayalı sınıflandırılmasından kaynaklanmaktadır (Ren vd., 2017). Performans değerlendirmesinde torchmetrics kütüphanesi kullanılarak mAP50, mAP50-95, Precision, Recall ve F1 skoru hesaplanmıştır.

Tablo 5

Faster R-CNN Eğitim Parametreleri

Parametre	Değer
Model	FasterRCNN-ResNet50-FPN(COCO pretrained)
Sınıf Sayısı	6 (5 sınıf + background)
Epoch Sayısı	50
En İyi Epoch	49
Batch Boyutu	4

Tablolar devamı

Optimizer	SGD (lr=0.005, momentum=0.9, weight_decay=0.0005)
LR Scheduler	StepLR (step_size=10, gamma=0.5)
Early Stopping Patience	10
Eğitim Süresi	~7 saat

Faster R-CNN Model Kullanımı

YOLOv8s'te olduğu gibi burada da model sıfırdan eğitilmemiştir. COCO veri seti üzerinde önceden eğitilmiş hazır ağırlıklar (Default) başlangıç noktası olarak alınır. Modelin omurgası ResNet-50-FPN'dir. Omurga, görüntüden temel özellikleri (kenar, doku, şekil) çıkaran ana ağ kısmıdır; ResNet-50 bu iş için yaygın kullanılan, kanıtlanmış bir mimaridir (He vd., 2016). FPN (Özellik Piramidi Ağı) ise farklı boyutlardaki nesneleri daha iyi yakalamayı sağlar (Lin vd., 2017). Hazır ağırlıklar sayesinde model, az veriyle bile sağlam bir başlangıç yapmıştır.

Sınıf Sayısı

Burada dikkat çeken bir nokta vardır. Veri setinde 5 taş türü olmasına rağmen sınıf sayısı (NUM_CLASSES = 6) 6 olarak tanımlanmıştır. Fazladan olan sınıf "background" (arka plan) sınıfıdır. Bu, Faster R-CNN mimarisinin bir zorunluluğudur. Faster R-CNN iki aşamalı bir modeldir. Önce görüntüde "burada bir nesne olabilir" denilen aday bölgeler üretir, sonra bu bölgeleri sınıflandırır. Bu sınıflandırma sırasında modelin "burası bir taş değil, sadece boş arka plan" diyebilmesi gerekir. İşte bu "boş alan" kararı için ayrı bir background sınıfı tanımlanır (Ren vd., 2017).

Tur Sayısı ve Erken Durdurma

Burada da mantık YOLOv8s ile aynıdır. 50 sayılı bir üst sınırdır, asıl yönetimi erken durdurma yapar (EPOCHS = 50, PATIENCE = 10). Ancak önemli bir fark vardır. YOLOv8s ve RT-DETR planlanan 50 tura ulaşmadan erken durmuşken, Faster R-CNN'in eğitimi 50 turun tamamını koşturmuştur. Bunun nedeni şudur: erken durdurma, üst üste 10 tur boyunca gelişme olmazsa devreye girer. Faster R-CNN'de en iyi sonuç 49. turda elde edilmiştir. 49'tan sonra 10 tur saymak için 59. tura kadar gitmek gerekirdi, ama eğitim zaten 50. turda planlı biçimde bittiği için erken durdurma tetiklenmemiştir. Bu, Faster R-CNN'in diğer iki modele göre daha geç olgunlaştığını, yani öğrenmeye daha uzun süre

devam ettiğini gösterir. Bu durum, modelin yaklaşık 7 saatlik uzun eğitim süresinin de bir nedenidir.

Yığın Boyutu

Model her seferinde yığın boyutu (BATCH_SIZE = 4) 4 görüntüyü birlikte işlemiştir. Bu sayı YOLOv8s'in 16'sından belirgin biçimde küçüktür ve bunun nedeni donanımsaldır. Faster R-CNN, ResNet-50-FPN omurgasıyla birlikte oldukça ağır bir modeldir ve eğitim sırasında çok fazla GPU belleği tüketir. Tesla T4'ün 15 GB belleğine ancak 4'lük bir grup sığabilmiştir çünkü daha büyük bir değer bellek taşmasına yol açardı. Bu küçük yığın boyutu, modelin neden bu kadar yavaş eğitildiğini de kısmen açıklar çünkü küçük gruplarla çalışmak aynı veriyi işlemek için daha çok adım gerektirir.

Optimizer

Optimizer (SGD, lr=0.005, momentum=0.9, weight_decay=0.0005), modelin hatalarından nasıl ders çıkaracağını belirleyen yöntemdir. YOLOv8s'te bu seçim yazılıma bırakılmışken, Faster R-CNN'de optimizer elle SGD (Stokastik Gradyan İnişi) olarak seçilmiştir. Bu rastgele bir tercih değildir: SGD, Faster R-CNN'in orijinal makalesinde kullanılan ve bu mimari için klasikleşmiş optimizierdir (Ren vd., 2017). Yanındaki değerler de (momentum 0,9, weight_decay 0,0005) literatürde bu model için standart kabul edilen ayarlardır. Öğrenme hızı (learning rate), modelin her adımda ne kadar büyük değişiklik yapacağını belirler; 0,005 değeri, Faster R-CNN eğitiminde yaygın kullanılan başlangıç değeridir. Kısacası bu parametreler, modelin standart değerlerine sadık kalınarak seçilmiştir.

Öğrenme Hızı Planlayıcısı

Bu, eğitim boyunca öğrenme hızını (StepLR, step_size=10, gamma=0.5) kademeli olarak azaltan bir ayardır. Mantığı şuna benzer: eğitimin başında model çok şey bilmediği için büyük adımlarla hızlı öğrenmesi iyidir ama sona yaklaşırken büyük adımlar en iyi noktayı kaçırmaya yol açabilir. Bu yüzden adımları küçültmek gerekir. Buradaki ayar (step_size=10, gamma=0.5) şu anlama gelir: her 10 turda bir öğrenme hızı yarıya indirilir. Yani model başlangıçta hızlı öğrenir, ilerledikçe daha dikkatli ve ince ayarlı hareket eder. Bu kademeli azaltma, modelin sona doğru daha kararlı bir noktaya oturmasını sağlar.

Değerlendirme Yöntemi (Torchmetrics)

YOLOv8s metriklerini kendi içinde otomatik hesaplarken, Faster R-CNN torchvision'da çalıştığı için metrikler elle hesaplanmıştır. Bunun için torchmetrics kütüphanesinin MeanAveragePrecision aracı kullanılmış; mAP50 ve mAP50-95 bu araçla, precision ve recall ise her tahminin gerçek kutularla örtüşme oranı (IoU) tek tek hesaplanarak elde edilmiştir. F1 skoru da precision ve recall'dan türetilmiştir. Bu ayrım önemlidir çünkü Faster R-CNN'in metrikleri YOLOv8s'inkiyle birebir aynı yöntemle değil ona denk gelen ayrı bir hesaplama yoluyla üretilmiştir. YOLOv8s'deki gibi de otomatik grafikler oluşturmamaktadır.

Şekil 6

Faster R-CNN Eğitim Kodu Örneği

```
In [2]: !pip install torchmetrics pycocotools -q

import torch
import torchvision
from torchvision.models.detection import fasterrcnn_resnet50_fpn, FasterRCNN_ResNet50_FPN_Weights
from torchvision.models.detection.faster_rcnn import FastRCNNPredictor
from torch.utils.data import Dataset, DataLoader
from torchvision import transforms
from torchmetrics.detection.mean_ap import MeanAveragePrecision
from PIL import Image
import os, json, time, csv
import numpy as np

# — CONFIG —
BASE = "/kaggle/input/datasets/baharakc/kidney-stone-dataset"
OUTPUT = "/kaggle/working/runs/faster_rcnn"
os.makedirs(f"{OUTPUT}/weights", exist_ok=True)

NUM_CLASSES = 6 # 5 sınıf + background
EPOCHS = 50
BATCH_SIZE = 4
LR = 0.005
PATIENCE = 10
DEVICE = torch.device("cuda" if torch.cuda.is_available() else "cpu")
CLASS_NAMES = ["background", "calcium_oxalate", "calcium_phosphate", "cystine", "mikst", "uric_acid"]

print(f"Device: {DEVICE} | GPU: {torch.cuda.get_device_name(0)}")
```

3.5.3. RT-DETR

RT-DETR (Real-Time Detection Transformer), Zhao ve diğerleri (2024) tarafından önerilen RT-DETR (Real-Time Detection Transformer), bilgi dahilinde geliştirilen ilk gerçek zamanlı uçtan uca nesne tespiti modelidir. RT-DETR-R50, COCO val2017'de %53,1 AP ve T4 GPU'da 108 FPS elde ederek aynı ölçekteki YOLO modellerini hem hız hem doğruluk açısından geride bırakmaktadır (Zhao vd., 2024). Bu çalışmada, hybrid encoder yapısı, IoU-aware query selection ve transformer decoder bileşenlerinden oluşan

RT-DETR-L varyantı; 465 katman, yaklaşık 32.8 milyon parametre ve 108 GFLOPs hesaplama maliyetine sahiptir. Bu çalışmada RT-DETR'nin seçilmesinin temel gerekçeleri şunlardır: doğrulama ve test setinde tüm sınıflarda %99.5 mAP50 ile en tutarlı performansı sergilemesi, val-test mAP50 farkının sıfır olması, mükemmel genelleme kapasitesi göstermesi, Faster R-CNN'e kıyasla çok daha hızlı çıkarım süresi ve daha küçük model boyutu (66MB), (4) COCO karşılaştırmalı değerlendirmelerinde YOLOv8'i geçmesidir.

Tablo 6

RT-DETR Eğitim Parametreleri

Parametre	Değer
Model	rtdetr-l.pt (COCO pretrained)
Katman Sayısı	465
Parametre Sayısı	32.816.351 (~32.8M)
Epoch Sayısı	50 (33. epochta early stopping)
En İyi Epoch	23
Görüntü Boyutu	640×640
Batch Boyutu	8
Optimizer	AdamW (lr=0.000125, momentum=0.9)
Early Stopping Patience	10
Eğitim Süresi	~1.6 saat

RT-DETR Model Kullanımı

Diğer iki modelde olduğu gibi RT-DETR de sıfırdan eğitilmemiştir; COCO veri seti üzerinde önceden eğitilmiş hazır ağırlıklar (rtdetr-l.pt) başlangıç noktası olarak alınmıştır. Buradaki "l" harfi modelin "large" (büyük) varyantı olduğunu gösterir. RT-DETR'in farklı boyutları vardır; bu çalışmada büyük varyant seçilmiştir çünkü transformer tabanlı mimarinin avantajlarının ortaya çıkması için yeterli model kapasitesi gerekir. Bu varyant yaklaşık 32,8 milyon parametre içerir, yani YOLOv8s'ten (11,1 milyon) belirgin biçimde daha büyük bir modeldir.

Tur Sayısı ve Erken Durdurma

Mantık YOLOv8s ile aynıdır: 50 bir üst sınırdır, asıl yönetimi patience=10 ile erken durdurma yapar. RT-DETR de bu mekanizma sayesinde 50 tura ulaşmadan erken durmuştur. Eğitim 33. turda sonlanmış, en iyi sonuç ise 23. turda elde edilmiştir. Bu

davranış YOLOv8s'e çok benzer: her iki Ultralytics modeli de erken olgunlaşmış ve eğitimleri yarıda otomatik olarak kesilmiştir. Bu, Faster R-CNN'in 50 turun tamamını koşmasıyla belirgin bir fark oluşturur.

Görüntü Boyutu

Giriş görüntü boyutu 640×640 pikseldir. Bu değer hem RT-DETR için standart çalışma çözünürlüğüdür hem de diğer iki modelle aynıdır. Üç modelin de aynı görüntü boyutunu kullanması bilinçli bir tercihtir, çünkü karşılaştırmanın adil olması için modellerin aynı koşullarda eğitilmesi gerekir. Farklı görüntü boyutları kullanılsaydı, performans farklarının modelden mi yoksa girdi boyutundan mı kaynaklandığını ayırt etmek zorlaşırdı.

Yığın Boyutu

Model her seferinde 8 görüntüyü birlikte işlemiştir. Bu değer üç modelin tam ortasındadır: YOLOv8s 16, RT-DETR 8, Faster R-CNN 4. Bu sıralama tesadüf değildir, doğrudan modellerin ağırlığını yansıtır. RT-DETR, YOLOv8s'ten daha büyük olduğu için aynı GPU belleğine daha az görüntü sığar; bu yüzden yığın boyutu 16'dan 8'e düşürülmüştür. Ancak Faster R-CNN kadar ağır olmadığı için 4'e kadar inmesi gerekmemiştir. Yani 8 değeri, modelin orta-ağır yapısının ve Tesla T4'ün 15 GB bellek sınırının birlikte belirlediği pratik bir denge noktasıdır.

Optimizör ve Öğrenme Hızı

YOLOv8s'te olduğu gibi, RT-DETR'de de optimizör elle belirtilmemiştir; Ultralytics çerçevesinin otomatik (auto) modu kullanılmıştır. Yazılım, veri setine göre AdamW yöntemini ve uygun öğrenme hızını kendisi atamıştır ($\text{lr} \approx 0,000125$). Bu tercihin gerekçesi YOLOv8s ile aynıdır: her iki Ultralytics modelinin de çerçeve önerilerine sadık kalınarak eğitilmesi, aralarındaki karşılaştırmayı tutarlı ve adil kılar. Dikkat edilmesi gereken bir nokta, RT-DETR'in otomatik atanan öğrenme hızının ($0,000125$), YOLOv8s'inkinden ($0,001111$) daha küçük olmasıdır. Bu fark, transformer tabanlı modellerin genellikle daha küçük öğrenme hızlarıyla daha kararlı eğitildiği yönündeki yaygın uygulamayla uyumludur; çerçeve bu ayarlamayı model yapısına bakarak kendisi yapmıştır.

Şekil 7

RT-DETR Eğitim Kodu Örneği

```
In [3]: !pip install ultralytics -q

from ultralytics import RTDETR
import torch

print(f"GPU: {torch.cuda.get_device_name(0)}")

model = RTDETR("rtdetr-l.pt")


results = model.train(
    data="/kaggle/input/datasets/baharakc/rtdetrdataset/data.yaml",
    epochs=50,
    imgsz=640,
    batch=8,
    device=0,
    project="/kaggle/working/runs",
    name="rtdetr-kidney-stone",
    patience=10,
    save=True,
    plots=True,
    workers=2,
)
```

Diğer Ayarlar

device=0, save=True, plots=True ve workers=2 ayarları YOLOv8s ile aynı işlevleri görür (GPU kullanımı, modelin kaydedilmesi, görsellerin otomatik üretimi ve veri yükleme süreçlerinin ayarlanması). RT-DETR de Ultralytics üzerinde çalıştığı için, eğitim sonunda results.png, karmaşıklık matrisi ve etiket dağılımı gibi değerlendirme görselleri otomatik olarak üretilmiştir. Ayrıca eğitim tamamlandıktan sonra model hem doğrulama hem de test setinde ayrı ayrı değerlendirilmiş (model.val() çağrıları ile), sınıf bazlı mAP50 değerleri tek tek raporlanmıştır.

Şekil 8

RT-DETR Confusion Matrix Grafikleri



3.5.4. Transfer Öğrenme ve Early Stopping

Tablo 7

Early Stopping Sonuçları

Model	Planlanan Epoch	Gerçekleşen Epoch	En İyi Epoch	Eğitim Süresi
YOLOv8s	50	32	22	~22 dakika
Faster R-CNN	50	50	49	~7 saat
RT-DETR	50	33	23	~1.6 saat

Üç model de COCO veri seti üzerinde önceden eğitilmiş ağırlıklarla başlatılmış ve böbrek taşı veri seti üzerinde ince ayar (fine-tuning) yapılmıştır (Lin vd., 2014). İnce ayar, eğitim sırasında modelin içindeki ağırlıklar yani öğrenilmiş bilgiler sıfırlanmaz sadece küçük miktarda güncellenir. Yani modelin önceden bildiği temel görsel yetenekler korunur, üzerine senin öğrettiğin bilgiler örneği bu doku mikst, bu yüzey ürik asit gibi bilgiler eklenir. COCO, doğal bağlamlarında yaygın nesneleri içeren 328.000 görüntü ve 2,5 milyon etiketli örnekten oluşan büyük ölçekli bir nesne tespiti veri setidir (Lin vd., 2014). Bu transfer öğrenme sınırlı tıbbi veri setlerinde daha hızlı yakınsama ve daha iyi genelleme performansı sağlamaktadır (Yosinski vd., 2014). Tüm modellerde ezberleme (overfitting) riskini minimize etmek amacıyla erken durdurma (early stopping) mekanizması uygulanmıştır. Tüm modellerde erken durdurma mekanizması

(patience=10) uygulanmış ve doğrulama performansında art arda 10 epoch boyunca iyileşme gözlemlenmediğinde eğitim otomatik olarak sonlandırılmıştır.

3.5.5. Değerlendirme Metrikleri

Modellerin performansı, nesne tespiti literatüründe yaygın olarak kullanılan beş temel metrik üzerinden değerlendirilmiştir (Padilla vd., 2021).

Precision (Kesinlik), modelin pozitif olarak etiketlediği örneklerin ne kadarının gerçekten pozitif olduğunu ölçmektedir:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2.1)$$

Yüksek precision değeri, modelin düşük sayıda yanlış pozitif (FP) ürettiğine işaret etmektedir. Bu da tespit edilen nesnelerin büyük çoğunluğunun gerçek nesne olduğu anlamına gelir (Padilla vd., 2021).

Recall (Duyarlılık), gerçek pozitif örneklerin ne kadarının model tarafından doğru tespit edilebildiğini ölçmektedir:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2.2)$$

Tıbbi görüntü analizinde kaçırılan bir tanı (FN), yanlış bir pozitif tespite (FP) kıyasla çok daha ciddi klinik sonuçlara yol açabileceğinden recall, özellikle kritik öneme sahip bir metriktir (Padilla vd., 2021).

F1 Skoru, precision ve recall arasındaki dengeyi tek bir değerde özetleyen harmonik ortalamadır:

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.3)$$

Bu metrik, özellikle sınıflar arası dengesizliğin söz konusu olduğu veri setlerinde model performansının bütüncül değerlendirilmesinde tercih edilmektedir (Padilla vd., 2021).

mAP50, IoU (Intersection over Union) eşiği 0.50 olarak sabit tutularak hesaplanan ortalama hassasiyettir. Bu eşikte, tahmin edilen sınırlayıcı kutunun gerçek nesne kutusuyla örtüşme oranı %50'nin üzerinde olan tespitler doğru pozitif (TP) olarak kabul edilmektedir (Padilla vd., 2021).

mAP50-95, IoU eřiđinin 0.50'den 0.95'e kadar 0.05 adımlarla deđiřtirilmesiyle elde edilen mAP deđerlerinin ortalamasıdır. Bu metrik, COCO nesne tespiti deđerlendirme standardında birincil performans ölçütü olarak benimsenmiřtir ve modelin hem gevřek hem de sıkı IoU eřiklerindeki genel bařarısını yansıtması bakımından mAP50'ye kıyasla daha kapsamlı bir deđerlendirme sunmaktadır (Padilla vd., 2021).

BÖLÜM 4. ANALİZ VE BULGULAR

4.1. Doğrulama Seti Sonuçları

Üç modelin doğrulama seti üzerindeki performans metrikleri Tablo 8'deki gibi karşılaştırmalı olarak sunulmaktadır.

Tablo 8

Doğrulama Seti Model Performans Karşılaştırması

Metrik	YOLOv8s	Faster R-CNN	RT-DETR
Map50	0.9932	0.9647	0.9950
Map50-95	0.9878	0.9572	0.9918
Precision	0.9902	0.9167	0.9794
Recall	0.9108	0.9851	0.9917
F1 Skoru	0.9489	0.9496	0.9855

Doğrulama seti sonuçlarına göre RT-DETR; mAP50 (0.9950), mAP50-95 (0.9918), Recall (0.9917) ve F1 skoru (0.9855) metriklerinde üç model arasında en yüksek performansı sergilemiştir. YOLOv8s, Precision (0.9902) metriğinde lider konumdayken Faster R-CNN, Recall (0.9851) değeriyle öne çıkmıştır. Her üç modelin de %96'nın üzerinde doğrulama mAP50 elde etmesi, böbrek taşı türü tespitinde güçlü bir öğrenme gerçekleştiğini ortaya koymaktadır. Ama veri setinin az olduğunu unutmayıp hata payı da yüksek olabilir.

4.2. Test Seti Sonuçları

Üç modelin test seti üzerindeki performans metrikleri Tablo 9'daki gibi karşılaştırmalı olarak sunulmaktadır.

Tablo 9

Test Seti Model Performans Karşılaştırması

Metrik	YOLOv8s	Faster R-CNN	RT-DETR
Map50	0.9608	1.0000	0.9950
Map50-95	0.9499	0.9726	0.9767
Precision	0.8856	0.9714	0.9414
Recall	0.9172	1.0000	0.9706

<i>Tablolar devamı</i>			
F1 Skoru	0.9012	0.9855	0.9558

Test seti sonuçlarında Faster R-CNN; mAP50 (1.0000) ve Recall (1.0000) ile en yüksek genelleme performansını sergilemiştir. RT-DETR ise tüm sınıflarda %99.5 mAP50 ile tutarlı test performansı göstermiştir. Faster R-CNN'nin test setinde mAP50 = 1.0000 gibi istatistiksel sınır değerlere ulaşması, test setinin yalnızca 33 görüntüden oluşmasıyla doğrudan ilişkilidir. Küçük test setlerinde sınıf başına düşen görüntü sayısının sınırlı olması, precision ve recall gibi metriklerin tek bir hatalı tahminden dahi belirgin biçimde etkilenmesine yol açmaktadır. Bu durum, elde edilen metrik değerlerinin mutlak doğruluk göstergesi olarak değil, genel eğilimin bir yansıması olarak değerlendirilmesi gerektiğine işaret etmektedir. Bu nedenle bu sonuçlar ihtiyatla yorumlanmalı ve daha büyük test setleriyle doğrulama yapılması önerilmektedir.

Mikst sınıfı test setinde yalnızca 1 görüntüyle temsil edildiğinden, bu sınıfa ait mAP50 değeri (0.9950) tek bir doğru tahminin yansımasıdır ve istatistiksel açıdan güvenilir bir performans göstergesi olarak değerlendirilemez (Japkowicz ve Shah, 2011). Benzer şekilde Ürik Asit (10 görüntü) ve Sistin (5 görüntü) sınıfları için de test seti sınırlı kalmaktadır. Bu nedenle söz konusu sınıflara ait bulgular ön bulgu niteliğinde yorumlanmalı ve daha büyük bir test setiyle doğrulama yapılması gerekmektedir.

4.3. Sınıf Bazlı Analiz

Tablo 10

YOLOv8s Sınıf Bazlı mAP50 Sonuçları

Sınıf	Val map50	Test map50	Val-Test Farkı
calcium_oxalate	0.9860	0.8480	-0.1380
calcium_phosphate	0.9950	0.9710	-0.0240
cystine	0.9950	0.9950	0.0000
mikst	0.9950	0.9950	0.0000
uric_acid	0.9950	0.9950	0.0000

Tablo 11*RT-DETR Sınıf Bazlı mAP50 Sonuçları*

Sınıf	Val map50	Test map50	Val-Test Farkı
calcium_oxalate	0.9950	0.9950	0.0000
calcium_phosphate	0.9950	0.9950	0.0000
cystine	0.9950	0.9950	0.0000
mikst	0.9950	0.9950	0.0000
uric_acid	0.9950	0.9950	0.0000

Tablo 12*Faster R-CNN Sınıf Bazlı mAP50 Sonuçları*

Sınıf	Val map50	Test map50	Val-Test Farkı
calcium_oxalate	0.9494	0.9260	0.0234
calcium_phosphate	1.0000	0.9368	0.0632
cystine	1.0000	1.0000	0.0000
mikst	0.8350	1.0000	0.1650
uric_acid	1.0000	1.0000	0.0000

RT-DETR tüm sınıflarda hem doğrulama hem de test setinde 0.9950 mAP50 elde etmiştir. RT-DETR değerlendirmesi Ultralytics framework'ü üzerinden yapılmıştır. Sınıf bazlı mAP50 değerlerinin tümünün 0.9950 çıkması, Ultralytics'in 101 noktalı precision-recall interpolasyon yönteminden kaynaklanmaktadır. Küçük test setlerinde model tüm sınıflarda eşik üzerinde doğru tahmin yaptığında eğri aynı düzeye yakınsayabilmektedir. Bu durum modelin metrik hesaplama yönteminin küçük veri setlerindeki sınırlılığını yansıtmakla birlikte Ultralytics'in bilinen bir davranışdır.

YOLOv8s'in calcium_oxalate (kalsiyum oksalat) sınıfında gözlemlenen test performansı düşüşü (val: 0.9860 - test: 0.8480), bu sınıfın morfolojik çeşitliliği ve test setindeki sınırlı örnek sayısı ile ilişkilendirilebilir. Calcium_oxalate sınıfında val-test farkı -0.1380 ile en yüksek düşüşü göstermektedir. Bu sınıf veri setindeki en yaygın taş türü olmakla birlikte morfolojik çeşitliliği yüksektir. Modelin eğitim setinde öğrendiklerini test setine tam genelleme yapamamıştır.

Faster R-CNN modelindeki sınıf dağılımda tutarsızlık ve istatistiksel güvenilirlik düşüktür. Sistin ve ürik asit sınıflarında mAP=1.0000 elde edilmesi, bu taş türlerinin görüntüsel olarak belirgin morfolojik özellikler taşımasından kaynaklanmaktadır.

Bununla birlikte, özellikle doğrulama setinde sistin için 7, ürik asit için yalnızca 2 görüntü bulunması nedeniyle bu sonuçlar istatistiksel olarak sınırlı güvenilirlik taşımaktadır. Bu durum, veri seti büyüklüğünün model performansı üzerindeki belirleyici etkisini bir kez daha ortaya koymaktadır (Sun vd., 2017).

4.4. Overfitting Analizi

Modellerin ezberleme yapıp yapmadığını eğitim/doğrulama kayıp eğrileri ve val-test mAP50 farkı üzerinden değerlendirilmiştir.

Tablo 13

Val-Test mAP50 Karşılaştırması (Overfitting Göstergesi)

Model	Val map50	Test map50	Fark	Değerlendirme
YOLOv8s	0,9932	0,9608	-0,0324	İyi genelleme
Faster R-CNN	0,9647	1,0000	+0,0353	Mükemmel genelleme
RT-DETR	0,9950	0,9950	0,0000	Mükemmel genelleme

Overfitting, bir makine öğrenmesi modelinin eğitim verisini "ezberlemesi" durumudur. Overfitting durumunda şu tablo ortaya çıkar: eğitim kaybı düşmeye devam ederken doğrulama kaybı belirli bir noktadan sonra yükselmeye başlar ve iki eğri arasındaki makas giderek açılır. Bu durum, modelin eğitim verisini ezberlediğini ve yeni örneklerle genelleme yapamadığını gösterir. Bizim çalışmamızdaki tüm modellerde eğitim ve doğrulama kayıplarının birlikte düşmesi, kayıplar arasındaki makasın açılmaması ve val-test mAP50 değerlerinin birbirine yakın seyretmesi, overfitting oluşmadığını ortaya koymaktadır. Early stopping mekanizması, RT-DETR ve YOLOv8s modellerinde bu dengenin korunmasında kritik bir rol üstlenmiştir.

4.5. Veri Dengesizliği Ve Sınıf Temsil Sorunu

Elde edilen taş görüntüleri sayısının az olmasının yanında en önemli sınırlılıkların da biri de sınıf dengesizliğidir. Türler göre dağılım incelendiğinde Kalsiyum Oksalat türünden 137, Ürik Asit türünden 82, Sistin türünden 57, Kalsiyum Fosfat türünden 53 ve Mikst türünden 9 görüntü elde edildiği görülmektedir. Veri artırma (augmentation) işlemi uygulanarak Mikst sınıfının eğitim setindeki görüntü sayısı artırılmış olsa da veri artırma orijinal görüntülerin dönüştürülmüş versiyonlarından oluşmaktadır. Bu durum modelin

Mikst sınıfına ait gerçek morfolojik çeşitliliği yeterince öğrenip öğrenemediği konusunda ciddi bir soru işareti doğurmaktadır. Nitekim Japkowicz ve Shah'ın (2011) da vurguladığı gibi, sınıf başına yetersiz örnek sayısı modelin o sınıfa ilişkin kararlarının güvenilirliğini doğrudan zayıflatmaktadır.

4.6. Hasta Düzeyinde Veri Bölünme Sorunu

Çalışmada kullanılan veri setinin bölünme sürecinde önemli bir kısıt fark edilmiştir. Veri seti oluşturulurken bölünme işlemi (eğitim-doğrulama-test seti) görüntü üzerinden gerçekleştirilmiş ancak aynı hasta bazında bölünme işlemi gerçekleştirilmemiştir. Kırpma işlemi uygulanan 18 hastaya ait görüntüler göz önüne alındığında, aynı hastaya ait farklı görüntülerin hem eğitim hem doğrulama hem de test setine girmiş olma ihtimali ortaya çıkmaktadır. Tıbbi görüntüleme çalışmalarında bu durum veri sızıntısı (data leakage) riski taşımakta ve modelin test setinde sergilediği performansın gerçek anlamda yeni bir hastaya genelleme kapasitesini tam olarak yansıtmayabileceği anlamına gelmektedir (Kaufman vd., 2012).

Eğer her görüntü farklı bir hastaya ait olsaydı hasta düzeyinde bölünme yapılabilirdi. Ama veri setinin az olmasından ve bir hastanın birden fazla taşla sahip olmasından dolayı hasta düzeyinde bölünme yapılamamasının en büyük sorunlarından biridir. Bizim çalışmamızda da bir hastada birden fazla taş görüntüsü olduğu için modelin elde ettiği test skorlarının yüksek olmasının bir kısmı da bu durumdan kaynaklandığı söylenilebilir.

Bu riski ortadan kaldırmak için de ilerleyen çalışmalarda hasta kimlik bilgilerinin veri setine entegre edilerek hasta bazlı bölünme uygulanabilir. Hasta bazlı bölünme uygulandıktan sonra raporlanan metriklerin güvenilirliğini artıracaktır. Ayrıca sistemin gerçek başarısı daha sağlıklı olacaktır.

Uygulama, görüntü yükleme, güven eşiği ayarlama, RT-DETR tabanlı nesne tespiti, bounding box görselleştirme ve her taş türüne özgü Türkçe koruyucu hekimlik önerileri sunma işlevlerini içermektedir. Koruyucu hekimlik önerileri kesinlik içermemekle beraber internetten araştırılıp sisteme aktarılmıştır. Önerilerin kesin doğruluğu yoktur. Sistem Hugging Face Spaces platformunda Şekil 9'ta görüldüğü üzere kalıcı olarak dağıtılmış ve şu adreste erişilebilir hale getirilmiştir: <https://huggingface.co/spaces/BaharCakici/kidney-stone-detection>

Güven eşiği (confidence threshold), modelin bir tahminini kabul etmek için aradığı en düşük güven seviyesidir. Örneğin model bir taş gördüğünde sadece "bu kalsiyum oksalat" demez; aynı zamanda bu tahmine ne kadar güvendiğini bir yüzdeyle belirtir. Örneğin "bu %92 ihtimalle kalsiyum oksalat" gibi. Bu yüzdeye güven skoru denir ve her tahmin için 0 ile 1 (yani %0 ile %100) arasında bir değer üretilir. Güven eşiği ise sisteme koyulan bir alt sınırdır. "Bana sadece şu yüzdenin üstündeki tahminleri göster, altındakileri görmezden gel." Örneğin eşiği 0,50 (%50) yaparsan, model yalnızca %50'den daha emin olduğu tahminleri gösterir, %30 güvenle yaptığı belirsiz bir tahmini ekrana hiç getirmez. Bunun mantığı şudur: model bazen zayıf, kararsız tahminler de üretir. Eğer her tahmin olduğu gibi gösterilirse, ekran yanlış ve güvenilmez sonuçlarla dolar. Güven eşiği bir filtre görevi görür. Düşük güvenli, şüpheli tahminleri eler, sadece modelin gerçekten emin olduğu sonuçları bırakır.

Hugging Face Inference API altyapısı sayesinde geliştirilen model ilerleyen çalışmalarda REST API olarak çağrılabilir hale gelmektedir. Bu altyapı ile mobil uygulama geliştirme, hastane bilgi sistemleri entegrasyonu ve klinik karar destek sistemlerine entegrasyon için kritik bir temel oluşturmaktadır (Wolf vd., 2020).

RT-DETR, 2024 yılında CVPR'de yayımlanan "DETRs Beat YOLOs on Real-Time Object Detection" başlıklı makaleyle (Zhao vd., 2024) kamuoyuna tanıtılmış, alanın en güncel dedektörlerinden biridir. Böbrek taşı tespitinde RT-DETR'nin uygulanması literatürde bildiğimiz kadarıyla ilk kez bu çalışmada gerçekleştirilmektedir. Sadece RT-DETR modeli verilerin eğitilmesiyle kalmayıp karar destek sistemi uygulamasına da bu modeli kullanarak sisteme gelen taş görüntü tespitlerinde de kullanılmıştır. Bu durum tezin özgün akademik katkısını ve araştırma sorusunun cevabını pekiştirmektedir. İleride yapılacak çalışmalar için bu tez başlangıç noktası veya karşılaştırma referansı olarak alınabilir.

SONUÇ VE ÖNERİLER

Bu tez, böbrek taşı türünün otomatik tespiti ve koruyucu hekimlik önerileri sunulması amacıyla YOLOv8s, Faster R-CNN ve RT-DETR modellerini karşılaştırmalı biçimde değerlendirmiştir. En iyi performanslı modeli temel alan web tabanlı bir karar destek sistemi geliştirmiştir. Bu bölümde temel bulgular özetlenmekte, teorik ve pratik katkılar ele alınmakta ve gelecek araştırmalar için öneriler sunulmaktadır.

Temel Bulgular

Araştırmanın temel bulgularını şu şekilde özetlemek mümkündür:

Doğrulama setinde RT-DETR (mAP50: 0.9950, F1: 0.9855) en yüksek performansı sergilemiştir. Transformer mimarisinin global dikkat mekanizması, böbrek taşlarının morfolojik çeşitliliğini yakalamada avantaj sağlamıştır.

Test setinde Faster R-CNN (mAP50: 1.0000, F1: 0.9855) mükemmel genelleme kapasitesiyle öne çıkmıştır ancak bu sonuç 33 görüntülük küçük test seti nedeniyle ihtiyatla yorumlanmalıdır.

RT-DETR'in doğrulama ve test setlerinde özdeş mAP50 (0.9950) elde etmesi, tüm sınıflarda tutarlı genelleme yeteneğini açıkça ortaya koymaktadır.

Hiçbir modelde overfitting gözlemlenmemiştir çünkü early stopping mekanizması eğitimi etkin biçimde yönetmiştir.

Veri seti büyüklüğü (329 orijinal görüntü) temel sınırlılık olarak öne çıkmıştır. Daha büyük veri setiyle modellerin daha düşük hata payıyla çalışması beklenmektedir.

Veri setinin azlığından dolayı ve test ve doğrulama setlerine veri arttırma yapılamadığı için sonuçlarda hata payı olma olasılığı ve sonuçların ihtiyatla yorumlanması gerekmektedir.

Üç modelin çıkarım hızları karşılaştırıldığında YOLOv8s yaklaşık 23 ms, RT-DETR yaklaşık 42 ms ve Faster R-CNN yaklaşık 470 ms ile görüntü başına işlem süresi sergilemektedir.

Böbrek taşı tür tahmin uygulaması sayesinde sonuçların daha hızlı çıktığı almasından dolayı mevcut süreci maliyet ve zaman bakımından önemli ölçüde azaltmayı hedeflemektedir.

Bu çalışmada model değerlendirmesi tek bir train/val/test bölünmesi üzerinden gerçekleştirilmiştir. Çalışmada elde ettiğimiz yüksek metriklerin istatistiksel güvenilirliğinin artırılması amacıyla k-fold cross-validation uygulanması önerilmektedir. Çapraz doğrulama (k-fold cross-validation) veri setini k eşit alt kümeye bölerek her alt kümeyi sırasıyla test seti olarak kullanan ve sonuçların ortalaması ile standart sapmasını raporlayan bir yöntemdir (Goodfellow vd., 2016). Bu yöntemin uygulanması, mevcut çalışmada modellerin genelleme kapasitelerini daha güvenilir şekilde ortaya çıkaracaktır. Özellikle 33 görüntüden oluşan test setinin kapasitesini artırarak istatistiksel belirsizliği minimuma indirgenmiş olur. Bu çalışmanın en kritik metodolojik eksikliğini gidermek açısından da çapraz doğrulama bir sonraki çalışmalarda zorunlu bir adım olarak değerlendirilmelidir.

MTA sürecinin yarattığı pratik engelleri büyük ölçüde ortadan kaldıracaktır.

Araştırma Sorularına İlişkin Çıkarımlar

Çalışmanın başında ortaya konan dört araştırma sorusuna, elde edilen bulgular ışığında aşağıdaki yanıtlar verilebilir.

1. Mimari karşılaştırma ve uygunluk: Üç mimari yaklaşım da böbrek taşı türü tespitinde yüksek performans sergilemiş, doğrulama setinde her biri %96'nın üzerinde mAP50 değerine ulaşmıştır. Bununla birlikte modeller farklı güçlü yönler göstermiştir. Doğrulama setinde RT-DETR en yüksek değerleri (mAP50: 0.9950, F1: 0.9855) elde ederken, test setinde Faster R-CNN mAP50'de %100'e ulaşmıştır. YOLOv8s ise en hızlı model olmuştur. Dolayısıyla tek bir mimarinin mutlak üstünlüğünden değil, her yaklaşımın farklı önceliklere uygun olduğundan söz edilebilir. İki aşamalı Faster R-CNN en yüksek doğruluğu sunmakla birlikte yavaştır; tek aşamalı YOLOv8s hızlıdır ancak sınıflar arası tutarlılığı daha değişkendir; transformer tabanlı RT-DETR ise doğruluk ile hız arasında en dengeli profili sergilemektedir. Klinik karar destek bağlamında performans tutarlılığı öncelikli ölçüt olarak alındığında, bu göreve en uygun mimari yaklaşımın transformer tabanlı RT-DETR olduğu sonucuna varılmıştır.

2. Model seçiminde belirleyici faktörler: Bulgular, model seçiminde yalnızca doğruluk metriklerinin yeterli olmadığını açıkça ortaya koymuştur. Görüntü başına tahmin süreleri YOLOv8s için yaklaşık 23 ms, RT-DETR için yaklaşık 42 ms ve Faster R-CNN için yaklaşık 470 ms olarak ölçülmüştür. Faster R-CNN, doğruluk açısından en yüksek değerlere ulaşmasına rağmen, bu yavaşlığı nedeniyle ücretsiz CPU tabanlı bir dağıtım

ortamında pratikte kullanılamaz düzeydedir. Buna karşılık RT-DETR, hem doğrulama hem de test setinde özdeş mAP50 değeri (0.9950) elde ederek genelleme tutarlılığı göstermiş, makul bir tahmin hızı sunmuş ve görece küçük model boyutuyla (66 MB) dağıtımına uygun olmuştur. Bu nedenle, klinik bir karar destek sistemi için model seçilirken doğruluğun yanı sıra tahmin hızı, genelleme tutarlılığı ve dağıtım uygunluğunun da belirleyici faktörler olduğu sonucuna ulaşılmıştır.

3. Transformer mimarisinin performansı ve katkısı: Daha önce böbrek taşı türü tespitine uygulanmamış olan RT-DETR'in bu çalışmada kullanılması, hem alana özgün bir katkı sağlamış hem de transformer mimarisinin tıbbi görüntü analizindeki potansiyelini somut biçimde göstermiştir. RT-DETR, doğrulama ve test setlerinde özdeş mAP50 değeri elde eden tek model olmuş; bu durum, modelin küresel dikkat (global attention) mekanizmasının daha önce görülmemiş verilere tutarlı genelleme sağladığına işaret etmektedir. Geleneksel mimarilerle karşılaştırıldığında RT-DETR, Faster R-CNN'in yüksek doğruluğuna yakın sonuçlar üretirken ondan çok daha hızlı çalışmış, YOLOv8s'in hızına yaklaşırken daha tutarlı bir sınıf performansı sergilemiştir. Bu bulgular, transformer tabanlı mimarilerin böbrek taşı türü tespitinde uygulanabilir ve umut verici bir yaklaşım olduğunu göstermektedir.

4. Karar destek sistemine dönüştürülebilirlik: En iyi performansı sergileyen RT-DETR modeli, Gradio kütüphanesi kullanılarak Hugging Face Spaces platformunda web tabanlı ve erişilebilir bir karar destek sistemine başarıyla dönüştürülmüştür. Geliştirilen sistem; görüntü yükleme, güven eşiği ayarlama, taş türü tespiti, sınırlayıcı kutu görselleştirme ve her taş türüne özgü Türkçe koruyucu hekimlik önerisi sunma işlevlerini içermektedir. Bu yönüyle çalışma, mevcut klinik sürecin pratik darboğazlarına somut ve işlevsel bir alternatif ortaya koymaktadır. Bununla birlikte, sistemin henüz bir hekim onay mekanizması içermemesi, gerçek klinik entegrasyon öncesinde giderilmesi gereken bir gerekliliktir. Dolayısıyla en iyi modelin işlevsel bir karar destek sistemine dönüştürülebileceği gösterilmiş, ancak klinik kullanım için ek geliştirmelere ihtiyaç duyulduğu da ortaya konmuştur.

Teorik Katkılar

Bu çalışma, böbrek taşı tespiti literatürüne üç temel teorik katkı sunmaktadır. İlk olarak, RT-DETR'in beş sınıflı böbrek taşı tespitine uygulanması alanın literatüründe bildiğimiz kadarıyla bir ilk olup transformer mimarisinin tıbbi görüntü analizindeki potansiyelini

somut biçimde göstermektedir. İkinci olarak, YOLOv8s, Faster R-CNN ve RT-DETR'i aynı veri seti ve protokol üzerinde karşılaştıran sistematik bir değerlendirme, mimari seçimin klinik sonuçlar üzerindeki etkisini ortaya koymaktadır. Üçüncü olarak, veri seti büyüklüğü ile model güvenilirliği arasındaki ilişkiye dair bulgular, tıbbi görüntü analizi araştırmalarında daha büyük ve çok merkezli veri setlerinin gerekliliğini vurgulayan literatürü desteklemektedir (Sun vd., 2017; Litjens vd., 2017).

Pratik Katkılar

Pratik açıdan en önemli katkı, Türkiye klinik pratiğinde böbrek taşı kimyasal analizi için MTA'ya gönderim sürecinin uzunluğu ve maliyetine pratik bir alternatif sunulmasıdır. Hugging Face Spaces üzerinde kalıcı olarak dağıtılan web uygulaması, uluslararası olarak erişilebilir ücretsiz ve anlık bir taş türü tespit aracı sunmaktadır. REST API altyapısının hazır olması ise ilerleyen çalışmalarda hastane bilgi sistemleri, mobil uygulamalar ve klinik karar destek platformlarıyla entegrasyon için somut bir zemin oluşturmaktadır. Bu sistem, böbrek taşı görüntüsünden otomatik taş türü tespiti, türe özgü koruyucu hekimlik önerileri ve web tabanlı erişim imkânı sunmaktadır. Sistemin hasta bakım kalitesini artırması, koruyucu hekimlik hizmetlerine talebi yükseltmesi ve harici laboratuvar ihtiyacını ortadan kaldırarak analiz ve laboratuvar maliyetlerini önemli ölçüde azaltması bekleniyor.

Çalışmanın Sınırlılıkları

Bu çalışma birtakım sınırlılıklar barındırmaktadır. İlk olarak, 329 orijinal görüntüden oluşan veri setinin boyutu klinik uygulamalar için yetersiz kalmaktadır. Faster R-CNN'nin mAP50=1.0000 gibi sınır değerlere ulaşması bu küçük boyutun bir yansımasıdır (Japkowicz ve Shah, 2011).

İkinci olarak, test seti 33 görüntüden oluşmakta olup bazı sınıfların test temsili son derece sınırlıdır. Özellikle Mikst sınıfı yalnızca 9 orijinal görüntüyle temsil edilmekte olup bu sayı modelin söz konusu sınıfa ait morfolojik çeşitliliği yeterince öğrenmesi için yetersiz kalmaktadır. Veri setindeki sınıf dengesizliği çalışmanın temel metodolojik sınırlılıklarından birini oluşturmaktadır.

Üçüncü olarak, çalışmada kullanılan görüntüler kontrollü bir hazırlık sürecinden geçirilmiştir. Ham toplu fotoğraflardan her taş tek tek kırılarak elde edildiğinden, her görüntüde taş merkezi konumda ve çerçevenin büyük bölümünü kaplayacak biçimde yer

almaktadır. Bundan dolayı görüntüler gerçek klinik BT verilerinin karmaşıklığını tam yansıtmayabilir.

Dördüncü olarak, çapraz doğrulama uygulanmamıştır.

Beşinci olarak, geliştirilen sistem henüz bir hekim onay mekanizması içermemektedir. Klinik pratiğe entegrasyonu için prospektif çalışmalar gerekmektedir.

Altıncı olarak çalışmada kullanılan görüntü bazlı bölünme olduğu için bazı hastaların görüntülerinin hem eğitim hem de test setinde olma olasılığını ortaya çıkarıyor. Bu da raporlanan metriklerin yüksek test skorlarının bir kısmı bu örtüşmeden dolayı olabilir.

Yedinci olarak çalışmada kullanılan derin öğrenme modellerinin eğitimi, kişisel bilgisayar donanımıyla gerçekleştirilememiştir. Modern nesne tespiti modelleri eğitim sürecinde yüksek miktarda GPU belleği (VRAM) ve paralel hesaplama gücü gerektirmektedir. Tüketici sınıfı GPU'ların sahip olduğu 4-8 GB VRAM kapasitesi bu modellerin eğitimi için yetersiz kalmaktadır. Eğitim süreleri bu sebepten dolayı çok daha yavaş çalışmış hatta yetersiz kalmıştır. Bu nedenle model eğitimleri bulut tabanlı platformlara taşınmak zorunda kalmıştır. Google Colabde de oturum süresinin kısıllığı ve eğitimlerin uzun sürmesinden dolayı eğitimi tamamlayamamıştır. Bundan dolayı da Kaggle ortamına geçiş yapmak zorunda kalmıştır. Daha büyük veri seti eğitimi için donanımlı bir bilgisayar gerekmektedir.

Gelecek Çalışma Önerileri

Bu çalışmadan hareketle aşağıdaki araştırma yönelimleri önerilmektedir:

Daha büyük ve çok merkezli veri setlerinin oluşturulması: Özellikle az temsil edilen sistin ve mikst sınıfları için yeterli örnek sayısına ulaşılması, model güvenilirliğini artıracaktır.

RT-DETR-X gibi daha büyük model varyantlarının denenmesi: Daha büyük veri seti koşullarında transformer mimarisinin sağladığı avantajın daha belirgin hale gelmesi beklenmektedir.

Elde edilen sonuçların güvenilirliğinin artırılması için çapraz doğrulama (k-fold cross-validation) uygulanması beklenmektedir. İstatistiksel güvenilirliğin artırılması için önerilmektedir.

Hekim onay mekanizmasının sisteme entegrasyonu: Klinik karar destek sistemlerinde son kararın uzman hekim tarafından verilmesi hem etik hem de yasal açıdan zorunludur.

Açıklanabilir yapay zekâ (XAI) yöntemlerinin entegrasyonu: Grad-CAM gibi görselleştirme teknikleri, modelin kararlarını hekime açıklayarak klinik kabulü kolaylaştıracaktır (Selvaraju vd., 2017).

Geliştirilen RT-DETR modelinin Hugging Face Inference API altyapısı üzerinden REST API olarak dışa açılması, ilerleyen çalışmalarda farklı platformlara entegrasyonun önünü açmaktadır. Bu entegrasyon sayesinde model; iOS ve Android tabanlı mobil uygulamalar, hastane bilgi yönetim sistemleri (HBYS), elektronik sağlık kayıt (ESK) sistemleri ve birinci basamak sağlık hizmetleri portalları gibi farklı platformlarda bir servis olarak kullanılabilir.

Sistemin hastane bilgi yönetim sistemleriyle entegrasyonu, üroloji kliniklerinde iş akışına doğrudan dahil edilmesini mümkün kılacaktır. Bu entegrasyonda model çıktısı; taş türü tahmini, güven skoru ve koruyucu hekimlik önerileriyle birlikte otomatik olarak hastanın elektronik sağlık kaydına işlenebilecektir. Hekim onay mekanizmasının bu iş akışına eklenmesiyle sistem, tam anlamıyla bir klinik karar destek aracına dönüşecektir.

Gelecek çalışmalarda az temsil edilen sınıflar için daha fazla orijinal görüntü toplanması ve GAN tabanlı sentetik veri üretimi gibi ileri yöntemlerin uygulanması önerilmektedir.

TERİMLER SÖZLÜĞÜ

Analysis	: Analiz
Anchor-Free	: Çapa Bağımsız
Auto	: Otomatik
API (Application Programming Interface)	: Uygulama Programlama Arayüzü
Artificial Intelligence	: Yapay Zeka
Aspect Ratio	: En-Boy Oranı
Auto-Orient	: Otomatik Yön Düzeltme
Background	: Arka plan
Batch Size	: Yığın Boyutu
Binary	: İkili
Bounding Box	: Sınırlayıcı Kutu
Calcium Oxalate	: Kalsiyum Oksalat
Calcium Phosphate	: Kalsiyum Fosfat
Confidence Threshold	: Güven Eşiği
Confusion Matrix	: Karmaşıklık Matrisi
Convex Hull	: Dışbükey Gövde
CPU (Central Processing Unit)	: Merkezi İşlemci Birimi
Crop	: Kırpma
Cross-Validation	: Çapraz Doğrulama
Cystine	: Sistin
Data Augmentation	: Veri Artırma
Data Leakage	: Veri Sızıntısı
Decision Support System	: Karar Destek Sistemi
Deep Learning	: Derin Öğrenme

Deafult	: Hazır Ağırlıklar
Detect Stones	: Taş Tespiti
Deployment	: Dağıtım
Device	: Cihaz
Early Stopping	: Erken Durdurma
Epoch	: Tur / Devir
Explainable Artificial Intelligence (XAI)	: Açıklanabilir Yapay Zekâ
F1 Score	: F1 Skoru
False Negative (FN)	: Yanlış Negatif
False Positive (FP)	: Yanlış Pozitif
Feature Pyramid Network (FPN)	: Özellik Piramidi Ağı
Fine-tuning	: İnce Ayar
Framework	: Çerçeve / Yazılım Çerçevesi
Gaussian Blur	: Bulanıklaştırma
GPU (Graphics Processing Unit)	: Grafik İşlemci Birimi
Hybrid Encoder	: Hibrit Kodlayıcı
Inference	: Çıkarım Yapma
Intersection over Union (IoU)	: Kesişim/Birleşim Oranı
Kidney Stone	: Böbrek Taşı
Learning Rate	: Öğrenme Hızı
Mean Average Precision (mAP)	: Ortalama Hassasiyet
Medical Image	: Medikal Resim
Momentum	: Hareket Miktarı
Nephrolithiasis	: Böbrek Taşı Hastalığı
Non-Maximum Suppression (NMS)	: Maksimum Olmayan Bastırma
Notebook	: Not Defteri

Object Detection	: Nesne Tespiti
Optimizer	: Optimizasyon Algoritması
Overfitting	: Ezberleme / Aşırı Öğrenme
Padding	: Dolgu
Patience	: Sabır Parametresi / Bekleme Süresi
Plot	: Arsa
Precision	: Kesinlik
Real-Time	: Gerçek Zaman
Recall	: Duyarlılık
Region Proposal Network (RPN)	: Bölge Öneri Ağı
Residual Connection	: Artık Bağlantı
Resize	: Yeniden Boyutlandırma
Salt & Pepper Noise	: Tuz-Biber Gürültüsü
Scheduler	: Planlayıcı
Shear	: Kaydırma / Eğme
Solidity	: Katılık
Small	: Küçük
Stretch	: Esnetme
Training Set	: Eğitim Seti
Transfer	: Lojistik
Transfer Learning	: Transfer Öğrenme
Transformer	: Dönüştürücü
True Positive (TP)	: Gerçek Pozitif
Uric Acid	: Ürik Asit
Urology	: Üroloji
Validation Set	: Doğrulama Seti

VRAM (Video Random Access Memory)	: Video Rastgele Erişimli Bellek
Query Selection	: Sorgu Seçimi
Weight Decay	: Ağırlık Sönümü
Worker	: İşçi

KAYNAKÇA

- Abraham, A., Kavoussi, N. L., Sui, W., Bejan, C., Capra, J. A. ve Hsi, R. (2022). Machine learning prediction of kidney stone composition using electronic health record-derived features. *Journal of Endourology*, 36(2), 243-250. <https://doi.org/10.1089/end.2021.0211>
- Bisong, E. (2019). *Building machine learning and deep learning models on google cloud platform* (1. Baskı). Apress. https://doi.org/10.1007/978-1-4842-4470-8_7
- Black, K. M., Law, H., Aldoukhi, A., Deng, J. ve Ghani, K. R. (2020). Deep learning computer vision algorithm for detecting kidney stone composition. *BJU International*, 125(6), 920-924. <https://doi.org/10.1111/bju.15035>
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A. ve Zagoruyko, S. (2020). End-to-end object detection with transformers. A. Vedaldi, H. Bischof, T. Brox ve J.-M. Frahm (Ed.), *Computer vision – ecvv 2020* içinde (ss. 213-229). Springer. https://doi.org/10.1007/978-3-030-58452-8_13
- Coe, F. L., Evan, A. ve Worcester, E. (2005). Kidney stone disease. *Journal of Clinical Investigation*, 115(10), 2598-2608. <https://doi.org/10.1172/JCI26662>
- Daudon, M., Dessombz, A., Frochot, V., Letavernier, E., Haymann, J.-P., Jungers, P. ve Bazin, D. (2016). Comprehensive morpho-constitutional analysis of urinary stones improves etiological diagnosis and therapeutic strategy of nephrolithiasis. *Comptes Rendus Chimie*, 19(11-12), 1470-1491. <https://doi.org/10.1016/j.crci.2016.05.008>
- Dwyer, B., Nelson, J. ve Solawetz, J. (2022). *Roboflow* (Versiyon 1.0) [Bilgisayar yazılımı]. Roboflow. <https://roboflow.com>
- El Beze, J., Mazeaud, C., Daul, C., Ochoa-Ruiz, G., Daudon, M., Eschwège, P. ve Hubert, J. (2022). Evaluation and understanding of automated urinary stone recognition methods. *BJU International*, 130(6), 786-798. <https://doi.org/10.1111/bju.15767>
- Frassetto, L. ve Kohlstadt, I. (2011). Treatment and prevention of kidney stones: An update. *American Family Physician*, 84(11), 1234-1242.
- Girshick, R., Donahue, J., Darrell, T. ve Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *IEEE Conference on Computer Vision and Pattern Recognition* içinde (ss. 580-587). IEEE. <https://doi.org/10.1109/CVPR.2014.81>
- Girshick, R. (2015). Fast r-cnn. *IEEE International Conference on Computer Vision (ICCV)* içinde (ss. 1440-1448). IEEE. <https://doi.org/10.1109/ICCV.2015.169>
- Gonzalez, R. C. ve Woods, R. E. (2018). *Digital image processing* (4. Baskı). Pearson.
- Goodfellow, I., Bengio, Y. ve Courville, A. (2016). *Deep learning*. MIT Press. <https://www.deeplearningbook.org>

- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* içinde (ss. 770-778). IEEE. <https://doi.org/10.1109/CVPR.2016.90>
- Japkowicz, N. ve Shah, M. (2011). *Evaluating learning algorithms: A classification perspective*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511921803>
- Jocher, G., Chaurasia, A. ve Qiu, J. (2023). *YOLO by Ultralytics* (Versiyon 8.0.0) [Bilgisayar yazılımı]. Ultralytics. <https://github.com/ultralytics/ultralytics>
- Kaggle. (2024, 2 Şubat). *Kaggle: the world's ai proving ground*. <https://www.kaggle.com> adresinden 2 Şubat 2026 tarihinde alınmıştır.
- Kaufman, S., Rosset, S., Perlich, C. ve Stitelman, O. (2012). Leakage in data mining: formulation, detection, and avoidance. *ACM Transactions on Knowledge Discovery from Data*, 6(4), 1-21. <https://doi.org/10.1145/2382577.2382579>
- Khan, S. R., Pearle, M. S., Robertson, W. G., Gambaro, G., Canales, B. K., Doizi, S., Traxer, O. ve Tiselius, H.-G. (2016). Kidney stones. *Nature Reviews Disease Primers*, 2, 16008. <https://doi.org/10.1038/nrdp.2016.8>
- Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B., Bussonnier, M., Frederic, J., Kelley, K., Hamrick, J., Grout, J., Corlay, S., Ivanov, P., Avila, D., Abdalla, S. ve Willing, C. (2016). Jupyter notebooks: a publishing format for reproducible computational workflows. F. Loizides & B. Schmidt (Ed.), *Positioning and power in academic publishing: players, agents and agendas* içinde (ss. 87-90). IOS Press. <https://doi.org/10.3233/978-1-61499-649-1-87>
- Knoll, T., Schubert, A. B., Fahlenkamp, D., Leusmann, D. B., Wendt-Nordahl, G. ve Schubert, G. (2011). Urolithiasis through the ages: data on more than 200,000 urinary stone analyses. *The Journal of Urology*, 185(4), 1304-1311. <https://doi.org/10.1016/j.juro.2010.11.073>
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. <https://doi.org/10.1145/3065386>
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P. ve Zitnick, C. L. (2014). Microsoft coco: common objects in context. D. Fleet, T. Pajdla, B. Schiele ve T. Tuytelaars (Ed.), *Computer Vision – ECCV 2014* içinde (ss. 740-755). Springer, Cham. https://doi.org/10.1007/978-3-319-10602-1_48
- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B. ve Belongie, S. (2017). Feature pyramid networks for object detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* içinde (ss. 2117-2125). IEEE. <https://doi.org/10.1109/CVPR.2017.106>

- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B. ve Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>
- Lopez, F., Varelo, A., Hinojosa, O., Mendez, M., Trinh, D.-H., ElBeze, Y., Hubert, J., Estrade, V., Gonzalez, M., Ochoa, G. ve Daul, C. (2021). Assessing deep learning methods for the identification of kidney stones in endoscopic images. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* içinde (ss. 2778-2781). IEEE. <https://doi.org/10.1109/EMBC46164.2021.9630211>
- Onal, E. G. ve Tekgul, H. (2022). Assessing kidney stone composition using smartphone microscopy and deep neural networks. *BJUI Compass*, 3(4), 310-315. <https://doi.org/10.1002/bco2.137>
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66. <https://doi.org/10.1109/TSMC.1979.4310076>
- Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L. ve da Silva, E. A. B. (2021). A comparative analysis of object detection metrics with a companion open-source toolkit. *Electronics*, 10(3), 279. <https://doi.org/10.3390/electronics10030279>
- Parks, J. H. ve Coe, F. L. (1996). The financial effects of kidney stone prevention. *Kidney International*, 50(5), 1706-1712. <https://doi.org/10.1038/ki.1996.489>
- Pearle, M. S., Goldfarb, D. S., Assimos, D. G., Curhan, G., Denu-Ciocca, C. J., Matlaga, B. R., Monga, M., Penniston, K. L., Preminger, G. M., Turk, T. M. T. ve White, J. R. (2014). Medical management of kidney stones: aua guideline. *The Journal of Urology*, 192(2), 316-324. <https://doi.org/10.1016/j.juro.2014.05.006>
- Peerapen, P. ve Thongboonkerd, V. (2023). Kidney stone prevention. *Advances in Nutrition*, 14(3), 555-569. <https://doi.org/10.1016/j.advnut.2023.03.002>
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A. (2016). You only look once: unified, real-time object detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* içinde (ss. 779-788). IEEE. <https://doi.org/10.1109/CVPR.2016.91>
- Ren, S., He, K., Girshick, R. ve Sun, J. (2017). Faster r-cnn: towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D. ve Batra, D. (2017). Grad-cam: visual explanations from deep networks via gradient-based localization. *IEEE International Conference on Computer Vision (ICCV)* içinde (ss. 618-626). IEEE. <https://doi.org/10.1109/ICCV.2017.74>

- Shorten, C. ve Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6, 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Shortliffe, E. H. ve Cimino, J. J. (Ed.). (2014). *Biomedical informatics: computer applications in health care and biomedicine* (4. Baskı). Springer. <https://doi.org/10.1007/978-1-4471-4474-8>
- Skolarikos, A., Somani, B., Neisius, A., Jung, H., Petřík, A., Tailly, T., Davis, N., Tzelves, L., Geraghty, R., Lombardo, R., Bezuidenhout, C. ve Gambaro, G. (2024). Metabolic evaluation and recurrence prevention for urinary stone patients: An EAU guidelines update. *European Urology*, 86(4), 343-363. <https://doi.org/10.1016/j.eururo.2024.05.029>
- Sun, C., Shrivastava, A., Singh, S. ve Gupta, A. (2017). Revisiting unreasonable effectiveness of data in deep learning era. *IEEE International Conference on Computer Vision (ICCV)* içinde (ss. 843-852). IEEE. <https://doi.org/10.1109/ICCV.2017.97>
- Turban, E., Aronson, J. E., Liang, T.-P. ve Sharda, R. (2005). *Decision support systems and intelligent systems* (7. Baskı). Pearson Prentice Hall.
- Türk, C., Neisius, A., Petrik, A., Seitz, C., Skolarikos, A., Thomas, K. ve Fankhauser, C. D. (2022). *Urolithiasis*. European Association of Urology. <https://uroweb.org/guidelines/urolithiasis>
- Wiederkehr, M. R. ve Moe, O. W. (2011). Uric acid nephrolithiasis: a systemic metabolic disorder. *Clinical Reviews in Bone and Mineral Metabolism*, 9, 207-217. <https://doi.org/10.1007/s12018-011-9106-6>
- Wolf, T., Debut, L., Sanh, V., Chaumond, J., Delangue, C., Moi, A., Cistac, P., Rault, T., Louf, R., Funtowicz, M., Davison, J., Shleifer, S., von Platen, P., Ma, C., Jernite, Y., Plu, J., Xu, C., Le Scao, T., Gugger, S., ... Rush, A. M. (2020). Transformers: state-of-the-art natural language processing. *Conference on Empirical Methods in Natural Language Processing: System Demonstrations* içinde (ss. 38-45). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2020.emnlp-demos.6>
- Wong, Y., Cook, P., Roderick, P. ve Somani, B. K. (2016). Metabolic syndrome and kidney stone disease: a systematic review of literature. *Journal of Endourology*, 30(3), 246-253. <https://doi.org/10.1089/end.2015.0567>
- Yosinski, J., Clune, J., Bengio, Y. ve Lipson, H. (2014). How transferable are features in deep neural networks? Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence ve K. Q. Weinberger (Ed.), *Advances in Neural Information Processing Systems* içinde (ss. 3320-3328). Curran Associates.
- Zhao, Y., Lv, W., Xu, S., Wei, J., Wang, G., Dang, Q., Liu, Y. ve Chen, J. (2024). DETRs beat YOLOs on real-time object detection. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* içinde (ss. 16965-16974). IEEE. <https://doi.org/10.1109/CVPR52733.2024.01605>

Zirker, L. (2026, 8 Ocak). *Recurrent kidney stones prevention: diet & lifestyle recommendations*, Renal and Urology News.
<https://www.renalandurologynews.com/features/recurrent-kidney-stones-prevention-diet-lifestyle/> adresinden 18.04.2026 tarihinde alınmıştır.

EKLER

Ek 1. Etik Kurul Onay Belgesi

Evrak Tarih ve Sayısı: 20.09.2025-E.513053



T.C.
SAKARYA ÜNİVERSİTESİ REKTÖRLÜĞÜ
Tıp Fakültesi Dekanlığı
Sağlık Bilimleri Bilimsel Araştırma Etik Kurulu



Sayı : E-43012747-050.04-513053-449
Konu : Sağlık Bilimleri Bilimsel Araştırma Etik
Kurul Başvuru Dosyası

20.09.2025

Sayın Doç. Dr. Hacı İbrahim ÇİMEN

Sakarya Üniversitesi Tıp Fakültesi
Üroloji Anabilim Dalı

İlgi : 14.08.2025 tarih ve 449 sayılı başvurunuz.

Destekleyicisi olduğunuz **"Yapay Zekaya Dayalı Böbrek Taşı Türü Tespiti ve Koruyucu Hekimlik Karar Destek Sistemi"** isimli çalışmanın ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş olup; çalışmanın başvuru dosyasında belirtilen şekilde etik ve bilimsel açıdan sakınca bulunmadığına etik kurul üyelerince karar verilmiştir.

Ancak çalışma bitiş tarihinden itibaren en geç 3 ay içerisinde çalışma sonuç raporunun Sağlık Bilimleri Bilimsel Araştırma Etik Kuruluna gönderilmesi gerekmektedir.

Bilgilerinize rica ederim.

Prof. Dr. Pelin TANYERİ
Sağlık Bilimleri Etik Kurulu Başkanı

Bu belge, güvenli elektronik imza ile onaylanmıştır.

Doğrulama Kodu: BS96RSV86L_Fin Kodu: 54472

Belge Takip Adresi: <https://turkiye.gov.tr/ebd/etik=57813&cD=BS96RSV86L&cS=513053>

Adres: Sakarya Üniversitesi Tıp Fakültesi Dekanlığı, Korucuk Kampüsü, Korucuk,
Adapazarı/Sakarya
Telefon No: 264 295 6630 Faks No: 264 295 6629
e-Posta: tip@sakarya.edu.tr Elektronik Ağ: www.tip.sakarya.edu.tr

Bilgi için: Hasan Konak
Unvanı: Sürekli İşçi



ÖZGEÇMİŞ

Adı Soyadı: Bahar ÇAKICI

ÖĞRENİM DURUMU

Öğrenim Derecesi	Öğrenim Yeri	Öğrenim Yılı
Yüksek Lisans	Sakarya Üniversitesi / İşletme Enstitüsü / Yönetim Bilişim Sistemleri	2023
Lisans	Sakarya Üniversitesi / İşletme Fakültesi / Yönetim Bilişim Sistemleri	2015
Lise	Prof. Dr. Sabahattin Zaim Anadolu Lisesi	2010

İŞ DENEYİMİ

Yıl	Yer	Görev
2020-2022	FarmaKod	Full Stack Developer
2022-Devam	Linktera Bilgi Teknolojileri	Product Engineer

YABANCI DİL

İngilizce

ESERLER

- Çakıcı, B. (2024). Bulut bilişim ve web. F. Dursun (Ed.), *Bulut bilişim: kavramlar, modeller ve uygulamalar* içinde (ss. 113–134). Değişim Yayınları.
- Çakıcı, B. ve Zeren, S. S. (2024). Günümüz bulut bilişim hizmet ortamları. F. Dursun (Ed.), *Bulut bilişim: kavramlar, modeller ve uygulamalar* içinde (ss. 67–86). Değişim Yayınları.