

TEKNOFEST

HAVACILIK, UZAY VE TEKNOLOJİ FESTİVALİ

SAĞLIKTA YAPAY ZEKÂ YARIŞMALARI

(Bilgisayarlı Görüyle Abdomen (Karın) Bölgesi için

Hastalık Tespiti Kategorisi)

PROJE DETAY RAPORU

LİSE KATEGORİSİ

TAKIM ADI: **DiagnosisByAI**

TAKIM ID: **417725**

İçindekiler

1. Proje Mevcut Durum Değerlendirmesi	3
2. Özgünlük	4
3. Sonuçlar ve İnceleme	5
4. Deney ve Eğitim Aşamalarında Kullanılan Veri Setleri	10
5. Referanslar	12



1. Proje Mevcut Durum Değerlendirmesi

Proje Sunuş Raporu'ndaki iş planlanmasına bağlı kalınarak, bir yandan güncel literatür takip edilmiş, bir yandan veri setleri işlemeye hazır hale getirilmiş bir yandan da önerilen modeller eğitilerek performans değerlendirmeleri yapılmıştır.

Modeller Üzerine:

Proje Sunuş Raporu'nda tek bir fotoğraf üzerinden inceleme yapabilecek modeller ile hacimsel algılama yapabilecek modellerin kullanılması önerilmiştir.

Proje Sunuş Raporu'nda tek bir fotoğraf üzerinde inceleme yapabilecek modeller konusunda YOLOR [1], EffcientDet [13] ve Swin [14] modelleri önerilmiştir. Bu modellerin COCO2017 veri seti üzerinde yapılan deneylerdeki performansları karşılaştırıldığında EffcientDet ve Swin modellerinin, performans veya hız/performans bakımından 2021 yılında çıkış yapmış YOLOR ve Scaled YOLOv4 [2] modellerine göre geri kaldığı görülmüş, bundan dolayı bu modellerin kullanılmasından vazgeçilmiştir. Veri seti üzerinde eğitilip test üzere YOLOR model ailesinden YOLOR-W6 ve YOLOR-E6 modelleri, Scaled YOLOv4 model ailesinden YOLOv4-P6 ve YOLOv4-P7 modellerinin kullanılmasına karar verilmiştir.

Proje Sunuş Raporu'nda hacimsel algılama yapabilecek modeller konusunda UNETR, 3D ResNet, Volume RCNN modelleri önerilmiştir. Bu ve başka modellerin performans analizleri ile ilgili literatür taramasına devam edilmiş, sonrasında, bu modellerden vazgeçilerek yarışma görevine daha uygun olacağı değerlendirilen MVP-Net [3] ve 3DCE [4] modellerinin kullanılmasına karar verilmiştir. Fakat bu modellerin fazla GPU tüketimi yüzünden eğitimleri ve testleri uzun sürmektedir. Bundan dolayı bu modeller üzerindeki denemelerimiz halen devam etmektedir.

Veri Setleri Üzerine:

Proje Sunuş Raporu'nda da vurgulandığı üzere öncelikle veri setleri kullanacağımız modellere uygun hale getirilmek üzere düzenlenmiştir. Ardından eğitim aşamasında karşılaşılan problemlere göre veri setleri üzerinde detaylarını aşağıda paylaştığımız ek düzenlemeler yapılmıştır.

İlk olarak Sağlık Bakanlığı tarafından paylaşılan veri seti incelenmiştir. Paylaşılan veri seti 150GB boyutunda olup DICOM formatında 355.596 görselden oluşmaktadır. Eğiteceğimiz modeller DICOM formatında görselleri alamadığından ve 150GB'lık veri seti boyutu modelleri eğiteceğimiz Kaggle platformunun sınırlarını aştığından dolayı veri setini küçültmek için tüm görseller JPG formatına çevrilmiştir. Görseller JPG formatına çevrilirken uygun pencereleme yöntemleri kullanılmıştır. Veri seti JPG formatına dönüştürüldükten sonra boyutu 15 GB'a kadar inmiştir. Ardından excel dosyası içinde paylaşılmış olan etiketler YOLO ve COCO veri formatlarına dönüştürülmüştür. Excel tablosunun içerisinde bulunan Başlangıç/Bitiş Kesiti etiket tipine sahip ve organlar ile hastalıkların bulunabilecekleri yerleri gösteren etiketler daha sonradan kullanılmak amacıyla ayrı bir JSON dosyasına kaydedilmiştir.

355.596 görselden oluşan veri seti incelendiğinde, 29.013 görselde hastalıklı bulguların olduğu görülmüş ve kalan 326.583 görselin sağlıklı olduğu ve bulgu içermediği gözlemlenmiştir. Bu veri seti ile YOLOR-E6 modeli eğitime çalışılmış fakat veri setinin boyutundan dolayı bir devirin (epoch) 4 saat kadar sürdüğü görülmüştür. Bu süreyi azaltmak amacıyla parametre açısından daha hafif bir model olan YOLOR-W6 modeli eğitilmiştir. YOLOR-W6 modelinin eğitiminin bir devri 2 saat sürmüştür. Model fazla sayıdaki işaretsiz görseller yüzünden hastalıkları tanımayı öğrenememiş ve doğruluk değerleri artış gösterememiştir. Bu sorunu

çözmek amacıyla veri seti %90 hastalıklı (bulgu içeren) ve %10 sağlıklı (bulgu bulunmayan) olacak şekilde daha küçük veri setine bölünmüştür. Bulgu içermeyen görseller ek veri setlerinden (bölüm 4'te detaylandırılmıştır) ve Sağlık Bakanlığı veri setindeki sağlıklı hastaların serilerden seçilmişlerdir. Veri seti hastalıklı ve sağlıklı oranları korunarak %80 eğitim, %20 test olacak şekilde ayrılmıştır. Aynı hastaya ait görüntülerin hepsinin eğitim veya test veri setinde bulunmasına ve ayrılmamasına dikkat edilmiştir. Elde edilen veri seti toplamda 32.236 görselden oluşmaktadır ve 1,5 GB'lık boyuta sahiptir. Son elde edilen veri seti kullanılarak YOLOR-E6, YOLOv4-P6 ve YOLOv4-P7 modelleri eğitilmiştir.

Modellerin Birleştirilmesiyle Elde Edilen Yeni Model Ağı - Sistemi ve Veri Seti'nin Bu Yeni Sisteme Uygun Olacak Biçimde Düzenlemesi Üzerine:

Proje Sunuş Raporu'nda değinilen "model birleştirme" yöntemlerine paralel olarak, modellerin bağımsız kullanılmasının yanında, yarışma sırasında verilecek olan organ konumlarını kullanan ve 6 modelden oluşan bir model ağı - sistemi geliştirilmiştir. Bu sistemdeki tüm modeller YOLOv4-P6 modelidir. Bu sistemde, her bir kesitin hangi organ aralığında olduğuna bakılmakta ve buna göre uygun modeller kullanılarak kesit işlenmektedir.

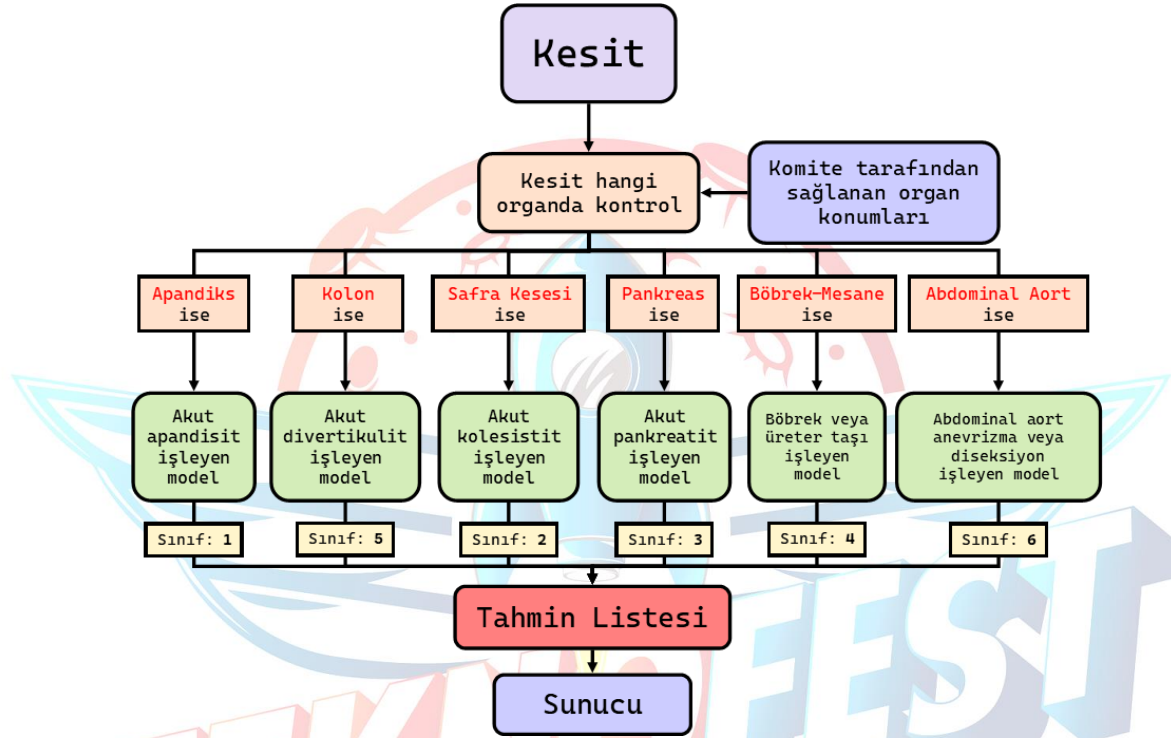
Bu sistemi eğitmek ve test etmek için (bölüm 4'te detayları verilen) ek veri setleri ve Excel tablosundaki Başlangıç/Bitiş Kesiti tipine sahip etiketler kullanılarak 6 model için 6 farklı veri seti hazırlanmıştır. 6 modelin her biri akut apandisit, akut kolesistit, akut pankreatit, böbrek ve üreter taşı, akut divertikülit, abdominal aort anevrizma ve diseksiyon sınıflarından *sadece birini* tahmin etmeye odaklanmaktadır.

Hazırlanan 6 veri setinde tüm veri setinin %10'u sağlıklı kesitlerden oluşmaktadır. Sağlıklı kesitler ek veri setleri ve Sağlık Bakanlığı tarafından paylaşılan veri setinden alınmıştır. Kesitler ek veri setlerinden alınırken bulgunun bulabileceği organların kesitleri alınmıştır. Sağlık Bakanlığı veri setinde ise bulgunun bulunabileceği abdominal aort, apandiks, böbrek-mesane, kolon, pankreas, safra kesesi gibi organların Başlangıç/Bitiş etiketleri arasında, modelin incelediği sınıfa ait bulgu içermeyen sağlıklı kesitlerden seçilmişlerdir. Akut apandisit modeli için geliştirilen veri setinde 5.627 görsel, böbrek ve üreter taşı için geliştirilen veri setinde 2.548 görsel, akut divertikülit için geliştirilen veri setinde 1.227 görsel, akut kolesistit için geliştirilen veri setinde 5.406 görsel, abdominal aortta anevrizma ve diseksiyon için geliştirilen veri setinde 10.861 görsel ve akut pankreatit için geliştirilen veri setinde 7.251 görsel bulunmaktadır. Tüm veri setleri %80'i eğitim %20'si test olacak şekilde hastalıklı-sağlıklı oranı korunarak ayrılmıştır.

2. Özgünlük

Projede kullanılan modeller, literatürde karşılaştırma için sıkça kullanılan COCO2017 gibi veri setlerinde en iyi performansları veren modellerden seçilmişlerdir. Bu modeller eğitilirken ezberlemeyi (overfitting) engellemek için görsellerde döndürme, yansıtma, yakınlaştırma, kırpma gibi yöntemlerin yanı sıra mozaik eğitim [5], HSV değerleri ile oynama gibi veri artırımı yöntemleri de kullanılmıştır. Modeller, COCO veri setinde önceden eğitilmiş ağırlıklar kullanılarak, transfer öğrenmesi ile eğitilmişlerdir. Bu sayede modellerin eğitim hızları ve doğrulukları artırılmıştır. Modellerin performanslarını karşılaştırmak için keskinlik (precision), duyarlılık (recall), F1 skoru ve mAP (mean average percision) gibi sıkça tercih edilen metrikler kullanılmıştır. YOLOR modelleri eğitilirken CIOU [6] ve cisimlilik ile sınıflandırma kayıp fonksiyonları kullanılmıştır. Scaled YOLOv4 modellerinde ise YOLOR modellerinden farklı olarak CIOU yerine GIoU [7] kayıp fonksiyonu kullanılmıştır. Hacimsel incelemeyi mümkün kılacak MVP-Net ve 3DCE modelleri üzerindeki eğitimlerimiz de devam etmektedir.

Ayrıca yarışma sırasında sağlanacak olan organ konumları bilgisini de en efektif şekilde kullanmak için her sınıfı ayrı ayrı inceleyen 6 modelden oluşan bir model ağı – sistemi oluşturulmuştur. Bu 6 modelden oluşan sistemde incelenen kesitin hangi organlar arasında olduğu yarışma sırasında komite tarafından sağlanan bilgilerden anlaşılmaktadır. Bu bilgilere göre hangi modellerin hangi kesiti işlemesi gerektiğine karar verilmektedir. Örneğin, eğer kesit apandiks ve böbrek içeriyorsa o zaman bu kesit akut apandisiti ve böbrek taşı tahmin eden modeller tarafından işlenir. Ardından tüm modellerden elde edilen etiketler uygun sınıf numaraları ile birleştirilir. Bu sistem sayesinde modeller tek bir sınıfa ve bölgeye odaklandığından dolayı doğruluk artırılmaktadır. Bu sistemin şeması şekil 1’de verilmiştir.



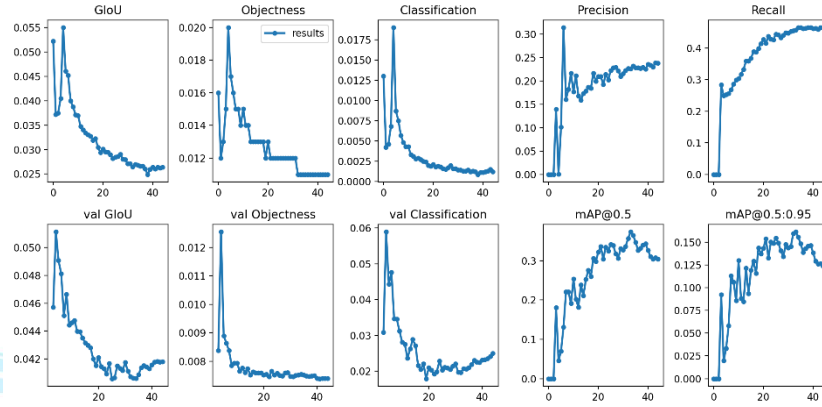
Şekil 1. 6 modelden oluşan sistemin çalışma şeması

Geliştirdiğimiz yöntemler (algoritmalar, modeller) daha önceden bilinen fakat farklı amaçlarla kullanılmakta olan yöntemlerin, yarışma hedefleri doğrultusunda uygun biçimde birleştirilmesi ile elde edilmektedir. Bu birleştirme, sonuç doğruluk oranını artırmak için, bu yöntemlerin farklı parametreleri için farklı kombinasyonların denenmesini de içermektedir. Bunlar çalışmamızın özgünlüğünü oluşturmaktadır.

3. Sonuçlar ve İnceleme

Öncelikle modellerin eğitilmesine YOLOR-W6 ile başlanmıştır. YOLOR-W6 modeli Sağlık Bakanlığı tarafından paylaşılan veri setinin tamamı kullanılarak ek veri bulunmadan eğitilmiştir. YOLOR-W6 modeli 512’lik görüntü boyutu, 40’lık grup boyutu (batch size), 0,01’lik öğrenme oranı (learning rate) ve transfer öğrenmesi yapılarak eğitilmiştir. Modelin bir deviri (epoch) 2 saat 20 dakika sürmüştür. Eğitim sonucunda model 0,213 keskinlik (precision), 0,03439 duyarlılık (recall), 0,1063 mAP.5 ve 0,0558 mAP.5:95 sonuçlarını elde etmiştir. Duyarlılık değerinin bu kadar düşük keskinlik değerinin duyarlılık değerine göre bu kadar yüksek olmasının sebebi modelin bulguları işaretlemeyi öğrenmemesinden kaynaklanmıştır. Keskinlik değeri modelin tahminlerinin kaçının doğru olduğunu, duyarlılık ise modelin tüm bulgulardan kaçını tahmin ettiğini belirtmektedir.

YOLOR-W6 modelinde gözlemden ve incelemelerden sonra veri setindeki bulgu bulunmayan sağlıklı resim sayısının azaltılması kararlaştırılmıştır. Yeni veri seti %90 bulgu içeren (etiketli) ve %10 bulgu içermeyen (sağlıklı) kesitlerden oluşturulmuştur. Ayrıca bu veri setine ek veri setlerinde veriler de eklenmiştir. Bu karma veri seti kullanılarak YOLOR-E6 modeli eğitilmiştir. YOLOR-E6 modeli YOLOR-W6 modelinin parametre açısından daha ağır versiyonudur. YOLOR-E6 modeli 512'lik görüntü boyutu, 22'lik grup boyutu, 0.01'lik öğrenme oranı ve transfer öğrenmesi kullanılarak eğitilmiştir. Toplamda 45 devir eğitilen modelin bir devri 21 dakika sürmüştür. Eğitimler sonucunda model 0,2374 keskinlik, 0,4648 duyarlılık, 0,3048 mAP.5 ve 0,1239 mAP.5:95 sonuçlarını elde etmiştir. Modelin eğitim sırasındaki değerleri şekil 2'de verilmiştir. Şekil 3'te ise bu modelin örnek çıktıları bulunmaktadır.




Şekil 2. YOLOR-E6 modelinin eğitim değerleri grafiği




Şekil 3. YOLOR-E6 modelinin örnek çıktıları

YOLOR-E6 modeline alternatif olarak Scaled YOLOv4 model ailesinden YOLOv4-P6 modeli YOLOR-E6 modeli eğitilirken kullanılan veri setinde eğitilmiştir. YOLOv4-P6 modeli 512'lik görüntü boyutu, 24'lük grup boyutu, 0.01'lik öğrenme oranı ve transfer öğrenmesi ile toplamda 53 devir boyunca eğitilmiştir. Bir devir 22 dakika sürmüştür. Eğitim sonucunda test veri setinde model 0,252 keskinlik, 0,572 duyarlılık, 0,477 mAP.5, 0,215 mAP.5:95 ve 0,303 F1 skoru elde etmiştir. Modelin eğitim sırasındaki değerlerinin grafiği şekil 4'te, modelin örnek çıktıları şekil 5'te verilmiştir.

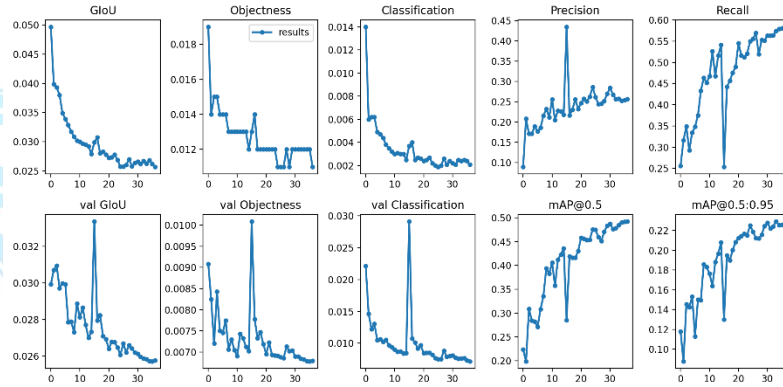


Şekil 4. YOLOv4-P6 modelinin eğitim değerleri grafiği




Şekil 5. YOLOv4-P6 modelinin örnek çıktıları

YOLOv4-P6 modeli eğitildikten sonra doğruluğu artırmak amacıyla parametre sayısı bakımından daha ağır bir model olan YOLOv4-P7 modeli eğitilmiştir. YOLOv4-P7 modeli YOLOv4-P6'da kullanılan veri setinin aynıysa ile eğitilmiştir. YOLOv4-P7 eğitilirken YOLOv4-P6'dan farklı olarak 14'lük grup boyutu kullanılmış diğer ayarlar değiştirilmemiştir. Model toplamda 37 devir boyunca eğitilmiş ve bir devir 37 dakika sürmüştür. Eğitim sonucunda test veri setinde model 0,257 keskinlik, 0,584 duyarlılık, 0,492 mAP.5, 0,227 mAP.5:95 ve 0,313 F1 skoru elde etmiştir. Modelin eğitim sırasındaki değerlerinin grafiği şekil 6'da, modelin örnek çıktıları şekil 7'de verilmiştir.



Şekil 6. YOLOv4-P7 modelinin eğitim değerleri grafiği

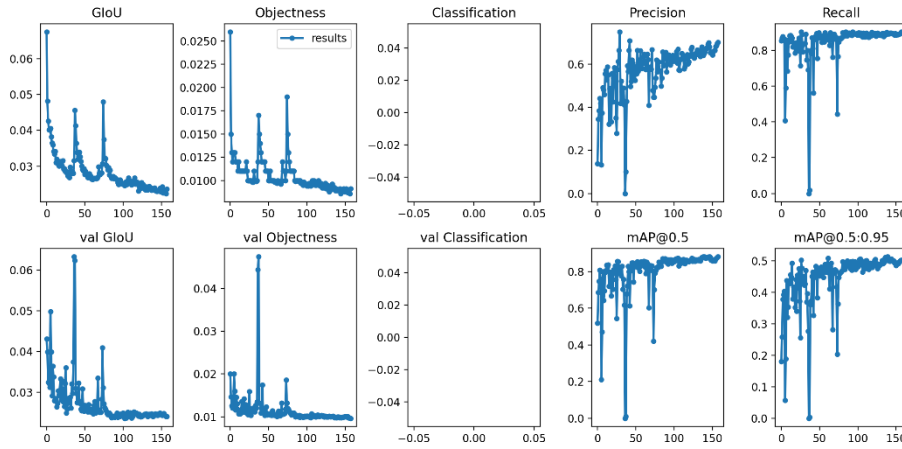


Şekil 7. YOLOv4-P7 modelinin örnek çıktıları

Tüm bu modeller eğitildikten sonra yarışma sırasında verilecek organların konumları verisini kullanarak doğrulukları artırmak amacıyla her bir bulgu sınıfını ayrı ayrı işleyecek 6 model geliştirilmiştir. (Bu modeller için veri setlerinin nasıl düzenlendiği Bölüm 1'de açıklanmıştır.) Eğitilen 6 model de YOLOv4-P6 modelleridir. Eğitilen tüm 6 model de 512'lik görüntü boyutu, 24'lük grup boyutu, 0,01'lik öğrenme oranı ve transfer öğrenmesi ile eğitilmiştir. Modellerin eğitildiği devir sayısı ve bir devirin aldığı süre değişiklik göstermiştir.

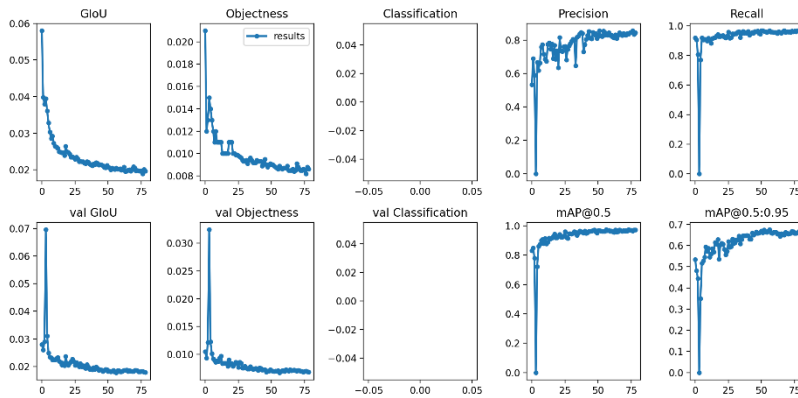
Eğitilen ilk model Akut kolisitleri tahmin edecek modeldir. Bu model safra kesesi kesitleri üzerinde çalışmaktadır. Bu iş için eğitilen YOLOv4-P6 modeli 158 devir boyunca eğitilmiştir

ve bir devir 5 dakika sürmüştür. Model eğitim sonucunda test veri seti üzerinde 0,703 keskinlik, 0,902 duyarlılık, 0,881 mAP.5, 0,502 mAP.5:.95 ve 0,791 F1 skorunu elde etmiştir. Modelin eğitim grafiği şekil 8’de gösterilmiştir.



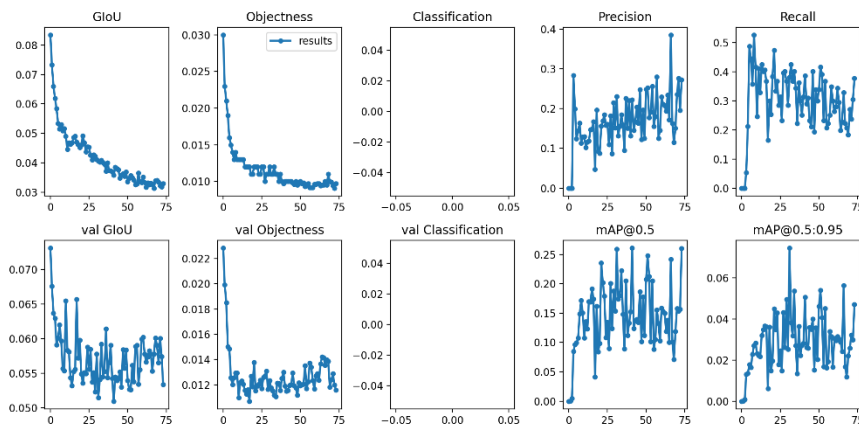
Şekil 8. Akut kolesistit modelinin eğitim değerleri grafiği

Bir sonraki model abdominal aort anevrizma ve diseksiyon tahmin eden modeldir. Abdominal aort kesitlerinde çalışmaktadır. Eğitilen YOLOv4-P6 modeli 79 devir boyunca eğitilmiştir ve bir devir 8 dakika sürmüştür. Model test veri seti üzerinde 0,843 keskinlik, 0,964 duyarlılık, 0,972 mAP.5, 0,666 mAP.5:.95 ve 0,9 F1 skorunu elde etmiştir. Modelin eğitim grafiği şekil 9’da gösterilmiştir.



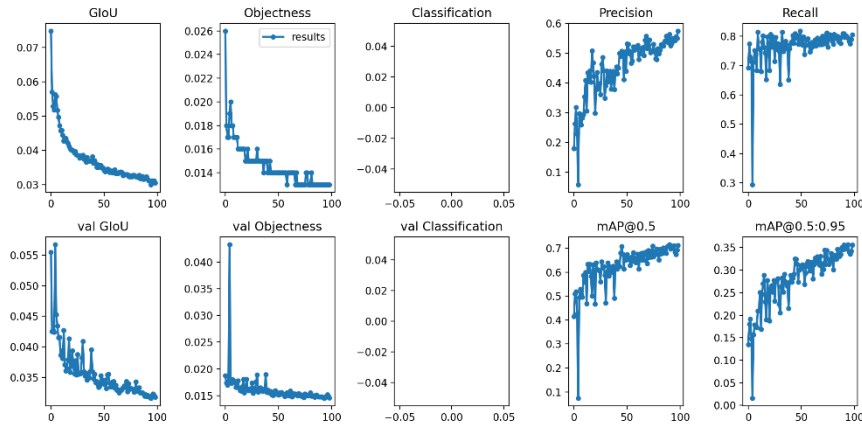
Şekil 9. Abdominal aort anevrizma ve diseksiyon modelinin eğitim değerleri grafiği

Akut divertikülit modeli kolon üzerinde çalışmaktadır. YOLOv4-P6 modeli 74 devir boyunca eğitilmiştir. Bir devir 2 dakika sürmüştür. Model test veri setinde 0,2731 keskinlik, 0,3768 duyarlılık, 0,2604 mAP.5, 0,04697 mAP.5:.95 ve 0,317 F1 skorunu elde etmiştir. Modelin eğitim grafiği şekil 10’da gösterilmiştir.



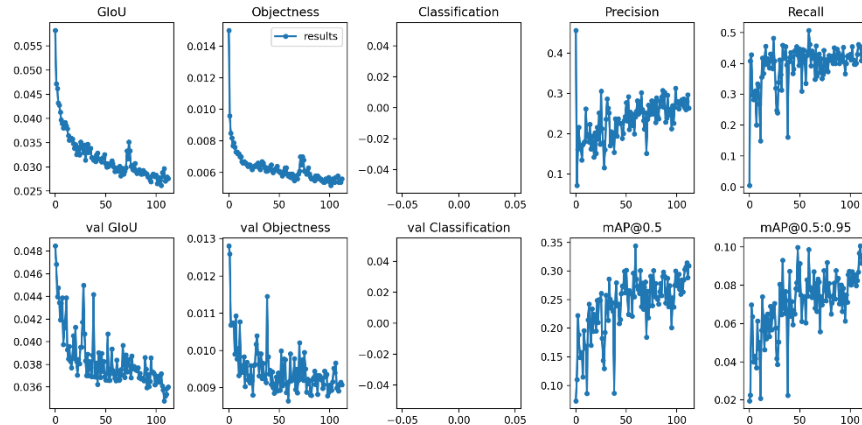
Şekil 10. Akut divertikülit modelinin eğitim değerleri grafiği

Akut pankreatit tahmin eden model pankreas üzerinde çalışmaktadır. YOLOv4-P6 modeli 99 devir boyunca eğitilmiştir. Bir devir 5 dakika sürmüştür. Model test veri setinde 0,5751 keskinlik, 0,8047 duyarlılık, 0,7125 mAP.5, 0,3558 mAP.5:.95 ve 0,671 F1 skorunu elde etmiştir. Modelin eğitim grafiği şekil 11’de gösterilmiştir.



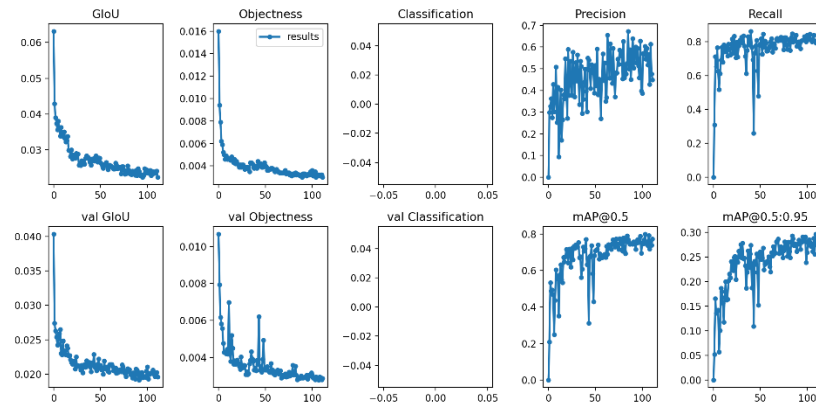
Şekil 11. Akut pankreatit modelinin eğitim değerleri grafiği

Akut apandisit modeli apandis içeren kesitler üzerinde çalışmaktadır. YOLOv4-P6 modeli 113 devir boyunca eğitilmiştir. Bir devir 4 dakika sürmüştür. Model test veri setinde 0,264 keskinlik, 0,452 duyarlılık, 0,31 mAP.5, 0,0954 mAP.5:.95 ve 0,333 F1 skorunu elde etmiştir. Modelin eğitim grafiği şekil 12’de gösterilmiştir.




Şekil 12. Akut apandisit modelinin eğitim değerleri grafiği

Böbrek taşı ve üreter taşı tahmin eden model ortaktır. Bu model Böbrek-Mesane üzerinde çalışmaktadır. Bu model için YOLOv4-P6 modeli 112 devir boyunca eğitilmiştir. Bir devir 2 dakika sürmüştür. Model test veri setinde 0,45 keskinlik, 0,84 duyarlılık, 0,773 mAP.5, 0,275 mAP.5:.95 ve 0,586 F1 skorunu elde etmiştir. Modelin eğitim grafiği şekil 13’te gösterilmiştir.



Şekil 13. Böbrek ve üreter taşı modelinin eğitim değerleri grafiği

Bahsedilen 6 modelin de birleştirilip sistem ortak test veri seti üzerinde test edildiğinde 0,609 keskinlik, 0,799 duyarlılık, 0,743 mAP.5, 0,418 mAP.5:95 ve 0,688 F1 skoru elde etmektedir. Bu değer önceki YOLOR-E6 ve YOLOv4-P6 modellerinden çok daha yüksektir. Bunun sebebi her bir modelin tek bir sınıfa odaklanması ve daha iyi öğrenmesidir. Fakat akut apandisit ve akut divertikülit algılayan modeller toplam sistemin doğruluğunu düşürmektedir. Bu modelleri daha iyi hale getirmek için çalışmalarımız devam etmektedir. 6 modelden oluşan sistemin her bir modelinin örnek çıktısı şekil 14’te verilmiştir.



Şekil 14. 6 modelin çıktıları
*a) Akut kolesistit b) abdominal aortta anevrizma veya diseksiyon
 c) akut divertikülit d) böbrek veya üreter taşı
 e) akut apandisit f) akut pankreatit*

4. Deney ve eğitim aşamalarında kullanılan veri setleri

Yarışma sırasında bulgu içermeyen kesitlerin doğru olarak belirlenmesi kesit başına 1 puan getirmektedir. Bulgu içeren bir kesitte ise bulgunun tespit edilmesi IoU skoruna bağlı olarak 0 ile 1 arasında bir puan getirecektir. Bulgu içermeyen kesitlerin doğru tahmin edilmesi tam puan getireceğinden dolayı modelin yanlış pozitif (false positive) tahminler yapmaması oldukça önemlidir. Bu yüzden Sağlık Bakanlığı veri seti dışında modellerin eğitiminde ve testinde AbdomenCT-1K [8], CHAOS - Combined (CT-MR) Healthy Abdominal Organ Segmentation [9] ve Multi-Atlas Labeling Beyond the Cranial Vault - Workshop and Challenge [10] veri setleri kullanılmıştır.

AbdomenCT-1K veri seti Jun Ma ve arkadaşları tarafından 2021 tarihli makalelerinde yayınlanmış açık kaynaklı bir veri setidir ve <https://github.com/JunMa11/AbdomenCT-1K> Github sayfasından indirilmesi için linkler bulunmaktadır. Bu veri setinde abdomen bölgesine ait CT ve MRI görüntüleri ve bu görüntülerden organların konumları hakkında bilgiler bulunmaktadır.

CHAOS - Combined (CT-MR) Healthy Abdominal Organ Segmentation veri seti CHAOS yarışması için Kavur ve arkadaşları tarafından oluşturulmuştur. Veri seti <https://zenodo.org/record/3431873> adresinden indirilebilir ve kullanılması için [9] [11] [12] makalelerine referans verilmesi gerekmektedir. Veri setinde abdomen CT ile MRI görüntüleri ve organların konumlarına ait etiketler bulunmaktadır. CT görüntülerinde karaciğer ve çevresine odaklanılmıştır ve sadece karaciğer etiketlenmiştir. Veri setinin %15'i anormal karaciğer görüntüleri içermektedir. Bu yüzden modellerin karaciğer görüntülerinde yapabilecekleri yanlış pozitifleri elemek için önemlidir.

Multi-Atlas Labeling Beyond the Cranial Vault - Workshop and Challenge veri seti yarışma için hazırlanmış olup abdomen ve serviks CT görüntülerinde oluşmaktadır. Veri setinde bu görüntüler ve bu görüntülerdeki organların etiketleri bulunmaktadır. Veri setinin kullanılması için <https://www.synapse.org/#!/Synapse:syn3193805/wiki/89480> web sitesine referans verilmesi yeterlidir.

Tüm bahsedilen veri setlerinde etiketler sadece 6 modelden oluşan sistem için veri setleri oluşturulurken kullanılmıştır. Bu veri setlerinde modellerin eğitimleri ve testleri için bulgu içermeyen sağlıklı görüntüler olarak kullanılmıştır. Bu sayede Sağlık Bakanlığı veri seti dışındaki farklı CT cihazları, görüntüleme yöntemleri ve hasta türleri de veri setine dahil edilerek modelin yaptığı yanlış pozitif (false positive) sayısının azaltılması hedeflenmiştir.

5. Referanslar

- [1] Wang, C. Y., Yeh, I. H., & Liao, H. Y. M. (2021). You only learn one representation: Unified network for multiple tasks. arXiv preprint arXiv:2105.04206.
- [2] Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2021). Scaled-yolov4: Scaling cross stage partial network. In Proceedings of the IEEE/cvf conference on computer vision and pattern recognition (pp. 13029-13038).
- [3] Li, Z., Zhang, S., Zhang, J., Huang, K., Wang, Y., & Yu, Y. (2019, October). MVP-Net: multi-view FPN with position-aware attention for deep universal lesion detection. In International Conference on Medical Image Computing and Computer-Assisted Intervention (pp. 13-21). Springer, Cham.
- [4] Yan, K., Bagheri, M., & Summers, R. M. (2018, September). 3D context enhanced region-based convolutional neural network for end-to-end lesion detection. In International Conference on Medical Image Computing and Computer-Assisted Intervention (pp. 511-519). Springer, Cham.
- [5] Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. arXiv preprint arXiv:2004.10934.

- [6] Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R., & Ren, D. (2020, April). Distance-IoU loss: Faster and better learning for bounding box regression. In Proceedings of the AAAI conference on artificial intelligence (Vol. 34, No. 07, pp. 12993-13000).
- [7] Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized intersection over union: A metric and a loss for bounding box regression. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 658-666).
- [8] Ma, J., Zhang, Y., Gu, S., Zhu, C., Ge, C., Zhang, Y., ... & Yang, X. (2021). Abdomenct-1k: Is abdominal organ segmentation a solved problem. IEEE Transactions on Pattern Analysis and Machine Intelligence.
- [9] A.E. Kavur, M. A. Selver, O. Dicle, M. Barış, N.S. Gezer. CHAOS - Combined (CT-MR) Healthy Abdominal Organ Segmentation Challenge Data (Version v1.03) [Data set]. Apr. 2019. Zenodo. <http://doi.org/10.5281/zenodo.3362844>
- [10] Multi-Atlas Labeling Beyond the Cranial Vault - Workshop and Challenge <https://doi.org/10.7303/syn3193805>
- [11] Kavur, A. E., Gezer, N. S., Barış, M., Aslan, S., Conze, P. H., Groza, V., ... & Selver, M. A. (2021). CHAOS challenge-combined (CT-MR) healthy abdominal organ segmentation. Medical Image Analysis, 69, 101950.
- [12] A.E. Kavur, N.S. Gezer, M. Barış, Y.Şahin, S. Özkan, B. Baydar, et al. "Comparison of semi-automatic and deep learning-based automatic methods for liver segmentation in living liver transplant donors", Diagnostic and Interventional Radiology, vol. 26, pp. 11–21, Jan. 2020. <https://doi.org/10.5152/dir.2019.19025>
- [13] Tan, M., Pang, R., & Le, Q. V. (2020). Efficientdet: Scalable and efficient object detection. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 10781-10790).
- [14] Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., ... & Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. In Proceedings of the IEEE/CVF International Conference on Computer Vision (pp. 10012-10022).