TEKNOFEST

HAVACILIK, UZAY VE TEKNOLOJİ FESTİVALİ

SAĞLIKTA YAPAY ZEKÂ YARIŞMALARI

(Bilgisayarlı Görüyle Abdomen (Karın) Bölgesi için Hastalık Tespiti Kategorisi)

PROJE DETAY RAPORU

TAKIM ADI: brAIn

TAKIM ID: 431160

İçindekiler

1. **Proje Mevcut Durum Değerlendirmesi…….…3**

2. **Özgünlük……..……..…….4**

3. **Sonuçlar ve İnceleme…….……..…5**
   - **3.1. Eğitim Sonuçları……..……...5**
   - **3.2. Test Sonuçları……..……...9**

4. **Deney ve Eğitim Aşamalarında Kullanılan Veri Setleri……11**

5. **Referanslar……..12**

6. **Ekler……12**

1. Proje Mevcut Durum Değerlendirmesi

Proje Sunuş Raporu hakem değerlendirilmesinde eksik görülen "Probleme en yakın çözüm önerisi sunan uluslararası makale özeti" başlığını tekrar gözden geçirip gerekli düzenlemeleri yaptık. Hakemlerce eksik görülen literatür bilgisini kapamak adına son yıllarda derin öğrenme metodları ile abdominal bölge çalışmalarını inceledik. Araştırmamız sonucunda elde ettiğimiz ve çalışmalarımızda referans alarak çalışmamızı şekillendirdiğimiz literatürdeki güncel makaleleri tekrar referans kısmında sunduk. "Özgünlük" başlığı hakem heyeti tarafından güçlü bulunmuş olsa da yaptığımız yeni düzenlemelerle öncekine kıyasla bu başlığın içeriğini daha iyi bir hale getirdik. Yine hakemlerce zayıf görülen "Proje planı ve iş takvimi" konusunu daha doğru bir takvimlendirme ve proje planı ile çalışma verimini maksimum seviyeye çıkardık.

Sağlık Bakanlığı tarafından verilen verilerle çalışmamızın eğitim aşamasını gerçekleştirirken; Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji Anabilim Dalından ek olarak her hastalıktan bilgisayarlı tomografi görüntü verilerini asistan hekimler eşliğinde inceledikten sonra elde ettiğimiz verileri, Sağlık Bakanlığı tarafından verilen verilerle birlikte çalışmamızın test aşamasında kullandık.

Daha sonra Teknofest tarafından paylaşılan veri setleri ile bir ön işleme gerçekleştirdik, bu ön işleme sırasında ".dcm" uzantılı verileri ".jpg" uzantılı verilere çevirdik bu işlemlerden sonra verilerin YOLO V5 algoritmasında işlenebilmesi için verileri YOLO formatına çevirdik, böylece veri setimiz model tarafından işlenebilecek hale getirdik. Ardından üniversitemizden aldığımız veri seti ile eğittiğimiz ön eğitimli object detection modelimiz üzerinde 4 günlük bir eğitim gerçekleştirdik.

Çalışmamızda izlediğimiz süreç Şekil 1' de gösterilmiştir

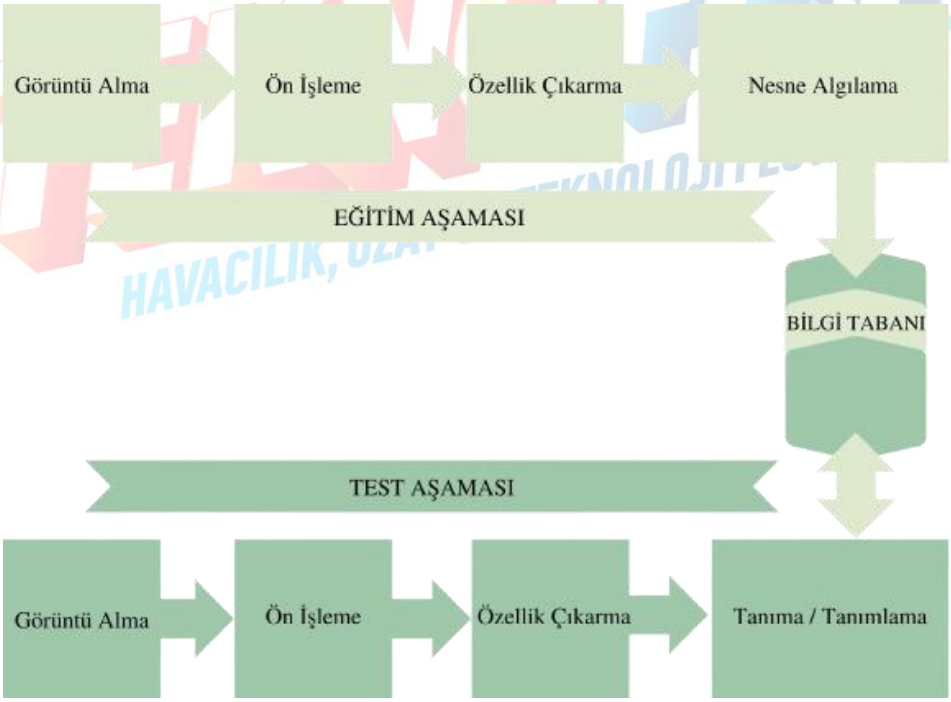

Şekil 1

2. Özgünlük

YOLO v5 algoritması, giriş görüntüsünden hedef bilgileri çıkarmak için özellik çıkarma ağı olarak CSPDarknet'i kullanır. CSP yapısı ve Darknet ağının birleşimidir. CSP ve CSP DarkNet yapıları Şekil 2'de gösterilmektedir.

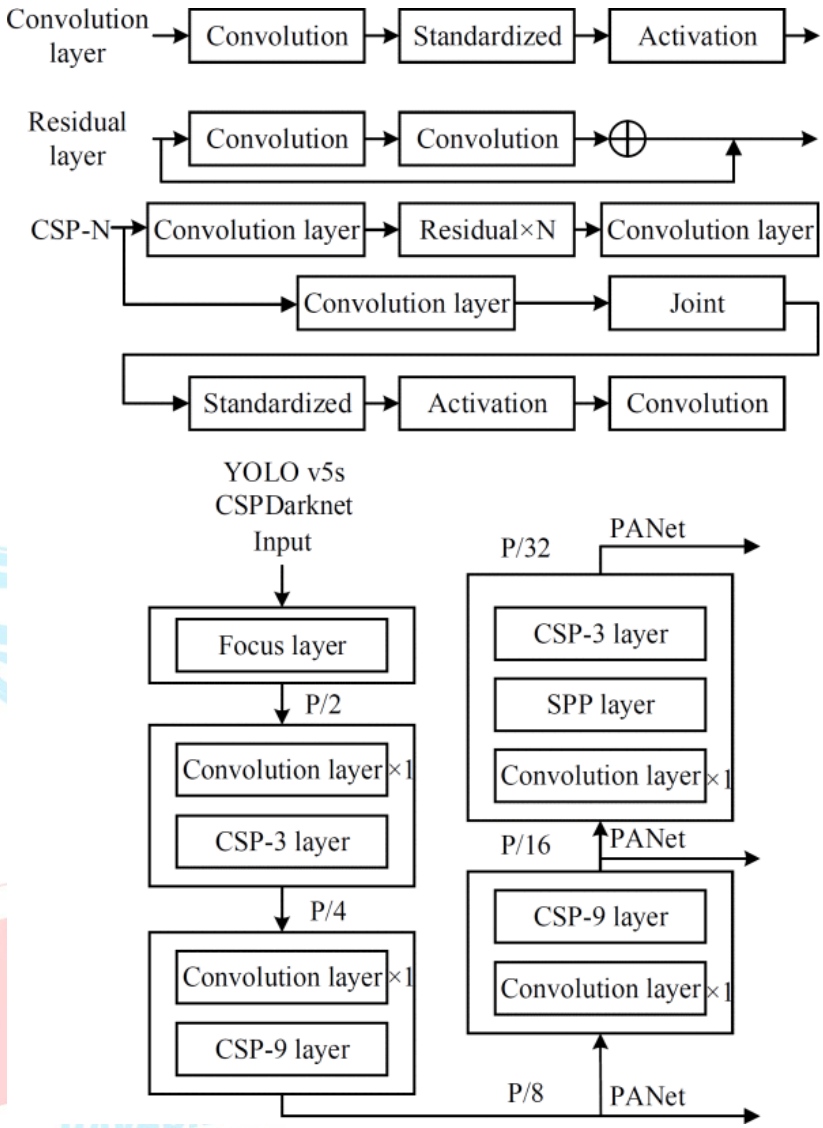

Şekil 2

Giriş tensörü için CSP, onu kanalda iki parçaya böler. Bir kısım tek seferde sarılır ve diğer kısım artıklarla birden çok kez sarılır. Çoklu evrişim-artık işlemi ile elde edilen tensör ve önceki parçanın tek evrişimi ile elde edilen tensör kanal boyutlarında eklemedir. CSP, çıktı grafiğinin daha fazla ağ gradyan bilgisi tutmasını sağlar ve daha az hesaplama ile ağın performansını korur.

Algılama sırasında, giriş tensörü algoritma tarafından S×S ızgaralarına bölünür. Hedefin merkez noktası belirli bir ızgarada bulunuyorsa, hedefin tespit edilmesinden ızgara sorumludur. Her ızgara için, üzerinde B çapaları tahmin edilir. Spesifik olarak, her bir bağlantı çerçevesi için (5+C) değerleri tahmin edin. İlk 5 değer, merkez noktasının konumunu ve çapa çerçevesinin boyutunu döndürmek ve çerçevede bir hedef olup olmadığını belirlemek için

kullanılır. Bunlar: tahmin çerçevesinin merkez koordinatı ile ızgara t_x ve t_y'nin sol üst noktasının koordinatı arasındaki mesafe, çerçevenin ve bağlantı çerçevesinin genişliğini ve yüksekliğini tahmin etmek için t_w ve t_h ölçekleme katsayıları ve güvendir. Hedefin varlığını yargılamak için Conf ve bir hedef olup olmadığının değerlendirilmesinin güveni. C, hedef kategorilerinin toplam sayısıdır. Kutuda hedefler varsa, çıkarılan hedefler sınıflandırılacaktır. Tahmin edilen değer ile çıktı hedef konumu arasındaki dönüştürme formülü aşağıdaki gibidir:

$$\boldsymbol{x = \sigma(t_x) + c_x}$$

$$\boldsymbol{y = \sigma(t_y) + c_y}$$

$$\boldsymbol{w = a^w e^{t_w}}$$

$$\boldsymbol{h = a^h e^{t_h}}$$

a^w ve a^h, bağlantı çerçevesinin genişliği ve yüksekliği iken, c_x ve c_y, bağlantı çerçevesinin bulunduğu ızgaranın sol üst noktasının koordinatlarıdır.

Hedef merkez noktasının konumunun gerilemesi için, ağ tarafından tahmin edilen merkez noktasının koordinatı ile merkez noktasının bulunduğu ızgaranın sol üst noktasının koordinatı arasındaki ofseti haritalamak için Sigmoid işlevi kullanılır. [0, 1] arasında bulunur. σ'nın işlenmesi nedeniyle, tahmin kutusunun merkez konumu, mevcut ızgara içinde sınırlandırılır ve ofset kapsamını sınırlar. Sol üst nokta c_x ve c_y koordinatlarına eşlemeden sonra ofseti ekleyin ve son olarak ağ tarafından tahmin edilen merkez nokta koordinatını (x,y) alın.

Toplam kayıp şu şekilde ifade edilir:

$$\boldsymbol{Loss = L_{box} + L_{cls} + L_{obj}}$$

Burada, L_{box} pozisyon regresyon kaybıdır; L_{cls} kategori kaybıdır.

3. Sonuçlar ve İnceleme

3.1. Eğitim Sonuçları

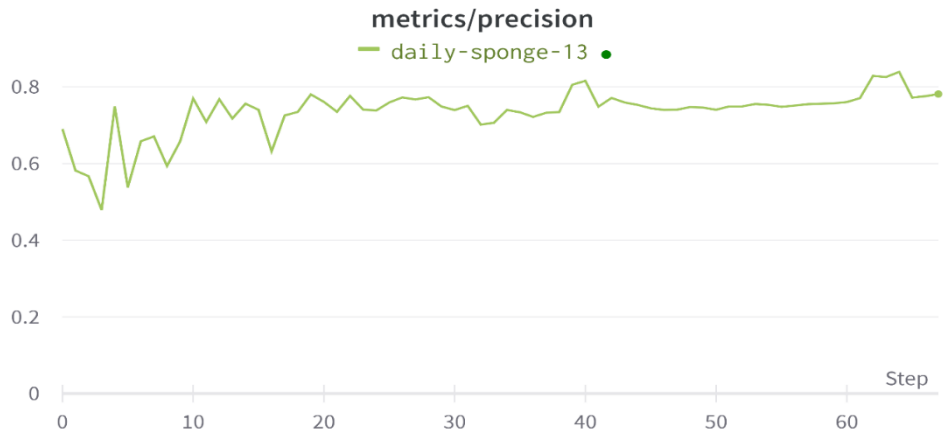

Precision, tp / (tp + fp) oranıdır; burada tp, gerçek pozitiflerin sayısı ve fp, yanlış pozitiflerin sayısıdır. Precision, sezgisel olarak sınıflandırıcının negatif olan bir örneği pozitif olarak etiketlememe yeteneğidir. En iyi değer 1 ve en kötü değer 0'dır.

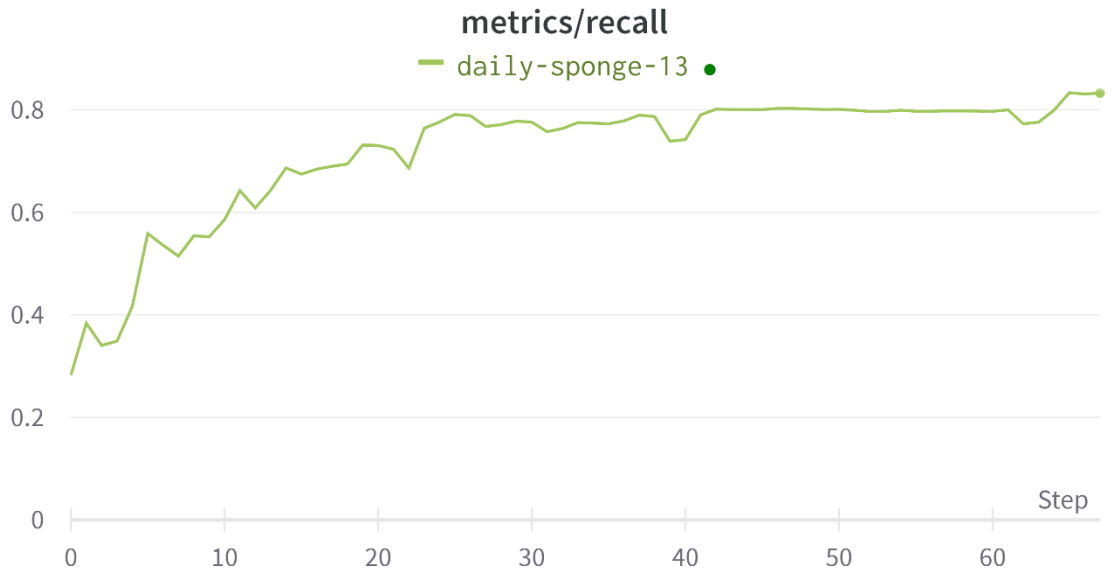

Recall, tp / (tp + fn) oranıdır, burada tp gerçek pozitiflerin sayısı ve fn yanlış negatiflerin sayısıdır. Recall, sınıflandırıcının tüm pozitif örnekleri bulma sezgisel yeteneğidir.
En iyi değer 1 ve en kötü değer 0'dır.

Eğitim sırasında sınıfların/hastalıkların yanlış tahmin edilme oranı (en yüksek: x, en düşük: 0)

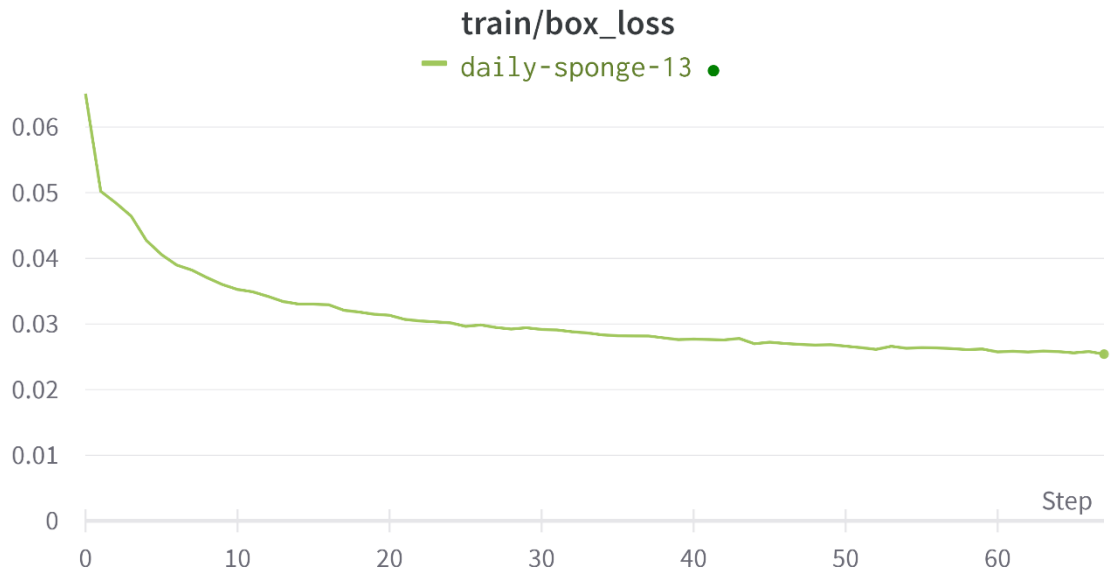

Train sırasında hastalıkların konumlarını (örn: 152,261-170,277) yanlış tahmin etme oranı (en yüksek: x, en düşük: 0)

Train sırasında bir görüntü penceresinin herhangi bir sınıftan bir nesne içerme olasılığının miktarını belirler (en yüksek: x, en düşük: 0)

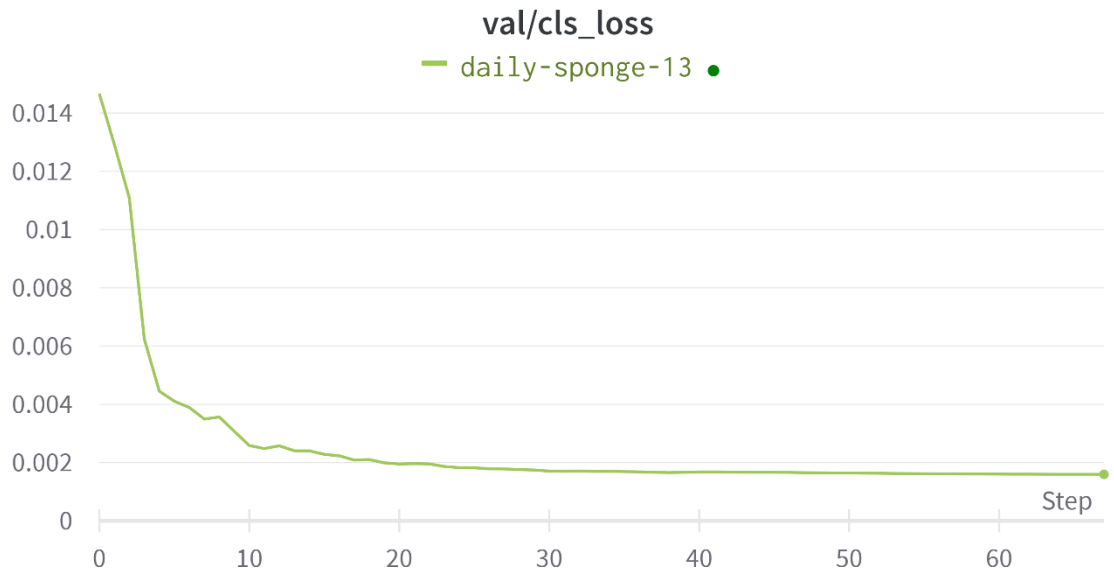

Validation sırasında sınıfların/hastalıkların yanlış tahmin edilme oranı (en yüksek: x, en düşük: 0)

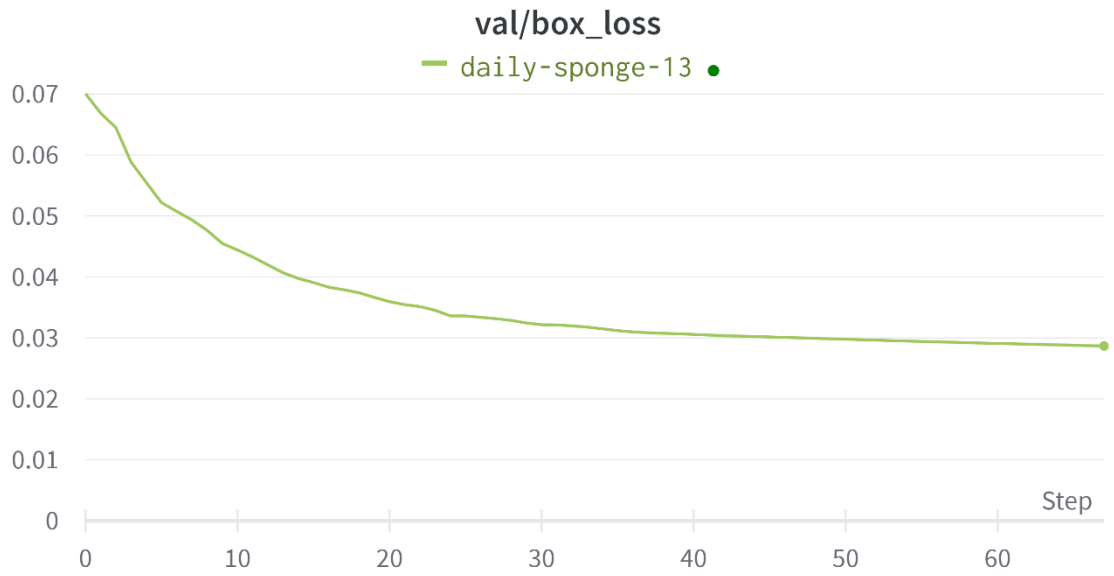

Validation sırasında hastalıkların konumlarını (örn: 152,261-170,277) yanlış tahmin etme oranı (en yüksek: x, en düşük: 0)

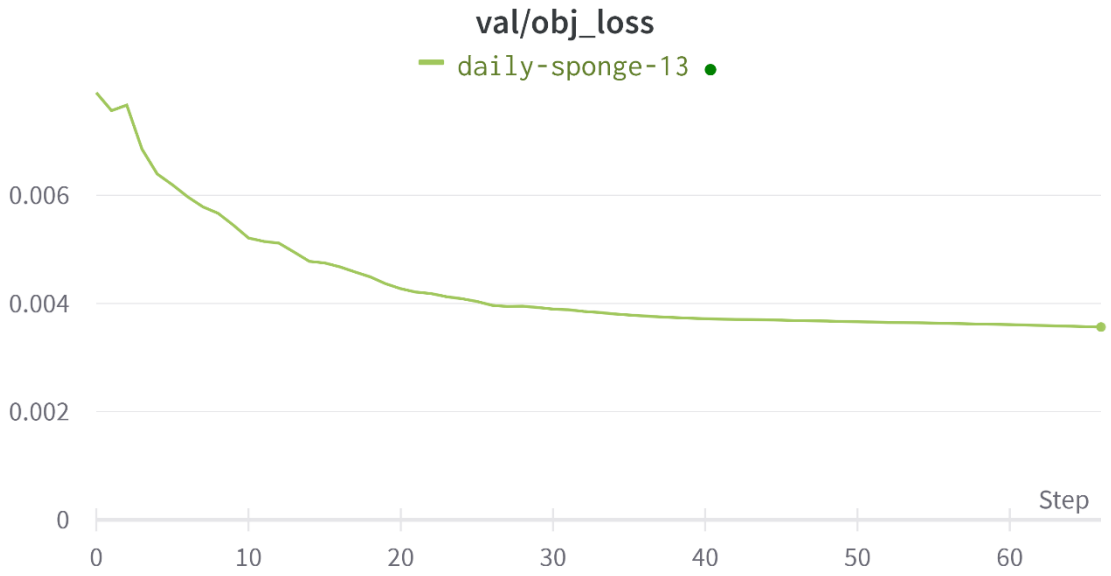

Validation sırasında bir görüntü penceresinin herhangi bir sınıftan bir nesne içerme olasılığının miktarını belirler (en yüksek: x, en düşük: 0)

3.2. Test Sonuçları

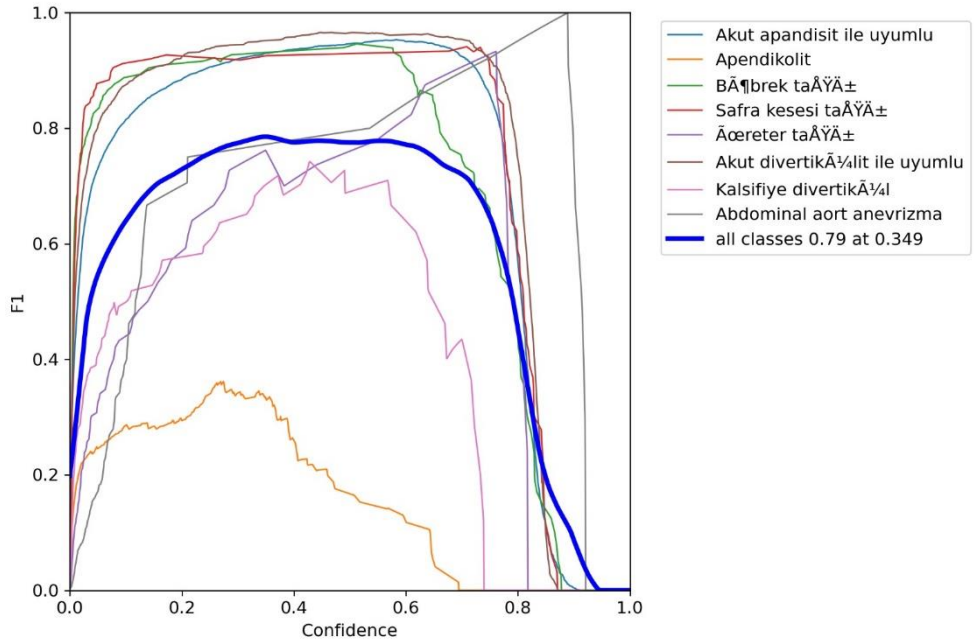

F1 Score, bir F1 Score'nın en iyi değerine 1'de ve en kötü puana 0'da ulaştığı, Precision ve recall'in harmonik bir ortalaması olarak yorumlanabilir.

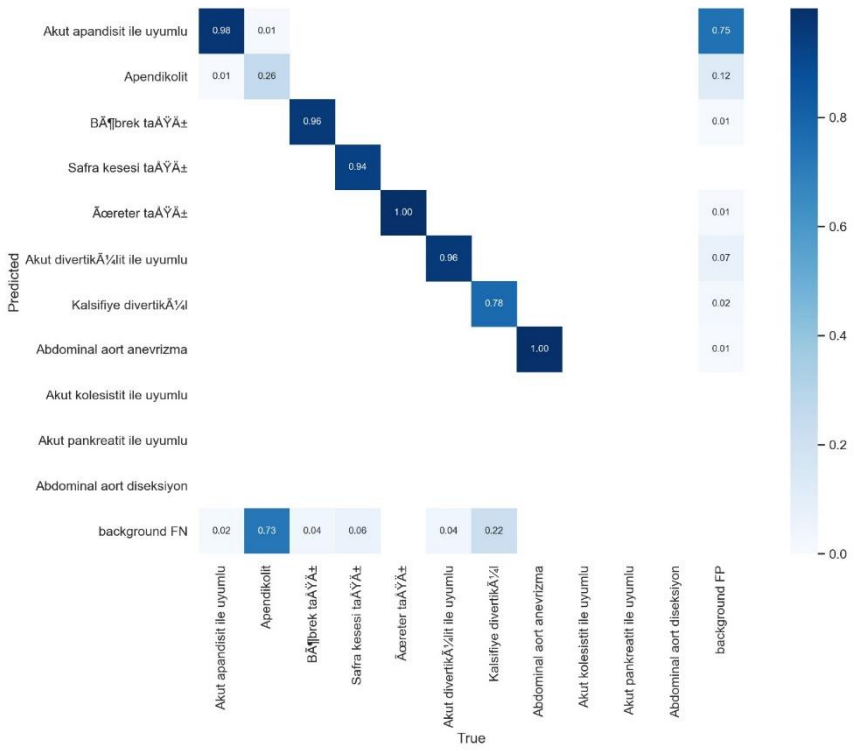

Karışıklık matrisi, bir sınıflandırma problemindeki tahmin sonuçlarının bir özetidir. Doğru ve yanlış tahminlerin sayısı, sayı değerleriyle özetlenir ve her sınıfa göre ayrılır.

(Abdominal Aort Anevrizması, Skor: 91)(Kalsifiye Divertikül, Skor: 58)(Üreter Taşı, Skor: 76)

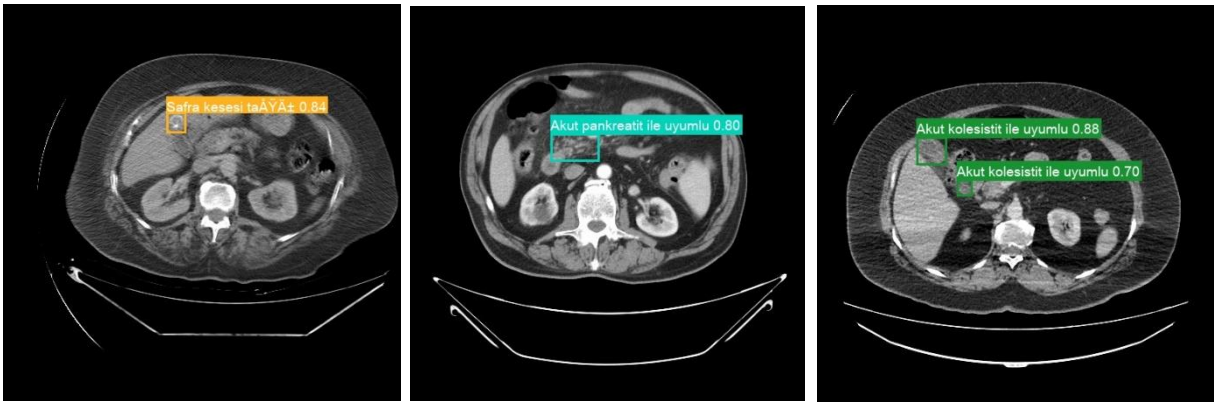

(Safra Kesesi Taşı, Skor: 84) (Akut Pankreatit, Skor: 80) (Akut Kolesistit, Skor: 70, 88)

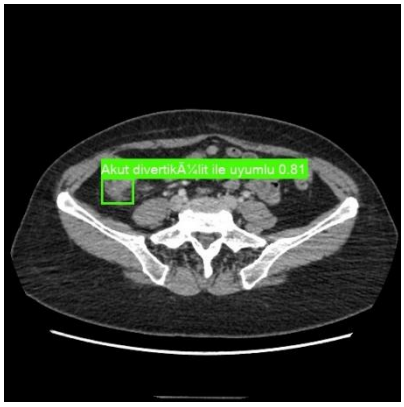

(Akut Divertikül, Skor: 81)

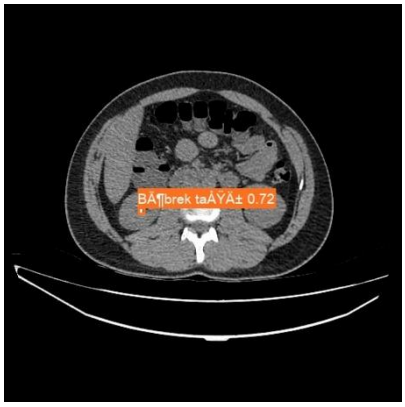

(Böbrek Taşı, Skor: 72)

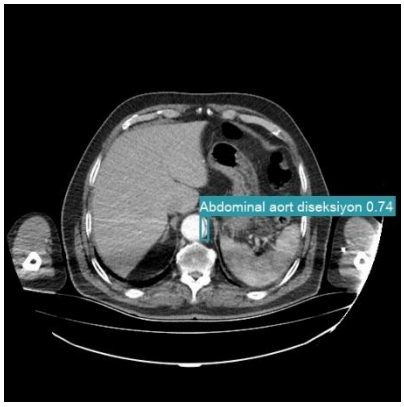

(Abdominal Aort Diseksiyonu, Skor: 74)

4. Deney ve Eğitim Aşamalarında Kullanılan Veri Setleri

Teknofest tarafından verilmesi beklenen veri setlerini beklerken Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji Anabilim Dalından 2022 TEKNOFEST etkinliğinde Sağlıkta Yapay Zeka Yarışması altında "Bilgisayarlı Görüyle Abdomen(karın) Bölgesi için Hastalık Tespiti Kategorisi" için akut apandisit, akut kolesistit, akut pankreatit, böbrek/üreter taşı, akut divertikülit, aort anevrizması hastalıklarına ve ek olarak bu hastalıkların bulunmadığı sağlıklı kişilere ait yeterli sayıda ilaçlı ve ilaçsız bilgisayarlı tomografi görüntüleri alınmıştır, gerekli izinler ektedir. Bu görüntüler üzerinde radyoloji asistan ve uzman hekimleriyle birlikte gerekli çalışmalar yapılıp makine eğitimi gerçekleştirilmiştir.

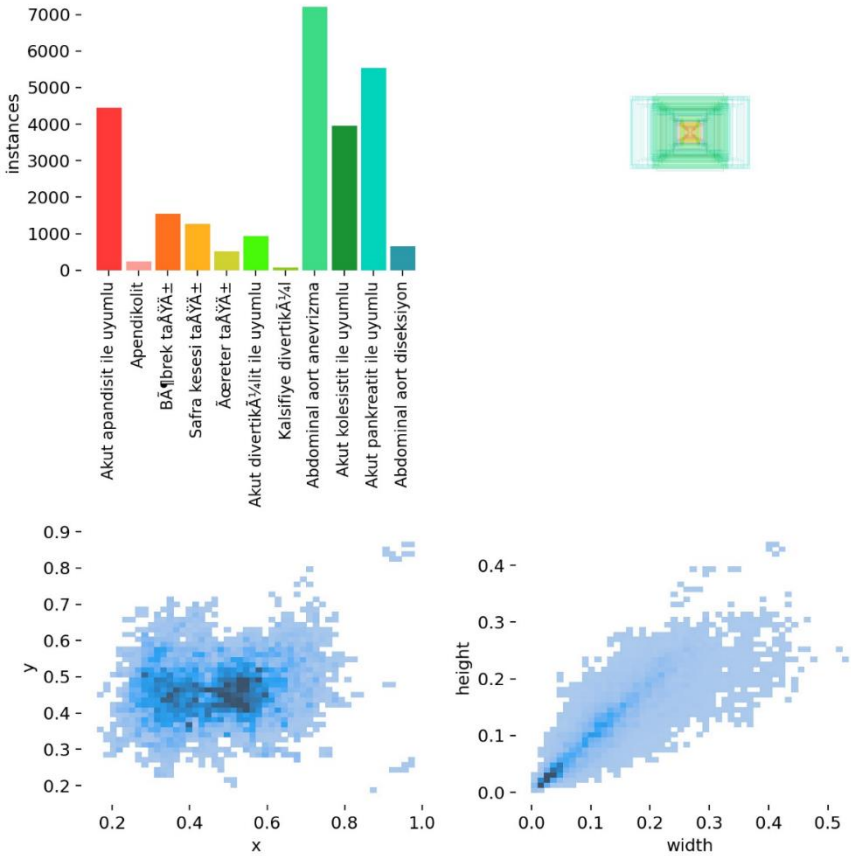

Veri Setindeki Sınıfların / Hastalıkların Dağılımları

5. Referanslar

1. Rehman, A., Khan, F.G. A deep learning based review on abdominal images. *Multimed Tools Appl* 80, 30321–30352 (2021). https://doi.org/10.1007/s11042-020-09592-0

2. Dillman, J.R., Somasundaram, E., Brady, S.L. *et al.* Current and emerging artificial intelligence applications for pediatric abdominal imaging. *Pediatr Radiol* (2021). https://doi.org/10.1007/s00247-021-05057-0

3. S. K. Zhou *et al*., "A Review of Deep Learning in Medical Imaging: Imaging Traits, Technology Trends, Case Studies With Progress Highlights, and Future Promises," in *Proceedings of the IEEE*, vol. 109, no. 5, pp. 820-838, May 2021, doi: 10.1109/JPROC.2021.3054390.

4. Chung, H., Ye, J.C. Score-based diffusion models for accelerated MRI, Medical Image Analysis, vol. 80, 2022, 102479, ISSN 1361-8415, https://doi.org/10.1016/j.media.2022.102479.

5. https://ieeexplore.ieee.org/mediastore_new/IEEE/content/media/9574103/9574447/9574450/9574450-fig-1-source-large.gif

6. Ekler

Gerekli İzinler