TEKNOFEST

HAVACILIK, UZAY VE TEKNOLOJİ FESTİVALİ

SAĞLIKTA YAPAY ZEKÂ YARIŞMALARI

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

PROJE DETAY RAPORU

TAKIM ADI: SAM-DetectioNet

TAKIM ID: 398654

İÇİNDEKİLER

1. Proje Mevcut Durum Değerlendirmesi 3
2. Özgünlük 3
3. Sonuçlar ve İnceleme 4
4. Deney ve eğitim aşamalarında kullanılan veri setleri 7
5. Referanslar 8

1. Proje Mevcut Durum Değerlendirmesi

Proje sunuş raporunda belirtildiği üzere Faster RCNN (Faster Regional Convolutional Neural Network / Daha Hızlı Bölgesel Evrişimsel Sinir Ağı) [1] mimarisi ResNet-18 [2], ResNet-50 [2] ve ResNet-101 [2] olmak üzere farklı omurga ağları kullanılmıştır. Proje sunumundan sonra Sağlık Bakanlığı tarafından paylaşılan veri seti kullanılarak gerçekleştirilen deneysel çalışmalarda, bu önceden eğitilmiş derin mimarilerin performansları karşılaştırılmıştır. Böylece, en başarılı mimari elde edilmeye çalışılmıştır. Ayrıca, veri artırma teknikleri kullanılarak performansa etkileri incelenmiş ve yaklaşık %2 IoU skor artışı sağlandığı gözlenmiştir. Son olarak, literatürde, yarışma şartlarına uygun veri setleri araştırılmış ve sentezlenmiştir.

Proje sunuş raporunda özgünlük olarak sunulan bölme yaklaşımına dayalı Faster RCNN modeli kullanılarak Sağlık Bakanlığı tarafından paylaşılan veri seti için deneysel çalışmalar gerçekleştirilmiştir. Bu yaklaşım, giriş görüntüsünü NXN'lik matrislere bölünmesi ve ardından her bir bölge için geliştirilen model kullanılarak tahmin sonuçlarının elde edilmesine dayalıdır. Daha sonra, bu tahmin sonuçları, bir birleştirme algoritmasına tabi tutularak orijinal boyuttaki görüntü üzerinde yeniden yerleştirilmiştir. Önerdiğimiz bu model kullanılarak küçük boyuttaki nesneleri yüksek performans ile tespit edilmiştir. Ayrıca, proje sunuş raporunda kullanılması planlanan Faster RCNN modelinin yanı sıra bölgesel nesne tespitine yönelik yüksek performansa sahip diğer mimariler araştırılmıştır. RetinaNet [3], EfficientDet [4], FPN (Feature Pyramid Networks) [5] ve R-FCN (Region-based Fully Convolutional Networks) [6] mimarileri kullanılarak deneysel çalışmalar gerçekleştirilmiştir. Birden fazla model uygulanması, omurga ağı için farklı derin mimarilerin kullanılması ve optimum eğitim parametrelerinin belirlenmesi gibi işlemlerden dolayı deneysel çalışmalar çok zaman almıştır. Bu nedenle, veri setinin bir bölümü için bu derin mimarilerin performansları hesaplanmış ve karşılaştırılmıştır. Sonuç olarak, en iyi performansa sahip mimari elde edilmeye çalışılmıştır.

Yarışma zamanına kadar, tüm veri seti (veri artırma teknikleri ve erişime açık diğer veri setleri) kullanılarak geliştirilen bölme yaklaşımına dayalı Faster RCNN, RetinaNet, EfficientDet ve FPN mimariler için deneysel çalışmalar devam edecektir. Abdomen(karın) bölgesinde hastalık tespiti için bu bölgesel tespit yöntemlerine dayalı en iyi omurga ağına sahip mimari elde edilmeye çalışılacaktır. En iyi performansa sahip derin mimari için optimum eğitim parametreler belirlenerek eğitim aşaması tamamlanacaktır.

2. Özgünlük

Bu projenin özgün yönleri şunlardır:

- Abdomen(karın) bölgesinde hastalık görüntüleri için yansıtma, döndürme ve bulanıklaştırma gibi veri arttırma (Data Augmentation) yöntemleri kullanılarak veri seti genişletilme çalışmaları yapılmıştır. Bu sayede hastalık tespit performansının artırılması amaçlanmaktadır.
- Sağlık Bakanlığı tarafından yarışmacılara verilen veri setine ek olarak bilgisayarlı görüyle abdomen (karın) bölgesi için hastalık tespiti ile ilgili erişime açık veri setleri ve ilgili görüntüler içeren medikal siteler tespit edilmiştir [7-11]. Bu veri setleri, yarışma şartlarına uygun veriler incelenmiş ve sentezlenmiştir. Böylece, veri setinin boyutu artırılarak geliştirilen derin öğrenme modelinin eğitim doğruluğunun yüksek olması ve modelin daha iyi öğrenebilmesi amaçlanmıştır.
- Abdomen(karın) bölgesinde hastalık tespiti için önceden eğitilmiş ResNet modeli kullanılarak Faster RCNN mimarisine dayalı bir model geliştirilmiştir. Önerilen modelde, ResNet modelinin ResNet18, ResNet50 ve ResNet101 gibi versiyonları için ayrı ayrı eğitim ve test aşamasına uygulanmıştır. Bu sayede, en iyi performansa sahip model elde edilmiştir.

- Bu projede, giriş görüntüsünü NXN'lik matrislere bölünmesi ve ardından her bir bölge için geliştirilecek model kullanılarak tahmin sonuçları elde edilmiştir. Daha sonra, her bir bölge için elde edilen tahmin sonuçları, bir birleştirme algoritmasına tabi tutularak orijinal boyuttaki görüntü üzerinde yeniden yerleştirilmiştir (Şekil 1). Önerdiğimiz bu model kullanılarak küçük boyuttaki nesneleri yüksek performans ile tespit edildiği gözlenmiştir (Şekil 4).

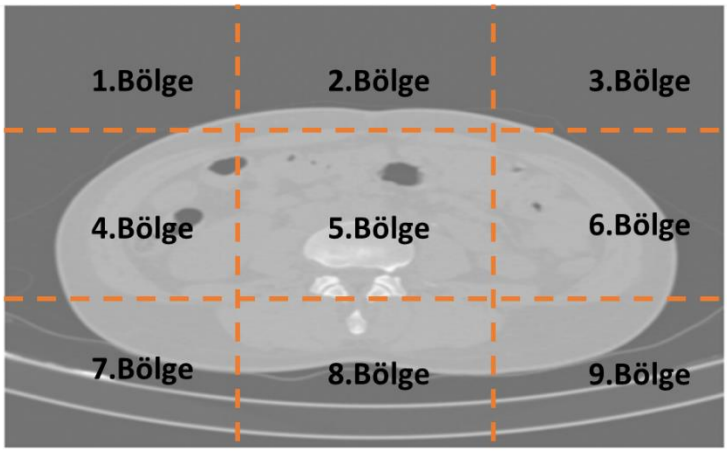

Şekil 1. Önerilen bölme yaklaşımı

Şekil 1'de görüleceği üzere, görüntüyü 3x3 boyutunda dilimlere ayrılmış ve 9 farklı bölge elde edilmiştir. Daha sonra, her bir bölge için geliştirilen derin öğrenme modeli uygulanmış ve ardından tüm tahmin sonuçları birleştirilmiştir.

- Literatürde geliştirilen en iyi performansa sahip bölgesel tespit yöntemleri araştırılmıştır. Bu doğrultuda, Faster RCNN mimarisinin yanı sıra, önerilen bölme yaklaşımına dayalı RetinaNet, EfficientDet, FPN (Feature Pyramid Networks) ve R-FCN (Region-based Fully Convolutional Networks) [6] mimarileri de kullanılarak deneysel çalışmalar gerçekleştirilmiştir. Yapılan bu çalışmalarda, veri boyutunun büyük olması ve birçok geliştirilmiş model kullanılmasından dolayı Sağlık Bakanlığı tarafından yarışmacılara verilen veri setinin sadece %10'u kullanılmıştır. Böylece, geliştirilen modellerin performansları daha kısa sürede elde edilerek performansları karşılaştırılmıştır. Sonuç olarak, kapsamlı yapılan deneysel çalışmalarda, Abdomen(karın) bölgesinde hastalık tespiti için en iyi performansa sahip derin mimari elde edilmesi amaçlanmıştır. Ayrıca, yarışma zamanına kadar, deneysel çalışmalar devam edecektir.

3. Sonuçlar ve İnceleme

Deneysel çalışmalarda kullanılan modellerin performansının değerlendirme esnasında her bir etiket için eğer olgu numarası-kesit numarası ve etiket değeri doğru ise Birleşimlerin Kesişimi (Intersection of Union- IoU) değeri hesaplanacaktır. Bu değer, Ground Truth (Kesin Referans) ile tahmin edilen bounding box arasındaki ilişkiye dayalıdır. Bu iki bounding box arasındaki benzerlik oranını Jaccard indeksi aracılığı ile hesaplamaktadır. Sonuç olarak, bu hesaplamaya göre iki şeklin Area of The Overlap (Kesişim) ile Area of the Union (Birleşim) oranı bize IoU değerimizi yani doğruluğu vermektedir [12]. Bu hesaplama ile ilgili görsel gösterim Şekil 2'de verilmiştir.

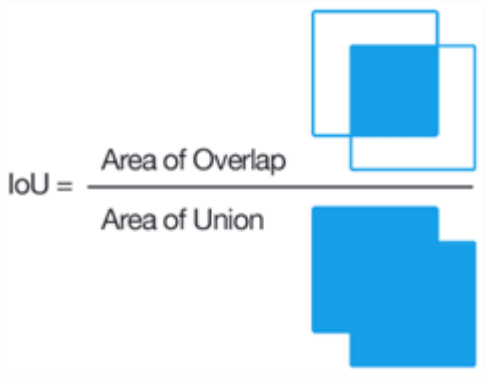

Şekil 2. IoU performans ölçütü

Bu çalışmada, Faster RCNN modeline dayalı Resnet18, Resnet50, Resnet101 omurga ağları kullanılarak eğitilmiş ve test edilmiştir. Yapılan deneysel çalışmalarda, veri boyutunun büyük olması ve birçok geliştirilmiş model kullanılmasından dolayı Sağlık Bakanlığı tarafından yarışmacılara verilen veri setinin sadece %40'ı kullanılmıştır. Böylece, geliştirilen modellerin performansları daha kısa sürede elde edilerek performansları karşılaştırılmıştır. Yarışma zamanında, tüm veri seti kullanılarak eğitim işlemi gerçekleştirilmiş olacaktır. Ayrıca, kullanılan bu veri kümesinin %70 eğitim ve %30 test olarak ayrılmıştır. Geliştirilen modelin eğitim parametreleri için 50 epoch, 32 batch size, 0.0001 öğrenme katsayısı ve Adam optimizasyon yöntemi kullanılmıştır. Bu deneysel çalışmalardan elde edilen performanslar Tablo 1'de verilmiştir.

Tablo 1. Eğitilen modelin test sonuçları

Performans kriteri	Faster RCNN		
	Resnet18	Resnet50	Resnet101
IoU	60.12	64.52	67,95

Tablo 1'den anlaşılacağı üzere, Faster RCNN mimarisine dayalı omurga ağları arasında en iyi performans ResNet101 mimarisi kullanılarak %67.95 IoU olarak elde edilmiştir. Bu modelden elde edilen çıktının IoU değerleri için eğitim performansı ve loss kaybı Şekil 3'te verilmiştir.

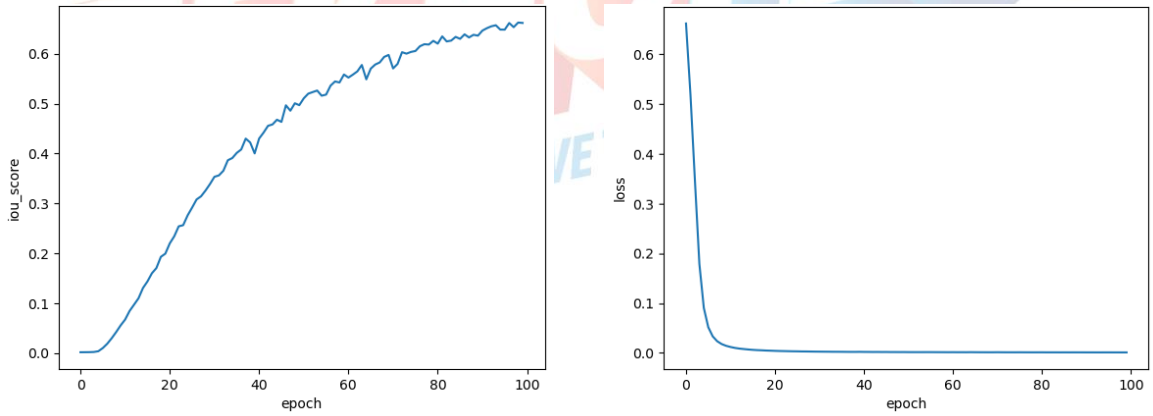

Şekil 3. ResNet101 tabanlı Faster RCNN modelinin eğitim/loss grafikleri

ResNet101 tabanlı Faster RCNN modeli için önerilen bölme yaklaşımı kullanılarak deneysel çalışmalar gerçekleştirilmiştir. Sonuç olarak, bölme yaklaşımı kullanılarak elde edilen IoU değeri, %69,47 olarak hesaplanmıştır. Bu sonuçlar, önerilen bölme yaklaşımının yaklaşık %2'lik bir performans artışı sağladığını göstermiştir. Buna ek olarak, önerilen yaklaşımın görsel tahmin sonuçları Şekil 4'te verilmiştir.

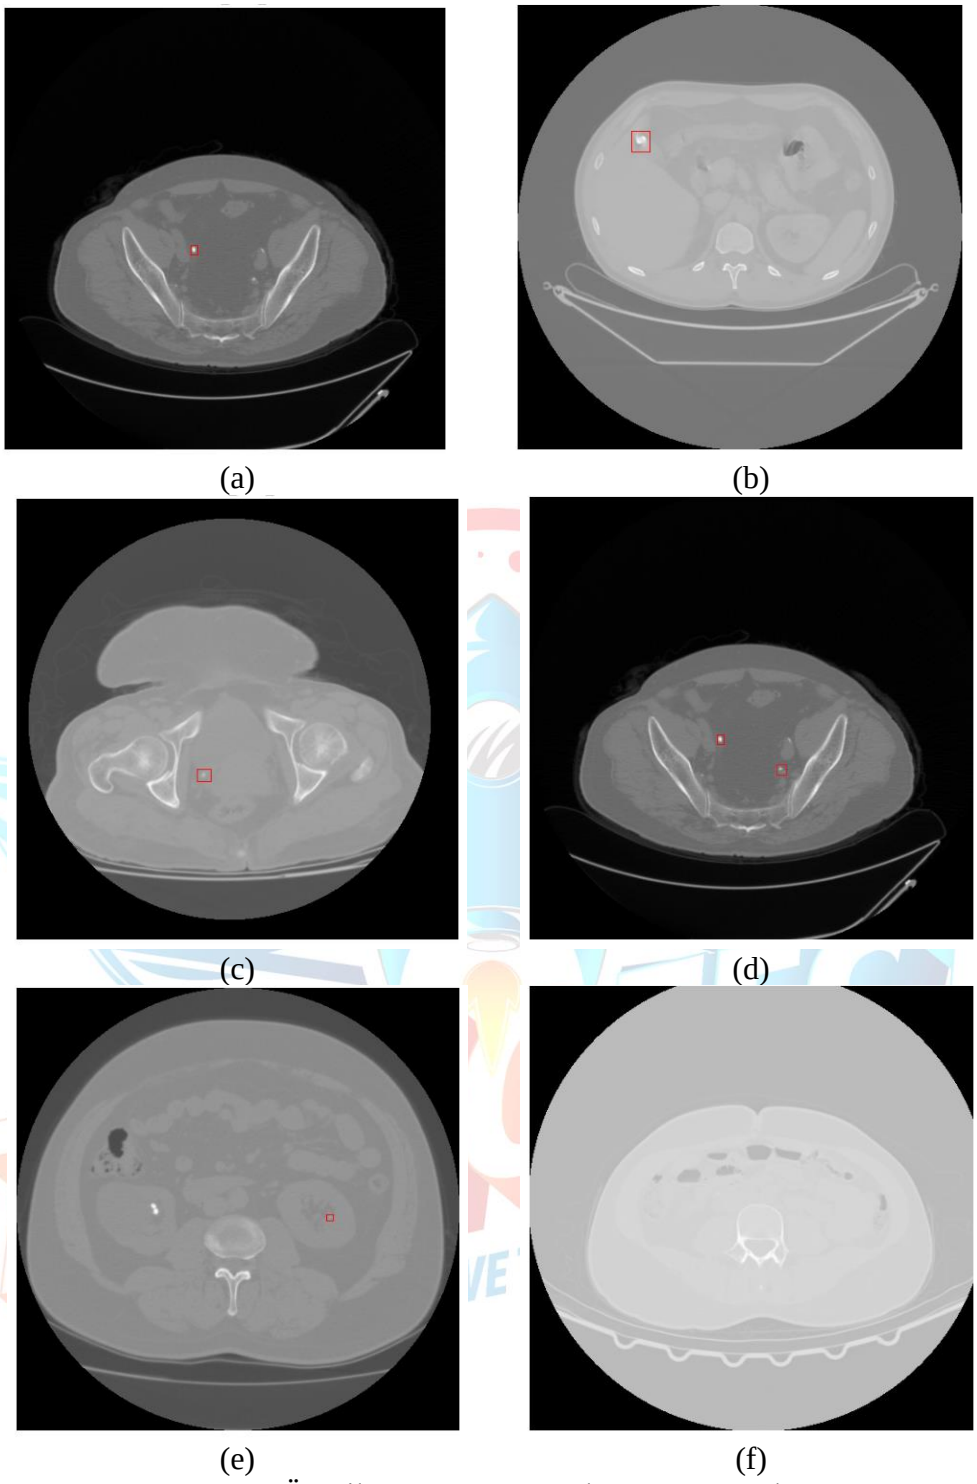

Şekil 4. Önerilen modelin görsel tahmin sonuçları

Şekil 4'te görüleceği üzere, önerilen model kullanılarak (a), (b) ve (c) şekillerini yüksek IoU değeri ile tespit etmiştir. Diğer yandan, Şekil 4(d)' de gösterildiği gibi, hastalığı doğru tespit etmesine rağmen hasta olmayan başka bir bölgeyi de hastalık olarak sınıflandırmıştır. Buna ek olarak, Şekil 4(e)'de iki farklı hastalık bölgesinden sadece birini doğru tespit ederken, Şekil 4(f)'de ise hiç tespit yapamamıştır. Yarışma zamanına kadar olan süreçte, önerilen modelin tespit edemediği hastalıklar analiz edilecek ve bu problemlerin çözümü için önerilen model geliştirilmesi hedeflenmektedir.

Son olarak, veri setinin 1/10'u kullanılarak Faster RCNN mimarisinin yanı sıra diğer derin mimarilerin performansları hesaplanmıştır. Bu sonuçlara göre en iyi performans Faster RCNN

ile EfficientDet mimarileri kullanılarak elde edilmiştir. Diğer yandan, RetinaNet ve FPN mimarileri, hastalık tespitinde başarısız sonuçlar vermiştir. Yarışma zamanına kadar, tüm veri seti kullanılarak deneysel çalışmalar devam edecektir. En iyi performansa sahip derin mimari belirlenecek ve yarışma anında kullanılacak bu modelin eğitim aşaması tamamlanacaktır.

4. Deney ve eğitim aşamalarında kullanılan veri setleri

Model eğitimlerimiz için öncelikle Sağlık Bakanlığı tarafından paylaşılan veri seti kullanılmıştır. Bu veri setinde, 1050 zip dosyası içerisinde farklı sayılarda kesitlerden oluşan Bilgisayarlı Tomografi (BT) görüntülerini içermektedir (Şekil 5). Ayrıca, DICOM formatında olan görüntüler için hazırlanan etiket ve Bounding Box koordinatlarının bulunduğu ayrıntılı bir excel dosyası bulunmaktadır.

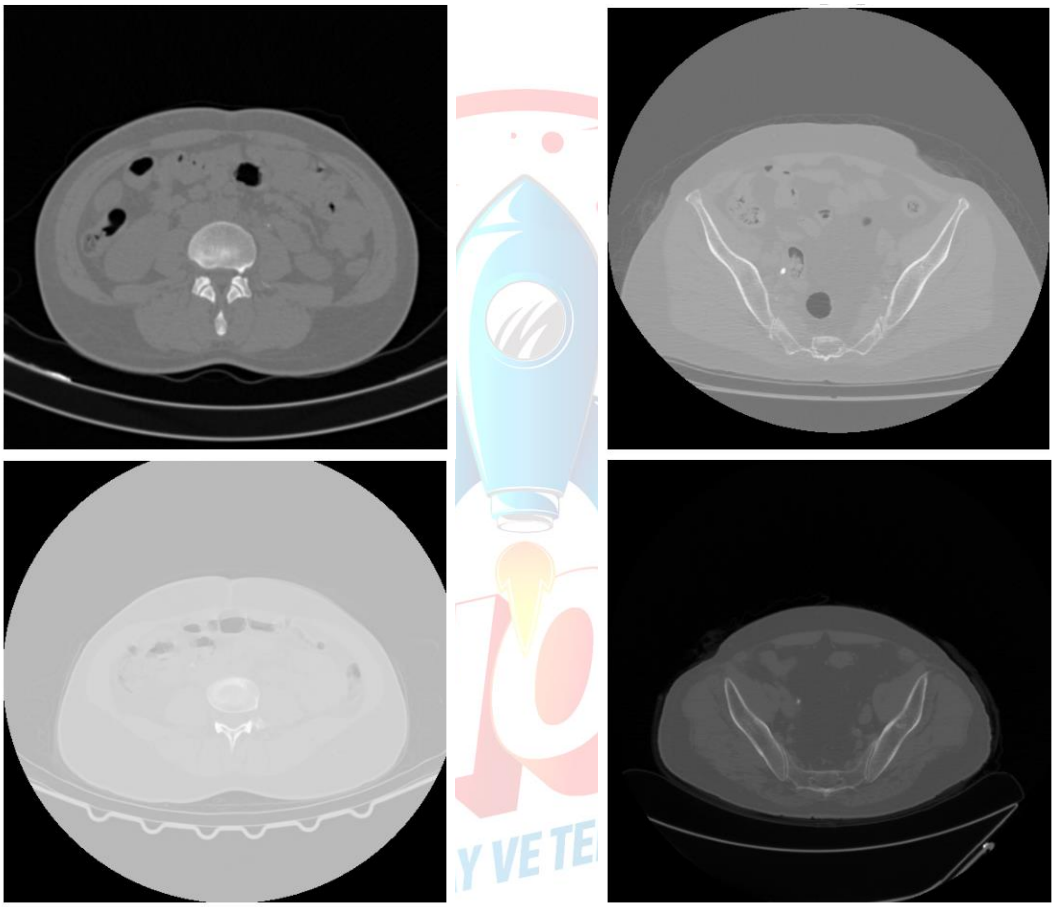

Şekil 5. Örnek veri seti görüntüleri

Mevcut çalışmada, bu veri seti kullanılarak birden fazla model adapte edilmiş ve performans sonuçları hesaplanmıştır. Birden fazla model uygulanması ve omurga ağı için farklı derin mimarilerin kullanılması gibi işlemler çok zaman almasından dolayı optimum eğitim parametrelerinin belirlenmesi (öğrenme katsayısı, optimizasyon yöntemi, batch size, epoch vs.) için deneysel çalışmalar yarışma zamanına kadar sürecektir.

Derin öğrenme modellerinin eğitim doğruluğunun yüksek olması ve modelin daha iyi öğrenebilmesi için aşamasında çok sayıda veri kullanılması gerekmektedir. Bu yüzden, çalışmamızda veri artırma teknikleri ve bu alan ile ilgili diğer veri setleri kullanılmasına karar verdik.

- İlk olarak, deneysel çalışmaların uzun sürmesinden dolayı veri setinin bir bölümü için yansıtma, döndürme ve bulanıklaştırma gibi veri arttırma (Data Augmentation) yöntemleri kullanılarak veri setinin genişletildi. Daha sonra, ResNet101 tabanlı Bölgesel ESA mimarisi kullanılarak veri artırma tekniklerinin performansa etkileri incelendi. Sonuç olarak, veri artırma teknikleri kullanılarak yaklaşık %2 IoU skor artışı

sağlandığı gözlendi.

- İkinci olarak, Sağlık Bakanlığı tarafından yarışmacılara verilen veri setine ek olarak bilgisayarlı görüyle abdomen (karın) bölgesi için hastalık tespiti ile ilgili veri setleri araştırılmıştır. Yapılan araştırmalar neticesinde, bu alan ile ilgili çok sayıda çalışma olmasına rağmen erişime açık az sayıda veri seti bulunmaktadır [7-11]. Bu veri setleri, açık kaynak olarak paylaşılmış ve ticari olmayan amaçlar için kullanılabilir. Bu nedenle verilerin kullanımını sağlayacak izinlere gerek kalmamıştır. [7-8]'de verilen veri setleri sentezlenmiş ve uygun veriler elde edilmiştir. Ayrıca, medikal alanda birçok görüntü içeren veri setlerini bulunduran sitelerde ise [9-11], yarışma şartlarına uyumlu veriler araştırılmaya devam etmektedir. Son olarak, yarışma zamanına kadar, [7-11]'den elde edilen veriler ile Sağlık Bakanlığı tarafından verilen veri seti birleştirilerek geliştirilen derin modelin eğitim aşaması gerçekleştirilecektir.

5. Referanslar

[1] Ren, S., He, K., Girshick, R., and Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. Advances in neural information processing systems, 28.

[2] He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).

[3] Lin, T. Y., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017). Focal loss for dense object detection. In Proceedings of the IEEE international conference on computer vision (pp. 2980-2988).

[4] Tan, M., Pang, R., and 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).

[5] Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., and Belongie, S. (2017). Feature pyramid networks for object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2117-2125).

[6] Dai, J., Li, Y., He, K., and Sun, J. (2016). R-fcn: Object detection via region-based fully convolutional networks. Advances in neural information processing systems, 29.

[7] https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone, Erişim Tarihi: 08.05.2022

[8] https://wiki.cancerimagingarchive.net/display/Public/Pancreas-CT, Erişim Tarihi: 08.05.2022

[9] https://medpix.nlm.nih.gov/home, Erişim Tarihi: 12.05.2022

[10] https://wiki.cancerimagingarchive.net/display/Public/, Erişim Tarihi: 18.05.2022

[11] https://radiopaedia.org/?lang=us, Erişim Tarihi: 26.05.2022

[12] https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/, Erişim Tarihi: 24.06.2022