TEKNOFEST

HAVACILIK, UZAY VE TEKNOLOJİ FESTİVALİ

SAĞLIKTA YAPAY ZEKÂ YARIŞMALARI

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

PROJE DETAY RAPORU

TAKIM ADI: KGM BLACK NIGHT AI

TAKIM ID: 407207

İçindekiler

1. Proje Mevcut Durum Değerlendirmesi 3
2. Özgünlük 3
2.1. YOLO (You Only Look Once) Algoritması 4
2.2. NnFormer Algoritması 5
3.3. Metis V1 Algoritması 5
3. Sonuçlar ve İnceleme 7
3.1. Geliştirilen Sistemin Sonuçları ve İncelemesi 7
3.2. Uygulanan Test Senaryoları ve Sonuçları 9
3.2.1. Test Senaryosu 9
3.3. Yapılan Test Sonuçları ve Uygulanan Yöntemin Uyumluluğu 10
3.4. Yapılan Hatalar, Yaşanan Sorunlar ve Kazanılan Tecrübeler 10
4. Deney ve Eğitim Aşamalarında Kullanılan Veri Setleri 11
4.1. Eğitim ve Test Aşamasında Kullanılan Veri Setleri 11
4.2. Eğitim ve Test Veri Setlerinin Analizleri 11
5. Referanslar 12

1. Proje Mevcut Durum Değerlendirmesi

Proje sunuş raporunda tanıtılan ekip üyeleri, yapay zeka algoritmasını geliştirmeye devam etmektedir. Projede P. Rajpurkar ve arkadaşlarının üretmiş oldukları AppendiXNet[1] makalesi ve J. Cai ve arkadaşlarının üretmiş oldukları "Yetişkin Çinlilerin normal pankreasını keşfetme"[2] makalesi probleme en yakın çözümü üreten uluslararası makaleler olarak özetlenmiştir.
Proje sunuş raporunda nnFormer ve SAHI YOLO v5x6 algoritmaları kullanılarak, hibrit tabanlı özgün Metis V1 algoritması üretilmesi planlanmıştır. Gelinen aşamada algoritmanın programlanması tamamlanmıştır. Programlama dili olarak Python kullanılmıştır. Böylelikle proje sunuş raporunda planlanan algoritma hayata geçirilmiştir. Algoritmanın testleri yarışma sürecine kadar devam edecektir. Fakat anlık olarak %98.7014 doğruluk oranı ile çalışmaktadır. Ayrıca nesne tespit dörtgeni düzgün bir şekilde oluşturulmaktadır. Aynı zamanda MBB kodları sağlıklı bir şekilde çıktı olarak vermektedir. Algoritmanın yapısı oluşturulurken temel alınan algoritmaların (NnFormer ve SAHI YOLOv5x6) en iyi yönlerinin entegrasyonu yapılmıştır. Ayrıca eksiklikler ve hatalar fark edilerek özgün yapılar entegre edilmiştir. Entegre edilen yapılar **2.3. Metis V1 algoritması** bölümünde maddeler halinde anlatılmıştır. Programlanması tamamlanan algoritmanın veri setine önem verilmiş ve farklı kaynaklardan veriler elde edilmeye çalışılmıştır.
Veri seti oluşturulurken temelde yarışma komitesi tarafından verilen veriler kullanılmaktadır. Fakat bunun yeterli olmadığı görülmüştür. Bu sebeple Kocaeli Eğitim ve Araştırma hastanesinin, Karabük Eğitim ve Araştırma hastanesinin etik kurullarına başvuru yapılarak veri talep edilmiştir. Her iki hastanede olumlu yanıt vermiştir. Kocaeli E.A. hastanesinden 7000, Karabük E.A. hastanesinden 700 veri alınmıştır. Alınan veriler ilgili hastanelerin radyalogları ile değerlendirilerek etiketleme işlemi yapılmıştır.
NOT: Hakemlerin talep etmesi durumunda etik kurul izinleri gösterilebilmektedir.
Elde edilen veriler Data Augmentation (veri çoğaltma) teknikleri kullanılarak çoğaltılmıştır. Kullanılan tekniklerin detayları **4.2. Eğitim ve Test veri setlerinin analizleri** bölümünde anlatılmıştır. Uygulanan tekniklerin sonucunda toplamda 11830 veri elde edilmiştir. Oluşturulan veri setinde apandiks iltihabı (akut apandisit), safra kesesi iltihabı (akut kolesistit), pankreas iltihabi (akut pankreatit), böbrek/üreter taşı, barsak divertikül iltihabı (akut divertikülit) ve karın ana damar balonlaşması/yırtılması (aorta anevrizma) örnek klinik hastalığı bulundurmaktadır. Bu verilerin %84'ü eğitim, %16'sı test verisi olarak kullanılmıştır.
Mevcut durumda; literatür araştırması tamamlanarak örnek makaleler belirlenmiş, geniş bir veri seti elde etmek için çalışmalar yapılmış ve veriler elde edilmiştir. Algortimanın temel taşları oluşturulmuştur. Algoritmaya özgün yapılar katılarak kodlama aşaması tamamlanmıştır, algoritmanın testleri yapılmış ve başarılı sonuçlar elde edilmiştir. Algoritmanın testleri yarışma gününe kadar devam edecektir ve mükemmelleştirme çalışmaları yapılmaktadır.

2. Özgünlük

Takımımız, yarışma şartnamesi doğrultusunda yedi tür etiketli (bir adeti "hastalık yok" etiketidir) hastalığı tespit eden yapay zeka algoritmasını geliştirmektedir. Geliştirdiği algoritmaya "Metis V1" adını vermiştir. Metis V1 algoritması temelde NnFormer ve SAHI YOLO 5x6 algoritmalarını kullanmaktadır. Bu bölümde Metis V1 algoritmasının temelden, özgün yapıya ulaşana kadar geçen süreci anlatılmaktadır.
Bu süreç ilk olarak temel alınacak algoritmaların seçimi ile başlamıştır. Araştırma sürecinde yapay zekâ algoritmalarının alt yapısı olan, makina öğrenmesi üzerinde durulmuştur. Literatür taraması yapılırken derin sinir ağı veya derin öğrenme (deep learning) kavramları ile karşılaşılmıştır. Derin öğrenme, çok katmanlı yapay sinir ağlarını ifade etmektedir. Yapay

sinir ağı ise insan beynini örnek alınarak geliştirilen, karmaşık problemleri çözen yapılardır. Derin öğrenmenin farklı çeşitleri mevcuttur. Bunlardan en ön plana çıkanı Evrişimsel Sinir Ağlarıdır (Convolutional Neural Network). CNN yapısının önemli özelliklerinden biri örüntü tanıma çalışmalarında, sinir ağının parametre sayısını azaltmasıdır. Bu özellik sayesinde CNN yapısının uygulama esnasında tespit yapabilmesi için, görüntünün tamamına ihtiyaç duyulmamaktadır. Farklı filtreler kullanılarak her katmanda evrişim yapılmaktadır. Evrişim yapılırken aynı anda işlenebilecek parametre sayısı büyük oranda düşürülür. Bu da modelin hızlı sonuç vermesini sağlar. CNN yapısı, hızlı sonuç vermesinin yanında zorlu görsel analiz görevlerinde üstün performans göstermektedir. Bu sebeple CNN tabanlı yöntemler üzerine literatür araştırması yapılmıştır. Takımımız araştırmalarında iki farklı yöntem finale kalmıştır. Bunlar NnFormer ve YOLO (You Only Look Once) algoritmalarıdır.
Metis V1 algoritması, **2.1. YOLO (You Only Look Once) Algoritması** ve **2.2. NnFormer Algoritması** bölümlerinde anlatılan algoritmaların en iyi yönlerini temel alarak geliştirilmiştir. Metis V1 temelinden kaynaklı hatalar, özgün yapılar eklenerek giderilmiştir. Metis V1 algoritmasının çalışma mantığı ve özgün yapıları **2.3. Metis V1 Algoritması** bölümünde anlatılmıştır.

2.1. YOLO (You Only Look Once) Algoritması

YOLO yapısı 2016 yılında gerçek zamanlı nesne tespiti gerçekleştirmek için "End to End" yaklaşımıyla geliştirilmiştir. Geliştirildiği yıldan itibaren farklı versiyonlar ile günümüze gelmiştir. You Only Look Once (sadece bir kez bakarsın) algoritması, isminden de anlaşılacağı üzere nesne tespit ve tanıma işlemini tek seferde ve hızlı bir şekilde gerçekleştirir. YOLO algoritması, temelde gerçek zamanlı nesne tespitini yüksek hızlarda yapabilmesi için oluşturulmuştur. YOLO algoritmasının çalıştığı görsellerdeki nesnelerin konumlarını aynı anda tespit edebilmektedir. YOLO algoritmasının çalışma prensibi şöyledir: Algoritmaya giren görsel anlık olarak bölgelere ayrılır. Her bölge sınıflandırılır. Sınıflandıran bölgedeki nesneler kutu içine alınır. Bu işleme "bounding box" denir. Bütün sınıflara bir güven puanı atanır. Güven puanı veri seti ile ilişkilidir. Algoritma, güven puanı yüksek olan bölgeye odaklanır ve tahmin gerçekleştirir. Tahmin işleminin sonunda nesne tespiti gerçekleşir ve doğruluk oranı yazılır. YOLO algoritmasının farklı versiyonları mevcuttur. Takımımız "YOLO v5x6" versiyonunu test etmiştir.

Model	size (pixels)	mAP^{val} 0.5:0.95	mAP^{val} 0.5	Speed CPU b1 (ms)	Speed V100 b1 (ms)	Speed V100 b32 (ms)	params (M)	FLOPs @640 (B)
YOLOv5x6	1280	55.0	72.7	3136	26.2	19.4	140.7	209.8

Şekil 1 YOLO v5x6 Algoritmasının Performans Tablosu

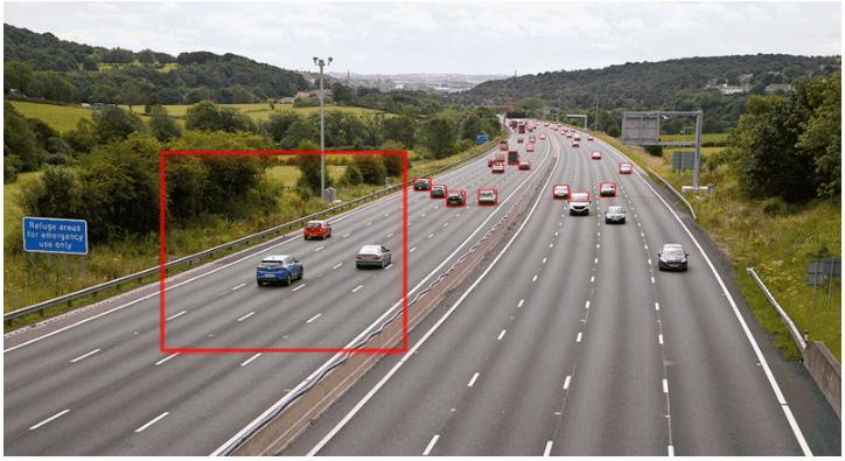

Şekil 2 SAHI Eklentisinin Örnek Gösterimi

Seçilen modelin eksiklikleri göz önünde bulundurulduğunda, ek yazılımlar entegre edilmiştir. Seçilen modelin eklenti yazılımı ise SAHI'dir (dilimleme destekli hiper çıkarım). SAHI algoritması büyük ölçekli görüntüler üzerinde nesne tespiti ve segmentasyon gerçekleştiren, hafif görüş kitaplığıdır. Neredeyse

bütün nesne tespit algoritmalarına eklenebilmektedir. Algoritmanın temel amacı işlenen görsellerdeki küçük ve uzakta bulunan nesneleri tespit etmektedir. Eklendiği algoritmanın performansına göre SAHI algoritmasının da performansı artmaktadır. Algoritmanın çalışma mantığını ifade etmek gerekirse, nesne tespiti yapılacak görsel üzerinde bir çerçeve oluşturur ve tarama yapar. Bu işlem gerçekleşirken iki önemli parametre vardır. Yükseklik ve genişlik. Bu parametreler algoritmanın verimli çalışmasında önemlidir. Bu işlemde tarama ile kastedilen aslında dilimleme (slicing) yöntemidir. Dilimleme ile çıkarım yapma yöntemi, orijinal görüntünün daha küçük dilimleri/parçaları üzerinden nesne tespiti yapma ve sonrasında bu tespitleri orijinal görüntü üzerinde birleştirme fikrini temel alır. Sliced Inference-Dilimleme ile Çıkarım konseptinin ana fikri, orijinal görüntünün daha küçük dilimleri üzerinde çıkarım yapmak ve ardından dilimlenmiş tahminleri orijinal görüntü üzerinde birleştirmektir. Şekil 2'de görüldüğü üzere uzaktaki araçlarda algoritma ile tespit edilebilmiştir.
Özetleyecek olursak SAHI YOLO 5x6 algoritmasının, hızlı çalışma dinamikleri ve dilimleme katmanı özgün modele entegre edilmiştir. Böylece Metis V1 algoritması, anlık gelen görsellerde daha doğru tespit yapan ve çok küçük nesneleri bile tespit edebilen hale gelmiştir.

2.2. NnFormer Algoritması

NnFormer algoritması, U-Net tabanında geliştirilmiş bir yapıdır. Bu sebeple özgün model geliştiren takımımız için çok büyük bir kaynak olmaktadır ve örnek teşkil etmektedir.
U-Net algoritması, Fully Convolutional Neural Network yapısı üzerinden oluşturulmuştur. Bu algoritmada Convolutional Neural Network (CNN) yapısının kullanılmamasının nedeni, sağlık alnında özelleştirilmiş olmasıdır. Çünkü CNN yapısı, medikal alandaki MRI, X-Ray, BT gibi yoğun görüntüleri işlemekte zorlanmaktadır. F-CNN yapısı, medikal görüntülerin işlenmesi için oluşturulmuştur.
2015 yılında Cell Tracking Challenge at ISBI yarışmasında F-CNN tabanında geliştirilen U-Net algoritması, büyük bir başarı göstermiştir. Bu başarı ile medakal alandaki görüntülerin işlenmesinde ön plana çıkmaya başlamıştır. U-Net algoritması çok başarılı olsada, Visual Transformer (ViT) yapısı olarak kullanıldığında doğru segmentasyon yapamamaktadır.
Ön bulgu raporunda takımımız, U-Net tabanlı NnFormer algoritmasının genel mamarisini kullanmayı planlamaktaydı. Gelinen aşamada ise entegrasypnu başarı ile sağlamış, **2.3. Metis V1 Algoritması** bölümünde anlatılmıştır.
NnFormer algoritması; kullanılmış olduğu üç açık kaynak veri setinde TransU-Net ve SwinU-Net gibi transformer kullanan algoritmalara göre daha yüksek oranda başarı göstermiştir. nnFormer'ın algoritma mimarisi klasik U-Net algoritması gibidir ve üç ana kısımdan oluşmaktadır. Bunlar; Encoder, bottleneck ve decoder'dir. Encoder, bir gömülü katman, iki tane yerel transformer bloğu ve iki tane down-sampling (Aşağı Örnekleme) katmanından oluşmaktadır. Decoder yapısı da Encoder'a benzer olarak iki tane transformer bloğu, iki tane up-sampling (Yukarı Örnekleme) bloğu ve maske tahmini yapmak için patch'i genişleten katmandan oluşmaktadır. Bunların yanı sıra; bottle-neck kısmında ise bir down-sampling, bir up-sampling ve üç tane transformer bulunmaktadır. Bottle-neck (Dar Alan), bu katmanlarda Decoder'ı desteklemek için alıcı bir alan oluşturmaktadır. U-Net'te sadık kalarak featurelar (özellikler) arasına bağlantılar verilmiştir. Böylelikle detaylar bağlantılar arasında kaybolmamaktadır.
Ekibimiz Metis V1 algoritmasının genel mimarisine, NnFormer algoritmasının mimarisini başarı ile inşa etmiştir. Böylelikle medical görüntüleme yöntemlerinden elde edilen yoğun görselleri daha rahat işleyebilir hale gelmiştir. Ayrıca takımımız, yarışma esnasında test edilecek olan ilaçlı veya ilaçsız BT görüntüleri üzerinde özelleştirme gerçekleştirmiştir.

3.3. Metis V1 Algoritması

Sağlıkta Yapay Zeka yarışması bilgisayarlı görü kategorisinde takımımız, kendi özgün

algoritmasını geliştirmekte ve kodlamaktadır. Algoritma yarışma kuralları çerçevesinde sadece ilaçlı veya ilaçsız BT görüntülerini işlemek için özelleştirilmektedir. Temelde SAHI YOLO 5x6 ve NnFormer algoritmasının en iyi yönlerini kullanmaktadır. Fakat entegrasyon sürecinde hız ve doğruluk oranı düşümleri sorunları oluşmuştur. Bu sorunlara karşın takımımız, kendi özgün katmanlarını entegre etmiştir. Algoritmanın yazılımda Python programlama dili kullanılmıştır. Takımımızın yazılımını tamamladığı Metis V1 algoritmasında kurulumu yapılan kütüphaneler tablo 1'de gösterilmiştir.

Tablo 1 Metis V1 Algoritmasında Kurulumu Yapılan Kütüphaneler

KÜTÜPHANE	VERSİYON	KÜTÜPHANE	VERSİYON
OpenCV	4.1.1	Pandas	1.1.4
Torch	1.7.0	Seaborn	0.11.0
Matplotlib	3.2.2	Tensorboard	2.4.1
Numpy	1.18.5	Pillow	7.1.2
Tqdm	4.41.0	PyYAML	5.3.1

Metis V1 algoritmasının kodlama ve entegrasyonu yapılırken ön bulgu raporundaki planan algoritma işleyişi kullanılmıştır. Büyük ölçüde gerçekleştirilen planın bazı noktaları hatalı veya yanlış olduğu fark edilmiştir. Şekil 3'de gerçekleştirilen algoritma işleyişi gösterilmiştir.

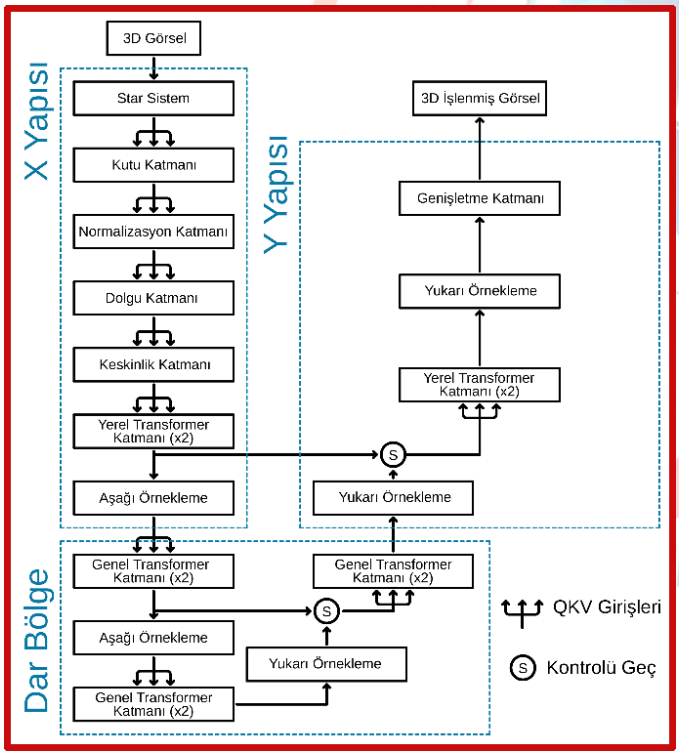

Şekil 3 Metis V1 Algoritmasının İşleyişinin Gösterimi

Algoritmanın işleyişi şu şekildedir. 3d görüntü sisteme girer. Görsel üzerinde bölgesel kutu oluşturur. Piksel yoğunluğunun noktasal olarak biriktiği noktalara yoğunlaşır. Algoritma veri seti üzerinden eğitilen görseller ile işlenen görseli karşılaştırır. Karşılaştırma işlemi sonucunda, belirli bir doğruluk oranı ile nesne tespiti yapılır. Tespit edilen nesnenin etrafına dörtgen çizdirilir. Doğruluk oranı ile birlikte hastalık etiketi dörtgenin sol-üst kısmında, hastalık kodu dörtgenin sağ-alt kısmında belirmektedir. Algoritmanın işlediği görsellerin MBB kodu çıkış olarak alınabilmektedir. Anlık olarak Metis V1 algoritması %98.7014 doğruluk oranını (özellikle böbrek taşı tespitinde) yakalamaktadır.

Not: Metis V1 algoritmasının kod bloğu hakemlerin talep etmesi durumunda kolaylıkla görüntülenebilmektedir.

Algoritmanın özgün katmanları beş madde de aşağıda anlatılmıştır;

- Star Katmanı, OpenCV tabanlı destek algoritmasıdır. Bu katmanda amaçlanan, algoritmanın 3d medikal görüntülere olan hassaslığını arttırmaktır. Algoritmanın hassaslığını arttırmak için ilgili görselde yoğun bulunan renk tonları belirlenmiştir. Yoğun bulunan renk tonları görmezden gelinerek, yoğun olmayan pikseller ön plana çıkarılmıştır. Star katmanı Python programlama dili ile kodlanarak entegrasyonu tamamlanmıştır.

- Kutu Katmanı, Silicing Aided Hyper Interference (dilimleme destekli hiper çıkarım) eklentisinin takımımız tarafından özgün entegrasyonunu kapsamaktadır. Bu katmanda

amaçlanan, görseli bölgesel dilimlere ayırmaktır. Her bölge kendi başına YOLO algoritması gibi davranır ve transfer fonksiyonu oluşturur. Her transfer fonksiyonu ile bir güven puanı belirlenir. Algoritma, güven puanı yüksek olan bölgeye yoğunlaşır. Entegrasyonu tamamlanan katman sayesinde algoritmanın çalışma hızı artmaktadır.

- Normalizasyon Katmanı, algoritmanın stabil çalışması için oluşturulmuştur. Stabilizeyi sağlamak için eğitim bağlantısı güncelleştirilmiştir. Eğitim ile eğitim arasında hatalar giderilmiştir. 50000+ adımda yapılan eğitimlerde bile hatasız çalışma performansı göstermiştir.
- Dolgu Katmanı, algoritmada sürekli evrişim yapmaktan sorumlu yapıdır. Bu yapı ile kenar bilgi kaybının azaltılması hedeflenmiştir. Aynı zamanda Dolgu yapısı ile yönetim zamanı azaltılmıştır. Bu etki ile algoritmanın çalışma performansı daha da iyileştirilmiştir. Entegrasyonu tamamlanan yapı, OpenCV kütüphanesi kullanılarak kodlanmıştır.
- Kararlılık Katmanı, yukarı örneklem yapmadan önceki son katmandır. Bu yapı ile segmentasyon yapılarının düzeltilmesi amaçlanmıştır. Aynı zamanda gradyan yapılarının yok olması önlenmiştir. Bu katman ile tespit edilen nesnenin etrafına çizdirilen dörtgenin netliği ayarlanmıştır. Ayrıca doğru MBB koordinatlarının verilmesi bu yapı ile sağlanmıştır.

Takımımız tarafından oluşturulan modele, arayüz tasarımı yapılarak kullanım kolaylığı sağlanması amaçlanmıştır. Yarışma esnasında sunucuya kolaylıkla bağlanabilmek veya modelin çalışma esnasında oluşabilecek hataları minimum indirmek amaçlanmaktadır. Bu sebeple özgün kontrol programı tasarlanmıştır. Özgün kontrol panelinin özellikleri şunlardır;

- Sunucuya bağlanmak için gerekli bilgiler girilebilir.
- Sunucudan gelen anlık veriler, dosya halinde görüntülenebilir.
- Sağ tarafta anlık olarak anlamlandırılan görseller görülebilir ve doğruluk oranı izlenebilir.
- MBB koordinatları ve IoU bilgilerinin bulunduğu dosya görüntülenebilir.

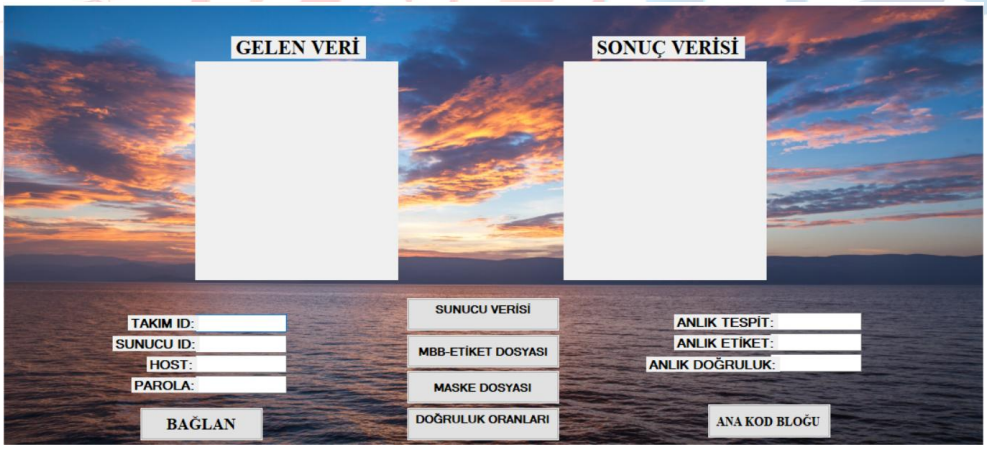

Şekil 4 Algoritma Kontrol Arayüzü

3. Sonuçlar ve İnceleme

3.1. Geliştirilen Sistemin Sonuçları ve İncelemesi

Gerçekleştirilen bu çalışmada, Python programlama dili ile yolo, OpenCV, Torch, Numpy v.b. kütüphaneler kullanılmıştır. Eğitilecek olan nesnelerin etiketleri ise kendi ID'lerini barındıran LabelMap ayarlanarak, Object Detection API üzerinden eğitim gerçekleştirilmiştir.

Tablo 2 Gerçekleştirilen Deneylerin Tablo ile Gösterimi

Deney Numarası	Eğitim Adımı	Başarı Oranı	Kayıp Oranı
Deney-1	1000	0.96241	0.03759
Deney-2	5000	0.94550	0.05450
Deney-3	10000	0.96937	0.03063
Deney-4	45000	0.98023	0.01977
Deney-5	60000	0.97769	0.02231
Deney-6	100000	0,98701	0.01299

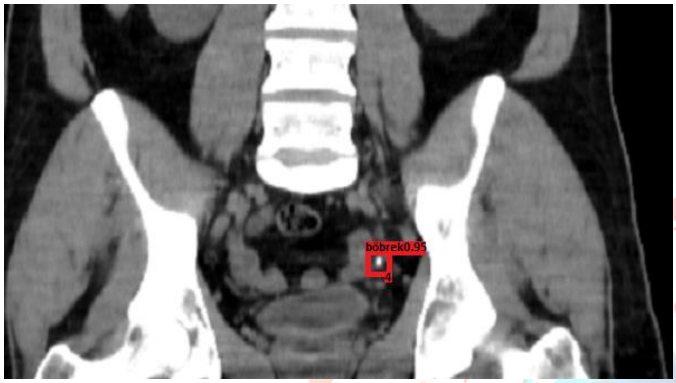

Şekil 5 Böbrek Taşı Tespit Örneği

Algoritmanın çalışma süresi boyunca farklı adım sayıları ile görseller üzerinde denemeler gerçekleştirilmiştir. Bu çalışma ile eğitim için doğru adım sayısının bulunması hedeflenmiştir. Ayrıca yapılan bu çalışma ile algoritmanın eğitildiği adım sayısının, doğruluk oranına etkisi görülmektedir. Toplamda 6 adet deney yapılmıştır. Yapılan her deney kendi içinde üç farklı aşamada tamamlanmıştır. Her deneyde adım sayısı değiştirilerek başarı ve kayıp sonuçları gözlemlenmiştir. Bu çalışmadan yola çıkarak doğru eğitim adım sayısının, nesne tanıma üzerinde etkisinin büyük olabileceği kanıtlanmıştır. Test sonunda 0.01299 kayı oranı ile 100000 adım ile eğitilen modelin daha doğru sonuçlar verdiği gözlemlenmiştir. Tablo 2'de gerçekleştirilen bütün deneylerin sonuçları gösterilmiştir. Bütün deneyler aynı veri seti üzerinde gerçekleştirilmiştir.

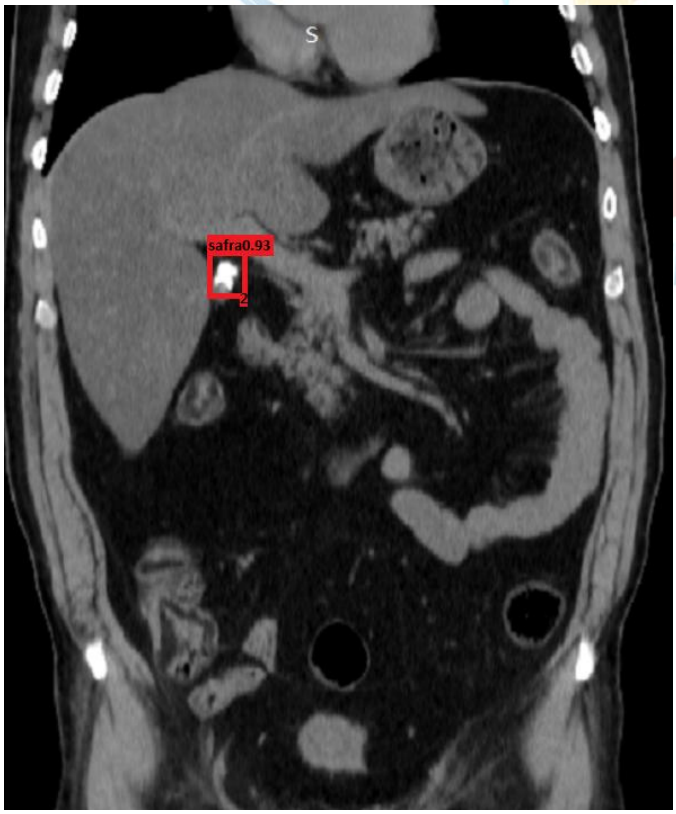

Şekil 6 Safra Kesesi İltihabı Tespit Örneği

Eğitim sürecinde en iyi tahmin oranının bulunması için farklı deneyler gerçekleştirilmiştir. Gerçekleştirilen çalışma kapsamında araştırılan en önemli işlemlerden biri; ilgili algoritmanın belirli nesnelerden oluşan veri seti üzerinde çalıştırılarak, başarılı bir şekilde tespit işleminin yapılıp yapılmadığının gözlemlenmesidir. Sonuçların farklılaşmasında en büyük etkenlerden biri de veri setinin kalitesidir. Ekibimiz veri setini büyük bir dikkat ile etiketleyerek oluşturmuştur. Bu kapsamda 11130 adet görselden oluşan veri seti ve doğru adım sayısı ile testler gerçekleştirilmiştir. Eğitilen model üzerinde görseller ile çıkarım yapılmıştır. Deney sonucunda en düşük başarı oranı 0.94550, en yüksek başarı oranı ise 0,98701 olarak ölçülmüştür. Bu sonuçlar doğrultusunda eğitim

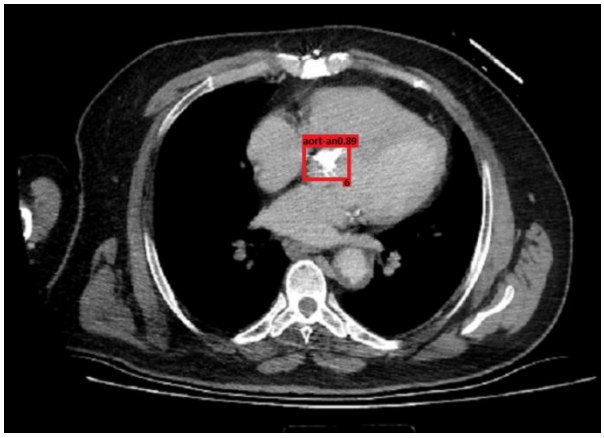

Şekil 7 Aort Anevrizma Tespit Örneği

adımlarının (epoch) farklılaşması, başarı sonucunu doğrudan etkilemiştir.
Bu çalışmada kullanılan Metis V1 modeli, örnek BT görüntüleri üzerinde nesne tespiti yapmıştır. Nesnenin bulunduğu konuma göre özelleşen algoritma, hangi hastalığın olduğunu da etiketinde yazdırmıştır. Ayrıca Excel formatında MBB kodlarının çıkarımını da yapmaktadır. Metis V1 algoritmasında bulunan özgün katmanlar ile düşük çözünürlüğe sahip görsellerin iyileştirilmesi hedeflenmiştir. Bu hedef doğrultusunda görselde bulunan öz niteliklerin tüm katmalara eşit şekilde yayılması YOLO temelli çalışma ile sağlanmıştır. Böylece ağ performansı artmıştır. Deneysel çalışmaların sonucunda Metis V1 modeli %95 F1-skor, %97 ortalama hassasiyete ve %98 IoU değeri ile açık ara fark ile hazır modellere kıyasla daha verimli olduğunu kanıtlamıştır. Ekibimiz en iyisini yapmak için çalışmalarına devam etmektedir.

3.2. Uygulanan Test Senaryoları ve Sonuçları

Projede geliştirilen Metis v1 algoritmasının test senaryolarının sonuçları Intersection over Union metriği üzerinden değerlendirilmiştir. Intersection over Union(IoU) metriği obje segmentasyonu ve tanıma algoritmalarında algoritmanın doğruluğu tanımak için çokça kullanılmaktadır[1]. IoU bounding box'la etiketlenmiş verilerin algoritma tarafından tahmin ederek çizmiş olduğu bounding box'la oranlanarak hesaplanmaktadır. IoU tahmin edilen bounding box'la etiketlenmiş bounding box'ın kesit alanını iki bounding box'ın toplam alanına bölerek hesaplanmaktadır.

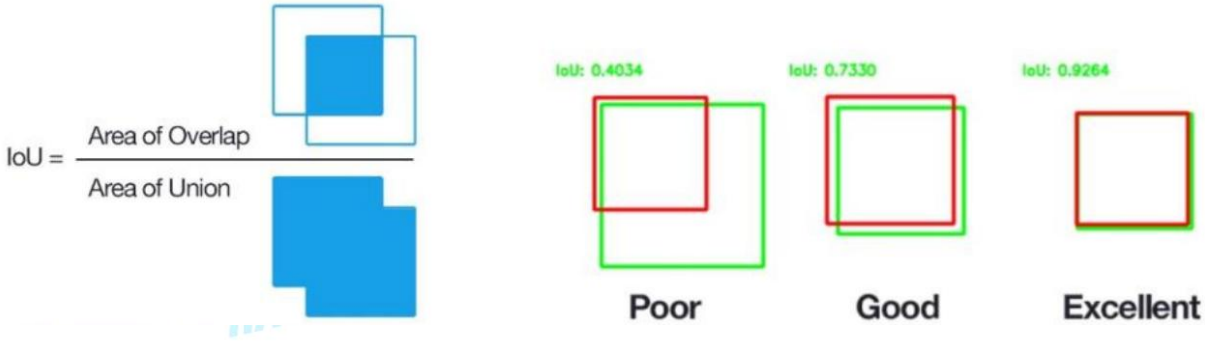

Şekil 8 IoU Hesaplama Görselleri

IoU kullanılarak yapılan testlerde algoritmanın 0.5 üzerinde vermiş olduğu değerler algoritmanın iyi bir şekilde çalıştığını göstermektedir.

3.2.1. Test Senaryosu

Projede geliştirilen Metis v1 algoritması apandiks iltihabı (akut apandisit), safra kesesi iltihabı (akut kolesistit), pankreas iltihabi (akut pankreatit), böbrek/üreter taşı, barsak divertikül iltihabı (akut divertikülit),karın ana damar balonlaşması/yırtılması (aorta anevrizma) başlıkları altında 6 klinik hastalığı tespit etmeye çalışmaktadır. Projede yapılan daha önceki test senaryoları değerlendirilerek Metis v1 algoritması nesne tespit algoritması olarak geliştirilmiştir. Metis v1 algoritması nesne tespit görevini yerine getirmek için SAHI

algoritmasının nesne tespit için kullandığı ızgara yapısından esinlenerek geliştirilmiştir. Metis v1 algoritması nesne tespit görevini yerine getirmek için kullandığı nesne sınıflandırma görevi için nnFormer yapısında kullanılan ViT yapısı kullanılmıştır. Projede yapılan geliştirmeler sonucunda özgün Metis v1 algoritması ortaya çıkmıştır. Projede yapılan test senaryosu 4'de algoritmanın tespit etmeye çalıştığı 6 klinik durum ve bulgu yok durumlu 7 etiketli TÜSEB veri seti 2000 epoch'ta Metis v1, nnFormer ve SAHI algoritmaları üzerinde eğitilmiştir. SAHI algoritmasının eğitim süresi Metis v1 ve nnFormer algoritmasından daha kısa sürmüştür. Eğitilen bu algoritmalar Karabük Eğitim ve Araştırma Hastanesinden alınarak oluşturulan veri setinden alınan her bir örnek klinik durumu tespit etmek üzere test edilmiştir. Yapılan bu testler neticesinde Metis v1 algoritması IoU değeri olarak nnFormer ve SAHI algoritmalarını geçmiştir.

Tablo 3 Test Sonuç Tablosu

TEST	SAHI YOLO	NnFormer	Metis V1
IoU	0.62	0.59	0.83

3.3. Yapılan Test Sonuçları ve Uygulanan Yöntemin Uyumluluğu

Projede geliştirilen Metis v1 algoritması nnFormer ve SAHI temelli geliştirilmiştir. nnFormer algoritması U-net algoritmasını temel alarak geliştirilmiştir. Yapılan test senaryolarında sistem donanımlarının projenin isterlerini karşılayıp karşılamayacağı belirlenmiştir. Bu test neticesinde sistem donanımlarının projenin isterlerini karşıladığı anlaşılmıştır. Yapılan test senaryosunda U-net ve nnFormer algoritması kıyaslanmıştır. Test senaryosunda Visual Transformer yapısının görüntü işlemede U-net gibi Fully Convolutional Neural Network algoritmalarına göre daha başarılı olduğu anlaşılmıştır. Test senaryosunun değerlendirilmesiyle sonucunda geliştirilen Metis v1 algoritmasında Visual Transformer yapısının kullanılmasına karar verilmiştir. Test senaryosunda Metis v1 algoritmasının temelinde kullanılacak olan nnFormer ve SAHI algoritmaları projede tespit edilmeye çalışılan hastalıklar arasında BT görüntülerinde görece küçük gözüken üç klinik durum eğitim için kullanılmıştır. Bu test senaryosunda SAHI temelli nesne tanıma algoritmasının görüntülerde görece küçük görülen nesneleri daha iyi sınıflandırdığı anlaşılmıştır. Test senaryosunun neticesinde geliştirilen Metis v1 algoritmasında kullanılacak olan nesne tanıma görevi SAHI algoritmasından esinlenerek geliştirilmiştir. Yapılan son test senaryosunda nnFormer, SAHI ve Metis v1 algoritması projede istenen 6 klinik hastalık ve bulgu yok durumlu TÜSEB veri setiyle eğitilmiştir. Yapılan son test senaryosunda SAHI algoritmasının Metis v1 algoritmasından daha hızlı eğitimi tamamladığı ancak IoU değeri olarak Metis v1 algoritmasından geride kalmaktadır. Yapılan test senaryolarının her bir basamağı değerlendirilmiş, değerlendirilen test sonuçlarına göre Metis v1 algoritması geliştirilmiştir. Bu yönüyle uygulanan yöntem test sonuçlarıyla uyumludur.

3.4. Yapılan Hatalar, Yaşanan Sorunlar ve Kazanılan Tecrübeler

Takımız ilk olarak Metis algoritmasının temellerini oluştururken hata yapmıştır. Kısıtlı bir literatür araştırma yapılmasından kaynaklanan konudan bağımsız algoritma tercihleri oluşmuştur. Bu durum literatür araştırmasının genişletilmesiyle ve farklı platformlardan teknik eğitimlerin alınmasıyla çözülmüştür.

Takımımız başka bir hata ile karşılaşmadan başarılı bir hazırlanma süreci geçirmişlerdir. Bu yarışma sürecinde takımımızdaki üyeler; yeni tanıştıkları alanda bilgi sahibi olma, yapay zeka alanında bilgi sahibi olma, Python programlama dili ile yazılım geliştirme ve Py-qt5 designer gibi uygulamaları tecrübe ederek teknik bilgilerini arttırma şansı yakalamışlardır. Bu kazanımların yanı sıra doküman hazırlama, ekip çalışmasına uyum, yaratıcı düşünebilme ve

stres altında sakin kalabilmek v.b. hayata dair yeni tecrübeler elde etmişlerdir. Sağlıkta Yapay Zeka yarışması kendi konusunun dışında, hayata dair bir çok tecrübeyi ekip arkadaşlarımıza kazandırmıştır.

4. Deney ve Eğitim Aşamalarında Kullanılan Veri Setleri

4.1. Eğitim ve Test Aşamasında Kullanılan Veri Setleri

Projede geliştirilen özgün Metis v1 algoritmasının eğitim ve test aşamalarında TÜSEB tarafından verilen 1050, Karabük Eğitim ve Araştırma hastanesinden alınan 700 ve Kocaeli Eğitim ve Araştırma hastanesinden alınan 7000 adet hastalık veri seti kullanılmıştır. Projede geliştirilen Metis v1 algoritmasının eğitim aşamasında TÜSEB'den alınan 1050 veri, Kocaeli Eğitim ve Araştırma Hastanesinden alınan 7000 son olarak veri çoğaltma ile elde edilen 3080 veri toplamda 11130 adet veri kullanılmıştır. Projede geliştirilen Metis v1 algoritmasının test aşamasında Karabük Eğitim Araştırma Hastanesinden alınarak oluşturulan 700 adet veri kullanılmıştır. Kullanılan bütün veriler DICOM formatında ve 512x512 piksel boyutlarındadır. Alınan bütün veriler bilgisayar ortamında görüntülenirken MicroDicom Viewer program kullanılmıştır. Veri paylaşımı yapan hastanelerden etik kurul onayı alınmıştır.

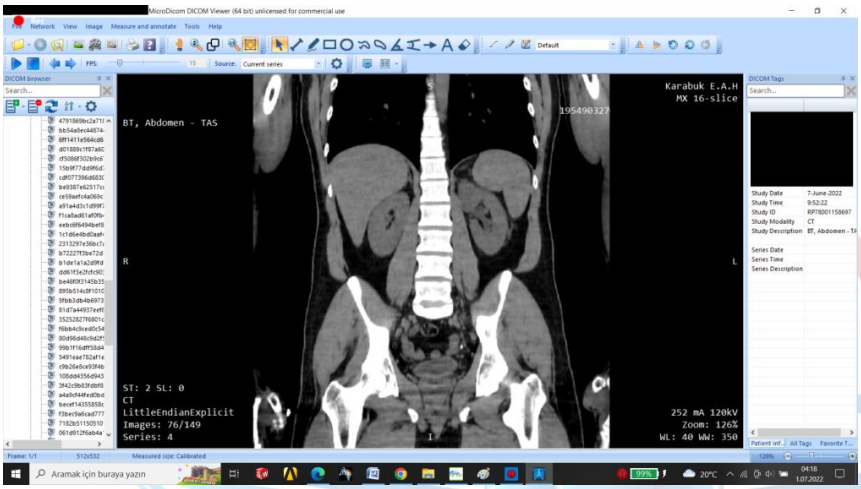

Şekil 9 Mikro Dıcom Viewer Programının Gösterimi

4.2. Eğitim ve Test Veri Setlerinin Analizleri

Projede geliştirilen Metis v1 algoritması apandiks iltihabı (akut apandisit), safra kesesi iltihabı (akut kolesistit), pankreas iltihabi (akut pankreatit), böbrek/üreter taşı, barsak divertikül iltihabı (akut divertikülit),karın ana damar balonlaşması/yırtılması (aorta anevrizma) başlıkları altında 6 klinik hastalığı tespit etmeye çalışmaktadır. Metis v1 algoritmasının eğitimi için kullanılan Kocaeli Eğitim ve Araştırma hastanesinden alınan veri seti bir radyolog doktor gözetiminde hasta BT raporları dikkate alınarak hazırlanmıştır. Veri seti 7000 adet algoritmanın teşhis etmeye çalıştığı klinik hastalık ve bu hastalıkların bulunmadığı bulgu yok durumu dahil edilerek hazırlanmıştır. Veri setinde kullanılacak verilerin belirlenmesinde hastaların yaş ve cinsiyet ayrımları yapılmamıştır. Hazırlanan veri setinde her bir hastalık örneğinde 1000 adet ham veriye ulaşılmaya çalışılmıştır. Veri sayısı 1000 ham veriye ulaşılamayan örneklerde data augmentation teknikleri kullanılarak çoğaltılmıştır. Data augmentation teknikleri radyolojik teşhiste önemli olan kriterler göz önüne alınarak uygulanmıştır. Takımımızın veri çoğaltma işlemi için kullandığı yöntemler şunlardır;

- Döndürme işlemi
- Gaussian blur ve Threshold uygulanması
- Kontur bulma ve kırpma işlemi uygulanması
- Clahe işlemi

- Median blur işlemi
- Verilerin toplanması işlemi

Veri seti, TÜSEB tarafından sağlanan veri setinin etiket yöntemleri kullanılarak etiketlenmiştir. Veri seti hazırlanırken etiketleme işlemi makesense.ai sitesin üzerinden yapılmıştır ve csv. formatına dönüştürülmüştür. Böylece veri seti kullanıma hazır hale getirilmiştir.

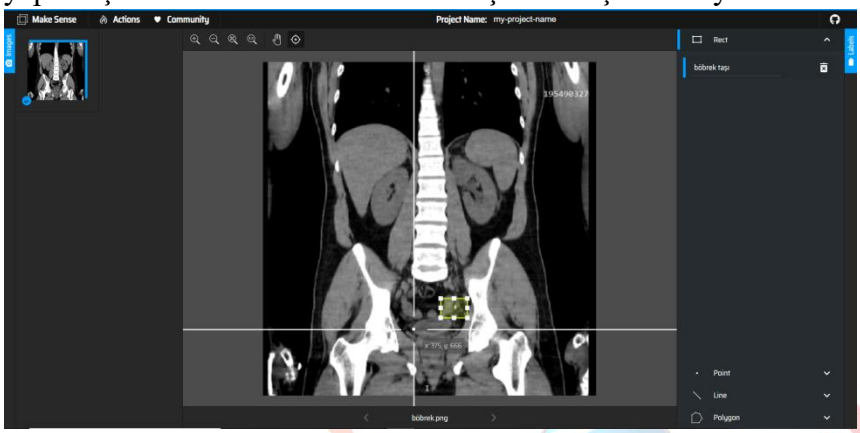

Şekil 10 Örnek Etiketleme İşleminin Gösterimi

Projede test aşamasında Karabük Eğitim ve Araştırma Hastanesi'nden alınarak oluşturulan 700 adet Metis v1 algoritmasının teşhis etmeye çalıştığı hastalıklar göz önüne alınarak hazırlanmıştır. Her bir klinik hastalık için 100 örnek hastalık verisine ulaşılmaya çalışılmıştır. 100 adete ulaşılamayan hastalıklarda radyolojik teşhiste önemli görülen noktalar göz önüne alınarak data augmentation teknikleri kullanılmıştır. Veri seti bir radyolog doktor gözetimi altında hazırlanmıştır. Veri setinin hazırlığında hasta cinsiyet ve yaş ayrımı yapılmamıştır. Veri seti TÜSEB veri seti örnek alınarak etiketlenmiş ve veri setinin hazırlıkları tamamlanmıştır. Metis v1 algoritması Kocaeli Eğt. ve Arş. Hastanesi ve TÜSEB tarafından alınan veri setiyle eğitilmiştir. Test aşamasında Karabük Eğt. ve Arş. Hastanesi'nden alınan verilerle test edilmiştir.

Sonuç olarak takımımızın veri seti anlık olarak hazır hale gelmiştir. Toplamda 11830 veriden oluşan, veri seti ile Sağlıkta Yapay Zeka yarışmasını kazanmayı hedeflemektedir.

5. Referanslar

[1] A. PARK, C. CHUTE, AppendiXNet: Deep Learning for Diagnosis of Appendicitis from A Small Dataset of CT Exams Using Video Pretraining, Nature Research, 2020, London

[2] J. CAI, X. GUO, K. WANG, Automatic quantitative evaluation of normal pancreas based on deep learning in a Chinese adult population, Abdominal Radiology, 2022, China

[3] L. BEYER, G. MMINDERER, An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, Cornell University, 2020, USA

[4] P. FISCHER, T. BROX, U-Net: Convolutional Networks for Biomedical Image Segmentation, Cornell University, 2015, USA

[5] Elmas Ç., Yapay Zeka Uygulamaları, Seçkin Yayıncılık, Ankara,2003

[6] Yücel GÖNÜL Şahin ULU, Abdülkadir BUCAK, Abdülkadir BİLİR, Yapay Sinir Ağları ve Klinik Araştırmalarda Kullanımı, Genel Tıp Dergisi, Afyon, 2015

[7] S. Albawi, T. A. Mohammed, S. Al-Zawi, Understanding of a Convolutional Neural Network, ICET, Antalya, 2017

[8] Semih Murat, İnsansız Hava Aracı Görüntülerinden Derin Öğrenme Yöntemleriyle Nesne Tanıma, Yüksek Lisans Tezi, İstanbul, 2021

[9] Volkan KAYA, Servet TUNCER, Ahmet BARAN, Derin Öğrenme Yöntemleri Kullanarak Nesne Tanıma, Erzincan, 2020

[10] Bilen BAŞARIR, Derin Öğrenme Tabanlı Nesne Takibi, Y. Lisans Tezi, Bursa, 2019