



Segmentation of prostate zones on a novel MRI database using Mask R-CNN: An implementation on PACS system

Çağlar Gürkan^{1,2*}, Abdulkadir Budak¹, Hakan Karatas¹, Kayıhan Akın³

¹Department of Artificial Intelligence and Image Processing, Akgun Computer Inc., 06790, Ankara, Türkiye

²Department of Electrical and Electronics Engineering, Graduate School of Science, Eskişehir Technical University, 26555, Eskişehir, Türkiye

³Department of Radiology, Lokman Hekim Akay Hospital, 06640, Ankara, Türkiye

Highlights:

- A novel data set was created and labelled by the radiologist.
- The artificial intelligence model was integrated on the PACS system.
- A ready-to-use decision support system was created for doctors.

Keywords:

- Prostate zone segmentation
- Prostate cancer
- T2W MRI
- PI-RADS v2
- Deep learning

Article Info:

Research Article

Received: 04.08.2022

Accepted: 02.08.2023

DOI:

10.17341/gazimmfd.1153507

Acknowledgement:

We would like to thank Akgün Computer Inc. for providing all kinds of opportunities for the execution of this project. This work has been supported by the of TÜBİTAK (Scientific and Technological Research Council of Turkey), grant no: 3191419.

Correspondence:

Author: Çağlar Gürkan
e-mail:
caglar.gurkan@outlook.com
phone: +90 537 977 0342

Graphical/Tabular Abstract

The Mask R-CNN uses DICOM data as input for segmentation of prostate zones. Segmentation results are saved in JSON file. The results are transferred to PACS servers using the Flask library based on the TCP/IP protocol. The outputs of segmentation are visualized. The block diagram is shown in Figure A.

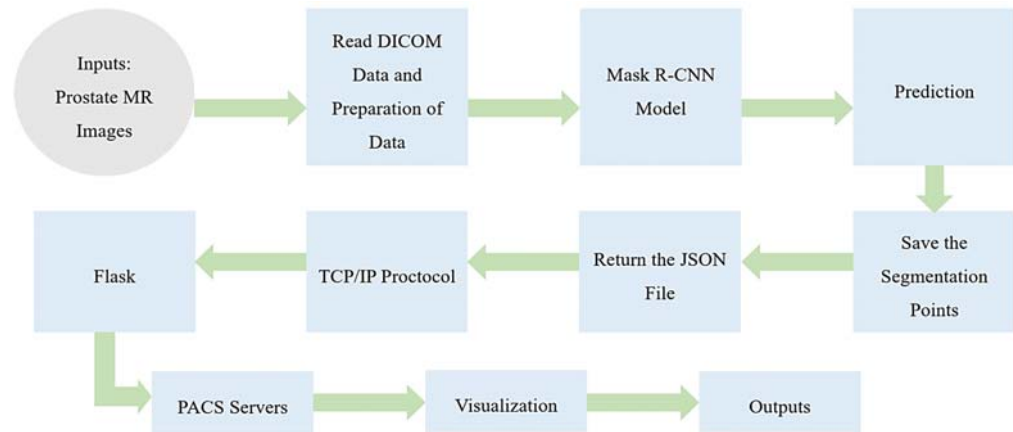


Figure A. Block diagram of prostate zone segmentation

Purpose:

The main purpose of this study is to perform fully automatic segmentation of prostate zones. While providing this, it is aimed to save the time while reducing the workload on health employees.

Theory and Methods:

The need for decision support systems in the field of health is increasing every year. One of the most important methods used in the building of this decision support system is artificial intelligence (AI). The use of computer vision, which is a sub-research area of artificial intelligence, in health is vital. Computer vision in the health area consists of four main tasks, image classification, localization, object detection, and image segmentation. In this context, researches related to segmentation were carried out in this study. The Mask R-CNN with different backbone models was used for segmentation of the prostate zones while examining prostate magnetic resonance imaging (MRI) images of 15 patients.

Results:

The X101-FPN (includes ResNext-101 and Feature Pyramid Network) with a 3x schedule and the R50-DC5 (makes fine tuning starting from the fifth convolution layer for ResNet-50, and includes dilated convolution layer) with a 3x schedule achieved equal performance with a mAP50 value of 96.040, while the training time of the R50-DC5 with a 3x schedule is 16.31 minutes, and the training time of the X101-FPN with a 3x schedule is 32.32 minutes. Therefore, the usability of the R50-DC5 with a schedule of 3x is higher because it gives faster segmentation results in the testing phase.

Conclusion:

AI model was integrated into the PACS system as ready-to-use in hospitals. In accordance with PI-RADS v2, the segmentation of prostate zones, which is important in the diagnosis of prostate cancer, was automated.



Mask R-CNN kullanılarak yeni bir MRG veri tabanında prostat bölgelerinin segmentasyonu: PACS sistemi üzerinde bir uygulama

Çağlar Gürkan^{1,2*}, Abdulkadir Budak¹, Hakan Karatas¹, Kayıhan Akın³

¹Yapay Zeka ve Görüntü İşleme Departmanı, Akgün Bilgisayar A.Ş., 06790, Etimesgut, Ankara, Türkiye

²Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Bölümü, 26555, Tepebaşı, Eskişehir, Türkiye

³Lokman Hekim Akay Hastanesi, Radyoloji Bölümü, 06640, Çankaya, Ankara, Türkiye

Ö N E Ç İ K A N L A R

- Radyolog tarafından yeni bir veri seti oluşturulmuş ve etiketlenmiştir
- Yapay zeka modeli PACS sistemine entegre edilmiştir
- Doktorlar için kullanıma hazır bir karar destek sistemi oluşturulmuştur

Makale Bilgileri

Araştırma Makalesi

Geliş: 04.08.2022

Kabul: 02.08.2023

DOI:

10.17341/gazimmfd.1153507

Anahtar Kelimeler:

Prostat bölge
segmentasyonu,
prostat kanseri,
T2W MRG,
PI-RADS v2,
derin öğrenme

ÖZ

Akciğer kanserinden sonra erkeklerde en yaygın rastlanan kanser türü prostat kanseridir. Günümüzde, ileri prostat görüntüleme radyologlar tarafından yapılan multiparametrik prostat manyetik rezonans görüntüleme (MRG) ile gerçekleştirilmektedir. Prostatın birçok patolojisi görüntülenebilse de, asıl amaç prostat kanseri olasılığını belirlemek ve biyopsi işlemine gerek olup olmadığına karar vermektir. Bu süreçte, T2 ağırlıklı görüntüler (T2W), difüzyon ağırlıklı görüntüler (DWI) ve dinamik kontrastlı görüntüler (DCE) olmak üzere farklı seriler halinde MRG görüntülerinin analizi dahil edilmektedir. Bununla birlikte, öncelikle prostat bölgelerinin ayrıştırılması gerekmektedir. Daha sonra ilgili prostat bölgelerinde lezyon taraması yapılmaktadır. Son olarak ise prostat lezyon skorlama işleminin PI-RADS v2'ye göre yapılmasına ihtiyaç duyulmaktadır. Bu nedenle prostat kanseri tanısının konulması karışık ve uzun bir süreçtir. Bu sebeple, prostat kanseri tanısının koyulması için karar destek sistemlerine ihtiyaç duyulmaktadır. Bu bağlamda, çalışmanın başlıca amacı prostat bölgelerinin otomatik olarak segmentasyonunu sağlamaktır. Segmentasyon görevinde 15 hastaya ait T2W MRG görüntüleri ile birlikte Mask R-CNN algoritması kullanılmıştır. Mask R-CNN algoritması ResNet-50 omurga modelinin kullanımı ile birlikte 96,040 mAP50 değeri ile segmentasyon performansı elde etmiştir. Son olarak, eğitilen model PACS sistemine entegre edilmiştir. Entegrasyon sayesinde hastanelerde kullanıma hazır bir yapay zeka destekli karar destek sistemi geliştirilmiştir. Böylelikle, sağlık çalışanları üzerindeki iş yükü azaltılırken zamandan da kazanç sağlanmıştır.

Segmentation of prostate zones on a novel MRI database using Mask R-CNN: An implementation on PACS system

H I G H L I G H T S

- A novel data set was created and labelled by the radiologist
- The artificial intelligence model was integrated on the PACS system
- A ready-to-use decision support system was created for doctors

Article Info

Research Article

Received: 04.08.2022

Accepted: 02.08.2023

DOI:

10.17341/gazimmfd.1153507

Keywords:

Prostate zone segmentation,
prostate cancer,
T2W MRI,
PI-RADS v2,
deep learning

ABSTRACT

After lung cancer, prostate cancer is the most common type of cancer in men. Nowadays, advanced prostate imaging is conducted by multiparametric prostate magnetic resonance imaging (MRI) performed by radiologists. Although many pathologies of the prostate can be visualized, the main purpose is to determine the probability of prostate cancer and to decide whether a biopsy is needed. This process includes the analysis of different series of Magnetic Resonance (MR) images, including T2-weighted images (T2W), diffuse-weighted images (DWI), and dynamic contrast enhanced images (DCE). However, firstly it is necessary to differentiate the prostate zones. Then, lesion scanning is performed in the relevant prostate zones. Finally, there is a need to perform prostate lesion scoring according to PI-RADS v2. Therefore, diagnosis of prostate cancer is a complex and long process. For this reason, decision support systems are needed for the diagnosis of prostate cancer. In this context, the main purpose of the study is to provide automatic segmentation of prostate regions. In the segmentation task, Mask R-CNN algorithm was used with T2W MR images of 15 patients. With the use of the ResNet-50 backbone model, the Mask R-CNN algorithm achieved the segmentation performance with a mAP50 value of 96.040. Finally, the trained model was integrated into the PACS system. Thanks to the integration, a ready-to-use in hospitals artificial intelligence-supported decision support system was developed. Thus, time was saved while reducing the workload on health employees.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *caglar.gurkan@outlook.com, kadir.budak@akgun.com.tr, hakan.karatas@akgun.com.tr, kayihanakin@gmail.com / Tel: +90 537 977 0342

1. Giriş (Introduction)

Prostat kanseri önemli bir halk sağlığı sorunudur. Prostat kanserinin prevalansı küresel anlamda her geçen yıl artmaktadır. Erkeklerde akciğer kanserinden sonra en çok rastlanan kanser türüdür [1]. Bu bağlamda, Dünyada her altı kişiden biri prostat kanseri nedeni ile kanser taramasına girmektedir. Ek olarak teşhis koyulan her otuz altı kişiden biri prostat kanseri nedeniyle yaşamını kaybetmektedir [1, 2]. Amerika Birleşik Devletleri'nde (ABD) prostat kanseri oranı %21 ile en yüksekken Kuzey Avrupa, Kuzey Amerika, Yeni Zelanda ve Avustralya'da bu oran her 100.000 erkekte 1 ile 9 arasında değişim göstermektedir [3]. 2019 yılında ABD'de meme kanseri, akciğer kanseri, kolon ve rektum kanseri gibi farklı kanser türleri arasında 174650 yeni prostat kanseri vakası ve 31620 kanser nedeni ölüm meydana gelmiştir [4].

Prostat kanseri yüksek derecede riskli olmasına rağmen ayırt edici çeşitli belirtileri var olsa da prostat kanserinin temel etken sebebi bilinmemektedir [5-7]. Prostat kanseri riskini artıran başlıca faktörler: (i) ailede prostat kanseri geçmişinin bulunması, (ii) genetik etmenler, (iii) etnik faktörler, (iv) kilolu olma durumu ve obezite olarak işaret edilmiştir [8-10]. Bu faktörler göz önünde bulundurulduğunda, prostat kanseri riski taşıyan bireylere yeşil sebze, balık, E vitamini ve minarel içeriği yüksek besinleri tüketmeleri önerilmesine ek olarak düzenli egzersiz yapmaları tavsiye edilmektedir [11]. Prostat kanserinin erken tanısı sadece belirtilen risk faktörleri ile ilişkilendirilememektedir. Bu sebeple kanser taramasının yapılması erken teşhis açısından oldukça önemlidir. Böylelikle erken aşamada gerekli önlemler alınabilir ve uygun tedavi yöntemi uygulanabilir.

Prostat kanseri teşhisinde kullanılan kanser taraması görüntüleme yöntemleri; Transrektal Ultrasonografi (TRUS), Bilgisayarlı Tomografi (BT) ve Manyetik Rezonans Görüntüleme (MRG) şeklindedir. Prostat kanseri tanısında sıklıkla MRG kullanılmakta olup multiparametrik MRG (mpMRG) önem arz etmektedir. mpMRG değerlendirme tekniğinde T2 ağırlıklı görüntüler (T2W), difüzyon ağırlıklı görüntüler (DWI), dinamik kontrastlı görüntüler (DCE) ve perfüzyon görüntüler başta olmak üzere farklı görüntüleme paketleri yer almaktadır. T2W, DWI, DCE ve perfüzyon ağırlıklı görüntülerin birlikte değerlendirilmesi prostat kanserinin tanısında umut verici sonuçların elde edilmesini sağlamaktadır [12, 13].

Prostat, McNeal tarafından tanımlanan Tranzisyonel, Periferik, Santral, Anterior Fibromusküler Stroma bölgelerinin oluşmaktadır [14]. Prostat kanserinin tanısında standardizasyonun sağlanması amacıyla Prostata Imaging - Reporting and Data System version 2 (PI-RADS v2) skorlama yöntemi geliştirilmiştir [15]. PI-RADS v2'de Tranzisyonel Bölge (TB) ve Periferik Bölge (PB) içerisinde lezyonun olup olmadığına bakılarak bir skorlama yöntemi tasarlanmıştır. TB ve PB için PI-RADS v2'de 1 ile 5 arasında bir skorlama işaret edilmiştir. PI-RADS v2 skorları ile ilgili detaylar aşağıda verilirken skorlama metodolojisine ait detaylar Tablo 1 ve 2'de sunulmuştur. PI-RADS 1, klinik olarak anlamlı kanser olma ihtimali çok düşüktür. PI-RADS 2, klinik olarak anlamlı kanser olma ihtimali düşüktür. PI-RADS 3, klinik olarak anlamlı kanser olma ihtimali ile olmama ihtimali neredeyse eşittir. PI-RADS 4, klinik olarak anlamlı kanser olma ihtimali yüksektir. PI-RADS 5, klinik olarak anlamlı kanser olma ihtimali çok yüksektir. Sonuç olarak, prostat kanserinin tanısında öncelikli olarak TB ve PB'nin ayrılması gerekmektedir. Bu işlemden sıklıkla T2W görüntüler kullanılmaktadır. Bölgelere ayırma işlemi tamamlandıktan sonra PI-RADS skorlaması yapılmaktadır. PI-RADS skorlamasında ise TB için öncelikli olarak T2W'in incelenmesi gerekirken PB için öncelikli olarak DWI'nin incelenmesi gerekmektedir.

Yukarıda belirtildiği üzere prostat kanseri tanısının konulabilmesi için farklı görüntü formatlarının analizine ve karşılaştırılmasına ihtiyaç

duyulmaktadır. Bu nedenle tanı süreci oldukça uzun ve karmaşıktır. Sonuç olarak karar destek mekanizmalarına ihtiyaç duyulmaktadır. Bu yüzden medikal görüntüleme teknikleri günden güne gelişmekte ve değer kazanmaktadır. Medikal görüntüleme teknikleri ultrason, BT, MRG, pozitron emisyon tomografisi (PET), retinal fotoğraflama, histolojik slaytlar ve dermatolojik görüntüleme örnek verilebilir. Bu görüntüleme teknikleri ile elde edilen sonuçlar probleme özgüdür. Sonuçlar radyologlar tarafından incelenmektedir. Bu durum radyologlar üzerindeki iş yükünü artırmasına ek olarak zaman açısından kayıplara neden olmaktadır. Son zamanlarda medikal görüntüleme teknikleri bilgisayar destekli tanı (BDT) sistemleri ile desteklenmektedir. BDT sistemleri söz konusu olduğunda günümüzde karşımıza çıkan teknoloji bilgisayarlı görüdür. Bilgisayarlı görüde ultrason [16], BT [17], MRG [18] ve X-Ray [19] gibi farklı görüntüleme modaliteleri kullanılmaktadır. Bu görüntüleme modalitelerine bilgisayarlı görü teknolojisinin dahil edildiği çalışmalar, sınıflandırma [20], hastalık tespit etme [21], görüntü eşleştirme [22] ve segmentasyon [23] şeklindedir.

Bu çalışmada, prostat bölgelerinin segmentasyonuna yönelik araştırmalar yürütülmüştür. Proje kapsamında yeni bir prostat MRI veri tabanı oluşturulmuştur. MRI veri tabanı serileri içerisinde yer alan T2W görseller alanında uzman radyolog tarafından prostat bölgeleri göz önünde bulundurularak işaretlenmiştir. Sonrasında, segmentasyon görevlerinde sıklıkla kullanılan bir derin öğrenme algoritması olan Mask R-CNN çalışmaya dahil edilmiştir. Mask R-CNN algoritması iki ana bölüme ayrılırken bunlardan birinci bölüm özellik çıkarımında kullanılan FPN+ResNeXt-101-32x8d omurga modeliyken diğer bölüm maske ve sınırlayıcı kutu tahminlenmesinde kullanılan klasik konvolüsyon ve tam bağlantı katmanlarıdır. Eğitilen Mask R-CNN modeli hem veri seti içinde hem de veri seti dışından test edilmiştir. Bu test aşamalarının takibinde nihai Mask R-CNN modeli Picture Archiving and Communication System (PACS) sistemine adapte edilmiştir. Sonuç olarak, hastanelerde kullanıma hazır prostate bölgelerinin segmentasyonunu sağlayan bir yapay zeka tanı sistemi uygulaması oluşturulmuştur.

Bu çalışmanın başlıca katkıları şunlardır:

- Yeni bir veri seti oluşturuldu ve radyolog tarafından etiketlendi.
- Özellik çıkarımı için farklı omurga ağ yapıları kullanılmış ve en iyi sonucu elde eden ağ sunulmuştur.
- Prostat bölgelerinin segmentasyonuna ait sonuçlar, aksiyal T2W MR görüntülerinde mevcut literatürden farklı olarak Mask R-CNN kullanılarak elde edildi.
- Eğitilen ve test edilen yapay zeka modeli hastanelerde kullanıma hazır şekilde PACS sistemi üzerine entegre edilmiştir.

Çalışmanın kalan bölümleri şu şekilde organize edilmiştir; 2. bölümde literatürdeki prostat bölgelerinin segmentasyonu üzerine yapılan çalışmalar incelenmiştir. 3. bölümde çalışma kapsamında oluşturulan yeni veri setinin özellikleri aktarılmıştır. Buna ek olarak çalışmada kullanılan segmentasyon algoritması sunulmuştur. Performans değerlendirme kullanılan metriklere değinilmiştir. Son olarak ise kullanılan yazılım ve donanım bilgileri aktarılmıştır. 4. bölümde kullanılan segmentasyon algoritması ile elde edilen sonuçlar aktarılmış, yorumlanmış ve literatürdeki mevcut çalışmalar ile karşılaştırılmıştır. 5. bölümde geliştirilen yapay zeka modelinin PACS sistemine entegrasyonu ile ilgili yürütülen çalışmalar aktarılmıştır. 6. bölümde çalışma hakkındaki son bilgiler sunulmuştur.

2. İlgili Çalışmalar (Related Works)

Bu bölümde, prostat alanlarının segmentasyonu ile ilgili literatürdeki başlıca çalışmalar sunulmuştur.

Cuocolo vd. [24] açık kaynak bir veri seti olan ProstateX veri setini kullanarak çalışmalarını yürütmüşlerdir. Bu veri setinde toplam 204 hastaya ait MR görüntüleri yer almaktadır. Bu çalışmada, 2 boyutlu

Tablo 1. Tranzisyonel bölge için PI-RADS (PI-RADS for transitional zone)

T2W	DWI	DCE	PI-RADS
1	Herhangi biri	Herhangi biri	1
2	≤ 3	Herhangi biri	2
	≥ 4	Herhangi biri	3
3	≤ 4	Herhangi biri	3
	5	Herhangi biri	4
4	Herhangi biri	Herhangi biri	4
5	Herhangi biri	Herhangi biri	5

* Herhangi biri 1-5 arasını işaret etmektedir.

Tablo 2. Periferik bölge için PI-RADS (PI-RADS for peripheral zone)

DWI	T2W	DCE	PI-RADS
1	Herhangi biri	Herhangi biri	1
2	Herhangi biri	Herhangi biri	2
3	Herhangi biri	-	3
		+	4
4	Herhangi biri	Herhangi biri	4
5	Herhangi biri	Herhangi biri	5

* Herhangi biri 1-5 arasını işaret etmektedir.

konvolüsyonları için ENet, ERFNet ve UNet modellerinin segmentasyon performansları karşılaştırılmıştır. En iyi segmentasyon performansını ENet modeli elde etmiştir. ENet modeli ile TB segmentasyonunda %87 dice skoru elde edilirken, PB segmentasyonunda ise %71 dice skoru elde edilmiştir. Duran vd. [25] ProstateX veri setini kullanarak çalışmalarını yürütmüşlerdir. Araştırmacılar ProstAttention-Net adını verdikleri bir model geliştirmişler ve bu modelin performansını UNet, ENet ve DeepLabv3+ gibi bilindik modellerin performansını ile karşılaştırmışlardır. Sonuç olarak ProstAttention-Net en iyi performansı elde etmiştir. ProstAttention-Net'in TB ve PB için elde ettiği ortalama dice skoru %87,5 şeklindedir. Mooij vd. [26] 53 hastaya ait T2W görüntüleri içeren açık kaynak bir veri setini kullanarak çalışmalarını yürütmüşlerdir. Çalışmada segmentasyon görevinde 3B yaklaşımlar kullanılmıştır. Araştırmacılar aniso-3DUNET ve iso-3DUNET adını verdikleri modelleri kullanmışlardır. aniso-3DUNET modeli daha iyi performans göstermiştir. TB ve PB için sırasıyla elde ettiği dice skorları %85 ve %60 şeklindedir. Aldoij vd. [27] 188 hastaya ait MR görüntüsünün yer aldığı bir veri setini kullanarak çalışmalarını yürütmüşlerdir. Bu veri setindeki T2W görüntüleri çalışmalarına dahil etmişlerdir. Veri setinde yer alan 141 hastayı eğitim için kullanırlarken 47 hastayı eğitilen modeli test etmek için kullanmışlardır. Araştırmacılar Dense-2-U-net adını verdikleri modeli geliştirmişler ve bu modelin performansını U-net ile karşılaştırmışlardır. Sonuç olarak Dense-2-U-net daha iyi performans göstermiştir. Dense-2-U-net'in TB ve PB için sırasıyla elde ettiği dice skorları %89,5 ve %78,1 şeklindedir. van Sloun vd. [28] 78 hastaya ait MR görüntüsünün yer aldığı bir veri setini kullanarak çalışmalarını yürütmüşlerdir. Veri setinde yer alan 54 hastayı eğitim için kullanırlarken 24 hastayı eğitilen modeli test etmek için kullanmışlardır. Araştırmacılar tam evrişim ağı (FCN) tabanlı yeni bir segmentasyon ağı önermişlerdir. Bu ağı TB ve PB için sırasıyla elde ettiği IoU skorları %96 ve %80 şeklindedir. Liu vd. [29] ProstateX veri setini kullanarak çalışmalarını yürütmüşlerdir. Araştırmacılar FCN tabanlı yeni bir segmentasyon ağı önermişlerdir. Önerilen ağda, omurga model olarak ResNet-50 ağı revize edilerek kullanılırken özellik piramit ağı (FPN) da segmentasyon ağına dahil edilmiştir. Önerilen ağı TB ve PB için elde ettiği dice skorları sırasıyla %92 ve %81 şeklindedir. Bardis vd. [30] 242 hastaya ait MR görüntüsünün yer aldığı bir veri setini kullanarak çalışmalarını yürütmüşlerdir. Çalışmada T2W görüntüler modelin eğitiminde kullanılmıştır. Üç tane U-Net modeli birbirine bağlanarak özellik haritası çıkarılmış ve segmentasyon görevi tamamlanmıştır. Modelin, TB ve PB için elde

ettiği dice skorları sırasıyla %91 ve %77,4 şeklindedir. Meyer vd. [31] açık kaynak bir veri seti olan SPIE-AAPM-NCI PROSTATEX veri setini kullanarak çalışmalarını yürütmüşlerdir. Bu veri setinde toplam 92 hastaya ait T2W MR görüntüleri yer almaktadır. Çalışmada segmentasyon görevinde 3B yaklaşımlar kullanılmıştır. Araştırmacılar 3D U-NET modelini segmentasyon görevinde kullanmışlardır. Modelin, TB ve PB için elde ettiği dice skorları sırasıyla %87,6 ve %79,8 şeklindedir. Rundo vd. [32] açık kaynaktan üç farklı veri setini (i) Cannizzaro Hospital, Catania Italy, (ii) Initiative for Collaborative Computer Vision Benchmarking (I2CVB), (iii) National Cancer Institute – International Symposium on Biomedical Imaging (NCI-ISBI) kullanarak çalışmalarını yürütmüşlerdir. İlk veri setinde 21 hastaya, ikinci veri setinde 19 hastaya ve üçüncü veri setinde 40 hastaya ait MR görüntüleri yer almaktadır. Bu üç veri seti çalışmada, teklili olarak ve karıştırılarak segmentasyon görevinde kullanılmıştır. Araştırmacılar USE-Net adını verdikleri modeli geliştirmişlerdir ve bu modelin performansını U-Net, pix2pix ve MixedScale Dense Network ile karşılaştırmışlardır. Geliştirilen bu model Squeeze-and-Excitation (SE) bloklarının klasik U-Net'e dahil edilmesiyle oluşturulmuştur. Sonuç olarak, USE-Net daha iyi performans göstermiştir. Kodlayıcı ve kod çözücü bölümlerinde SE bloklarının kullanıldığı USE-Net modeli üçüncü veri seti üzerinde en iyi performansı elde ederken, TB ve PB için elde ettiği dice skorları sırasıyla %93,7 ve %80,1 şeklindedir. Montagne vd. [33] 40 hastaya ait MR görüntüsünün yer aldığı bir veri setini kullanarak çalışmalarını yürütmüşlerdir. Çalışmada T2W görüntüler modelin eğitiminde kullanılmıştır. Araştırmacılar segmentasyon görevinde U-Net modelini kullanmışlardır. Modelin, TB ve prostatın tamamı (PB+TB) için elde ettiği dice skorları sırasıyla %91 ve %94 şeklindedir. Rouvière vd. [34] NCI-ISBI açık kaynak veri setini kullanarak çalışmalarını yürütmüşlerdir. Bu veri setinde 70 hastaya ait MR görüntüleri yer almaktadır. Çalışmada segmentasyon görevinde 3B yaklaşımlar kullanılmıştır. Araştırmacılar segmentasyon görevinde derin sinir ağlarını (DSA) kullanmışlardır. Modelin, TB ve prostatın tamamı (PB+TB) için elde ettiği dice skorları sırasıyla %91,8 ve %96,4 şeklindedir. Zhu vd. [35] 163 hastaya ait MR görüntüsünün yer aldığı bir veri setini kullanarak çalışmalarını yürütmüşlerdir. Çalışmada T2W görüntüler modelin eğitiminde kullanılmıştır. Araştırmacılar segmentasyon görevinde kademeli olarak U-Net modelini kullanmışlardır. Modelin, PB ve prostatın tamamı (PB+TB) için elde ettiği dice skorları sırasıyla %79,3 ve %92,7 şeklindedir. Khan vd. [36] açık kaynaktan iki farklı veri setini (i) UKMMC, (ii) NCI-ISBI kullanarak çalışmalarını yürütmüşlerdir.

İlk veri setinde 40 hastaya ve ikinci veri setinde 11 hastaya ait MR görüntüleri yer almaktadır. Çalışmada T2W görüntüler modelin eğitiminde kullanılmıştır. Bu görüntüler üzerinde filtreleme gibi görüntü işleme yöntemleri, yeniden boyutlandırma, kırma işlemi, normalizasyon, veri çoğaltma ve yama-tabanlı analiz olmak üzere çeşitli ön işleme yöntemleri kullanılmıştır. Araştırmacılar segmentasyon görevinde FCN, SegNet, U-Net ve DeepLabV3+ modellerini kullanmışlardır. UKMMC veri setinde yama tabanlı analiz olmaksızın prostatın tamamı (PB+TB) için en iyi dice skoru U-Net modeli ile %85 olarak elde edilirken, yama tabanlı analizde prostatın tamamı (PB+TB) için en iyi dice skoru DeepLabV3+ modeli ile %91,9 olarak elde edilmiştir. NCI-ISBI veri setinde yama tabanlı analiz olmaksızın TB ve prostatın tamamı (PB+TB) için en iyi dice skorları sırasıyla DeepLabV3+ modeli ile %76,4 ve %90,7 olarak elde edilirken, yama tabanlı analizde TB ve prostatın tamamı (PB+TB) için en iyi dice skorları sırasıyla DeepLabV3+ modeli ile %78,9 ve %92,8 olarak elde edilmiştir. Sunoqrot vd. [37] 244 hastaya ait MR görüntüsünün yer aldığı bir veri setini kullanarak çalışmalarını yürütmüşlerdir. Çalışmada T2W görüntüler modelin eğitiminde kullanılmıştır. Araştırmacılar segmentasyon görevinde V-Net, nnU-Net-2D ve nnU-Net-3D modellerini kullanmışlardır. En iyi segmentasyon performansını nnU-Net-3D göstermiştir. nnU-Net-3D'in elde ettiği dice skoru sonuçları PB, PB olmayan bölge ve prostatın tamamı (PB+PB olmayan) için sırasıyla %82,5, %91,6 ve %94,0 şeklindedir. Qin vd. [38] açık kaynaktan iki farklı veri setini (i) PROMM, (ii) NCI-ISBI kullanarak çalışmalarını yürütmüşlerdir. İlk veri setinde 202 hastaya ve ikinci veri setinde 60 hastaya ait MR görüntüleri yer almaktadır. Çalışmada T2W görüntüler modelin eğitiminde kullanılmıştır. Araştırmacılar segmentasyon görevinde U-Net modelini geliştirerek ResNet, piramit dikkat ve residual arıtma bloklarını eklemişlerdir. Modelin PROMM veri setinde TB ve PB için elde ettiği dice skorları sırasıyla %89,6 ve %77,1 şeklindedir. Modelin NCI-ISBI veri setinde TB ve PB için elde ettiği dice skorları sırasıyla %88,9 ve %79,9 şeklindedir.

3. Materyal ve Yöntem (Material and Method)

Bu bölüm, veri seti ve veri ön işleme, segmentasyon algoritması ve performans değerlendirme metrikleri olmak üzere üç alt başlıktan oluşmaktadır.

Şekil 1, çalışmada kullanılan metodolojiyi aktarmaktadır. Bu bağlamda, öncelikle prostat bölgelerinin segmentasyonu için görsel

veri seti oluşturulmuştur. Sonrasında görsellerin 16 bitten 8 bite dönüştürülmesi, 2D kesitlerin elde edilmesi, N4 Bias Field Correction ve min-max normalizasyon gibi ön işleme yöntemleri kullanılmıştır. Veri seti ve veri ön işleme ile ilgili bilgiler Bölüm 3.1'de aktarılmıştır. Veri seti üzerindeki işlemler sona erdikten sonra Mask R-CNN ağının eğitimi aşamasına geçilmiştir. Modelin eğitiminden sonra model test edilmiş, sonuçlar elde edilmiş ve görselleştirilmiştir. Model ile ilgili detaylar Bölüm 3.2'de sunulmuştur. Elde edilen sonuçlar ise detaylı bir şekilde Bölüm 4'de gösterilmiştir.

3.1. Veri seti ve Veri Ön İşleme (Data set and data preprocessing)

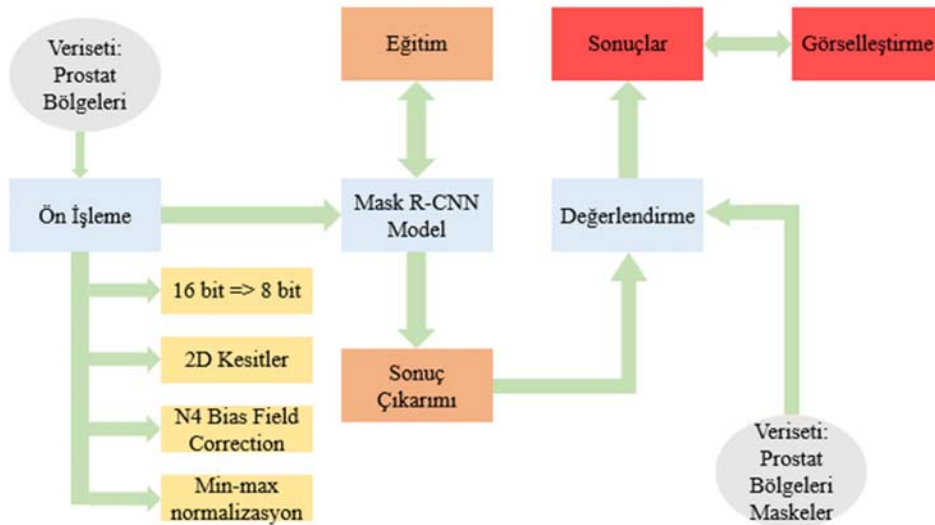
Çalışmada 15 hastanın prostat MR görüntüleri incelenmiştir. 16 bitlik MR görüntüleri, 512 x 512 piksel boyutunda kayıpsız olarak 8 bitlik gri görüntü kesitlerine ayrılmıştır. Bu işlem sırasında yeniden örnekleme parametreleri 0,46*0,46*4 mm olarak ayarlanmıştır. Ardından özellikle eski nesil cihazlarda MRI görüntüsünü bozan düşük frekanslı bir sinyal olan bias alan sinyalinin etkisinin azaltılması için N4 Bias Field Correction algoritması kullanılmıştır. Normalizasyon tekniği min-max olarak tercih edilmiştir. Sonuç olarak COCO Annotator etiketleme aracı kullanılarak toplam 204 görsel etiketlenmiştir. Bu görsellerin %90'ı eğitim sürecinde, %10'u ise eğitilen modelin test edilmesi sürecinde kullanılmıştır. Kullanılan veri setinde yer alan 2 adet örnek görüntü ve bu görüntülere ait prostat bölgelerini gösteren maskeler Şekil 2'de gösterilmiştir.

3.2. Segmentasyon Algoritması (Segmentation Algorithm)

Bu bölüm, evrişimsel sinir ağları, özellik çıkarımı algoritması, omurga model seçilimi ve Mask R-CNN olmak üzere dört alt başlıktan oluşmaktadır.


3.2.1. Evrişimsel sinir ağları (Convolutional neural networks)

Evrişimli sinir ağları (ESA); konvolüsyon, havuzlama, toplu normalleştirme, düzleştirme, seyreltme ve tam bağlantı olmak üzere çeşitli katmanlardan oluşmaktadır. Klasik bir ESA tasarımının en önemli katmanı konvolüsyon katmanlarıdır. Konvolüsyon katmanları girdi görüntüleri üzerinden özellik çıkarımını gerçekleştirir. Havuzlama katmanı, konvolüsyon katmanından sonra en sık kullanılan diğer bir ESA katmanıdır. Havuzlama katmanlarının ESA mimari tasarımlarında kullanılmasının en önemli nedenleri, girdi görüntüsü boyutunu küçültürken model tarafından incelenen parametre



Şekil 1. Deneysel prosedüre ait blok diyagram (Block diagram of experimental procedure)

sayısını azaltmak, modelin eğitimi esnasındaki hesaplamaları daha hızlı yapmak ve girdi görsellerinden elde edilen özelliklerin en alakalıları kullanarak aşırı öğrenmeyi engellemek olarak açıklanabilir. Modelin eğitimi esnasındaki yakınsamayı azaltmak amacı ile ise toplu normalleştirme katmanları kullanılmaktadır. ESA mimari tasarımlarının son katmanı olan tam bağlantı veya yoğun katman olarak isimlendirilen katmanlardan önceki son katman düzleştirme katmanıdır. Bu katman kendisinden önce kullanılan katmanlar aracılığı ile elde edilen özellik matrisini tek bir sütunda matrise dönüştürmektedir. Tam bağlantı katmanları klasik bir sinir ağıdır ve sınıflandırma işlemini kendisinden önceki katmanlardan elde edilen özellik matrisini kullanarak gerçekleştirmektedir [39].



*Yeşil: Transizyonel Bölge, Mor: Periferik Bölge

Şekil 2. (a) Kullanılan veri setine ait örnek görsel, (b) bu görsele ait maske, (c) kullanılan veri setine ait diğer bir örnek görsel, (d) bu görsele ait maske ((a) Sample image of the belonging to used data set, (b) mask of this image, (c) another sample image of the belonging to used data set, (d) mask of this image)

3.2.2. Özellik çıkarımı algoritması (Feature extraction algorithm)

FPN, doğruluk ve hız göz önünde bulundurularak tasarlanmış bir özellik çıkarıcıdır. Ek olarak FPN'ler modelin eğitim ve tahmin


süresini kısaltmasına ek olarak başarı oranını da artırmaktadır. Bu bağlamda, nesne algılama ve segmentasyon problemlerinde kullanılan klasik özellik çıkarıcıların yerine almıştır. FPN, yüksek kaliteli bilgileri içeren çoklu özellik haritasından başka bir deyişle çok ölçekli özellik haritalarından oluşur. FPN ait genel yapı Şekil 3'de gösterilmiştir.

FPN mekanizması aşağıdan yukarı ve yukarıdan aşağı olmak üzere iki yoldan oluşmaktadır. Bu yapı Şekil 4'de gösterilmiştir.

- FPN'lerde aşağıdan yukarıya doğru olan yol, özellik çıkarımı işlemini gerçekleştiren klasik bir evrimsel bir sinir ağıdır. FPN'lerde yapıda yukarı çıkıldıkça görsellerin uzaysal çözünürlüğü azalırken anlamsal değerlerin kalitesi artar. Bu bağlamda, daha yüksek anlamsal değere sahip olan yapılar tespit edildiğinde, ilgili her katmanın anlamsal değeri artar.
- FPN'lerde yukarıdan aşağıya doğru olan yol, anlamsal açıdan zengin bir katmandan daha yüksek çözünürlüklü katmanlar oluşturmak için kullanılır. Oluşturulan yeni katmanlar anlamsal açıdan güçlüyken, tüm alt ve üst örneklemelerden sonraki nesnelere konum bilgileri kesin değildir. Tahmin edici algoritmanın konum bilgisini daha iyi tahmin etmesini sağlamak amacıyla yeniden yapılandırılmış katmanlar ve karşılık gelen özellik haritaları arasında yanıl bağlantılar eklenmektedir. Sonuç olarak elde edilen form, eğitimi kolaylaştıran bağlantıların atlama işlevi kazandığı bir sistemi oluşturmaktadır. Bu eklentiler ile birlikte genel yapı ResNet'e benzer bir form kazanmaktadır. Bu yapı Şekil 3'de gösterilmiştir.

3.2.3. Omurga model seçilimi (Backbone model selection)

Omurga model seçilimi aşamasında Detectron2 derin öğrenme yazılım çerçevesinden faydalanılmıştır [40]. Omurga modellere ait bilgiler Tablo 3'de gösterilmiştir. R50 ResNet-50 modelini, R101 ResNet-101 modelini, X-101-32x8d ise ResNeXt-101-32x8d modelini belirtmektedir. FPN, maske ve sınırlayıcı kutu tahmini için sırasıyla standart konvolüsyon ve tam bağlantı katmanlarına sahip bir ResNet ve FPN birleşik omurgasını kullanmaktadır. C4, ResNet'e ait dördüncü konvolüsyon katmanına kadar dondurma işlemini gerçekleştirmektedir ve beşinci konvolüsyon katmanından itibaren ince ayar yaparak ağırlıkları kullanmaktadır. DC5, maske ve sınırlayıcı kutu tahmini için sırasıyla standart konvolüsyon ve tam bağlantı katmanlarına sahip bir ResNet mimarisini kullanmaktadır. Fakat, ResNet'e ait dördüncü konvolüsyon katmanına kadar dondurma işlemini gerçekleştirmektedir ve beşinci konvolüsyon katmanında dilate konvolüsyon ile ince ayar yaparak ağırlıkları kullanmaktadır. Öğrenme oranı 3x ve 1x olan modeller sırası ile yaklaşık olarak 37 ve 12 COCO epoğuna karşılık gelmektedir. Öğrenme oranı 3x olan modeller 1x olan modellere göre daha fazla eğitilmiş modellerdir.



Şekil 3. FPN çalışma mekanizması (FPN working mechanism)

R50-C4 modeli için öğrenme oranı 1x, sn/iterasyon olmak üzere eğitim süresi 0,584, sn/görsel olmak üzere sonuç çıkarımı süresi 0,110, eğitim belleği 5,2 GB, sınırlayıcı kutular için AP değeri 36,8 ve maske tahmini için AP değeri 32,2 olarak elde edilmiştir. R50-DC5 modeli için öğrenme oranı 1x, sn/iterasyon olmak üzere eğitim süresi 0,471, sn/görsel olmak üzere sonuç çıkarımı süresi 0,076, eğitim belleği 6,5 GB, sınırlayıcı kutular için AP değeri 38,3 ve maske tahmini için AP değeri 34,2 olarak elde edilmiştir. R50-FPN modeli için öğrenme oranı 1x, sn/iterasyon olmak üzere eğitim süresi 0,261, sn/görsel olmak üzere sonuç çıkarımı süresi 0,043, eğitim belleği 3,4 GB, sınırlayıcı kutular için AP değeri 38,6 ve maske tahmini için AP değeri 35,2 olarak elde edilmiştir. R50-C4 modeli için öğrenme oranı 3x, sn/iterasyon olmak üzere eğitim süresi 0,575, sn/görsel olmak üzere sonuç çıkarımı süresi 0,111, eğitim belleği 5,2 GB, sınırlayıcı kutular için AP değeri 39,8 ve maske tahmini için AP değeri 34,4 olarak elde edilmiştir. R50-DC5 modeli için öğrenme oranı 3x, sn/iterasyon olmak üzere eğitim süresi 0,470, sn/görsel olmak üzere sonuç çıkarımı süresi 0,076, eğitim belleği 6,5 GB, sınırlayıcı kutular için AP değeri 40,0 ve maske tahmini için AP değeri 35,9 olarak elde edilmiştir. R50-FPN modeli için öğrenme oranı 3x, sn/iterasyon olmak üzere eğitim süresi 0,261, sn/görsel olmak üzere sonuç çıkarımı süresi 0,043, eğitim belleği 3,4 GB, sınırlayıcı kutular için AP değeri 41,0 ve maske tahmini için AP değeri 37,2 olarak elde edilmiştir. R101-C4 modeli için öğrenme oranı 1x, sn/iterasyon olmak üzere eğitim süresi 0,652, sn/görsel olmak üzere sonuç çıkarımı süresi 0,145, eğitim belleği 6,3 GB, sınırlayıcı kutular için AP değeri 42,6 ve maske tahmini için AP değeri 36,7 olarak elde edilmiştir. R101-DC5 modeli için öğrenme oranı 3x, sn/iterasyon olmak üzere eğitim süresi 0,545, sn/görsel olmak üzere sonuç çıkarımı süresi 0,092, eğitim belleği 7,6 GB, sınırlayıcı kutular için AP değeri 41,9 ve maske tahmini için AP değeri 37,3 olarak elde edilmiştir. R101-FPN modeli için öğrenme oranı 3x, sn/iterasyon olmak üzere eğitim süresi 0,340, sn/görsel olmak üzere sonuç çıkarımı süresi 0,056, eğitim belleği 4,6 GB, sınırlayıcı kutular için AP değeri 42,9 ve maske tahmini için AP değeri 38,6 olarak elde edilmiştir. X101-FPN modeli için öğrenme oranı 3x, sn/iterasyon olmak üzere eğitim süresi 0,690, sn/görsel


olmak üzere sonuç çıkarımı süresi 0,103, eğitim belleği 7,2 GB, sınırlayıcı kutular için AP değeri 44,3 ve maske tahmini için AP değeri 39,5 olarak elde edilmiştir. Yukarıda sunulan bilgiler COCO veri setine ait olup bu bilgiler ışığında çalışmalar yürütülmüştür ve test çalışmaları yürütülmüştür.

Microsoft ekibi tarafından geliştirilen ResNet 2015 yılında düzenlenen ImageNet yarışmasında %3,37 hata oranı ile birinci olmuştur [41]. ResNet mimarisinin katman sayısına göre değişen ve bu katman sayısına göre isimlendirilen tasarımları bulunmaktadır. Bu tasarımlardan sıklıkla kullanılanları ise ResNet-50, ResNet-101, ResNet-152'dir. ResNet mimari tasarımı ile geçmiş katmanlardan elde edilen öznetelikler sonraki katmanlara aktarılmaktadır. ResNet mimarisinde katmanlar arasındaki geçiş Residual Block (ResBlock) kullanımı ile sağlanmaktadır [41]. ResNet-50, 16'sı ResBlock olmak üzere toplam 50 katmandan, ResNet-101 ise 33'ü ResBlock olmak üzere toplam 101 katmandan oluşmaktadır. ResNet mimari tasarımı Şekil 5a'da gösterilmiştir. Facebook ekibi tarafından geliştirilen ResNeXt 2017 yılından düzenlenen ImageNet yarışmasında birinciliği elde etmiştir [42]. Yüksek düzeyde modülerleştirilmiş bir evrişimli sinir ağı mimarisi olan ResNeXt, görüntü sınıflandırma görevlerinde sıklıkla kullanılmaktadır. ResNeXt, aynı yapıdaki birçok tekrarlanan matris dönüşümünü bir araya getirerek yeni bir matris oluşturmaktadır. Bu işlemler bölme, dönüştürme ve birleştirme olarak adlandırılmıştır. ResNeXt-101-32x8d'e ait mimari tasarım Şekil 5b'de gösterilmiştir.

3.2.4. Mask R-CNN (Mask R-CNN)

Mask R-CNN segmentasyon görevlerinde sıklıkla kullanılan bir mimari tasarımdır. Faster R-CNN'nin uzantısıdır ve iki aşaması vardır:

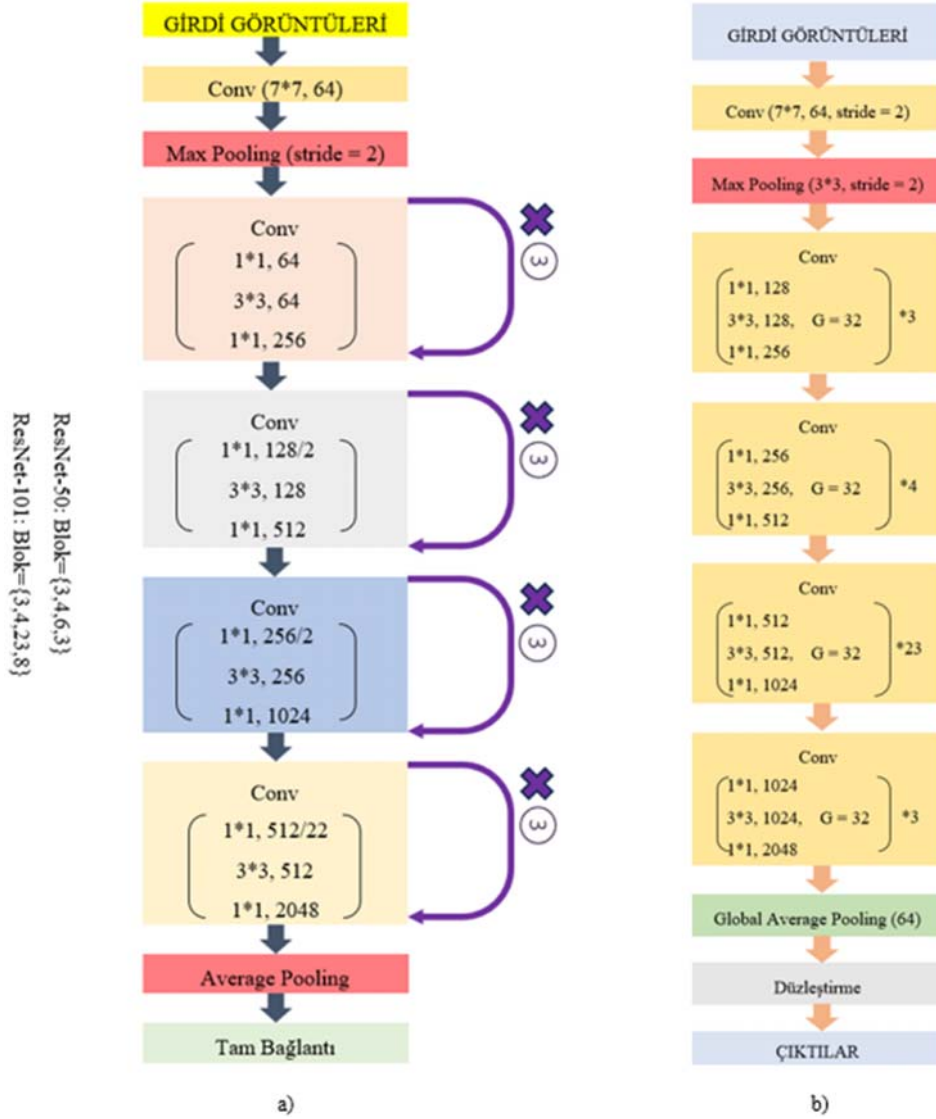
1. Giriş görüntüsünde nesnenin olabileceği alanlarla ilgili tahminler üretilir.



Şekil 4. FPN anlamsal değer ve görsel çözünürlük kıyaslaması (FPN semantic value and image resolution comparison)

Tablo 3. Model seçilimi (Model selection) [40]

Modelin İsmi	Öğrenme Oranı	Eğitim Süresi (sn/iterasyon)	Sonuç Çıkarımı Süresi (sn/görsel)	Eğitim Belleği (GB)	Sınırlayıcı Kutu (AP)	Maske Tahmini (AP)
R50-C4	1x	0,584	0,110	5,2	36,8	32,2
R50-DC5	1x	0,471	0,076	6,5	38,3	34,2
R50-FPN	1x	0,261	0,043	3,4	38,6	35,2
R50-C4	3x	0,575	0,111	5,2	39,8	34,4
R50-DC5	3x	0,470	0,076	6,5	40,0	35,9
R50-FPN	3x	0,261	0,043	3,4	41,0	37,2
R101-C4	3x	0,652	0,145	6,3	42,6	36,7
R101-DC5	3x	0,545	0,092	7,6	41,9	37,3
R101-FPN	3x	0,340	0,056	4,6	42,9	38,6
X101-FPN	3x	0,690	0,103	7,2	44,3	39,5



Şekil 5. (a) ResNet (b) ResNeXt-101-32x8d mimari tasarımları ((a) ResNet (b) ResNeXt-101-32x8d architecture designs)

2. İlgili nesnenin sınıfı tahmin edilir sonra sınırlayıcı kutular artırılır ve ilk aşamadaki tahmin göz önünde bulundurularak nesnenin piksel düzeyine göre bir maske oluşturulur.

Mask R-CNN'e ait mimari tasarım ait mimari tasarım Şekil 6'da gösterilmiştir. Giriş görüntüleri üzerinden özellik haritasının çıkarımı için farklı omurga modelleri ve nesne olabilecek yerlerin önerisi için hafif bir sinir ağı yapısı olan RPN kullanılmaktadır. Sonrasında üç alt dal ile sınıf, sınırlayıcı kutu ve maske bilgileri için tahminler üretilir. Sınıf bilgisi için görsel tabanlı sınıflandırma, maske bilgisi için piksel tabanlı sınıflandırma ve sınırlayıcı kutu bilgisi için regresyon analizleri yapılmaktadır. Sonuç olarak ise nihai çıktılar oluşturulmaktadır.

3.3. Performans Değerlendirme Metrikleri (Performance Evaluation Metrics)

Mean average precision (mAP) performans değerlendirme metriği nesne algılama ve segmentasyon problemlerinde en sık kullanılan ölçütlerden biridir. Bu nedenle, bu çalışmada kullanılan modellerin performanslarının karşılaştırılmasında da mAP tercih edilmiştir. mAP performans değerlendirme metriğine ait değerlendirme yapısı ve 1408

matematiksel arka plan aşağıda özetlenmiştir. Segmentasyon görevlerinde AP değerinin hesaplanmasında öncelikli olarak Intersection over Union (IoU) performans değerlendirme metriğinin hesaplanması gerekmektedir. IoU, tahmin edilen sınırlayıcı kutu alanı ile gerçekte olan sınırlayıcı kutu alanının kesişimi ve birleşiminin alanlarının oranıyla hesaplanmaktadır.

Ortalama Hassasiyet veya mAP skoru, mevcut farklı algılama zorluklarına bağlı olarak tüm sınıflar ve/veya genel IoU eşikleri üzerinden ortalama AP alınarak hesaplanır.

True Positive (TP): IoU değeri 0,5'ten büyükse bu bölümde değerlendirilir.

False Positive (FP): IoU değeri 0,5'ten küçükse veya sınırlayıcı kutular ikilendiyse bu bölümde değerlendirilir.

False Negative (FN): Herhangi bir nesne tespit edilmediyse veya IoU değeri 0,5'ten büyükken sınıfı yanlış ise bu bölümde değerlendirilir.

Bu TP, FP ve FN parametrelerinin kullanımı ile Keskinlik ve Duyarlılık parametreleri hesaplanmaktadır. Bu parametrelere ait formüller Eş. 1 ve Eş. 2'de gösterilmiştir.

$$\text{Kesinlik} = \text{TP} / (\text{TP} + \text{FP}) \quad (1)$$

$$\text{Duyarlılık} = \text{TP} / (\text{TP} + \text{FN}) \quad (2)$$

Bu çalışmada IoU eşik değeri 0,5 olarak alınmıştır. Bu bağlamda performans değerlendirmesinde mAP50 değeri referans alınmıştır.

4. Deneysel Analizler ve Tartışma (Experimental Analysis and Discussion)

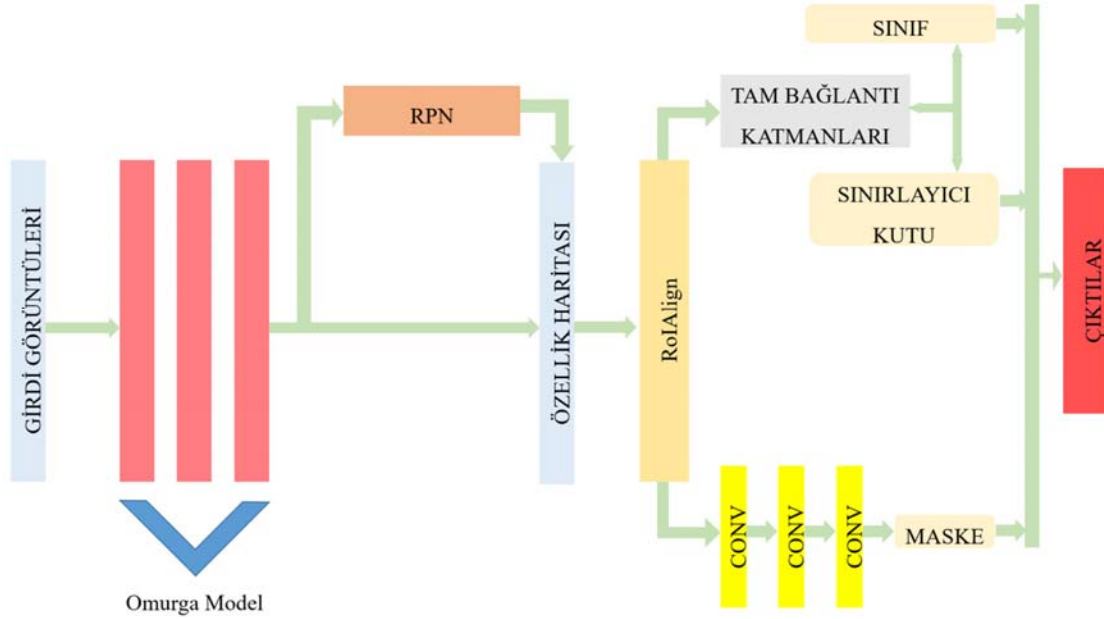
Deneysel çalışmalarda kullanılan yazılım ve donanım bilgisi aşağıdaki gibidir;

Spyder Tümeleşik Geliştirme Ortamı (IDE) üzerinde Python programlama dilinde eğitim ve testler gerçekleştirilmiştir. Segmentasyon ağı, PyTorch ve Detectron2 derin öğrenme yazılım çerçeveleri kullanılarak geliştirilmiştir. SimpleITK kütüphanesi görüntülerin ön işlenmesi aşamasında kullanılmıştır. Ayrıca OpenCV ve Matplotlib kütüphanesi kullanılarak şekiller oluşturulmuştur. Deneysel çalışmalar 16 GB RAM'e sahip Intel(R) Core(TM) i7-6700 @ 3.40 GHz ve 12 GB belleğe sahip NVIDIA GeForce RTX 3060, CUDA 11.5 sürümü üzerinde gerçekleştirilmiştir. Ayrıca eğitim ve test sürecinde CuDNN hızlandırma mekanizması kullanılmıştır.

Deneysel çalışmalarda kullanılan hiperparametrelere ek olarak modelin eğitim ve test aşamalarına ait detaylar aşağıdaki gibidir;

Kayıp fonksiyonu olarak Cross Entropy, Çapraz Düzensizlik kullanılmıştır. Optimizasyon algoritması olarak Stochastic Gradient Descent (SGD), Olasılıksal Dereceli Azalma tercih edilmiştir. Ayrıca modelin eğitiminde 0,9 eşik değeri ile birlikte Nesterov Momentum kullanılmıştır. Küme boyutu 4 olarak seçilirken model 3000 epok boyunca eğitilmiştir. İlk öğrenme oranı 1e-3 olarak set edilirken, 1500. epokta 1e-4, 2400. epokta ise 1e-5 olarak güncellenmiştir.

Tablo 4, Mask R-CNN ile elde edilen sonuçları göstermektedir. Öğrenme oranı 1x olan R50-C4 modeli, 81,645 mAP50 değerini 10,54 dakika (min) eğitim süresinde elde etmiştir. Öğrenme oranı 1x olan R50-DC5 modeli, 89,810 mAP50 değerini 16,28 min eğitim süresinde elde etmiştir. Öğrenme oranı 1x olan R50-FPN modeli, 95,512 mAP50 değerini 13,49 min eğitim süresinde elde etmiştir. Öğrenme oranı 3x olan R50-C4 modeli, 91,775 mAP50 değerini 11,31 min eğitim süresinde elde etmiştir. Öğrenme oranı 3x olan R50-DC5 modeli, 96,040 mAP50 değerini 16,31 min eğitim süresinde elde etmiştir. Öğrenme oranı 3x olan R50-FPN modeli, 94,992 mAP50 değerini 13,12 min eğitim süresinde elde etmiştir. Öğrenme oranı 3x olan R101-C4 modeli, 92,079 mAP50 değerini 15,30 min eğitim süresinde elde etmiştir. Öğrenme oranı 3x olan R101-DC5 modeli, 92,079 mAP50 değerini 23,02 min eğitim süresinde elde etmiştir. Öğrenme oranı 3x olan R101-FPN modeli, 91,470 mAP50 değerini 19,46 min eğitim süresinde elde etmiştir. Öğrenme oranı 3x olan X101-FPN modeli, 96,040 mAP50 değerini 32,32 min eğitim süresinde elde etmiştir.



Şekil 6. Mask R-CNN mimari tasarımı (Mask R-CNN architecture design)

Tablo 4. Mask R-CNN ile elde edilen sonuçlar (Results with Mask R-CNN)

Omurga Modeller	Öğrenme Oranı	mAP50	Eğitim Süresi (dk)
R50-C4	1x	81,645	10,54
R50-DC5	1x	89,810	16,28
R50-FPN	1x	95,512	13,49
R50-C4	3x	91,775	11,31
R50-DC5	3x	96,040	16,31
R50-FPN	3x	94,992	13,12
R101-C4	3x	92,079	15,30
R101-DC5	3x	92,079	23,02
R101-FPN	3x	91,470	19,46
X101-FPN	3x	96,040	32,32


Eğitim süresi en kısa olan üç omurga modeli; öğrenme oranı 1x olan R50-C4 modeli 10,54 min ile en kısa eğitim süresine, öğrenme oranı 3x olan R50-C4 modeli 11,31 min ile en kısa ikinci eğitim süresine ve öğrenme oranı 3x olan R50-FPN modeli 13,12 min ile en kısa üçüncü eğitim süresine sahiptir. Eğitim süresi en uzun olan üç omurga modeli; öğrenme oranı 3x olan X101-FPN modeli 32,32 min ile en uzun eğitim süresine, öğrenme oranı 3x olan R101-DC5 modeli 23,02 min ile en uzun ikinci eğitim süresine, öğrenme oranı 3x olan R101-FPN modeli 19,46 min ile en uzun üçüncü eğitim süresine sahiptir. En iyi başarıyı elde eden üç omurga modeli; öğrenme oranı 3x olan X101-FPN modeli ve öğrenme oranı 3x olan R50-DC5 modeli eşit olmak üzere 96,040 mAP50 değeri ile birinciliği, öğrenme oranı 1x olan R50-FPN modeli 95,512 mAP50 değeri ile ikinciliği, öğrenme oranı 3x olan R50-FPN modeli 94,992 mAP50 değeri ile üçüncülüğü elde etmiştir. En kötü üç başarıyı elde eden üç omurga modeli; öğrenme oranı 1x olan R50-C4 modeli 81,645 mAP50 değeri ile en kötü performansı, öğrenme oranı 1x olan R50-DC5 modeli 89,810 mAP50 değeri ile en kötü ikinci performansı, öğrenme oranı 3x olan R101-FPN modeli 91,470 mAP50 değeri ile en kötü üçüncü performansı elde etmiştir. Başarım ve eğitim süresi birlikte değerlendirildiğinde en iyi üç omurga modeli; öğrenme oranı 3x olan R50-DC5 modeli 96,040 mAP50 değeri ve 16,31min eğitim süresi ile birinciliği, öğrenme oranı 1x olan R50-FPN modeli 95,512 mAP50 değeri ve 13,49 min eğitim süresi ile ikinciliği, öğrenme oranı 3x olan R50-FPN modeli 94,992 mAP50 değeri ve 13,12 min eğitim süresi ile üçünlüğü elde etmiştir.

Şekil 7, eğitim süresi mAP50 değerinin karşılaştırmasını sunmaktadır. Öğrenme oranı 3x olan X101-FPN modeli ve öğrenme oranı 3x olan R50-DC5 modeli 96,040 mAP50 değeri ile eşit başarıyı elde ederken, öğrenme oranı 3x olan R50-DC5 modelinin eğitim süresi 16,31 min olup öğrenme oranı olan X101-FPN modelinin eğitim süresi 32,32 min'dir. Bu nedenle öğrenme oranı 3x olan R50-DC5 modelinin kullanılabilirliği daha yüksektir çünkü test aşamasında daha hızlı segmentasyon sonucu vermektedir. 16,31 min olan model eğitim süresi ve 96,040 olan mAP50 değerine bağlı olarak PACS sistemi üzerindeki entegrasyon sürecine öğrenme oranı 3x olan R50-DC5 modeli ile devam edilmiştir. Ancak 13,49 min olan eğitim süresine bağlı olarak model dosyasının boyutuna ve 95,512 olan mAP50 değerine bakıldığında daha hızlı segmentasyon sonucu elde edilmek istenirse öğrenme oranı 1x olan R50-FPN modelinin de kullanılabilirliği yüksektir.


Şekil 8, Şekil 9 ve Şekil 10, girdi görüntüleri kullanılarak öğrenme oranı 1x olan R50-C4, öğrenme oranı 1x olan R50-DC5, öğrenme oranı 1x olan R50-FPN, öğrenme oranı 3x olan R50-C4, öğrenme oranı 3x olan R50-DC5, öğrenme oranı 3x olan R50-FPN, öğrenme oranı 3x olan R101-C4, öğrenme oranı 3x olan R101-DC5, öğrenme oranı 3x olan R101-FPN, öğrenme oranı 3x olan X101-FPN modelleri ile tahmin edilen maskeleri ve doğru maske karşılaştırmasını

göstermektedir. Şekil 8'deki giriş görseli üzerinde kullanılan segmentasyon modellerinin PB'ye ait alanın sol üst bölümünde piksel tabanlı sınıflandırmanın düşük duyarlılık ile sonuç verdiği görülmektedir. Buna karşın TB'ye ait bölümde piksel tabanlı sınıflandırma yüksek duyarlılık ile sonuç vermektedir. Şekil 9 ve Şekil 10'daki giriş görseli üzerinde kullanılan segmentasyon modellerinin PB ve TB'ye ait alanları segmente etmede piksel tabanlı sınıflandırmanın Şekil 8'deki giriş görseline göre daha yüksek duyarlılık ile sonuç verdiği görülmektedir. Buna karşılık PB ve TB'yi kapsayan bölümün ortasında bulunan yere karşılık gelen alanda PB'yi doğru maskeye göre daha geniş bir alanda düşük duyarlılık ile piksel tabanlı olarak sınıflandırmıştır. Ayrıca PB'ye ait sağ ve sol üst alanların segmente edilmesinde etmede piksel tabanlı sınıflandırmanın nispeten daha düşük duyarlılık ile sonuç verdiği görülmektedir. Yukarıda açıklanan durumun nedeni TB'den PB'ye geçişteki kenarların daha belirgin olması ile açıklanabilmesine ek olarak PB'nin altında kalan bölgenin TB ile benzer piksel değerlerine karşılık gelmesi nedeni ile kenarların belirgin olmaması ile açıklanabilir. Ayrıca PB'nin sağ ve sol üst köşelerinin keskin sınırları olmayan bir yapı ile etiketlenmesi de bir diğer neden olarak söylenebilir. İlgili analizler Şekil 11'de gösterilmiştir.


Tablo 5, çalışmada elde edilen sonuçlar ile literatürdeki benzer çalışmaların karşılaştırmasını sunmaktadır. Literatürde sıklıkla kullanılan açık kaynak veri setleri ProstateX, SPIE-AAPM-NCI PROSTATEX, Cannizzaro Hospital, Catania Italy, I2CVB, NCI-ISBI, UKMMC ve PROMM şeklindedir. Veri setlerinin boyutları değişken olmakla birlikte hasta sayıları en az 11 en çok 244 şeklindedir. Bu veri setlerinin kullanımı ile PB, TB ve tüm prostatın segmentasyonuna yönelik çalışmalar yürütülmüştür. Ancak yapılan araştırmalarda PB ve TB'nin segmentasyonu için yapılan araştırmaların sayısı daha fazladır. Segmentasyon için sıklıkla kullanılan modeller U-Net, SegNet, ENet, DeepLabV3+ ve FCN şeklindedir. Ek olarak, bu modellerin revize edilmiş yapıları da kullanılmaktadır. Ayrıca, araştırmacılar tarafından yeni segmentasyon modelleri de önerilmiştir. Modellerin performansının karşılaştırılmasında kullanılan ölçütlerin ise dice, IoU ve mAP olduğu görülmektedir. Bizler tarafından yapılan araştırmada, 15 hastaya ait MR görüntüleri kullanılmıştır. Görüntülerin etiketlenmesinden sonra toplam 204 adet kesitte prostat bölgeleri etiketlenmiştir. Performans değerlendirme metriği olarak mAP kullanılmıştır. Elde ettiğimiz segmentasyon sonuçları literatürdeki çalışmalara göre daha umut vericidir. Bunun nedeni, veri setindeki MR görüntülerinin radyolog tarafından işaretlenmesi olarak gösterilebilmektedir. Buna ek olarak, literatürdeki mevcut çalışmalarda hastanelerde kullanımı hazır bir model oluşturulmamıştır. Yapılan çalışmalar araştırma ölçeğinde kalmıştır. Bizler tarafından oluşturulan segmentasyon modeli ise PACS sistemi üzerinde entegre edilmiştir. Bu bağlamda, geçmiş çalışmalardan farklılaşmıştır.




Şekil 7. Omurga modellerin performans karşılaştırması (Performance comparison of backbone models)




Şekil 8. (a) Girdi görüntüsü, (b) doğru maske, (c) R50-C4 ve 1x, (d) R50-DC5 ve 1x, (e) R50-FPN ve 1x, (f) R50-C4 ve 3x, (g) R50-DC5 ve 3x, (h) R50-FPN ve 3x, (i) R101-C4 ve 3x, (j) R101-DC5 ve 3x, (k) R101-FPN ve 3x, (l) X101-FPN ve 3x
((a) Input image, (b) true mask, (c) R50-C4 and 1x, (d) R50-DC5 and 1x, (e) R50-FPN and 1x, (f) R50-C4 and 3x, (g) R50-DC5 and 3x, (h) R50-FPN and 3x, (i) R101-C4 and 3x, (j) R101-DC5 and 3x, (k) R101-FPN and 3x, (l) X101-FPN and 3x)



Şekil 9. (a) Girdi görüntüsü, (b) doğru maske, (c) R50-C4 ve 1x, (d) R50-DC5 ve 1x, (e) R50-FPN ve 1x, (f) R50-C4 ve 3x, (g) R50-DC5 ve 3x, (h) R50-FPN ve 3x, (i) R101-C4 ve 3x, (j) R101-DC5 ve 3x, (k) R101-FPN ve 3x, (l) X101-FPN ve 3x
((a) Input image, (b) true mask, (c) R50-C4 and 1x, (d) R50-DC5 and 1x, (e) R50-FPN and 1x, (f) R50-C4 and 3x, (g) R50-DC5 and 3x, (h) R50-FPN and 3x, (i) R101-C4 and 3x, (j) R101-DC5 and 3x, (k) R101-FPN and 3x, (l) X101-FPN and 3x)



Şekil 10. (a) Girdi görüntüsü, (b) doğru maske, (c) R50-C4 ve 1x, (d) R50-DC5 ve 1x, (e) R50-FPN ve 1x, (f) R50-C4 ve 3x, (g) R50-DC5 ve 3x, (h) R50-FPN ve 3x, (i) R101-C4 ve 3x, (j) R101-DC5 ve 3x, (k) R101-FPN ve 3x, (l) X101-FPN ve 3x
 ((a) Input image, (b) true mask, (c) R50-C4 and 1x, (d) R50-DC5 and 1x, (e) R50-FPN and 1x, (f) R50-C4 and 3x, (g) R50-DC5 and 3x, (h) R50-FPN and 3x, (i) R101-C4 and 3x, (j) R101-DC5 and 3x, (k) R101-FPN and 3x, (l) X101-FPN and 3x)



Şekil 11. Modelin tahminlerinin analizi (Analysis of the model's predictions)

5. Entegrasyon (Integration)

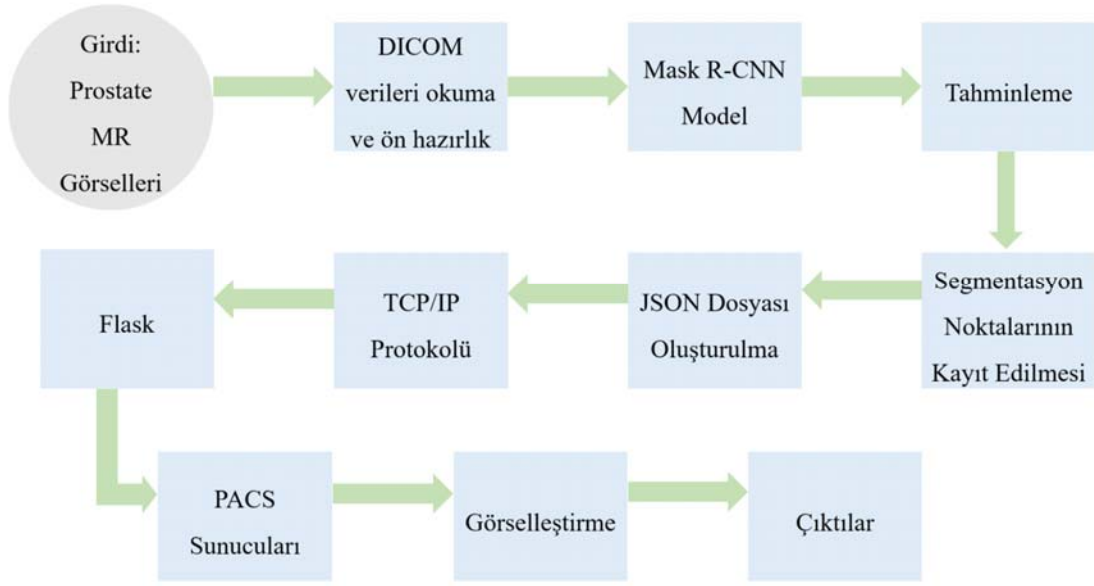
Entegrasyon çalışmalarında öğrenme oranı 3x olan R50-DC5 modeli yüksek mAP50 değeri ve hızlı sonuç vermesi nedeni ile kullanılmıştır. Modelin eğitilmesinden sonra yapılan entegrasyon çalışmasına ait blok diyagram Şekil 12'de gösterilmiştir. Eğitilen model girdi olarak MR görüntüsünü kullanmaktadır. MR görüntülerinin formatı DICOM olup içerisinde birden fazla seriyi barındırmaktadır. PACS arşiv sunucusuna gelen DICOM formatındaki MR görüntüleri önceden tanımlanmış olan iş kurallarıyla ayrıştırılarak ilgili tetkikler BDT sistemine aktarılmıştır. Eğitilen model ile çıktı üretmek için ihtiyaç duyulan seri ise T2W görsellerdir. Bu aşamada hastalara ait DICOM meta dataların okunması işlemi gerçekleştirilmiş ve tanımlaması 'Ax T2 PROPELLER' olan seriler ayrıştırılmıştır. Bu seri içerisinde bulunan görseller 16 bit olup modele girdi olarak verilmesi için png formatına dönüştürülmüştür. Tahminleme işlemleri için hazır hale getirilen görüntüler ilgili yapay zeka modeline yönlendirilmiş sonrasında bu seri içerisinde yer alan görseller eğitilen Mask R-CNN segmentasyon modeline girdi olarak verilmiştir. Model tahmin olarak, segmentasyon ve sınırlayıcı kutulara ait noktalara ek olarak sınıf bilgisini ve sınıflandırma başarı oranını da cevap olarak

döndürmüştür. İhtiyaç duyulan bilgiler segmentasyon noktaları, sınıf bilgisi ve sınıflandırma başarı oranı olduğu için sınırlayıcı kutu noktalarına ait sonuçlar kaldırılmıştır. Daha sonra bu bilgileri içeren json uzantılı bir dosya oluşturulmuştur. Hazırlanan çıktılar, BDT sistemine aktararak DICOM formatında presentation state (PR) ve structured report (SR) olarak dönüştürülmüş, daha sonra ise PACS sunucusunda arşivlenmek ve DICOM görüntüleyicilerde gösterilmek üzere istem yapan sunucuya geri gönderilmiştir. BDT sistemi ile yapay zeka uygulamalarının haberleşmesi, TCP/IP haberleşme protokolü üzerinden ve Flask kütüphanesinin kullanımı ile gerçekleştirilmiştir. Sonuç olarak ise PACS sunucuları üzerinde hastanelerde kullanımı hazır şekilde çıktılar oluşturulmuştur.

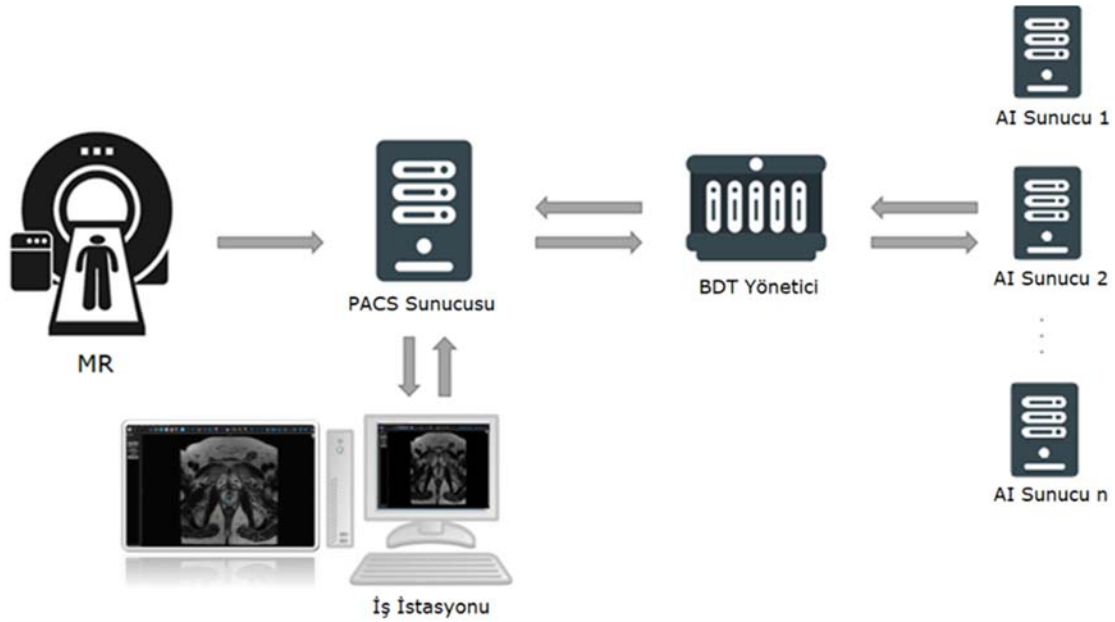
PACS sunucusunun çalışma mekanizmasına ait blok diyagram Şekil 13'de gösterilmiştir. MR cihazlarından gelen DICOM verileri, hastanelerdeki iş istasyonları üzerinde ve bu iş istasyonu ile PACS sunucusu arasındaki haberleşme aracılığı ile görselleştirilmektedir. BDT sistemi, görselleştirme için gerekli olan ve modelin tahmin üretmesi ile elde edilen segmentasyon noktaları, sınıf bilgisi ve sınıflandırma başarı oranı bilgilerini içerisinde tutmaktadır, sonrasında ise bu bilgileri AI sunuculara aktarmaktadır.

Tablo 5. Önceki benzer çalışmalarla karşılaştırma (Comparison with previous similar studies)

Yazarlar	Veri setleri ve Boyutları	Segmentasyon Modeli	Sonuçlar
Cuocolo vd. [24]	ProstateX veri setini kullanmışlardır. Veri seti boyutu: 204 hasta	ENet	TB: %87 dice skoru PB: %71 dice skoru
Duran vd. [25]	ProstateX veri setini kullanmışlardır. Veri seti boyutu: 204 hasta	ProstAttention-Net	TB ve PB için ortalama %87,5 dice skoru
Mooij vd. [26]	Kendi veri setlerini oluşturmuşlardır. Veri seti boyutu: 53 hasta	aniso-3DUNET	TB: %85 dice skoru PB: %65 dice skoru
Aldoj vd. [27]	Kendi veri setlerini oluşturmuşlardır. Veri seti boyutu: 188 hasta	Dense-2-U-net	TB: %89,5 dice skoru PB: %78,1 dice skoru
van Sloun vd. [28]	Kendi veri setlerini oluşturmuşlardır. Veri seti boyutu: 78 hasta	FCN	TB: %96 IoU skoru PB: %80 IoU skoru
Liu vd. [29]	ProstateX veri setini kullanmışlardır. Veri seti boyutu: 204 hasta	ResNet-50 ağı revizyonu ve FPN	TB: %92 dice skoru PB: %81 dice skoru
Bardis vd. [30]	Kendi veri setlerini oluşturmuşlardır. Veri seti boyutu: 242 hasta	Üç adet U-Net	TB: %92 dice skoru PB: %77,4 dice skoru
Meyer vd. [31]	SPIE-AAPM-NCI PROSTATEx veri setini kullanmışlardır. Veri seti boyutu: 92 hasta	3D U-NET	TB: %87,6 dice skoru PB: %79,8 dice skoru
Rundo vd. [32]	Cannizzaro Hospital, Catania Italy veri setini kullanmışlardır. Veri seti boyutu: 21 hasta I2CVB veri setini kullanmışlardır. Veri seti boyutu: 19 hasta NCI-ISBI veri setini kullanmışlardır. Veri seti boyutu: 40 hasta	USE-Net	En iyi sonuçlar NCI-ISBI veri seti ile elde edilmiştir. TB: %93,7 dice skoru PB: %80,1 dice skoru
Montagne vd. [33]	Kendi veri setlerini oluşturmuşlardır. Veri seti boyutu: 40 hasta	U-Net	TB: %91 dice skoru Prostatın tamamı (PB+TB): %94 dice skoru
Rouvière vd. [34]	NCI-ISBI veri setini kullanmışlardır. Veri seti boyutu: 70 hasta	DSA	TB: %91,8 dice skoru Prostatın tamamı (PB+TB): %96,4 dice skoru
Zhu vd. [35]	Kendi veri setlerini oluşturmuşlardır. Veri seti boyutu: 163 hasta	Kademeli U-Net	PB: %79,3 dice skoru Prostatın tamamı (PB+TB): %92,7 dice skoru
Khan vd. [36]	UKMMC veri setini kullanmışlardır. Veri seti boyutu: 40 hasta	U-Net	Yama tabanlı analiz hariç tutulduğunda Prostatın tamamı (PB+TB): %85 dice skoru
		DeepLabV3+	Yama tabanlı analiz dahil edildiğinde Prostatın tamamı (PB+TB): %91,9 dice skoru
	NCI-ISBI veri setini kullanmışlardır. Veri seti boyutu: 11 hasta	DeepLabV3+	Yama tabanlı analiz hariç tutulduğunda TB: %76,4 dice skoru Prostatın tamamı (PB+TB): %90,7 dice skoru
		DeepLabV3+	Yama tabanlı analiz dahil edildiğinde TB: %78,9 dice skoru Prostatın tamamı (PB+TB): %92,8 dice skoru
Sunoqrot vd. [37]	Kendi veri setlerini oluşturmuşlardır. Veri seti boyutu: 244 hasta	nnU-Net-3D	PB: %82,5 dice skoru PB olmayan: %91,6 dice skoru Prostatın tamamı (PB+PB olmayan): %94,0 dice skoru
Qin vd. [38]	PROMM veri setini kullanmışlardır. Veri seti boyutu: 202 hasta NCI-ISBI veri setini kullanmışlardır. Veri seti boyutu: 60 hasta	U-Net revizyonu, ResNet, piramit dikkat, residual artıma blokları	TB: %89,6 dice skoru PB: %77,1 dice skoru TB: %88,9 dice skoru PB: %79,9 dice skoru
Bu çalışmada önerilen model	Yeni bir veri seti oluşturulmuştur. Veri seti boyutu: 15 hastaya ait 204 etiketli kesit	Mask R-CNN	TB ve PB için mAP50: 96,040



Şekil 12. Entegrasyon blok diyagramı (Integration block diagram)




Şekil 13. PACS sunucuları iş akışı diyagramı (PACS servers workflow diagram)

AI sunucuları ise segmentasyon noktaları, sınıf bilgisi ve sınıflandırma başarı oranı bilgilerinin giriş görüntüsü üzerine işlenmesi aşamasını tamamlamaktadır. İleri ve geri iş akışı ile birlikte sonuçlar hastanelerde doktorlara sunulmaktadır. Yürütülen entegrasyon çalışmaları sonucunda elde edilen çıktılar Şekil 14'de gösterilmiştir. PACS sunucusu ara yüzünde örnek hastanın prostat bölgelerine ait segmentasyon sonuçları çizgisel ayırıcı kullanılarak gösterilmiştir. Geliştirilen PACS sunucusu ara yüzünde hastalara ait bilgilere ek olarak DICOM meta data bilgileri de gözlemlenebilmektedir. Ayrıca PACS sunucusu ara yüzünde yakınlaştırma, uzaklaştırma, parlaklık ayarlama ve çizim yapabilmek gibi diğer araçlar da bulunmaktadır. Bu araçların kullanımı neticesinde doktorlara görseller üzerinde işlem yapabilmeleri olanağı da sunulmuştur.

6. Sonuçlar (Conclusions)

Bu çalışmada, TB ve PB olmak üzere iki prostat bölgesinin otomatik segmentasyonuna yönelik olarak araştırmalar yürütülmüştür. Bu bağlamda, radyolog tarafından yeni bir veri seti oluşturulmuştur. Bu veri seti üzerinde eğitim için segmentasyon algoritması olarak Mask R-CNN kullanılmıştır. Bu algoritma (i) 1x öğrenme oranı olan R50-C4, (ii) 1x öğrenme oranı olan R50-DC5, (iii) 1x öğrenme oranı olan R50-FPN, (iv) 3x öğrenme oranı olan R50-C4, (v) 3x öğrenme oranı olan R50-DC5, (vi) 3x öğrenme oranı olan R50-FPN, (vii) 3x öğrenme oranı olan R101-C4, (viii) 3x öğrenme oranı olan R101-DC5, (ix) 3x öğrenme oranı olan R101-FPN ve (x) 3x öğrenme oranı olan X101-FPN olmak üzere on farklı omurga modeli ile birlikte test edilmiştir. Elde edilen segmentasyon sonuçlarının başarımları



Şekil 14. PACS ara yüzünde segmentasyon sonuçları (Segmentation results in the PACS interface)

segmentasyon başarımları oranı ve eğitim süresi ile birlikte karşılaştırmalı olarak sunulmuştur. En iyi segmentasyon sonucu 96,040 mAP50 değeri ile öğrenme oranı 3x olan R50-DC5 modeli 16,31 min eğitim süresinde elde etmiştir. Bu modelin başarımları literatürdeki mevcut çalışmalar ile karşılaştırılmış ve artı-eksi yönleri sunulmuştur. Böylelikle gelecekte yapılacak araştırma çalışmalarına ışık tutulmuştur. Bunlara ek olarak, çalışmada elde edilen segmentasyon modeli hastanelerde kullanıma hazır bir şekilde PACS sistemine entegre edilmiştir. Böylelikle PI-RADS v2'ye uygun şekilde prostat kanseri tanısının koyulmasında önem arz eden prostat bölgelerinin ayrıştırılması otomatize edilmiştir. Bu entegrasyon sayesinde radyologların iş yükü azaltılırken zamandan kazanç sağlanacaktır. Sonuç olarak, prostat kanserine yönelik olarak bilgisayarlı görüş destekli bir karar destek mekanizması oluşturulmuştur. Yapılacak gelecek çalışmalar kullanılan veri setinin boyutu artırmak, farklı segmentasyon modelleri ile deneysel çalışmalar yapmak, lezyon tespiti üzerine çalışmalar yürütmek ve PI-RADS v2'ye uygun prostat kanseri tanı sistemi geliştirmektir.

Kaynaklar (References)

1. Jemal A., Siegel R., Ward E., Hao Y., Xu J., Thun M.J., Cancer statistics, 2009, CA Cancer J. Clin., 59 (4), 225–249, 2009.
2. American Cancer Society. Information and resources about for cancer: Breast, colon, lung, prostate. Phytochemicals. <https://www.cancer.org/>. Yayın tarihi 2000. Erişim tarihi Ağustos 02, 2022.
3. Mizuno K., Beltran H., Future directions for precision oncology in prostate cancer, The Prostate, 82(S1), 2022.
4. Siegel R.L., Miller K.D., Jemal A. Cancer statistics, 2019. CA Cancer J. Clin., 69 (1), 7–34, 2019.
5. Martin R.M., Vatten L., Gunnell D., Romundstad P., Blood pressure and risk of prostate cancer: Cohort Norway (CONOR), Cancer Causes Control, 21 (3), 463–472, 2010.
6. Venkateswaran V., Klotz L.H., Diet and prostate cancer: Mechanisms of action and implications for chemoprevention, Nature Reviews Urology, 7 (8), 442–453, 2010.
7. Alexander D.D., Mink P.J., Cushing C.A., Scourman B., A review and meta-analysis of prospective studies of red and processed meat intake and prostate cancer. Nutr. J., 9 (50), 2010.
8. Tarver T., Cancer facts & figures 2012. American Cancer Society (ACS), J. Consum Health, 16 (3), 366–367, 2012.
9. Giovannucci E., Liu Y., Platz E.A., Stampfer M.J., Willett W.C., Risk factors for prostate cancer incidence and progression in the health professionals follow-up study, Int. J. Cancer, 121 (7), 1571–1578, 2007.
10. Rodriguez C, Freedland S.J., Deka A., Jacobs E.J., McCullough M.L., Patel A.V., Thun M.J., Calle E.E., Body mass index, weight change, and risk of prostate cancer in the Cancer Prevention Study II Nutrition Cohort, Cancer Epidemiol Biomarkers Prev., 16 (1), 63–69, 2007.
11. Steinberg G.D., Carter B.S., Beaty T.H., Childs B., Walsh P.C., Family history and the risk of prostate cancer, The Prostate, 17 (4), 337–347, 1990.
12. Hoeks C.M.A., Barentsz J.O., Hambroek T., Yakar D., Somford D.M., Heijmink S.W.T.P.J., Scheenen T.W.J., Vos P.C., Huisman H., Van Oort I.M., Witjes J.A., Heerschap A., Fütterer J.J., Prostate cancer:

- Multiparametric MR imaging for detection, localization, and staging, *Radiology*, 261 (1), 46–66, 2011.
13. Junker D., Schäfer G., Kobel C., Kremser C., Bektic J., Jaschke W., Aigner F., Comparison of real-time elastography and multiparametric MRI for prostate cancer detection: A whole-mount step-section analysis, *Am. J. Roentgenol*, 202 (3), 2014.
 14. McNeal J.E., The zonal anatomy of the prostate, *The Prostate*, 2 (1), 35–49, 1981.
 15. Weinreb J.C., Barentsz J.O., Choyke P.L., Cornud F., Haider M.A., Macura K.J., Margolis, D., Schnall, M.D., Shtern, F., Tempany, C.M., Thoeny, H.C., Verma, S., PI-RADS prostate imaging - reporting and data system: 2015, version 2. *Eur. Urol.*, 69 (1), 16–40, 2016.
 16. Droste R., Cai Y., Sharma H., Chatelain P., Drukker L., Papageorgiou A.T., Noble, J.A., Ultrasound Image Representation Learning by Modeling Sonographer Visual Attention, *Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics*, Editör: Chung A.C.S., Gee J.C., Yushkevich P.A., Bao S., Springer Cham, Zürich, İsviçre, 11492.592–604, 2019.
 17. Seçgin A., Kara M., Güler S., Examination of various classification strategies in classification of lung nodüle characteristics, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (2), 709–726, 2019.
 18. Ari A., Hanbay D., Tumor detection in MR images of regional convolutional neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3), 1395–1408, 2019.
 19. Karaci A., Detection and classification of shoulder implants from X-ray images: YOLO and pretrained convolution neural network based approach, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (1), 283–294, 2022.
 20. Gürkahraman K., Karakiş R., Brain tumors classification with deep learning using data augmentation, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (2), 997–1012, 2021.
 21. Yilmaz A., Diagnosing COVID-19 from X-Ray images with using multi-channel CNN architecture, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (4), 1761–1774, 2021.
 22. Balakrishnan G., Zhao A., Sabuncu M.R., Guttag J., Dalca A.V., VoxelMorph: A learning framework for deformable medical image registration, *IEEE Trans. Med. Imaging*, 38 (8), 1788–1800, 2019.
 23. Isensee F., Petersen J., Klein A., Zimmerer D., Jaeger P.F., Kohl S., Wasserthal J., Koehler G., Norajitra T., Wirkert S., Maier-Hein K.H., nnU-Net: Self-adapting framework for U-Net-based medical image segmentation, 2019.
 24. Cuocolo R., Comelli A., Stefano A., Benfante V., Dahiya N., Stanzone A., Castaldo A., De Lucia D.R., Yezzi A., Imbriaco M., Deep learning whole-gland and zonal prostate segmentation on a public MRI dataset, *J. Magn. Reson. Imaging*, 54 (2), 452–459, 2021.
 25. Duran A., Dussert G., Rouvière O., Jaouen T., Jodoïn P.M., Lartizien C., ProstAttention-Net: A deep attention model for prostate cancer segmentation by aggressiveness in MRI scans, *Med. Image Anal.*, 77, 2022.
 26. Mooij G., Bagulho I., Huisman H., Automatic segmentation of prostate zones, 2018.
 27. Aldoş N., Biavati F., Michallek F., Stober S., Dewey M., Automatic prostate and prostate zones segmentation of magnetic resonance images using DenseNet-like U-net. *Sci. Rep.*, 10 (1), 2020.
 28. van Sloun R.J.G., Wildeboer R.R., Mannaerts C.K., Postema A.W., Gayet M., Beerlage H.P., Salomon G., Wijkstra H., Mischi M., Deep learning for real-time, automatic, and scanner-adapted prostate (zone) segmentation of transrectal ultrasound, for example, magnetic resonance imaging–transrectal ultrasound fusion prostate biopsy, *Eur. Urol. Focus*, 7 (1), 78–85, 2021.
 29. Liu Y., Sung K., Yang G., Afshari Mirak S., Hosseiny M., Azadikhah A., Zhong X., Reiter R.E., Lee Y., Raman S.S., Automatic prostate zonal segmentation using fully convolutional network with feature pyramid attention, *IEEE Access*, 7, 163626–163632, 2019.
 30. Bardis M., Houshyar R., Chantaduly C., Tran-Harding K., Ushinsky A., Chahine C., Rupasinghe M., Chow D., Chang P., Segmentation of the prostate transition zone and peripheral zone on mr images with deep learning, *Radiol Imaging Cancer*, 3 (3), 2021.
 31. Meyer A., Rakr M., Schindele D., Blaschke S., Schostak M., Fedorov A., Hansen C., Towards Patient-Individual Pi-rads v2 Sector Map: CNN for Automatic Segmentation of Prostatic Zones from T2-Weighted MRI, *International Symposium on Biomedical Imaging, Venedik-İtalya*, 696–700, 8-11 Nisan, 2019.
 32. Rundo L., Han C., Nagano Y., Zhang J., Hataya R., Militello C., Tangherloni A., Nobile M.S., Ferretti C., Besozzi D., Gilardi M.C., Vitabile S., Mauri G., Nakayama H., Cazzaniga P., USE-Net: Incorporating squeeze-and-excitation blocks into U-Net for prostate zonal segmentation of multi-institutional MRI datasets, *Neurocomputing*, 365, 31–43, 2019.
 33. Montagne S., Hamzaoui D., Allera A., Ezziane M., Luzurier A., Quint R., Kalai M., Ayache N., Delingette H., Renard-Penna R., Challenge of prostate MRI segmentation on T2-weighted images: inter-observer variability and impact of prostate morphology, *Insights Imaging*, 12 (1), 2021.
 34. Rouvière O., Moldovan P.C., Vlachomitrou A., Gouttard S., Riche B., Groth A., Rabotnikov M., Ruffion A., Colombel M., Crouzet S., Weese J., Rabilloud M., Combined model-based and deep learning-based automated 3D zonal segmentation of the prostate on T2-weighted MR images: clinical evaluation, *Eur. Radiol.*, 32 (5), 3248–3259, 2022.
 35. Zhu Y., Wei R., Gao G., Ding L., Zhang X., Wang X., Zhang J., Fully automatic segmentation on prostate MR images based on cascaded fully convolution network, *J. Magn. Reson. Imaging*, 49 (4), 1149–1156, 2019.
 36. Khan Z., Yahya N., Alsaih K., Ali S.S.A., Meriaudeau F., Evaluation of deep neural networks for semantic segmentation of prostate in T2W MRI, *Sensors*, 20 (11), 1–17, 2020.
 37. Sunoşrot M.R.S., Selnæs K.M., Sandsmark E., Langørgen S., Bertilsson H., Bathen T.F., Elshot M., The reproducibility of deep learning-based segmentation of the prostate gland and zones on t2-weighted mr images, *Diagnostics*, 11 (9), 2021.
 38. Qin X., Zhu Y., Wang W., Gui S., Zheng B., Wang P., 3D multi-scale discriminative network with multi-directional edge loss for prostate zonal segmentation in bi-parametric MR images, *Neurocomputing*, 418, 148–161, 2020.
 39. Gurkan C., Kozalioglu S., Palandoken M., Real time mask detection, social distance and crowd analysis using convolutional neural networks and YOLO architecture designs. *Acad. Perspect. Procedia*, 4 (1), 195–204, 2021.
 40. Wu Y., Kirillov A., Massa F., Lo W.Y., Girshick R., Detectron2, 2019.
 41. He K., Zhang X., Ren S., Sun J., Deep Residual Learning for Image Recognition, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Las Vegas-A.B.D.*, 770–778, 26 Haziran-1 Temmuz, 2016.
 42. Xie S., Girshick R., Dollár P., Tu Z., He K., Aggregated Residual Transformations for Deep Neural Networks, *IEEE Conference on Computer Vision and Pattern Recognition, Honolulu-Hawaii*, 5987–5995, 21-26 Temmuz, 2017.