



**DERİN ÖĞRENME TABANLI PROSTAT GÖRÜNTÜLERİNİN
SEGMENTASYONU**

Hakan ÖCAL

**DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

NİSAN 2022

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Hakan ÖCAL

14/04/2022

DERİN ÖĞRENME TABANLI PROSTAT GÖRÜNTÜLERİNİN SEGMENTASYONU
(Doktora Tezi)

Hakan ÖCAL

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Nisan 2022

ÖZET

Çağımızın en büyük hastalıklarından birisi olan kanserle mücadelede birçok çalışma yapılmaktadır. Erkekler arasında önde gelen kanser türlerinden birisi ise prostat kanseridir. Prostat kanseri erken safhada teşhis edilebilirse tedavisi kolaydır. Prostat bezesinin görüntülenmesinde açısız (axial, coronal, sagittal) görüntüleme imkânı sayesinde daha kesin bilgiler sunduğu için Manyetik Rezonans Görüntüleme en çok kullanılan tanılama yöntemidir. Fakat Manyetik Rezonans (MR) cihazlarından elde edilen görüntülerinde prostat bezesinin tutarsız ve homojen olmayan görüntüsü uzman radyologlar tarafından yapılan manuel segmentasyonu (bölütlemesi) zaman alıcı ve sıkıcı bir iş haline getirmektedir. Bu sorunla başa çıkabilmek için günümüzde bilgisayar destekli Derin Evrişimsel Sinir Ağları'ndan (DESA) oluşan akıllı mimariler geliştirilmeye başlanmıştır. Bu tez çalışmasında DESA mimarilerinden ilham alarak prostat görüntülerinin uçtan uca otomatik bölütlemesi için derin öğrenme tabanlı iki farklı füzyon mimarisi önerilmiştir. Önerilen birinci mimaride, 3 Boyutlu Artık Bloklı U-Net (ResU-Net 3B) ile 2 Boyutlu Artık Bloklı U-Net (ResU-Net 2B) modelleri kaynaştırılmıştır. Önerilen ikinci mimaride ise, ET-net (Kenar Dikkat Ağı), 3 boyutlu Volümetrik Evrişimsel Sinir Ağı (V-Net 3B) ve 2 Boyutlu Artık Bloklı U-Net (ResU-Net 2B) modelleri kaynaştırılmıştır. Önerilen birinci mimaride, modelin performansını en iyi seviyeye çıkarmak için yeni bir yaklaşım olarak Dinamik Durum Tipi Odak Twersky (DDTOT) kayıp fonksiyonu kullanılmıştır. Önerilen ikinci mimaride ise, modelin performansını en iyi seviyeye çıkarmak için yeni bir yaklaşım olarak Ağırlıklandırılmış Odak Twersky(AOT) hibrit kayıp fonksiyonu kullanılmıştır. İki farklı halka açık prostat veri setinde (Promise12 ve NCI_ISBI-2013) elde edilen test sonuçları önerilen her iki modelin de çok sağlam modeller olduğunu göstermektedir.

Bilim Kodu : 92432

Anahtar Kelimeler : Prostat segmentasyonu, derin öğrenme, ET-V-Net, ResU-Net, hibrit kayıp fonksiyonu, evrişimsel sinir ağları, görüntü işleme

Sayfa Adedi : 80

Danışman : Prof. Dr. Necaattin BARIŞCI

SEGMENTATION OF DEEP LEARNING-BASED PROSTATE IMAGES

(Ph.D. Thesis)

Hakan ÖCAL

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

April 2022

ABSTRACT

Many studies are carried out in the fight against cancer, which is one of the biggest diseases of our age. One of the leading types of cancer among men is prostate cancer. Prostate cancer is easy to treat if detected at an early stage. Magnetic Resonance Imaging is the most used diagnostic method, as it provides more precise information thanks to the angular (axial, coronal, sagittal) imaging opportunity in the imaging of the prostate gland. However, the inconsistent and inhomogeneous appearance of the prostate gland in the images obtained from Magnetic Resonance (MR) devices makes manual segmentation by expert radiologists a time-consuming and tedious task. Therefore, intelligent architectures consisting of computer-aided Deep Convolutional Neural Networks (DCNN) have been developed. This thesis proposes two different deep learning-based fusion architectures for end-to-end automatic segmentation of prostate images, inspired by DCNN architectures. 3D U-Net with Residual Blocks (ResU-Net 3D) and 2D U-Net with Residual Blocks (ResU-Net 2D) models are fused in the first proposed architecture. In the second proposed architecture, ET-Net (Edge Attention Network), 3D Volumetric Convolutional Neural Network (V-Net 3D), and 2D Residual Block U-Net (ResU-Net 2D) models are fused. In the first proposed architecture, the Dynamic Case-Wise Focal Twersky (DCWFT) loss function is used as a new approach to optimizing the model's performance. In the second proposed architecture, the Weighted Focal Twersky (WFT) hybrid loss function is used as a new approach to optimizing the model's performance. Test results from two different public prostate datasets (Promise12 and NCI_ISBI-2013) show that the proposed models are very robust.

Science Code : 92432

Key Words : Prostate segmentation, deep learning, ET-V-Net, ResU-Net, hybrid loss function, convolutional neural networks, image processing

Page Number : 80

Supervisor : Prof. Dr. Necaattin BARIŞCI

TEŞEKKÜR

Tez çalışmam süresince engin bilgi birikiminin yanında akademik tecrübelerini benim ile paylaşarak hoşgörü ve sabırla destek olan doktora tez danışmanım Sayın Prof. Dr. Necaattin BARIŞCI hocama,

Tez izleme komitemde olmayı kabul eden, destekleyen ve tez çalışmama değerli katkılarını sunan Sayın Prof. Dr. Sabri KOÇER ve Doç. Dr. Hüseyin POLAT hocalarıma,

Derin öğrenme konusunda engin tecrübelerini paylaşarak hayatımda mihenk taşı olan hayatını eğitime adanmış Prof. Dr. Uğur HALICI hocama,

Benimle akademik tecrübelerini paylaşan Prof. Dr. Kemal POLAT ve Doç. Dr. Nihat DALDAL hocalarıma,

Eğitimim süresince hep gurur duyduğum ve kendimi bir parçası olarak gördüğüm Gazi Üniversitesi Bilgisayar Mühendisliği bölümü akademik ve idari çalışanlarına,

Bu süreçte hep yanımda olan, beni destekleyen, zorlu günlerimin dostu annem Döndü ÖCAL'a,

Çalışmalarım boyunca sevgisiyle beni hiçbir zaman yalnız bırakmayan oğlum Ahmet Batuhan ÖCAL'a sonsuz teşekkür, sevgi ve saygılarımı sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER.....	vii
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETİ	5
2.1. Geleneksel Prostat Bölütlemesi Yöntemleri	5
2.2. Derin Öğrenme Tabanlı Prostat Bölütlemesi Yöntemleri	6
3. MATERYAL VE YÖNTEM	9
3.1. Görüntü Bölütleme Yöntemleri.....	9
3.1.1. Eşikleme	10
3.1.2. Kümeleme metodu.....	11
3.1.3. Hareket ve interaktif bölütleme	12
3.1.4. Sıkıştırma tabanlı metotlar.....	12
3.1.5. Histogram tabanlı metotlar	13
3.1.6. Kenar algılama.....	13
3.1.7. Çift kümele metodu	14
3.1.8. Bölge-büyütme metodu	14
3.1.9. Model tabanlı bölütleme	15
3.1.10. Çok ölçekli bölütleme.....	15
3.1.11. Yarı-otomatik bölütleme.....	15
3.1.12. Anlamsal bölütleme	15
3.2. Prostat Kanseri Tanılama Yaklaşımları.....	17
3.2.1. Dijital rektal muayene	18

	Sayfa
3.2.2. Prostat spesifik antijen testi	18
3.2.3. Transrektal ultrasonografi.....	18
3.2.4. Manyetik rezonans görüntüleme ve/veya bilgisayarlı tomografi	19
3.3. Yapay Sinir Ağı.....	20
3.4. Evrişimsel Sinir Ağları	21
3.5. Derin Evrişimsel Sinir Ağları.....	22
3.5.1. Evrişim işleminin gerçekleştirilmesi	24
3.5.2. Havuzlama katmanı	25
3.5.3. Derin öğrenme modellerinde kullanılan hiper parametreler.....	26
3.6. Artık Bloklar	31
3.7. Artık Bloklu U-Net.....	31
3.7.1. Kodlayıcı	32
3.7.2. Atlama bağlantıları	32
3.7.3. Köprü	33
3.7.4. Kod çözücü aşaması	33
3.8. Volümetrik Evrişimli Sinir Ağı.....	34
3.9. Prostat Bölütlemesi İçin Kullanılan Veri Kümeleri	35
3.10. Veri Kümelerinin (Setlerinin) Ön İşlenmesi	36
4. DERİN ÖĞRENME TABANLI PROSTAT GÖRÜNTÜLERİNİN BÖLÜTLEMESİ	39
4.1. Model 1: Dinamik Durum tipi Odak Twersky Fonksiyonuna Sahip Füzyon Modeli	39
4.1.1. Kodlayıcı aşaması.....	39
4.1.2. Kod çözücü aşaması	40
4.1.3. Dinamik durum tipi odak twersky kayıp fonksiyonu (DDTOT).....	40
4.2. Model 2: Hibrid Loss Fonksiyonunu Kullanan Üçlü Füzyon Modeli	44
4.2.1. Kodlayıcı aşaması.....	47

	Sayfa
4.2.2.Kod çözücü aşaması	47
4.2.3.Ağırlıklandırılmış odak twersky kayıp fonksiyonu (AOT)	47
5. ARAŞTIRMA BULGULARI VE TARTIŞMA	49
5.1. Uygulama Detayları	49
5.2. Performans Metrikleri	49
5.3. Model 1'in Veri Setleri Üzerindeki Uygulama Detayları	50
5.3.1. Model 1'in PROMISE 12 veri setindeki performans değerlendirmesi	51
5.3.2. Model 1'in NCI_ISBI-13 veri seti üzerindeki performans değerlendirme....	55
5.4. Model 2'nin Veri Setleri Üzerindeki Uygulama Detayları	58
5.4.1. Model 2' nin PROMISE 12 veri seti üzerindeki performans değerlendirmesi.....	59
6. SONUÇ VE ÖNERİLER	67
KAYNAKLAR	69
ÖZGEÇMİŞ	79

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3. 1. Prostat bölütleme veri tabanları	36
Çizelge 4. 1. U-Net+ResNet 3B modelinin detayları	42
Çizelge 4. 2. U-Net+ResNet 2B modelinin detayları	43
Çizelge 4. 3. ResU-Net 2B modelinin detayları	45
Çizelge 4. 4. ET-Vnet 3B modelinin detayları	46
Çizelge 5. 1. Önerilen model ile Promise12 veri setinde test edilen en son mimariler arasında karşılaştırmalı analiz	55
Çizelge 5. 2. Önerilen model ile NCI_ISBI-13 veri kümesindeki en son mimariler arasındaki karşılaştırmalı analiz	57
Çizelge 5. 3. Önerilen model ile Promise12 veri setindeki en son mimariler arasında karşılaştırmalı analiz	62
Çizelge 5. 4. Önerilen model ile NCI_ISBI-13 veri kümesindeki en son mimariler arasında karşılaştırmalı analiz	66

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3. 1. Biyolojik ve yapay sinir ağı temsili	20
Şekil 3. 2. Yapay sinir ağı mimarisi.....	21
Şekil 3. 3. Derin öğrenme mimarisi	23
Şekil 3. 4. Evrişim işlemi.....	24
Şekil 3. 5. Havuzlama Çeşitleri.....	25
Şekil 3. 6. Piksel Ekleme Yöntemi	27
Şekil 3. 7. Kaydırma (stride) yöntemi.....	28
Şekil 3. 8. Yığın normalleştirme	28
Şekil 3. 10. Artık blok örneği.....	31
Şekil 3. 11. Artık bloklu U-Net mimarisi	34
Şekil 3. 12. V-Net mimarisi	35
Şekil 4. 1. ET-V-Net 3B modelinin blok diyagramı.....	44
Şekil 5. 1. En az bağlantılı noktaların çıkarılması	50
Şekil 5. 2. Önerilen füzyon modelin Promise 12 veri seti üzerindeki bölütleme aşamaları	51
Şekil 5. 3. Önerilen füzyon modelin NCI_ISBI-13 veri seti üzerindeki bölütleme aşamaları	51
Şekil 5. 4. U-Net+ResNet 2B'nin geçerleme hassasiyeti ve kaybının Promise 12 veri seti üzerindeki sonuçları	52
Şekil 5. 5. U-Net+ResNet 3B'nin geçerleme hassasiyeti ve kaybının Promise 12 veri seti üzerindeki sonuçları	52
Şekil 5. 6. Promise 12 yarışmasının 25. vaka test sonuçları	53
Şekil 5. 7. Promise 12 yarışmasının 40. vakasının test sonuçları	54
Şekil 5. 8. U-Net+ResNet 3B' nin geçerleme hassasiyeti ve kaybının Promise 12 veri seti üzerindeki sonuçları	56
Şekil 5. 9. U-Net+ResNet 3B' nin geçerleme hassasiyeti ve kaybının NCI_ISBI-13 veri seti üzerindeki sonuçları	56
Şekil 5. 10. Önerilen modelin NCI_ISBI-13 bölütleme sonucu	57

Şekil	Sayfa
Şekil 5. 11. En az bağlantılı piksellerin çıkarılması.....	58
Şekil 5. 12. Model 2'nin Promise 12 veri seti üzerindeki bölütleme aşamaları	59
Şekil 5. 13. Model 2'nin NCI_ISBI-13 veri seti üzerindeki bölütleme aşamaları.....	59
Şekil 5. 14. ET-Vnet 3B' nin geçerleme hassasiyeti ve kaybının Promise 12 veri seti üzerindeki sonuçları	60
Şekil 5. 15. ResU-Net 2B' nin geçerleme hassasiyeti ve kaybının Promise 12 veri seti üzerindeki sonuçları	60
Şekil 5. 16. Önerilen modelin Promise 12 veri setinin 3. vakasındaki 64 dilimlik test sonuçları	61
Şekil 5. 17. Önerilen modelin Promise 12 yarışmasının 41. vakasındaki test sonuçları	63
Şekil 5. 18. ET-Vnet 3B veri setinin NCI_ISBI-13 veri seti üzerindeki geçerleme hassasiyeti ve geçerleme kayıpları sonuçları	64
Şekil 5. 19. ResU-Net 2B veri setinin NCI_ISBI-13 veri seti üzerindeki geçerleme hassasiyeti ve geçerleme kayıpları sonuçları	65
Şekil 5. 20. Önerilen modelin NCI_ISBI-13 veri setindeki bölütleme sonucu	65

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3. 1. Eşikleme örneği	11
Resim 3. 2. Anlamsal (semantik) bölütleme	16
Resim 3. 3. Sınırlayıcı kutu (bounding box) örneği.....	17
Resim 3. 4. Transrektal ultrasonografi örneği	19



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
AOT	Ağırlıklandırılmış Odak Twersky
ATM	Ağırlık Toplama Modülü
BHF	Bağıl Hacim Farkı
BT	Bilgisayarlı Tomografi
DESA	Derin Evrişimsel Sinir Ağları
DDTOT	Dinamik Durum Tipi Odak Twersky
ESA	Evrişimli Sinir Ağları
EVİRŞ	Evrişim
GN	Grup Normalizasyonu
HBYKD	Hacimsel Bütünsel Yuvalanmış Kenar Dedektörü
HM	Hausdorff Mesafesi
KYM	Kenar Yönlendirme Modülü
MDL	Minimum Açıklama Uzunluğu
MRG	Manyetik Rezonans Görüntüleme
MR	Manyetik Rezonans
NORM	Normalizasyon
PSA	Prostat Spesifik Antijen
PSAA	Pramit Sahne Ayırıştırma Ağı
SNAEKM	Sınır Noktaları Arasındaki En kısa Mesafe
TRUS	Transrektal Ultrasonografi
TBESA	Tam Bağlı Evrişimsel Sinir Ağı
YN	Yığın Normalizasyonu
ZBK	Zar Benzerlik Katsayısı

1. GİRİŞ

Prostat her erkekte bulunan bir bezedir ve genç erişkin erkeklerde 18-20 gram ağırlığındadır. Yetişkin bir erkekte yaklaşık olarak bir ceviz büyüklüğüne ulaşır. Mesane sonrası karın organlarının en alt kısmında, rektumun hemen önünde (kalın bağırsağın son kısmı) bulunur. Vücudun normal işleyişinde iki işlevi vardır. İlk işlevi, boşaltım sisteminde boşaltım sırasında idrarı mesaneden taşımak ve boşalma sırasında sperm iletimini sağlamaktır. Aynı zamanda, seminal sıvıda bulunan ve spermi besleyen ve dişi üreme sistemine ilerlerken onları koruyan özel bir protein salgılar.

Prostat kanseri, prostat bezindeki hücrelerin kontrol dışı büyümesiyle ortaya çıkar. Prostat kanseri, iyi huylu prostat bezi büyümesinden farklı olarak prostatın merkezinden değil, kapsüle yakın, merkezden uzak bölgesinden kaynaklanır. Bu nedenle prostat kanserinde idrar şikâyetleri daha geç dönemde hastayı rahatsız eder. Prostat kanseri yavaş seyirli olduğu gibi tümör, oldukça agresif karakter göstererek kemik ve diğer organlara sıçrayabilir. Prostat kanseri dünya ve ülkemiz genelinde erkekler arasında en yaygın 2. kanser türüdür. Erken teşhis ve erken tedavi hastalar için hayati önem taşımaktadır.

Prostat kanserinin çeşitli tipleri vardır. Bunlardan Asiner adenokarsinomlar, prostat bezini düzenleyen bez hücrelerinde gelişen kanserlerdir. Bunlar en yaygın prostat kanseri türüdür. Neredeyse prostat kanseri olan bütün insanlarda kanser bu tiptedir.

Ductal adenokarsinom, prostat bezesinin kanallarını (tüplerini) kaplayan hücrelerde başlar. Asiner adenokarsinomdan daha hızlı büyüme ve yayılma eğilimindedir.

Geçiş hücresi (veya ürotelyal) kanseri, idrar taşıyan tüpü vücudun dışına (üretra) bağlayan hücrelerde başlar. Bu kanser türü genellikle mesanede başlar ve prostata yayılır. Ancak nadiren prostatta başlayabilir ve mesanenin girişine ve yakındaki dokulara yayılabilir.

Skuamöz hücre kanseri (Squamous cell carcinoma), prostat bezesini saran düz hücrelerden gelişir. Prostat adenokarsinomundan daha hızlı büyür ve yayılırlar.

Küçük hücreli prostat kanseri, küçük yuvarlak hücrelerden oluşur. Bir tür nöro-endokrin kanseridir.

Siegel ve arkadaşlarının yaptığı ABD 2022 istatistiksel kanser araştırmalarına göre tahminen 608 360 kişi kanserden ölmesi beklenmektedir. Erkeklerde ölümlerin büyük bir bölümü sırasıyla akciğer, prostat ve kolon kanserlerinden kaynaklanacaktır. Prostat kanserinin erkeklerde kanser vakalarının %26'sını oluşturacağı tahmin edilmektedir. Prostat kanseri vakalarının sayısı 268 490, ölüm sayısı ise 34 500 olarak tahmin edilmektedir. Prostat kanserinin, erkekler arasında vaka bazında akciğer kanserini geçerek birinci sıraya geleceği düşünülmektedir. Prostat kanseri erken dönemde tanındığında ölüm oranı düşük bir kanser türüdür [1].

Manyetik Rezonans Görüntüleme (MRG) ile prostat bezinin görüntülenmesi, Bilgisayarlı Tomografi (BT) ve Transrektal ultrasonografi (TRUS) gibi diğer tanı yöntemlerine kıyasla en etkili yol olarak kabul edilmiştir [2, 3].

Prostat görüntülerinin otomatik bölütlenmesi, akıllı olmayan görüntüleme sistemleri sayesinde son on yılda kayda değer ilerleme kaydetmiştir [4, 5]. Bununla birlikte, prostat bölütlemesi, MRG ile elde edilen görüntülerin homojen olmaması ve tutarsızlığı nedeniyle hala zorlu bir iştir [6, 7].

Otomatik prostat bölütlemesine farklı bir yaklaşım olarak Derin Evrişimli Sinir Ağları (DESA), prostat görüntülerini başarılı bir şekilde segmentlere ayırdığını kanıtlamıştır. Prostat bölütlemesinde birçok DESA modeli kullanılmıştır. Beklendiği gibi, en gelişmiş performansı elde ettiler [8–10]. Bununla birlikte, vakalar arasında prostat bezlerinin şekil ve boyutundaki değişkenlik, prostat görüntüleme artefaktları, prostat bezi ve çevre dokular arasındaki bulanık sınırlar ve endorektal helisler etrafındaki homojen olmayan sinyal yoğunluğu ve MR cihazı farklılıkları nedeniyle prostat görüntülerinin manuel bölütlenmesi günler alan zor bir iştir. Yukarıda bahsedilen bu zorlukları NCI_ISBI-2013(NCI_ISBI-13) ve PROMISE 12 veri setlerinde [7] görmek mümkündür. Anlatılan bütün bu zorlukların üstesinden gelebilmek için önceki çalışmalarda birçok tam otomatik ve yarı otomatik DESA tabanlı yöntem önerilmiştir. DESA tabanlı derin öğrenme mimarilerinden ilham alan bu çalışmada, organ bölütlemesinde en çok kullanılan modelleri birleştirerek yeni bir üçlü füzyon modeli önerilmektedir.

Tez çalışmasının literatüre katkısı

Bu tez çalışmasında önerilen her iki derin öğrenme mimarisi de uçtan uca otomatikleştirilmiş bir derin öğrenme mimarisidir.

Bu çalışmanın literatüre sağladığı başlıca katkılar şunlardır:

- Önerilen birinci mimaride ilk defa ResU-Net 2B ve ET-V-Net 3B modelleri birleştirilerek yeni bir füzyon mimarisi önerilmiştir. İkinci mimaride ise ResU-Net 2B ve ResU-Net 3B modelleri birleştirilerek yeni ve sağlam bir füzyon mimarisi önerilmiştir. Ayrıca, önerilen mimarilerin prostat görüntülerinin sınırlarını daha iyi tanımasını sağlamak için modellerin kod çözücü ve kodlayıcı aşamasındaki her bir evrişim katmanına artık bloklar eklenmiştir.
- Ayrıca birinci mimari için eğitim ve test aşamalarında en iyi performans sonuçlarını sağlayan Ağırlıklandırılmış Odak Twersky(AOT) kayıp fonksiyonu yeni bir yaklaşım olarak önerilmektedir. AOT aslında Ağırlıklandırılmış İkili Çapraz Entropi kayıp fonksiyonu ile Odak Twersky kayıp fonksiyonun hibrit olarak birleşimidir. İkinci mimaride ise DESA'nın öğrenme kaybını istikrarlı bir şekilde düşüren Dinamik Durum Tipi Odak Twersky (DDTOT) kayıp fonksiyonu ilk defa önerilmiştir. Önerilen kayıp fonksiyonunda parti boyutuna göre bir parametre girilmektedir. Önerilen kayıp fonksiyonu parti boyutunu da içine alan İkili Çapraz Entropi ile Odak Twersky kayıp fonksiyonunun hibrit olarak birleşimidir.
- Önerilen her iki füzyon mimarisi, halka açık iki farklı veri seti olan PROMISE 12(MICCAI Grand Challenge 2012) ve NCI_ISBI-13 prostat bölütleme veri setlerinde eğitilmiş ve test edilmiştir. Literatürdeki en son önerilen yaklaşımlarla yapılan karşılaştırmalı performans analizleri sonucunda önerilen modelin üstün performans gösterdiği görülmüştür.
- Önerilen mimarilerde dikkat edilmesi gereken en önemli katkılardan birisi de 2 boyutlu (2B) görüntü işleyen bir derin öğrenme ağı ile 3 boyutlu (3B) veri işleyen derin öğrenme ağlarının birleştirilmesidir. 2B derin öğrenme ağ modelleri veri kümelerindeki MR görüntülerinden elde edilen 2 boyutlu prostat kesitleri üzerinde eğitilmiştir. 3B ağ

modelleri ise 64 ve 32 görüntü kesitinden oluşan 3B prostat görüntüleri üzerinde eğitilmiştir.

Tez çalışmasının bölümleri

Tez çalışmasının 2. bölümünde konuyla ilgili daha önce literatürde yapılan makale ve tez çalışmaları hakkında bilgiler verilmiştir. Üçüncü bölümde, kullanılan veri kümesi ve tasarlanan derin öğrenme mimarisi hakkında detaylı bilgiler verilmiştir. Bu bölümde ayrıca veri setlerindeki görüntülerin nasıl bir görüntü ön işlemeden geçirildiği ve örnek görüntüler verilmiştir. Dördüncü bölümde, önerilen modeller literatürde yaygın olarak kullanılan performans metrikleri ile ölçülmüştür. Beşinci bölümde ise önerilen modellerin iki farklı veri seti üzerinde detaylı değerlendirmesi resim ve grafiklerle desteklenerek sunulmuştur. Beşinci bölümde önerilen modelin prostat görüntüleri üzerindeki test sonuçları değerlendirilmiş ve tartışılmıştır. Son olarak, tezin altıncı bölümünde önerilen mimarilerin detaylı olarak değerlendirmesi ve geleceğe yönelik çalışmalar hakkında bilgi verilmiştir.

2. LİTERATÜR ÖZETİ

Prostat görüntülerinin bölütlemesi yöntemleri geleneksel ve öğrenme tabanlı yöntemler olarak ayrılabilir.

2.1. Geleneksel Prostat Bölütlemesi Yöntemleri

Son zamanlarda, geleneksel prostat bölütleme yöntemlerinin çoğu çoklu atlas tekniklerine, grafik kesim optimizasyon yöntemlerine ve deforme olabilen modellere odaklanmaktadır. Çoklu atlas yöntemleri, temel olarak, bölütleme doğruluğunu geliştirmek için hedef görüntü ile çoklu atlaslar arasındaki benzerliğe dayanmaktadır.

Litjens ve arkadaşları, 50 kullanılabılır eğitim verisini atlas olarak kullandılar ve bunları bir metrik olarak yerleştirilmiş karşılıklı bilgileri kullanarak görünmeyen görüntülere kaydetmişlerdir [7].

Jia ve arkadaşları, sağlam bir kayıt, atlas seçimi ve yakınlaştırma sürecini içeren çoklu atlas tabanlı bir prostat bölütleme çerçevesi tasarlamışlardır [8].

Gao ve arkadaşları çok merkezli ve çok satıcı MRG prostat bölütlemesi için yerel görünüme özgü vokseller ağırlıklandırması ile çok atlaslı bir yaklaşım sunmuşlardır. Bu çoklu atlas teknikleri için en büyük zorluk görüntünün kayıdır [9].

Wu ve arkadaşları, prostatı bölümlere ayırmak için uzaysal olarak sürekli bir maksimum akış modeli önermişlerdir [10].

Mahapatra ve arkadaşları, tam otomatik bir prostat MR bölütlemesi gerçekleştirmek için rastgele orman ve süper piksel tabanlı grafik kesimlerinden yararlanmışlardır [11].

Tian ve arkadaşları, prostat MRG bölütlemesi için süper piksel/süpervokseller tabanlı grafik kesim çerçevelerini sunmuşlardır [12].

2.2. Derin Öğrenme Tabanlı Prostat Bölütlemesi Yöntemleri

Geleneksel prostat bölütlemesi yöntemleri ile karşılaştırıldığında derin öğrenme tabanlı prostat bölütlemesi yöntemlerinin çok daha üstün performans elde ettikleri görülmektedir.

Derin öğrenme tabanlı prostat segmentasyonu alanında Yan ve arkadaşları [13] 270 MRG prostat taramasından oluşan bir veri setinde Piramit Sahne Ayırıştırma Ağı'nın (PSAA) segmentasyon performansını Tam Bağlı Evrişimsel Sinir Ağı (TBESA) ve U-Net ile karşılaştırmıştır. Salvaggio ve arkadaşları [14] prostat MR görüntülerinde medyan lob büyümesi olan yüz üç hastada manuel ve derin öğrenme tabanlı ENet'in segmentasyon performanslarını karşılaştırmıştır. Brosch ve arkadaşları [15] kalp ve beyin gibi yapıların segmentasyonunda kullanılan önerilen model tabanlı segmentasyon, MRG prostat ve kardiyak segmentasyonunda topluluk U-net ağını içermektedir. Meyer ve arkadaşları [16] yüksek çözünürlüklü izotropik prostat segmentasyonu üretmek için ek tarama özelliklerini işleyen PROMISE 12 ve ProstateX veri kümelerinde anizotropik bir 3B çoklu akış DESA mimarisini test etmiştir. Anas ve arkadaşları [17] optimizasyonu geliştirmek için, tekrarlayan bir ağda artık bloklar kullanmışlardır. Önerilen mimari, gerçek zamanlı olarak prostat biyopsisi sırasında dinamik bir karar ağıdır. Ayrıca önerilen modele seyrek örnekleme ve yoğun katmanlar ekleyerek ağ ultrasondan kaynaklanan artefaktlara karşı güçlendirilmeye çalışılmıştır. Jia ve arkadaşları [18] kaba segmentasyon için Atlas kaydını önermiş ve iki farklı veri setinde MR görüntülerinin ince segmentasyonu için VGG-19 ağından kendi ağlarına aktarılan öğrenme tekniğini kullanmışlardır. Liu ve arkadaşları [19] bilgisayarlı tomografiden (CT) elde edilen prostat görüntülerini bölütlere ayırmak için bir DESA mimarisi önermiştir. Önerilen mimarinin test sonuçları, kurul onaylı doktorların sonuçlarıyla karşılaştırılmıştır. Abraham ve Nair [20] bir softmax sınıflandırıcı kullanarak seyrek yığılanmış otomatik kodlayıcı derin öğrenme ağı önermişlerdir. Bu çalışmada, prostat görüntülerindeki düşük düzeyli öznitelikler, Seyrek yığılı bir otomatik kodlayıcı kullanılarak yüksek düzey özniteliklere dönüştürülmüştür. Cheng ve arkadaşları [21] prostat görüntülerinin segmentasyonu için DESA tabanlı 3B yüzey rekonstrüksiyonu ve Hacimsel Bütünsel olarak Yuvalanmış Kenar Dedektörü (HBYKD) önermişlerdir. Zhou ve arkadaşları [22] düzlem içi çözünürlük ve mesafe arasındaki farkı dengelemek için çözünürlüğe duyarlı U şeklinde bir 3B derin öğrenme mimarisi önermişlerdir. Mimariye artık bloklar da eklenmiştir. Ayrıca, odak zarlarını ve ikili çapraz entropiyi birleştiren, her çağda mini parti

boyutuna duyarlı, durum bazında bir kayıp fonksiyonu önerilmiştir. Yu ve diğerleri [23] MR'dan elde edilen prostat görüntülerini otomatik olarak bölütlere ayırmak için komşu ve uzak konvolüsyonel katmanlar arasında karışık artık bağlantılara sahip hacimsel bir DESA mimarisi önermişlerdir. Mun ve arkadaşları [24] PROMISE 12 veri setinden elde edilen prostat MR görüntülerinin segmentasyonunda DESA tabanlı mimarilerin performansını puanlayan altı farklı metriği (Zar, Jaccard, Kosinüs Benzerliği, Çapraz Entropi, Hamming mesafesi, Öklid mesafesi) analiz etmiş ve karşılaştırmışlardır. He ve arkadaşları [25], MR'dan elde edilen 3B prostat görüntülerini bölütlere ayırmak için aktif şekil modelini (AŞM) geliştirerek DESA tabanlı bir mimari önermişlerdir. Tang ve arkadaşları [26] prostat görüntülerinin yarı otomatik segmentasyonu için, 3B MR görüntülerini 2B dilimlere ve tahmini komşu dilimlere ayırdılar. Modellerin performans ölçütleri için Bhattacharyya benzerliği ve aktif bant teorisi kullanılmıştır. Brosch ve arkadaşları [27] tıbbi görüntülerin segmentasyonu için organ sınırlarını tespit eden uyarlanabilir bir DESA mimarisi önermişlerdir. Önerilen model prostat görüntülerinin bölütlenmesinde test edilmiştir. Meyer ve arkadaşları [28] prostat bölütlemesinde kesinliği artırmak için eksenel, sagittal ve koronal MR görüntülerinden izotropik yüksek çözünürlüklü görüntüleri alan ve bölütlere ayıran bir 3B çoklu akış U-Net mimarisi önermişlerdir. Zhang ve arkadaşları [29] U-Net katmanlarındaki evrişimler sırasında bilgilerin kaybolabileceğini göz önünde bulundurarak Z şeklinde bir DESA mimarisi önermişlerdir. Ayrıca önerilen mimari için 2B yeniden boyutlandırmanın daha uygun olduğu belirtilmiştir. Jin ve arkadaşları [30] V-Net 3B'ye bir bikübik enterpolasyon algoritması ekleyerek MR prostat görüntülerinin bölütlenmesi için yeni bir yaklaşım önermişlerdir. Öcal ve Barışçı [31] prostat görüntülerinin bölütlenmesi için 3B ve 2B hacimsel DESA (V-Net) ağlarını birleştiren bir mimari önermişlerdir.

Bu bölümde literatürde prostat görüntülerinin bölütlemesiyle ilgili çeşitli veri setleri üzerinde yapılan çalışmalar hakkında özet bilgiler sunulmuştur. Prostat görüntülerinin bölütlemesi zorlu ve zaman alıcı bir süreçtir. Daha önceki yapılan çalışmalarda hem halka açık veri setinde hem de etik kurulu onayı ile hastanelerden alınan veri setlerinde yapılan çalışmalarda %92 zar katsayısı test puanının üzerine çıkılamamıştır. Bu çalışmada kullanılan iki farklı füzyon modeli ile prostat görüntülerinin bölütlemesindeki zorluklarla başa çıkılmaya çalışılmıştır.



3. MATERYAL VE YÖNTEM

Bu bölümde görüntü bölütlemesi yöntemleri, derin öğrenme mimarisinin detaylı incelemesi ve önerilen derin öğrenme modelleri hakkında detaylı bilgiler verilmiştir.

3.1. Görüntü Bölütleme Yöntemleri

Bölütleme genellikle görüntü analizinin ilk aşamasıdır. Görüntü bölütlemesi, bir görüntüyü her biri içerisinde farklı özelliklerin tutulduğu anlamlı bölgelere ayırmak olarak tarif edilebilir. Örneğin bu, görüntü içerisindeki benzer parlaklıklar olabilir ve bu parlaklıklar ilgili görüntünün farklı bölgelerindeki nesneleri temsil edebilir. Uygulamaya bağlı olarak değişebilen bu bölütlere (bölütler-elemanlar) başka bir örnek olarak; hava-yer fotoğrafında, yolda hareket eden araçları ve çevreyi yoldan ayırt edebilmek için bir bölütleme yapılabilir (Yolu çevreden ayırabilen bir bölütleme). Unutulmamalıdır ki, tüm görüntülere uygulanabilecek genel bir bölütleme yöntemi yoktur ve hiçbir bölütleme yöntemi mükemmel değildir. Başka bir deyişle, görüntü iyileştirme ve onarma problemlerinde olduğu gibi görüntü bölütlemesi için tasarlanan yöntemler ve bu yöntemlerin başarımları, görüntüden görüntüye ve uygulamaya dayalı olarak değişiklik arz eder. Ayrıca, Otomatik görüntü bölütlemesi görüntü işlemenin en zor işlemlerinden birisidir.

Görüntü bölütlemesi; R görüntüsünü $R_1, R_2, \dots, R_n$ bölgelerine bölme sürecidir. “Segmentasyon tamamlandığında Eş. 3.1. elde edilir.

$$\bigcup_{i=1}^n R_i = R \quad (3.1.)$$

Gri seviyeli görüntülerde bölütleme algoritmaları; gri seviye (parlaklık) değerlerinin süreksizlik ve benzerlik özelliğine dayandırılır.

Süreksizlik tabanlı bölütleme algoritmaları; izole nokta, ince çizgi veya resim kenarları gibi (gri seviye değerleri birden değişen) süreksizlikleri, düşük ve yüksek filtrelemedeki gibi benzer maskeler kullanarak tespit edebilmeye dayanır.

Benzerlik tabanlı bölütleme algoritmaları; ya eşikleme, bölgede büyüyen, ya da bölge bölme ve birleştirmeye dayanmaktadır. Görüntünün özelliğine göre çeşitli bölütleme yöntemleri vardır.


3.1.1. Eşikleme

En basit görüntü bölütleme yöntemi, eşikleme yöntemi olarak adlandırılır. Bu yöntem, gri tonlamalı bir görüntüyü ikili bir görüntüye dönüştürmek için bir kırpma seviyesine (veya bir eşik değerine) dayanır.

Bu yöntemin anahtarı eşik değerini seçmektir (veya çoklu seviyeler seçildiğindeki değerler). Endüstride azami entropi yöntemi, dengeli histogram eşiklemesi, hibrit eşiklemesi, Otsu yöntemi (maksimum değişkenlik) ve k-aracı kümelemesi gibi birçok popüler yöntem kullanılmaktadır [32].

Son zamanlarda, bilgisayarlı tomografi (BT) görüntülerinin eşiklenmesi için yöntemler geliştirilmiştir. Temel fikir, Otsu'nun yönteminden farklı olarak eşiklerin (yeniden inşa edilmiş) görüntü yerine radyograflardan türetilmiş olmasıdır [33, 34].

Yeni yöntemler, çok boyutlu bulanık kurallara dayalı doğrusal olmayan eşiklerin kullanımını önermiştir. Bu çalışmalarda, her bir pikselin bir bölütleme üyeliği konusundaki kararı, görüntü aydınlatma ortamı ve uygulamasına dayalı bulanık mantık ve evrimsel algoritmalarla elde edilen çok boyutlu kurallara dayanmaktadır [35]. Eşikleme örneği Resim 3.1.' de görülmektedir.



Resim 3. 1. Eşikleme örneği

3.1.2. Kümeleme metodu

K-means algoritması, bir görüntüyü K kümelerine bölmek için kullanılan yinelemeli bir tekniktir [38]. Temel algoritma şu şekildedir:

- K küme merkezleri, rastgele veya bazı sezgisel yöntemlere dayalı olarak seçilir, örneğin K-means ++
- Görüntüdeki her piksel, piksel ile küme merkezi arasındaki mesafeyi en aza indiren kümeye atanır.
- Küme merkezlerinde kümedeki tüm piksellerin ortalaması yeniden hesaplanır.
- Yakınsama elde edilene kadar 2. ve 3. adımlar tekrarlanır (yani, piksel kümelerini değiştirmez).

Bu durumda, mesafe piksel ile küme merkezi arasındaki kare veya mutlak farktır. Fark tipik olarak piksel rengine, yoğunluğuna, dokusuna ve konumuna veya bu faktörlerin ağırlıklı bir kombinasyonuna dayanır. K manuel, rastgele veya bir sezgisel tarama ile seçilebilir. Bu algoritmanın birleşmesi garanti edilir, ancak en uygun çözümü getirmeyebilir. Çözümün kalitesi, ilk kümesine ve K'nın değerine bağlıdır.

3.1.3. Hareket ve interaktif bölütleme

Hareket tabanlı bölütleme, bölütleme yapmak için görüntüdeki harekete dayanan bir tekniktir.

Fikir basittir: Bir çift görüntü arasındaki farklara bakılır. İlgili nesnenin hareket ettiği varsayılarak, farkın bu nesne olduğu bulunur. Bu fikri geliştirmek için, Kenney ve arkadaşları tarafından etkileşimli bölütleme önerilmiştir [37]. Bu çalışmada hareket tabanlı etkileşimli bölütleme için, gerekli hareket sinyalinin üretmek amacıyla nesneleri tetiklemek için bir robot algoritma kullanılmıştır. Etkileşimli bölütlemeyi, Dov Katz ve Oliver Brock tarafından önerilen etkileşimli algı çerçevesi takip etmektedir.

3.1.4. Sıkıştırma tabanlı metotlar

Sıkıştırma temelli yöntemler, optimal bölütlemenin, tüm veri bölütlemelerinde, kodlama uzunluğunu en aza indiren yöntem olduğunu kabul eder [38, 39]. Bu iki kavram arasındaki bağlantı (sıkıştırma temelli yöntem ve optimal bölütleme), bölütlemenin bir görüntüdeki kalıpları bulmaya çalışarak görüntüdeki herhangi bir düzenliği veriyi sıkıştırmak için kullanabilmektir. Metot her bölütü kendi dokusu ve sınır şekli ile açıklar. Bu bileşenlerin her biri bir olasılık dağılım fonksiyonu ile modellenmiştir ve kodlama uzunluğu aşağıdaki gibi hesaplanmaktadır:

- Sınır kodlaması, doğal görüntülerdeki bölgelerin düzgün bir kontura sahip olma eğiliminde olduğu gerçeğini artırır. Bu daha önce Huffman kodlaması tarafından bir görüntüdeki konturların fark zinciri kodunu kodlamak için kullanılır. Bu nedenle, pürüzsüz bir sınır, elde ettiği en kısa kodlama uzunluğudur.
- Doku, kayıplı sıkıştırma ile kodlanır. Ancak burada model, verilen verinin uzunluğu, modelin entropisinin örnek sayısı ile çarpımıyla yaklaşık olarak hesaplanır. Her bölgedeki doku, entropisi kapalı bir form ifadesine sahip olan çok değişkenli normal bir dağılım tarafından modellenmiştir. Bu modelin ilginç bir özelliği, tahmin edilen entropinin tepeden verinin gerçek entropisini sınırlamasıdır. Bunun nedeni, verilen ortalama ve kovaryansa sahip tüm dağılımlar arasında, normal dağılımın en büyük

entropiye sahip olmasıdır. Dolayısıyla, gerçek kodlama uzunluğu, algoritmanın en aza indirmeye çalıştığından daha fazla olamaz.

3.1.5. Histogram tabanlı metotlar

Histogram tabanlı yöntemler, diğer görüntü bölütleme yöntemleriyle karşılaştırıldığında çok etkilidir. Çünkü tipik olarak piksellerden yalnızca bir kez geçmeleri yeterlidir. Bu teknikte, görüntüdeki tüm piksellerden bir histogram hesaplanır ve görüntüdeki kümeleri bulmak için histogramdaki tepe noktaları ve vadiler kullanılır [40]. Renk veya yoğunluk da ölçü olarak kullanılabilir.

Bu tekniğin iyileştirilmesinin yolu, histogram yöntemini, görüntüdeki kümeleri daha küçük kümelere bölmek için tekrar tekrar uygulamaktır. Bu işlem, maksimum özellik küme sayısı oluşana kadar daha küçük kümelere bölünerek tekrarlanır [41, 42].

Histogram arama yönteminin bir dezavantajı, görüntüdeki önemli tepe noktaları ve vadileri tespit etmenin zor olabileceğidir.

3.1.6. Kenar algılama

Kenar algılama, görüntü işleme içinde kendi başına iyi gelişmiş bir alandır. Bölge sınırları ve kenarları birbiriyle yakından ilişkilidir. Çünkü bölge sınırlarındaki yoğunlukta keskin bir ayarlama gerektirir. Bu nedenle kenar algılama teknikleri, başka bir bölütleme tekniğinin temeli olarak kullanılmıştır.

Kenar tespiti (edge detection) ile belirlenen kenarlar çoğu zaman kesilir. Bununla birlikte, bir nesneyi bir görüntüden ayırmak için kapalı bölge sınırlarına ihtiyaç vardır. İstenen kenarlar, bu tür nesneler veya mekansal taksonlar arasındaki sınırlardır [43, 44].

Mekansal taksonlar, hiyerarşik iç içe geçmiş bir sahne mimarisi içindeki soyutlama seviyelerinde yer alan net bir piksel bölgesinden oluşan bilgi granülleridir [45, 46]. Bu bilgi granülleri figür zemininin Gestalt psikolojik tanımlarına benzerler ancak ön plan, nesne grupları, nesneler ve göze çarpan nesne parçalarını içerecek şekilde genişletilirler. Mekansal takson bölgesine, bir silüete uygulandığı gibi, kenar tespit yöntemleri uygulanabilir. Bu

yöntem özellikle, ayrılan kenar, aldatıcı bir konturun parçası olduğunda kullanışlıdır [47, 48].

3.1.7. Çift kümele metodu

Bu yöntem, görüntünün üç özelliğinin bir birleşimidir. Bunlar görüntünün histogram analizine dayanan bölümü, kümelerin (nesnelerin) yüksek kompaktlığı ve sınırlarının yüksek gradyanlarıdır [49].

3.1.8. Bölge-büyütme metodu

Bölge yetiştirme yöntemleri temel olarak bir bölgedeki komşu piksellerin benzer değerlere sahip olduğu varsayımına dayanır. Ortak prosedür, bir pikseli komşularıyla karşılaştırmaktır. Bir benzerlik kriteri karşılanırsa piksel, bir veya daha fazla komşusu ile aynı kümeye ait olacak şekilde ayarlanabilir. Benzerlik kriterinin seçimi önemlidir ve sonuçlar her durumda gürültüden etkilenir.

Bölge büyütme yöntemlerinden birisi, ekilen bölge yetiştirme yöntemidir. Bu yöntem, görüntü ile birlikte girdi olarak bir dizi tohum alır. Tohumlar, bölünecek nesnelerin her birini işaretler. Bölgeler tüm ayrılmamış komşu piksellerin bölgelerle karşılaştırılmasıyla yinelenerek büyütülür. Bir pikselin yoğunluk değeri ile bölgenin ortalaması olan delta arasındaki fark, benzerliğin bir ölçüsü olarak kullanılır. Bu şekilde ölçülen en küçük farkı olan piksel ilgili bölgeye atanır. Bu işlem, tüm pikseller bir bölgeye atanana kadar devam eder.

Bir diğer bölge büyütme yöntemi ise, tohumsuz bölge yetiştirme yöntemidir. Açık tohum gerektirmeyen değiştirilmiş bir algoritmadır. Tek bir bölge ile başlar. Burada seçilen piksel son bölütlemeyi belirgin şekilde etkilemez. Her yinelemede, komşu pikselleri, ekilmiş bölge büyümesiyle aynı şekilde dikkate alır.

3.1.9. Model tabanlı bölütleme

Modele dayalı yaklaşımların merkezi varsayımı, ilgilenilen yapıların belirli bir modele yönelme eğiliminde olduğu yönündedir. Bu nedenle, kişi şekli ve değişkenliğini karakterize eden olasılıksal bir model arayabilir. Bir görüntüyü segmentlere ayırırken, bu modeli öncelikli olarak kullanmakla ilgili kısıtlamalar getirilebilir [49]. Böyle bir görev eğitim örneklerinin ortak bir poza kaydedilmesini, kayıtlı örneklerin varyasyonunun olasılıkla gösterilmesini ve model ile görüntü arasındaki istatistiksel çıkarımı içerebilir. Literatürdeki model tabanlı bölütleme için diğer önemli yöntemler arasında aktif şekil modelleri ve aktif görünüm modelleri bulunmaktadır.

3.1.10. Çok ölçekli bölütleme

Ölçek-uzayı bölütlemeyi veya çoklu ölçek bölütlemeyi, birden fazla düzleştirme ölçeğindeki görüntü tanımlayıcılarının hesaplanmasına dayanarak, sinyal ve görüntü bölütlemeyi için genel bir çerçevedir.


3.1.11. Yarı-otomatik bölütleme

Bu tür bölütlemelerde, kullanıcı, fare tıklamaları ile ilgilenilen bölgeyi gösterir ve algoritmalar, görüntünün kenarına en iyi uyan yolu gösterecek şekilde uygulanır. SIOX, Livewire, Akıllı Makas veya IT-SNAPS gibi teknikler bu tür bölütlemelerde kullanılır. Alternatif bir yarı-otomatik bölütleme türünde, algoritmalar kullanıcı tarafından seçilen veya daha önce olasılıklarla belirlenmiş bir uzamsal takson (yani ön plan, nesne grubu, nesne veya nesne kısmı) döndürür [50, 45].

3.1.12. Anlamsal bölütleme

Anlamsal bölütleme, kabadan ince çıkarımlara doğru ilerlemenin doğal bir adımıdır. Bütün girdi için bir tahmin yapmaktan oluşan sınıflandırmada orijinin yeri saptanabilmektedir. Bir sonraki adım, sadece sınıfları değil, aynı zamanda bu sınıfların uzaysal konumlarıyla ilgili ek bilgi sağlayan yerelleştirme / tespit etmedir.

Son olarak, anlamsal bölütleme, her piksel için etiketler çıkaran yoğun tahminler yaparak ince taneli çıkarımlar elde etmektedir, böylece her piksel, etrafındaki nesne cevher bölgesinin sınıfı ile etiketlenir [51]. Resim 3.2.' de anlamsal bölütleme örneği gösterilmektedir [52].



Resim 3.2. Anlamsal (semantik) bölütleme

Bölge tabanlı bölütleme

Bölge tabanlı yöntemler genellikle, bir görüntüden serbest biçimli bölgeleri çıkaran ve bunları tanımlayan ve ardından bölge temelli sınıflandırmayı izleyen “tanıma kullanarak bölütleme” yolunu izlemektedir. Test zamanında, bölge tabanlı tahminler, genellikle onu içeren en yüksek puanlama bölgesine göre bir pikselin etiketlenmesiyle piksel tahminlerine dönüştürülür [51, 52].

Tamamen evrişimli ağ-tabanlı anlamsal bölütleme

Tamamen Evrişimli Ağ (TEA), bölge önerilerini çıkarmadan piksellerden piksellere eşlemeyi öğrenir. TEA ağ sistemi, klasik ESA (Evrişimli Sinir Ağı)’nın bir uzantısıdır. Ana fikir, klasik ESA’nın isteğe bağlı girdiler olarak girdiler almasını sağlamaktır. ESA’ların yalnızca belirli büyüklükteki girişler için etiket kabul etme ve üretme kısıtlaması, sabitlenmiş tam bağlı katmanlardan gelir. Bunların aksine, TEA’lar, yalnızca isteğe bağlı, çok boyutlu girdiler hakkında tahminlerde bulunma yeteneği veren evrişimli ve havuzlayıcı katmanlara sahiptir [51, 52].

Zayıf denetimli anlamsal bölütleme

Semantik bölütlemedeki ilgili yöntemlerin çoğu, piksel bazında bölütleme maskeleri olan çok sayıda görüntüye dayanır. Bununla birlikte, bu maskeleri manuel olarak açıklamak oldukça zaman alıcı, sinir bozucu ve ticari olarak pahalıdır. Bu nedenle, kısa bir süre önce, açıklamalı sınırlayıcı kutular kullanarak anlamsal bölütleme yerine getirmeye adanmış bazı denetlenmiş yöntemler önerilmiştir. Resim 3.3. 'de Zayıf denetimli Anlamsal Bölütleme örneği gösterilmektedir [51, 52].



Resim 3.3. Sınırlayıcı kutu (bounding box) örneği

3.2. Prostat Kanseri Tanılama Yaklaşımları

Doktorlar kanseri bulmak veya teşhis etmek için birçok test kullanır. Ayrıca kanserin başladığı yerden vücudun başka bir bölgesine yayılıp yayılmadığını öğrenmek için testler yaparlar. Bu yayılma durumuna metastaz denir. Örneğin, görüntüleme testleri kanserin yayılıp yayılmadığını gösterebilir. Görüntüleme testleri vücudun iç kısımlarını gösterir. Doktorlar ayrıca hangi tedavilerin en iyi sonucu verebileceğini öğrenmek için testler yapabilir.

Çoğu kanser türü için, biyopsi doktorun vücudun bir bölgesinde kanser olup olmadığını bilmesinin tek kesin yoludur. Bir biyopside, doktor laboratuvarında test etmek için küçük bir doku örneği alır. Biyopsi mümkün değilse, doktor tanı koymaya yardımcı olacak başka testler önerebilir, ancak bu durum prostat kanseri için nadirdir. Örneğin, bir biyopsi yapmayı zorlaştıran bir başka tıbbi problem olduğunda veya bir kişinin çok yüksek bir Prostat

Spesifik Antijen (PSA) seviyesine ve kanseri belirten bir kemik taramasına sahip olduğunda biyopsi yapılamaz.

3.2.1. Dijital rektal muayene

Sağlık hizmeti sağlayıcısı rektuma eldivenli bir parmak sokacak ve prostattaki sert, topaklı veya anormal alanlar hissedecektir. Testin tamamlanması yalnızca birkaç dakika sürer. Test sırasında hafif ve anlık bir rahatsızlık hissedilebilir. İşlem prostatta önemli bir ağrıya veya hasara neden olmaz.

3.2.2. Prostat spesifik antijen testi

Prostat spesifik antijen (PSA) seviyelerini kontrol etmek için tüm erkekleri rutin olarak taramak uluslararası tıp camiasındaki tartışmalı bir konudur. Bunun birkaç nedeni vardır. PSA testleri güvenilirmezdir ve hiçbir kanser olmadığında prostat kanseri tanısı önerebilir (yanlış-pozitif sonuç). Ayrıca, prostat kanserli erkeklerin %15'inde normal PSA seviyelerine (yanlış negatif sonuç) sahiptir, bu yüzden birçok vaka kaçırılabilir. PSA testi tedavi gerektiren agresif prostat kanseri bulabilir, ancak hiçbir zaman semptomlara neden olmayacak veya ömrü kısaltmayacak şekilde yavaş büyüyen kanseri de bulabilir [51].

3.2.3. Transrektal ultrasonografi

Ultrasonografi aletinin makattan yerleştirilen bölümüyle prostatın içyapısı incelenir. Prostat dokusundan yansıyan ses dalgaları bir bilgisayar programı ile eşitlenerek ekranda 'sonogram' olarak adlandırılan resme dönüştürülür. Bu yöntem sayesinde prostatın büyüklüğü ve içyapısı hakkında daha detaylı bilgi elde edinebilmek mümkündür. Resim 3.4., TRUS ile çekilmiş bir prostat görüntüsü örneğidir. Soldaki resimde görülen siyah bölge kist olarak etiketlenmiştir.



Resim 3.4. Transrektal ultrasonografi örneği

3.2.4. Manyetik rezonans görüntüleme ve/veya bilgisayarlı tomografi


Bilgisayarlı tomografi (BT veya CAT) taraması, farklı açılardan çekilen röntgenleri kullanarak vücudun içinde 3 boyutlu bir resim oluşturur. Bir bilgisayar bu görüntüleri herhangi bir anormallik veya tümör gösteren ayrıntılı, kesitsel bir görünümde birleştirir. BT yöntemi tümörün boyutunu ölçmek için kullanılabilir. Bazen, görüntü üzerinde daha iyi ayrıntı sağlamak için taramadan önce hastaya kontrast madde olarak adlandırılan özel bir boya verilir.

Pozitron emisyon tomografi (PET) veya PET-CT taraması, vücudun içindeki organların ve dokuların resimlerini oluşturmanın bir yoludur. Hastanın vücuduna az miktarda radyoaktif madde enjekte edilir. Bu madde en çok enerjiyi kullanan hücreler tarafından alınır. Kanser aktif olarak enerji kullanmaya meyilli olduğu için radyoaktif maddenin daha fazlasını emer. Tomografi cihazı daha sonra bu maddeyi vücudun iç görüntülerini üretmek için tespit eder. Manyetik rezonans görüntüleme (MRG) taraması, vücudun ayrıntılı görüntülerini elde etmek için X-ışınları yerine manyetik alanları kullanır. MRG, tümörün boyutunu ölçmek için kullanılabilir. Daha net bir resim oluşturmak için taramadan önce hastaya, kontrast madde adı verilen özel bir boya verilir. Bu boya hastanın damarına enjekte edilebilir veya yutmak için sıvı olarak verilebilir [52].

3.3. Yapay Sinir Ağı

Algılayıcıların ardındaki fikir, nöronların dentiritler, hücre gövdeleri ve aksonlar gibi belirli kısımlarını, iç çalışmaları hakkında sahip olduğumuz sınırlı bilginin basitleştirilmiş matematiksel modellerini kullanarak Şekil 3.1.' de görüldüğü gibi taklit etmektir. Bu taklit etme işlemine anoloji de denilmektedir.


Biyolojik nöronlarda dentiritlerden alınan sinyaller aksona gönderilmektedir. Akson kanalıyla giden sinyal akson terminalleri yoluyla diğer nöronlar için başka bir girdi olarak kullanılabilir. Bazı sinyaller diğerlerinden daha önemlidir ve bazı nöronların daha kolay ateşlenmesini tetikleyebilmektedir. Nöronlar arası bağlantılar daha güçlü veya daha zayıf hale gelebilmekte ve yeni bağlantılar ortaya çıkabilirken diğerleri ortadan kalkabilmektedir. Bu sürecin çoğunu, ağırlıklı giriş sinyallerinin bir listesini alan ve bu ağırlıklı girişlerin toplamı belirli bir önyargıya ulaşırsa bir tür sinyal veren bir işlev bularak taklit edebiliriz. Bu basitleştirilmiş model, nöronlar arasındaki bağlantıların (dentiritler veya aksonlar) oluşturulmasını veya yok edilmesini taklit etmemektedir. Aynı zamanda bu model sinyal zamanlamasını da göz ardı etmektedir. Ancak, bu kısıtlı model tek başına basit sınıflandırma görevleriyle çalışacak kadar güçlüdür.



Şekil 3. 1. Biyolojik ve yapay sinir ağı temsili

Yapay Sinir Ağlarının (YSA) işleyişi, sinir sistemimizdeki nöronların çalışma şekline benzemektedir. YSA Şekil 3.2.' de görüldüğü gibi üç katmandan oluşmaktadır. Bunlar giriş katmanı, gizli katman ve çıkış katmanıdır.

Giriş katmanı, çeşitli metinler, sayılar, ses dosyaları, görüntü pikselleri vb. biçiminde giriş bilgilerini alan YSA' nın ilk katmanıdır. YSA' nın ikinci bölümü orta katman olarak da anılan gizli katmanlardır. Bu gizli katmanlar, girdi verileri üzerinde çeşitli türlerde matematiksel hesaplamalar gerçekleştirir ve bu girdileri oluşturan desen parçalarını tanır. Çıktı katmanında ise orta katmanın yaptığı titiz hesaplamaların sonucu bir çıktı olarak elde edilmektedir.



Şekil 3. 2. Yapay sinir ağı mimarisi

3.4. Evrimsel Sinir Ağları

Evrimsel Sinir Ağı'nın(ESA) önerilmesinden geniş alanda uygulamasına kadar, teorik olarak ispatlama, deneysel geliştirme, büyük ölçekli uygulama ve derinlemesine araştırma aşamalarından geçilmiştir. İnsan görsel bilgisinde alıcı alanların ve nörobilişsel makinelerin önerisi, teorinin embriyonik aşamasında önemli bir teori olmaktadır. 1962'de Hubel ve arkadaşları [53] biyolojik araştırmalar yoluyla beyindeki görsel bilginin retinadan iletilmesinin çok seviyeli alıcı alan uyarımı yoluyla gerçekleştirildiğini göstermiştir. Bu, alıcı alan kavramının önerilen ilk örneğidir. 1980'de Fukushima [54], alıcı alanlar kavramına dayanan bir nörobilişsel makine önermiştir. Bu öneri evrimsel sinir ağlarının ilk uygulama ağı olarak kabul edilmektedir. 1998 yılında, Lécun ve arkadaşları [55], deneysel geliştirme


aşamasına giren ağı denetimli eğitimi için gradyan tabanlı bir geri yayılım algoritması kullanan LeNet5'i önermiştir. Akademik çevrenin evrişimli sinir ağlarına olan ilgisi de LeNet5 ağına önerisiyle başlamış ve el yazısı tanıma başarıyla uygulanmıştır. LeNet5 ağından sonra evrişimli sinir ağı deneysel geliştirme aşamasına geçmiştir. Derin öğrenme uygulamalarında evrişimli sinir ağlarının konumu 2012 yılında AlexNet ağına tanıtılmasıyla yeniden belirlenmiştir. Krizhevsky ve arkadaşları tarafından [56] önerilen AlexNet, ImageNet' in eğitim setinin görüntü sınıflandırmasında 2012 yılında en başarılı mimari olarak evrişimli sinir ağlarını bilgisayarla görüntü tanıma bir araştırma nesnesi haline getirmiştir.

3.5. Derin Evrişimsel Sinir Ağları

Derin Evrişimsel Sinir Ağları (DESA) veya derin öğrenme, makine öğrenimi ve yapay zekanın yükselişinde makine öğrenmenin bir alt dalı olarak ön plana çıkmıştır. Bu ağlar, insan beyninin öğrenme sürecini matematiksel olarak modelleyerek derin sinir ağlarını kullanmaktadır ve denetimsiz bir şekilde büyük ölçekli verilerden (ses, metin, görüntüler vb.) özellikler çıkarmaktadır [57]. Bir sinir ağı birçok nörondan oluşmaktadır. Her nöron, küçük bir bilgi işlem birimi olarak kabul edilmektedir. Nöronlar, tüm DESA' yı oluşturmak için belirli bir şekilde birbirine bağlanmıştır. Sinir ağlarının ortaya çıkışı, uçtan uca görüntü işlemeyi mümkün kılmaktadır. Ağı gizli katmanları birden çok katmana dönüştüğünde oluşan mimari derin öğrenme olarak adlandırılmaktadır. Derin sinir ağının eğitimindeki zorluğu çözmek için, katman katman başlatma ve gruplama gereklidir. Bu da derin öğrenmeyi diğer yapay sinir ağlarından ayırt edici bir özelliktir. Bilgisayarlı görüntüleme alanında, derin öğrenme esas olarak veri boyutunun azaltılması, bölütleme, sınıflandırma, el yazısı sayı tanıma, desen tanıma ve diğer birçok alanda kullanılmaktadır. Görüntü tanıma, görüntü onarımı, görüntü bölütleme, nesne takibi, sahne analizi gibi alanlarda çok yüksek başarılar göstermektedir [58].

Derin öğrenme yöntemleri denetlenebilir, yarı denetlenebilir veya denetlenemez olarak sıralanabilmektedir [56, 59, 60]. DESA yönteminde, makine öğrenme yönteminden farklı olarak özellikler direkt olarak veriden öğrenilir. Fakat makine öğrenmesinde özellikler manuel olarak verilir. Şekil 3.3.' de temel derin öğrenme mimarisi görülmektedir. Şekil 3.3.' de görüldüğü gibi görüntüler matris formunda sayısal değerlere dönüştürülerek Giriş Katmanı' na beslenir. Burada yuvarlak şekiller yapay nöronları ve aralarındaki bağlantılar

ağırlıkları ifade etmektedir. Giriş değerleri ağırlık matrisleriyle çarpılarak Gizli Katman'lara beslenir. Daha sonra çıkış katmanında girişten beslenen değerler hakkında bir sonuca varılıp kayıp hesaplanarak ağırlıklar yeniden güncellenmektedir.



Şekil 3. 3. Derin öğrenme mimarisi

Modern derin öğrenme modellerinin çoğu, yapay sinir ağlarına, özellikle Evrimsel Sinir Ağlarına (ESA) dayanmaktadır, ancak bunlar aynı zamanda derin inanç ağlarındaki düğümler ve derin Boltzmann makinelerinde bulunan düğümler gibi derin üretken modellerde katman halinde düzenlenmiş gizli değişkenleri de içerebilir [60].

Derin öğrenmede, her seviye girdi verilerini biraz daha soyut ve kompozit bir gösterime dönüştürmeyi öğrenir. Bir görüntü tanıma uygulamasında, ham girdi bir piksel matrisi olabilir; birinci temsil katmanı pikselleri soyutlayabilir ve kenarları kodlayabilir; ikinci katman kenar düzenlemelerini oluşturabilir ve kodlayabilir; üçüncü katman bir burnu ve gözleri kodlayabilir ve dördüncü katman görüntünün bir yüz içerdiğini algılayabilir. Daha da önemlisi, derinlemesine bir öğrenme süreci, hangi özellikleri hangi seviyede kendi başına en uygun şekilde yerleştireceğini öğrenebilir. (Elbette bu, elle ayarlama ihtiyacını tamamen ortadan kaldırmaz; örneğin, değişen sayıda katman ve katman boyutu farklı derecelerde soyutlama sağlayabilir.) [56, 62].


Derin öğrenme mimarilerinde her bir katman bir önceki katmandan aldığı girdiyi lojistik regresyona tabi tutarak ileri katmanlara doğru yayar. Her bir algılayıcının (Perceptron) hareket geçmesi için beyindeki akson tepeciklerinin yerini alan aktivasyon fonksiyonları (Softmax, ReLU, LeakyReLU, SeLU, Sigmoid, Tanjant Hiperbolik v.b.) ve hataların

düzletildiği geriye yayılım-optimizasyon algoritmaları (Adam, Nadam, Stochastic Gradient Descent (SGD), RMSprob, Adadelata, Adagrad v.b.) kullanılır. Derin öğrenme modeli veriler üzerinden eğitilmesi ve modelin görüntüleri tanımadaki başarısının test edilmesi olmak üzere iki aşamada eğitimini tamamlar.

3.5.1. Evrişim işleminin gerçekleştirilmesi

ESA'ların çalışmasına geçmeden önce, bir görüntünün ne olduğu ve nasıl temsil edildiği gibi temel bilgileri ele alınabilir. Bir RGB görüntüsü, üç düzleme sahip bir piksel değerleri matrisinden başka bir şey değildir, oysa gri tonlamalı bir görüntü aynıdır ancak tek bir düzlemi vardır.

Şekil 3.4.'de görüldüğü gibi 5x5 boyutundaki giriş verisindeki 3x3'lük piksel grubu 3x3'lük çekirdek(kernel) denilen bir ağırlık matrisi ile çarpılmaktadır. Her bir pikselin karşılık gelen ağırlık matrisi ile çarpımından elde edilen sonuçlar toplanarak evrişimsel özellik için bir sayı değeri elde edilmektedir. Elde edilen bu sayı değeri tekrar işlenmek için bir sonraki gizli katmana aktarılmaktadır.




Şekil 3. 4. Evrişim işlemi

3.5.2. Havuzlama katmanı

Evrişim Katmanına benzer şekilde, Havuzlama katmanı, evrişimli özelliğin uzamsal boyutunu küçültmekten sorumludur. Bu, boyutları küçülterek verileri işlemek için gereken hesaplama gücünü azaltmaktır. Havuzlama katmanı, genellikle evrişim katmanlarından sonra kullanılmaktadır. Bazı durumlarda ESA'nın çıkış kısmı olan tam bağlı katmanlar arasında da havuzlama katmanı kullanılabilir. Havuzlama katmanında, havuz boyutu ve adım (stride) değeri olmak üzere 2 parametre vardır. Şekil 3.5.'de gösterildiği gibi ortalama havuzlama ve maksimum havuzlama olmak üzere iki tür havuzlama vardır.

Maksimum Havuzlama' da yaptığımız şey, çekirdeğin kapsadığı görüntünün bir kısmından bir pikselin maksimum değerini bulmaktır. Maksimum Havuzlama ayrıca Gürültü Bastırıcı olarak da çalışır. Gürültülü aktivasyonları tamamen ortadan kaldırır ve ayrıca boyutsallık azaltma ile birlikte gürültü giderme gerçekleştirir.

Öte yandan, Ortalama Havuzlama, görüntünün, çekirdeğin kapsadığı kısmından tüm değerlerin ortalamasını döndürmektedir. Ortalama Havuzlama, bir gürültü bastırma mekanizması olarak basitçe boyutsallık azaltma gerçekleştirmektedir. Dolayısıyla, Maksimum Havuzlama, Ortalama Havuzlama'dan çok daha iyi performans göstermektedir.



Şekil 3. 5. Havuzlama çeşitleri

3.5.3. Derin öğrenme modellerinde kullanılan hiper parametreler

Derin öğrenme modeli, verilerden öğrenilmesi gereken bir dizi parametreye sahip bir matematiksel formülün tanımıdır. Matematiksel model yoluyla verilere model uydurma derin öğrenmenin en önemli noktasıdır. Bu, model eğitimi olarak bilinen bir süreç aracılığıyla yapılmaktadır. Başka bir deyişle, bir modeli mevcut verilerle eğiterek modelin parametreleri verilere uygun hale getirilmektedir.

Ancak, düzenli eğitim sürecinden doğrudan öğrenilemeyecek başka parametre türleri de vardır. Bu parametreler, modelin karmaşıklığı veya ne kadar hızlı öğrenmesi gerektiği gibi "üst düzey" özelliklerini ifade eder. Bunlara hiper parametreler denir. Hiper parametreler genellikle asıl eğitim süreci başlamadan önce düzenlenmektedir.


Öğrenme oranı

Spesifik olarak, öğrenme hızı, genellikle 0,0 ile 1,0 arasında küçük bir pozitif değere sahip sinir ağlarının eğitiminde kullanılan yapılandırılabilir bir hiper parametredir. Öğrenme oranı, modelin probleme ne kadar çabuk adapte olduğunu kontrol eder. Her güncellemede ağırlıklarda yapılan daha küçük değişiklikler göz önüne alındığında, daha küçük öğrenme oranları daha fazla eğitim dönemi gerektirirken, daha büyük öğrenme oranları hızlı değişikliklerle sonuçlanır ve daha az eğitim dönemi gerektirir. Çok büyük bir öğrenme hızı, modelin çok hızlı bir şekilde optimal olmayan bir çözüme yakınsamasına neden olabilirken, çok küçük bir öğrenme hızı sürecin tıkanmasına neden olabilmektedir. Derin öğrenme sinir ağlarını eğitmenin zorluğu, öğrenme oranının dikkatlice seçilmesini içerir. Model için en önemli hiper parametre olabilir.

Piksel ekleme

Piksel ekleme(padding), bir derin öğrenme ağının evrimsel filtreler tarafından işlenirken bir görüntüye eklenen piksel miktarını ifade ettiğinden, evrimsel sinir ağlarıyla ilgili bir terimdir. Örneğin, bir derin öğrenme ağındaki piksel ekleme(padding) sıfıra ayarlanırsa, eklenen her piksel değeri sıfır değerinde olmaktadır. Bununla birlikte, sıfır dolgu bire ayarlanırsa, görüntüye sıfır piksel değerine sahip bir piksel kenarlığı eklenmektedir.

Piksel ekleme, evrişimli bir sinir ağının bir görüntüyü işlediği alanı genişleterek çalışmaktadır. Evrişimsel filtreler, görüntü boyunca hareket eden, her pikseli tarayan ve verileri daha küçük veya bazen daha büyük bir biçime dönüştüren sinir ağı filtresidir. Evrişimsel filtrenin görüntünün tümünü kapsaması için görüntünün kenarlarına Şekil 3.6.'da görüldüğü gibi pikseler eklenir. ESA tarafından işlenen bir görüntüye piksel eklemek, görüntülerin daha doğru analizine olanak tanımaktadır.




Şekil 3. 6. Piksel Ekleme Yöntemi

Kaydırma

Kaydırma (Stride), evrişimli sinir ağlarının veya görüntülerin ve video verilerinin sıkıştırılması için ayarlanmış sinir ağlarının bir bileşenidir. Kaydırma, görüntü veya video üzerindeki hareket miktarını değiştiren sinir ağının filtresinin bir parametresidir.


Örneğin, bir sinir ağının adımı 1'e ayarlanırsa, filtre bir seferde bir piksel veya birim hareket eder. Filtrenin boyutu, kodlanmış çıktı hacmini etkiler, bu nedenle adım, genellikle bir kesir veya ondalık sayı yerine bir tam sayıya ayarlanır. Kaydırma yönteminde Şekil 3.7.' de olduğu gibi, adım veya hareket arttıkça elde edilen çıktı daha küçük olacaktır. Kaydırma, çıktı katmanında boyutun en aza indirilmesine izin vermek için görüntünün çerçevesine boşluk veya sıfır pikseler ekleyen özellik olan dolgu ile birlikte çalışan bir parametredir.



Şekil 3. 7. Kaydırma (stride) yöntemi

Yığın normalleştirme

Yığın Normalleştirme (YN), katmanlar arası çıktıları bir sinir ağının normalleştirme adı verilen standart bir biçimine dönüştüren denetimli bir öğrenme tekniğidir. Bu yöntem, sonraki katman tarafından daha verimli bir şekilde işlenmek üzere önceki katmanın çıktısının dağılımını etkin bir şekilde sıfırlamaktadır. Yığın Normalleştirme, çok yüksek veya çok düşük değerler yerine, değerlerin belirli bir aralıkta olmasını sağlar ve her katmanın diğerlerinden bağımsız olarak öğrenmesine izin verir. Böylelikle, bu yöntem sayesinde modelin daha hızlı öğrenmesi sağlanır. Yığın Normalleştirme Şekil 3.8.' de görülmektedir.




Şekil 3. 8. Yığın normalleştirme

Grup normalleştirme

Grup Normalleştirme (GN), Örnek Normalleştirme ve Katman Normalleştirme arasında bir orta yoldur. Kanalları farklı gruplar halinde düzenler ve Yükseklik ve Genişlik (H, W)

eksenleri boyunca ve bir grup kanal boyunca aritmetik ortalama(μ_i) ve standart sapmayı (σ_i) hesaplar. Burada S_i , x_i ile aynı giriş özelliğinde ve aynı kanal grubunda bulunan katsayılar kümesidir. GN, Şekil 3.9.' da görülmektedir.



Şekil 3. 9. Grup normalleştirme

Mini-yığın boyutu

Teorik olarak, Mini-yığın boyutunun seçimi çoğunlukla hesaplama dayalıdır. Mini-yığın boyutu daha büyük olduğunda, paralel mimarilerin kullanılması nedeniyle güncellemeler daha verimli bir şekilde hesaplanabilmektedir. Mini-yığın boyutu daha küçük olduğunda daha fazla güncelleme yapılabilmektedir. Genelleme/test performansını etkilememesi gerektiğinden, Mini-yığın boyutu diğer hiper parametrelerden ayrı olarak optimize edilebilmektedir (örneğin, momentum dışında diğer hiper parametreler optimize edilirken önce ayarlanabilir ve sonra sabitlenebilir).

Adım sayısı

Adım sayısı, öğrenme algoritmasının tüm eğitim veri kümesi boyunca çalışacağı sayıyı tanımlayan bir hiper parametredir. Adım sayısının kullanılması, eğitim veri kümesindeki her bir örneğin dahili model parametrelerini güncelleme fırsatına sahip olduğu anlamına gelmektedir. Bir adımsayı, bir veya daha fazla gruptan oluşur. Örneğin, yukarıda olduğu gibi, bir kümeye sahip bir adıma toplu gradyan iniş öğrenme algoritması denmektedir. Her bir döngünün eğitim veri kümesi üzerinde ilerlediği adımların sayısı üzerinden bir for-döngüsü düşünebilir. Bu for-döngüsü içinde, bir yığının belirtilen "yığın boyutu" numune

sayısına sahip olduđu, her numune serisi üzerinde yinelenen başka bir iç içe for-loop vardır. Adımların sayısı temel olarak büyüktür, genellikle yüzlerce veya binlercedir ve öğrenme algoritmasının modelden kaynaklanan hata yeterince minimize edilene kadar çalışmasına izin verilmektedir.

Aktivasyon fonksiyonu

Beyindeki akson tepeciklerinden analogi yapılarak elde edilen aktivasyon fonksiyonu, küçük girişler için küçük bir değer üretmektedir. Eğer girdi değerleri belirli bir eşiğı aşarsa daha büyük bir değer veren bir fonksiyondur. Girişler yeterince büyükse, aktivasyon fonksiyonu bir çıktı üretmektedir. Girdi değerleri yeterince büyük değilse hiçbir çıkış değeri üretmez. Başka bir deyişle, bir aktivasyon fonksiyonu bir değerin kritik sayıdan büyük olup olmadığını kontrol eden bir kapı gibidir.

Aktivasyon fonksiyonları, evrişimli sinir ağlarına doğrusal olmama (non-linearity) ekleyerek sinir ağlarının güçlü işlemleri öğrenmesine izin verdiği için yararlı olmaktadır. Aktivasyon fonksiyonları ileri beslemeli bir sinir ağından kaldırılacak olsaydı, tüm ağ girişinde basit bir doğrusal işlem veya matris dönüşümü olarak tekrar girdiler tekrar çarpılır ve görüntü işleme gibi karmaşık ve zorlu işlemler yerine getirilmesi mümkün değildir.

Veri biliminde en çok kullanılan aktivasyon fonksiyonları, doğrultulmuş doğrusal birim (ReLU) fonksiyonu, lojistik sigmoid fonksiyonu, tanjant hiperbolik fonksiyonlarıdır.

Ağırlık başlatıcılar

Bir evrişimli sinir ağı kurarken ilk olarak göz önünde bulundurulacak adım, parametrelerin başlatılmasıdır. Eğer parametreler doğru bir şekilde başlatılırsa optimizasyon en kısa sürede sağlanacaktır. Parametreler doğru bir şekilde başlatılmadığı takdirde, gradyan inişini kullanarak bir minimuma yaklaşmak imkânsız olacaktır.

Seyreltme


Seyreltme, rastgele seçilen belirli nöron setinin eğitim aşaması sırasında birimlerin (yani nöronların) yok sayılması anlamına gelmektedir. Seyreltme yöntemi ile, belirli bir ileri veya

geri geiş sırasında belirli bir nron grubunun dikkate alınmaması saėlanarak modelin veri setini ezberlemesine (over-fitting) karşı bir nlem alınmaktadır.

Her eėitim ařamasında, bireysel dėmler ya 1-tahmin (1-prediction) olasılıkla aėdan ıkarılır ya da 1-tahmin olasılıkla tutulur ve bylece azaltılmıř bir aė kalır. Ayrıca seyreltilen bir dėme gelen ve giden kenarlar da kaldırılır.

3.6. Artık Bloklar

DESA' daki katmanların okluėundan dolayı aė olduka derindir. Bundan dolayı ilk katmanlarda ėrenilen bilgiler unutulabilmektedir. Artık bloklar, evriřimli katmanların aėın ilk katmanlarında ėrendikleri bilgileri unutmamasını saėlamaktadır. řekil 3.10.' da artık blok rneėi grlmektedir.



řekil 3. 10. Artık blok rneėi

3.7. Artık Bloklı U-Net

U-Net, 2015 yılında Almanya'nın Freiburg niversitesi'nde Biyomedikal Grnt Bltlemesi iin Olaf Ronneberger ve arkadaşları tarafından geliřtirilen bir mimaridir [65]. Gnmzde herhangi bir anlamsal blmleme grevinde en popler olarak kullanılan yaklařımlardan biridir. Daha az eėitim rneėinden ėrenmek iin tasarlanmıř tamamen evriřimli bir sinir aėıdır.

U-Net, bir kpr aracılıėıyla baėlanan drt kodlayıcı bloėu ve drt kod zc bloėundan oluřan U řeklinde bir kodlayıcı-kod zc aė mimarisidir. Kodlayıcı aėı (szleřme yolu)

uzaysal boyutların yarısını ve her kodlayıcı bloğundaki filtre (özellik kanalları) sayısını iki katına çıkarmaktadır. Benzer şekilde, kod çözücü ağı, uzaysal boyutları iki katına çıkarır ve özellik kanallarının sayısını yarıya indirmektedir.

Artık blokların kullanılması, yok olan gradyan(vanishing gradient) veya patlayan gradyan (exploding gradient) sorunu hakkında endişelenmeden daha derin bir ağ oluşturmaya yardımcı olmaktadır. Ayrıca ağın kolay eğitime yardımcı olmaktadır.

ResU-Net' teki zengin atlama bağlantıları, farklı katmanlar arasında daha iyi bilgi akışına yardımcı olmaktadır. Bu durum eğitim sırasında daha iyi gradyan akışına yardımcı olmaktadır.

3.7.1. Kodlayıcı

Kodlayıcı ağı, özellik çıkarıcı olarak hareket eder ve bir kodlayıcı blok dizisi aracılığıyla giriş görüntüsünün soyut bir temsilini öğrenir. Her bir kodlayıcı bloğu, her bir evrişimin bir Rektifiye Edilmiş Doğrusal Birim (ReLU) aktivasyon fonksiyonu tarafından takip edildiği iki adet 3×3 evrişimden oluşmaktadır. ReLU etkinleştirme işlevi, eğitim verilerinin daha iyi genelleştirilmesine yardımcı olan ağına doğrusal olmama özelliğini getirmektedir. ReLU' nun çıkışı, karşılık gelen kod çözücü bloğu için bir atlama bağlantısı görevi görmektedir.

Ardından, özellik haritalarının uzamsal boyutlarının (yükseklik ve genişlik) yarı yarıya azaltıldığı 2×2 maksimum havuzlama gelmektedir. Bu, eğitilebilir parametrelerin sayısını azaltarak hesaplama maliyetini azaltmaktadır.

3.7.2. Atlama bağlantıları

Atlama bağlantıları, kod çözücünün daha iyi anlamsal özellikler oluşturmaya yardımcı olan ek bilgiler sağlamaktadır. Ayrıca, herhangi bir bozulma olmaksızın gradyanların doğrudan önceki katmanların akışına yardımcı olan bir kısayol bağlantısı görevi görmektedirler. Temel olarak, atlama bağlantısı geri yayılım sırasında daha iyi gradyan akışına yardımcı olmaktadır. Bu da ağı daha iyi temsili öğrenmesine yardımcı olmaktadır.


3.7.3. Köprü

Köprü, kodlayıcı ve kod çözücü ağını birbirine bağlayarak bilgi akışını tamamlamaktadır. Her bir evrişimin bir ReLU aktivasyon fonksiyonu tarafından takip edildiği iki adet 3×3 evrişimden oluşmaktadır.

3.7.4. Kod çözücü aşaması

Kod çözücü aşaması Şekil 3.11’ de görülen mimari dikey olarak iki eş parçaya ayrıldığında sağ bölümü temsil etmektedir. Kod çözücü soyut temsili almak ve anlamsal bir bölümlenme maskesi oluşturmak için kullanılmaktadır. Dekoder bloğu 2×2 devrik evrişim ile başlamaktadır. Ardından, kodlayıcı bloğundan ilgili atlamalı bağlantı özellik haritasıyla birleştirilmektedir. Bu atlama bağlantıları, bazen ağı derinliği nedeniyle kaybolan önceki katmanlardan özellikler sağlamaktadır. Bundan sonra, her bir evrişimin bir ReLU aktivasyon fonksiyonu tarafından takip edildiği iki adet 3×3 evrişim kullanılmaktadır.

Son kod çözücünün çıkışı, sigmoid aktivasyonu ile 1×1 evrişimden geçmektedir. Sigmoid aktivasyon işlevi, piksel bazında sınıflandırmayı temsil eden bölütleme maskesini vermektedir.




Şekil 3. 11. Artık bloklu U-Net mimarisi

3.8. Volümetrik Evrişimli Sinir Ağı

Milletari ve arkadaşları [64], hacimsel, tamamen evrişimli 3B görüntü bölütleme için Volümetrik Evrişimli Sinir Ağı (V-Net) mimarisini önermişlerdir. Önerilen 3 boyutlu V-Net modeli Şekil 3.12'de gösterilmektedir. Görselden de anlaşılacağı üzere V-Net ve U-Net [63] birbirine çok benzemektedir. Ancak V-Net mimarisinde, özellik haritası şeklinde kareler ile temsil edilmektedir. Ek olarak, V-Net'in kayıp bilgiyi (turuncu çizgi) tamamlamak için sıkıştırılmış yoldaki öznitelik haritasını üst üste bindirmek için U-Net' den bağlantı yollarını aldığı (turuncu çizgi) şekilden görülmektedir. Burada önemli bir fark, V-Net ve U-Net'in en önemli farklarından birisi, V-Net'in her aşamada (gri yol) Artık bloğun atlama bağlantısını kullanmasıdır. Bu durum U-Net'te artık blok eklemeye eşdeğerdir. Artık bloklar, V-Net'in en önemli iyileştirmesidir. Ayrıca V-Net mimarisinde U-Net' den farklı olarak ilk katmanda bir evrişimsel filtre, ikinci katmanda ise iki evrişimsel filtre kullanılmaktadır. Bundan dolayı V-Net mimarisi U-Net' e göre yapılan performans

testlerinde çok iyi bir performans elde etmiştir. Her bir evrimsel katmanında hem verilerin özellikleri hem de resimlerin çözünürlüğü düşürülmektedir. Şekildeki gibi kırmızı renkli noktali tireli çizgi ile ağ dikey olarak ikiye bölündüğünde, ağın sol kısmı bir sıkıştırma (kodlayıcı aşaması) yolundan oluşurken, sağ kısım sinyali orijinal boyutuna ulaşana kadar görüntüyü açmaktadır.



Şekil 3. 12. V-Net mimarisi

3.9. Prostat Bölütlemesi İçin Kullanılan Veri Kümeleri

Prostat kanseri veri tabanları, Prostat kanseri tanılama sistemleri üzerine çalışan araştırmacılar arasında da yaygın kullanıma sahiptir. Manyetik Rezonans (MR) görüntülerinin derin öğrenme yoluyla işlenmesinde derin öğrenme modelinin hassasiyetinin artırılabilmesi için büyük miktarda veriye ihtiyaç duyulmaktadır.

Prostat görüntüleri MR, TRUS ve Pet-CT gibi farklı görüntüleme cihazları kullanılarak elde edilebilmektedir. Fakat bu görüntüler şekli, çözünürlüğü, 2 boyutlu veya 3 boyutlu oluşuna

göre farklılıklar arz etmektedir. Bu görüntüleme cihazları içerisinde prostat bezesinin görüntülenmesi için en gelişmiş yöntem, üç açıdan (Axial, Sagittal, Coronal) prostat bezesinin yapısına dair bilgiler verdiği için MR cihazı ile görüntüleme yöntemi olmaktadır.

Bu tez çalışmasında önerilen modelleri eğitmek ve test etmek için Tablo-1’de gösterilen iki farklı halka açık veri seti kullanılmıştır. Bunlardan biri, T2 MRG taramalarından oluşan MICCAI Grand Challenge 2012 (PROMISE 12) veri setidir. PROMISE 12 eğitim veri seti, T2 ağırlıklı 50 taramayı ve temel gerçeklerini (ground truth) içerir. Modelleri test etme için ise PROMISE 12 tarafından otuz test görüntüsü sağlanmaktadır. Test taramalarının temel gerçekleri açık erişim değildir. Test taramalarının tahmin sonuçları yarışma yöneticileri tarafından bağımsız olarak değerlendirilmektedir. Veri setlerinin eğitim taramaları 128 x 128 x 64 boyutlarında ve meta (MHD/RAW) formatındadır. PROMISE 12 test taramaları farklı boyutlardadır. PROMISE 12 yarışması veri seti 4 farklı enstitüden farklı vakalara ait prostat görüntüleri alınarak oluşturulmuştur [7].

NCI_ISBI -13 veri seti, 60 eğitim T2 ağırlıklı MR taramasından oluşmaktadır. Görüntüler Boston Medical Center’da 1.5T Philips Achieva makinesi ve Radboud University Nijmegen Medical Center’da 3T Siemens TIM makinesi ile alınmıştır. Bu MR görüntülerinin düzlem içi çözünürlüğü ve düzlem içi mesafesi sırasıyla 0,39-0,75 mm ve 3,0-4,0 mm arasında değişmektedir. Ek olarak, veri seti 10 doğrulama ve 10 test taraması içermektedir [65].

Çizelge 3. 1. Prostat bölütleme veri tabanları

Veri Kümesi	Antrenman vaka sayısı	Test vaka sayısı	Ağırlıklandırma	Magnet Gücü	Görüntü Formatı
Promise12[30]	50	30	T2	1.5T ve 3T	RAW
NCI_ISBI-13[32]	60	10	T1 ve T2	1.5 ve 3T	DICOM

3.10. Veri Kümelerinin (Setlerinin) Ön İşlenmesi

Derin öğrenme yöntemleri, daha iyi performans sonuçları elde etmek için genellikle büyük veri kümeleri gerektirir. Bu nedenle, görüntü sayısını artırmak için her iki veri setinde de çeşitli veri artırımı yöntemleri uygulanmıştır. PROMISE 12 test setinin temel gerçekleri açık erişim değildir. Bu nedenle PROMISE 12 eğitim veri seti, önerilen modeli test etmek için 40 eğitim ve 10 teste bölünmüştür. 3B eğitim görüntülerinde görüldüğü gibi görüntünün

kenarlarından merkeze doğru 10x10 ölçekleme ve kırpma yöntemi ile veri büyütme uygulanmıştır. Bu ölçekleme ve kırpma, önerilen modelin lezyonların kenarlarını daha iyi tespit etmesini sağlamayı amaçlamaktadır. MR görüntülerinin derinliğini bozmamak için tüm görüntülere aynı derinlikte ölçekleme ve kırpma uygulanmıştır. PROMISE 12 veri setinin bölünmesiyle elde edilen 40 eğitim vakasından, sınır veri büyütme yöntemi ile 128 x 128 x 64'lük 650 hasta elde edilmiştir. Ayrıca PROMISE 12 Grand Challenge test setini test etmek için 50 eğitim görüntüsünden 128 x 128 x 64 boyutlarında 784 eğitim görüntüsü elde edilmiştir. NCI_ISBI-13 eğitim setindeki 60 eğitim görüntüsünden sınır veri büyütme yöntemi ile 128 x 128 x 32 boyutlarında 6098 görüntü elde edilmiştir. 2B eğitim setleri, her iki 2B veri seti de yatay ve dikey çevirme, rastgele döndürme, rastgele parlaklık, rastgele bozulma ve elastik dönüşüm yöntemleri uygulanarak artırılmıştır. Modelin iki boyutlu kısmının eğitimi için veriler üzerinden 512 x 512 x 1 boyutlarında PROMISE 12 veri setinden 8500 görüntü ve NCI_ISBI-13 veri setinden 512 x 512 x 1 boyutlarında 14192 görüntü yukarıda anılan veri büyütme yöntemleriyle elde edilmiştir. Ayrıca prostat bölgesini görüntüde daha belirgin hale getirmek için kontrast germe yöntemi de uygulanmıştır.



4. DERİN ÖĞRENME TABANLI PROSTAT GÖRÜNTÜLERİNİN BÖLÜTLEMESİ

Bu tez çalışmasında prostat görüntülerinin derin öğrenme yoluyla bölütlenmesi için iki farklı model önerilmiştir. İlk model U-Net+ResNet 3B ve U-Net+ResNet 2B'yi kaynaştıran derin öğrenme tabanlı füzyon modelidir. İkinci model ise 3 farklı derin öğrenme modelinin kaynaştırıldığı (ET-Net, V-Net 3B ve ResU-Net 2B) derin öğrenme tabanlı füzyon modelidir. Bu bölümde önerilen modeller detaylı olarak açıklanmaktadır.

4.1. Model 1: Dinamik Durum Tipi Odak Twersky Fonksiyonuna Sahip Füzyon Modeli

Önerilen model U-Net+ResNet 3B ve U-Net+ResNet 2B modellerinin kaynaştırılmasıyla elde edilmiştir. DDTOT kayıp fonksiyonun önerilen füzyon modelde modelin hassasiyetini artırmak için kullanılmıştır [66]. Önerilen füzyon modelini oluşturan mimariler Çizelge 4.1. ve Çizelge 4.2.'de gösterilmiştir. Önerilen modelde daha iyi performans elde etmek için, U-Net mimarisine Çizelge 4.1. ve Çizelge 4.2.'de gösterildiği gibi artık (Residual) bloklar eklenmiştir. Yığın Normalleştirme (YN), önerilen füzyon modelinin hem kodlayıcı hem de kod çözücü katmanlarında kullanılmıştır [67].

4.1.1. Kodlayıcı aşaması

Her modelde ağırlık başlatma olarak Xavier başlatma [68] ve aktivasyon işlevi için ReLU kullanılmıştır. ADAM, füzyon modeli oluşturan her iki modelde de optimize edici olarak kullanılmıştır [69]. U-Net+ResNet 3B modelinde her evrişim katmanı $3 \times 3 \times 3$ evrişimden oluşur. Kanallardaki özellikleri normalleştirmek için her katmanda YN kullanılmıştır. Ayrıca ilk dört katmanda $2 \times 2 \times 2$ maksimum havuzlama kullanılmıştır. Modelin eğitimi için modele PROMISE 12 veri setinden $128 \times 128 \times 64$ ve NCI_ISBI-13 veri setinden $128 \times 128 \times 32$ boyutlarında 3B görüntüler beslenmiştir. U-Net + Resnet 2B'de her evrişim bloğunda 3×3 'lük evrişimler kullanılmıştır. Ek olarak, katmanın özelliklerindeki en önemli özellikleri seçmek 2×2 maksimum havuzlama kullanılmıştır. Modelin eğitimi için modele $512 \times 512 \times 1$ boyutlarında 2B görüntüler beslenmiştir.

4.1.2. Kod çözücü aşaması

Kod çözücü aşaması, darboğaz yoluyla kodlayıcıdan düşük çözünürlüklü özellik haritalarının örneklerini almaktadır. Kod çözücü bölümü, alt örnekleme aşamasından özellik haritalarının yukarı-örneklenmesi olan ters evrişimi gerçekleştirmektedir. Kod çözücü aşamasında, bir dizi birleştirme ve yukarı-örnekleme işlemi gerçekleştirilmiştir. Bu işlemler, özellik haritasını kodlayıcıdan gelen görüntüyü orijinal düşük çözünürlüklü tahmini giriş görüntüsüne genişletmektedir. Önerilen modellerin kod çözücü aşamalarında, her bir evrişim katmanı, U-Net+ResNet 3B için 3 x 3 x 3 evrişimden ve U-Net+ResNet 2B için 3 x 3 evrişimden oluşmaktadır. Aynı şekilde her katmanda aktivasyon fonksiyonu olarak ReLU, Xavier kullanılmıştır. Sondan bir önceki katmanların çıktısı, lezyon ve arka plan için önceden tanımlanmış olasılık haritasını veren ve sigmoid aktivasyon fonksiyonunu kullanan U-Net+ResNet 3B için 1 x 1 x 1 ve U-Net+ResNet 2B için 1x1 evrişim katmanına beslenmektedir.

4.1.3. Dinamik durum tipi odak twersky kayıp fonksiyonu (DDTOT)

Prostat görüntülerinin bölütlemesinde, sınırlı halka açık veri setleri, derin ESA tabanlı ağırları eğitmek için yetersizdir [70]. Ek olarak, MR cihazlarının modeline (T1, T2 gibi) bağlı olarak çeşitli çözünürlüklerde farklı görüntüler, prostat görüntülerinin bölütlemesinde başka bir zorluktur [7, 71]. Bu çalışmada, Zhou ve arkadaşları [22] tarafından önerilen durum bazında odak kaybı fonksiyonundan esinlenerek, yeni bir yaklaşım olarak DDTOT kayıp fonksiyonu önerilmiştir. Eş. 4.1'de gösterilen Odak Twersky fonksiyonunun 1'den çıkarılmasıyla elde edilen Eş. 4.2'deki Odak Twersky kayıp fonksiyonu sınıf dengesizliklerinin üstesinden gelmek için başarılı bir çözüm olarak sunulmuştur [72, 73]. Bu nedenle, Eş. 4.3'de açıklandığı gibi, prostat MR görüntülerinin veri dengesizliğini ve bireysel farklılıklarını hafifletmek için Odak Twersky kaybına yeni bir yaklaşım olarak dinamik vaka bazında Odak Twersky kaybı önerilmiştir [74].

$$T I = \frac{\sum_{i=1}^N p_{ic} g_{ic+} \in}{\sum_{i=1}^N p_{ic} g_{ic} + \alpha \sum_{i=1}^N p_{ic} \bar{g}_{ic} + \beta \sum_{i=1}^N p_{ic} g_{ic+} \in} \quad (4.1)$$

$$FTL = (1 - T I)^{1/\gamma} \quad (4.2)$$

$$\mathcal{L}_{cf\ Twersky} = \frac{1}{N_b} \sum_{c=1}^{N_b} \left(1 - \frac{\sum_{i=1}^N p_{ic} g_{ic} + \epsilon}{\sum_{i=1}^N p_{ic} g_{ic} + \alpha \sum_{i=1}^N p_{i\bar{c}} g_{ic} + \beta \sum_{i=1}^N p_{ic} g_{i\bar{c}} + \epsilon} \right)^{1/\gamma} \quad (4.3)$$

Burada N_b mini parti boyutunu; p_{ic} , i pikselinin c lezyon sınıfına ait olma olasılığı ve $p_{i\bar{c}}$, i pikselinin lezyon olmayan $\bar{c}$ sınıfına ait olma olasılığıdır. Aynısı sırasıyla g_{ic} ve $g_{i\bar{c}}$ için de geçerlidir. α ve β hiper parametreleri, önemli sınıf dengesizliği durumunda hatırlamayı iyileştirmek için vurguyu değiştirmek üzere ayarlanabilmektedir. Eş. 4.3'de γ değeri görüntünün arka planı ile prostat bezesi arasında bir kontrol parametresidir. Yapılan denemeler sonucunda 4/3 olarak en ideal değerinde belirlenmiştir. Eş. 4.3'deki ϵ değeri sıfıra bölmeyi önlemek için sayısal kararlılık sağlar.

Toplam kayıp fonksiyonu $\mathcal{L}$ Eş. 4.4'te ifade edilmiştir.

$$\mathcal{L} = \mathcal{L}_{bce} + \log(\beta \mathcal{L}_{cf\ Twersky}) \quad (4.4)$$

Burada $\mathcal{L}_{bce}$ ikili çapraz entropi kayıp fonksiyonunu [75] ifade ederken, β ise bu iki kayıp fonksiyonun dengelemek için bir ağırlık olarak kullanılmıştır. Yaptığımız deneylere göre β 1 değerine ayarlandığında en iyi sonuç alınmaktadır.

Çizelge 4. 1. U-Net+ResNet 3B modelinin detayları

Giriş (Yığın Boyutu, Yükseklik, Genişlik, Derinlik, Kanallar) (4,512,512,1,1)

Katman Adı	Katman Detayları	Çıkış boyutu	Norm/Aktivasyon/ Ağırlık Başlatıcı
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok Maksimum Havuzlama(2x2x2)	(1,128,128,64,32)	YN, ReLU,Xavier
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok Maksimum Havuzlama(2x2x2)	(1,64,64,64,64)	YN, ReLU,Xavier
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok Maksimum Havuzlama(2x2x2)	(1,32,32,64,128)	YN, ReLU,Xavier
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok Maksimum Havuzlama(2x2x2)	(1,16,16,64,256)	YN, ReLU,Xavier
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,8,8,64,512)	YN, ReLU,Xavier
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,16,16,64,256)	YN, ReLU,Xavier
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,32,32,64,128)	YN, ReLU,Xavier
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,64,64,64,64)	YN, ReLU,Xavier
3B U-Net+Artık Blok	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,128,128,64,32)	YN, ReLU,Xavier
3B Single Output	Evrş 1 x 1 x 1	(1,128,128,64,1)	YN,ReLU,Xavier


Çizelge 4. 2. U-Net+ResNet 2B modelinin detayları

Giriş (Yığın Boyutu, Yükseklik, Genişlik, Derinlik, Kanallar) (4,512,512,1,1)

Katman Adı	Katman Detayları	Çıkış boyutu	Norm/Aktivasyon/ Ağırlık Başlatıcı
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok Maksimum Havuzlama(2x2)	(4,512,512,1,32)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok Maksimum Havuzlama(2x2)	(4,256,256,1,64)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok Maksimum Havuzlama(2x2)	(4,128,128,1,128)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok Maksimum Havuzlama(2x2)	(4,64,64,1,256)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,32,32,1,512)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,64,64,1,256)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,128,128,1,128)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,256,256,1,64)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,512,512,1,32)	YN, ReLU,Xavier
2B Single Output	Evrş 1 x 1	(4,512,512,1,1)	YN,ReLU,Xavier

4.2. Model 2: Hibrit Loss Fonksiyonunu Kullanan Üçlü Füzyon Modeli

Bu çalışmada, MR tabanlı prostat görüntülerinin bölütlemesi için artık bloklara sahip ResU-Net 2B' yi, kenar yönlendirme modülü (KYM), Ağırlıklı Toplama Modülü (ATM) ve V-Net 3B mimarileri MR tabanlı prostat görüntülerinin bölütlemesi için kaynaştırılmıştır. Ayrıca, ilk kez önerilen Ağırlıklandırılmış Odak Twersky (AOT) kayıp işlevi, mimarinin performansını önemli ölçüde artırmıştır [76]. Önerilen füzyon modelini oluşturan mimariler Çizelge 4.3. ve Çizelge 4.4.'de gösterilmiştir. ResU-Net 2B için yığın normalleştirme (YN) ve ET-V-Net 3B için ise grup normalleştirme (GN) modellerin hem kodlayıcı hem de kod çözücü katmanlarında kullanılmıştır [67, 77-78]. Şekil 4.1.'de daha iyi organ bölütlemesi elde eden Zhang ve arkadaşları tarafından önerilen ET-Net mimarisi, Jungiang tarafından retinadan diyabetin saptanması için V-Net mimarisine kaynaştırılmıştır [79, 80]. Önerilen modeller kodlayıcı ve kod çözücü aşamalarından oluşmaktadır.



Şekil 4. 1. ET-V-Net 3B modelinin blok diyagramı

Çizelge 4. 3. ResU-Net 2B modelinin detayları

Girişler(Parti boyutu,Yükseklik,Genişlik,Derinlik,Kanallar):(4,512,512,1,1)

Katman adı	Katman Detayları	Çıkış boyutu	Aktivasyon/Norm/Ağırl. Başlatma
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok Maksimum	(4,512,512,1,32)	YN, ReLU,Xavier Havuzlama(2x2)
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok Maksimum	(4,256,256,1,64)	YN, ReLU,Xavier Havuzlama(2x2)
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok Maksimum	(4,128,128,1,128)	YN, ReLU,Xavier Havuzlama(2x2)
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok Maksimum	(4,64,64,1,256)	YN, ReLU,Xavier Havuzlama(2x2)
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,32,32,1,512)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,64,64,1,256)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,128,128,1,128)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,256,256,1,64)	YN, ReLU,Xavier
2B U-Net+Artık Blok	Evrş 3 x 3 Evrş 3 x 3 ResNet Blok	(4,512,512,1,32)	YN, ReLU,Xavier
2B Tekil Çıkış	Evrş 1 x 1	(4,512,512,1,1)	YN,ReLU,Xavier

Çizelge 4. 4. ET-V-Net 3B modelinin detayları

Girişler(Parti boyutu,Yükseklik,Genişlik,Derinlik,Kanallar):(1,128,128,64,1)

Katman adı	Katman detayları	Çıkış boyutu	Aktivasyon/Norm/Ağırlık Başlatma
Katman 1	Evrş 3 x 3 x 3 ResNet Blok	(1,128,128,64,16)	GN, ReLU,Xavier
Aşağı örnekleme 1 Katman 2	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3	(1,64,64,64,32)	GN,ReLU,Xavier GN, ReLU,Xavier
	Evrş 3 x 3 x 3 ResNet Blok		
Aşağı örnekleme 2	Evrş 3 x 3 x 3		GN,ReLU,Xavier
Katman 3	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,32,32,64,64)	GN, ReLU,Xavier
Aşağı örnekleme 3	Evrş 3 x 3 x 3		GN,ReLU,Xavier
Katman 4	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,16,16,64,128)	GN, ReLU,Xavier
Aşağı örnekleme 4 Katman 5	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,8,8,64,256)	GN,ReLU,Xavier GN, ReLU,Xavier
Upsample 1	Evrş 3 x 3 x 3		GN,ReLU,Xavier
Katman 6	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,16,16,64,128)	GN, ReLU,Xavier
Upsample 2	Evrş 3 x 3 x 3		GN,ReLU,Xavier
Katman 7	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,32,32,64,64)	GN, ReLU,Xavier
Upsample 3	Evrş 3 x 3 x 3		GN,ReLU,Xavier
Katman 8	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,64,64,64,32)	GN, ReLU,Xavier
Upsample 4	Evrş 3 x 3 x 3		GN,ReLU,Xavier
Katman 9	Evrş 3 x 3 x 3 Evrş 3 x 3 x 3 ResNet Blok	(1,128,128,64,16)	GN, ReLU,Xavier
Katman 10	ET-Net		
3B Single Output	Evrş 1 x 1 x 1	(1,128,128,64,16)+ET-Net	GN,ReLU,Xavier

4.2.1. Kodlayıcı aşaması

Her modelde ağırlık başlatma olarak Xavier başlatma [68] ve aktivasyon işlevi için ReLU kullanılmıştır. ADAM, füzyon modeli oluşturan her iki modelde de optimize edici olarak kullanılmıştır [69]. ET-V-Net 3B modelinde her evrişim katmanı $3 \times 3 \times 3$ evrişimden oluşur. Kanallardaki özellikleri normalleştirmek için her katmanda GN kullanılmıştır. Modelin eğitimi için modele PROMISE 12 veri setinden $128 \times 128 \times 64$ ve NCI_ISBI-13 veri setinden $128 \times 128 \times 32$ boyutlarında 3B görüntüler beslenmiştir. ResU-Net 2B'de her evrişim bloğunda 3×3 'lük evrişimler kullanılmıştır. Ek olarak, katmanın özelliklerindeki en önemli özellikleri seçmek 2×2 maksimum havuzlama kullanılmıştır. Modelin eğitimi için modele $512 \times 512 \times 1$ boyutlarında 2B görüntüler beslenmiştir.

4.2.2. Kod çözücü aşaması

Kod çözücü aşaması, darboğaz yoluyla kodlayıcıdan düşük çözünürlüklü özellik haritalarının örneklerini almaktadır. Kod çözücü bölümü, alt örnekleme aşamasından özellik haritalarının yukarı-örneklenmesi olan ters evrişimi gerçekleştirmektedir. Kod çözücü aşamasında, bir dizi birleştirme ve yukarı-örnekleme işlemi gerçekleştirilmiştir. Bu işlemler, özellik haritasını kodlayıcıdan gelen görüntüyü orijinal düşük çözünürlüklü tahmini giriş görüntüsüne genişletmektedir. Önerilen modellerin kod çözücü aşamalarında, her bir evrişim katmanı, ET-V-Net 3B için $3 \times 3 \times 3$ evrişimden ve ResU-Net 2B için 3×3 evrişimden oluşmaktadır. Aynı şekilde her katmanda aktivasyon fonksiyonu olarak ReLU, ve ağırlık başlatıcı olarak Xavier ağırlık başlatıcı kullanılmıştır. Sonra bir önceki katmanların çıktısı, lezyon ve arka plan için önceden tanımlanmış olasılık haritasını veren ve sigmoid aktivasyon fonksiyonunu kullanan ET-V-Net 3B için $1 \times 1 \times 1$ ve ResU-Net 2B için 1×1 evrişim katmanına beslenmektedir.

4.2.3. Ağırlıklandırılmış odak twersky kayıp fonksiyonu (AOT)

Prostat görüntülerinin bölütlemesinde, sınırlı halka açık veri setleri, derin ESA tabanlı ağırları eğitmek için yetersizdir [70]. Ek olarak, MR cihazlarının modeline (T1, T2 gibi) bağlı olarak çeşitli çözünürlüklerde farklı görüntüler, prostat görüntülerinin bölütlemesinde başka bir zorluktur [7, 71]. Bu çalışmada, Zhou ve arkadaşları [22] tarafından önerilen durum bazında odak kaybı fonksiyonundan esinlenerek, yeni bir yaklaşım olarak AOT hibrit fonksiyonu

önerilmiştir. Eş. 4.4'de gösterilen Odak Twersky kayıp fonksiyonu sınıf dengesizliklerinin üstesinden gelmek için başarılı bir çözüm olarak sunulmuştur [72, 73]. Bu nedenle, Eş. 4.5'de açıklandığı gibi, prostat MR görüntülerinin veri dengesizliğini ve bireysel farklılıklarını hafifletmek için Odak Twersky kayıp fonksiyonuna yeni bir yaklaşım olarak ağırlıklandırılmış fokal twersky kaybı önerilmiştir [74].

$$FTL = (1 - T I)^{1/\gamma} \quad (4.5)$$

$$\mathcal{L}_{cf\ Twersky} = \frac{1}{N_b} \sum_{c=1}^{N_b} \left(1 - \frac{\sum_{i=1}^N p_{ic} g_{ic} + \epsilon}{\sum_{i=1}^N p_{ic} g_{ic} + \alpha \sum_{i=1}^N p_{i\bar{c}} g_{ic} + \beta \sum_{i=1}^N p_{ic} g_{i\bar{c}} + \epsilon} \right)^{1/\gamma} \quad (4.6)$$

Burada N_b mini parti boyutunu; p_{ic} , i pikselinin c lezyon sınıfına ait olma olasılığı ve $p_{i\bar{c}}$, i pikselinin lezyon olmayan $\bar{c}$ sınıfına ait olma olasılığıdır. Aynısı sırasıyla g_{ic} ve $g_{i\bar{c}}$ için de geçerlidir. Burada α ve β hiper parametreleri, önemli sınıf dengesizliği durumunda hatırlamayı iyileştirmek için vurguyu değiştirmek üzere ayarlanabilmektedir. Burada γ yapılan denemeler sonucunda 4/3 olarak seçilmiştir.

Toplam kayıp fonksiyonu $\mathcal{L}$ Eş. 4.6'te ifade edilmiştir.

$$\mathcal{L} = \mathcal{L}_{wbce} + \log(\beta \mathcal{L}_{cf\ Twersky}) \quad (4.7)$$

Burada $\mathcal{L}_{wbce}$ ağırlıklı ikili çapraz entropi kayıp fonksiyonunu [75] ifade etmektedir. Ağırlıklı ikili çapraz entropi, ikili çapraz entropiye pozitif bir beta ağırlığı eklenerek elde edilir. Pozitif beta ağırlığı, yanlış negatifleri azaltmak için $\beta > 1$ ve yanlış pozitiflerin sayısını azaltmak için $\beta < 1$ olarak seçilmiştir. Denemeler sonucunda $\beta = 0,7$ olarak seçilmiştir. Ayrıca, iki kayıplı fonksiyonlar arasında tutarlılığı sağlamak için Odak Twersky kayıp fonksiyonundan döndürülen değerin doğal logaritması alınmıştır.

5. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde derin öğrenme tabanlı prostat görüntülerinin bölütlemesi için önerilen modellerin ölçülmesi maksadıyla yapılan deneyler, bu deneylerin yapıldığı bilgisayar donanımları ve kullanılan veri setleri, deney sonuçlarını değerlendirme metrikleri ve son olarak önerilen modellerin PROMISE 12 ve NCI_ISBI-2013 veri setleri üzerinde test edilmiş literatürdeki diğer modellerle karşılaştırması yer almaktadır.

5.1. Uygulama Detayları

Önerilen üçlü modelin eğitiminde kullanılan bilgisayarın donanımı Intel I5-8300H işlemci ve 32 GB RAM'dan oluşmaktadır. Ayrıca modelin eğitilmesi için ekran kartı olarak NVIDIA GTX 1080TI kullanılmıştır. Yukarıda bahsedilen donanım konfigürasyonu ile veri setlerinin eğitimi ve testi gerçekleştirilmiştir. Bilgisayarda yazılım konfigürasyonu olarak Windows 10-64 bit işletim sistemi kullanılmıştır. Önerilen derin öğrenme modelini kodlamak için Python 3.6 programlama dili kullanılmıştır. Her iki ağ için de öğrenme oranı $1e-3$ olarak belirlenmiştir. Ayrıca ResU-Net 2B için parti büyüklüğü = 4 ve ET-V-Net 3B için parti büyüklüğü = 1 olarak belirlenmiştir. Modellerin eğitimi, her iki veri seti için 120 000 adım sayısı boyunca gerçekleştirilmiştir.

5.2. Performans Metrikleri

Segmentasyon performansını nicel olarak karşılaştırmak için dört standart değerlendirme metriği kullanılmıştır. Bunlar Eş. 5.1'de gösterilen Sınır Noktaları Arasındaki En Kısa Mesafe (SNAEKM), Eş. 5.2'de gösterilen Hausdorff Mesafesi (HM), Eş. 5.3'de gösterilen Zar Benzerlik Katsayısı (ZBK)'dır. Bu eşitliklerde X_s sembolü temel gerçek görüntü değerlerini ifade ederken, Y_s sembolü ise tahmin edilen bölütleme görüntü değerini ifade etmektedir. PROMISE 12 ve NCI_ISBI-13 veri setlerinde önerilen modellerin testleri yapılırken kullanılan metriklerde 3 farklı puanlama tekniği kullanılmıştır. Bunlar tüm MR görüntüsündeki tüm prostat hacmini ifade eden whole, prostat hacminin ilk 1/3'lük kısmını ifade eden base ve prostat hacminin son 1/3'lük kısmını ifade eden apex'tir. Önerilen modelin metriklere göre puanlamasında SNAEKM puanlamasında en düşük olan değerler, HM puanlamasında en düşük olan değerler ve ZBK puanlamasında en yüksek olan değerler en iyi değerler olarak kabul edilmektedir.


$$SNAEKM(X_s, Y_s) = \frac{1}{N_{X_s} + N_{Y_s}} \left(\sum_{x \in X_s} \min_{y \in Y_s} d(x, y) + \sum_{y \in Y_s} \min_{x \in X_s} d(x, y) \right) \quad (5.1)$$

$$HM(X_s, Y_s) = \max(HM_{asym}(X_s, Y_s), HM_{asym}(Y_s, X_s)) \quad (5.2)$$

$$ZBK(X, Y) = \frac{2|X \cap Y|}{|X| + |Y|} \quad (5.3)$$


5.3. Model 1'in Veri Setleri Üzerindeki Uygulama Detayları

Önerilen füzyon mimarisinde U-Net+Resnet 3B ve U-Net+Resnet 2B modelleri birleştirilmiştir. Şekil 5.1.'de gösterildiği gibi, SimpleITK'nın SimpleITK.connectedcomponent modülü kullanılarak önerilen füzyon mimarisini oluşturan modellerden elde edilen test görüntülerinden en az bağlantılı noktalar çıkarılmıştır.




Şekil 5. 1. En az bağlantılı noktaların çıkarılması

Birbiriyle en az bağlantılı noktalar çıkarıldıktan sonra, bölütleme sonuçlarının örtüşen bölgeleri hesaplanmış ve kaydedilmiştir. Son olarak, Şekil 5.2. ve Şekil 5.3.' de görülebileceği gibi, nihai bölütleme sonucunu oluşturmak için örtüşen bölgeler ve en yüksek bağlantılı veya birbirine yakın noktalar birleştirilmiştir.




Şekil 5. 2. Önerilen füzyon modelin PROMISE 12 veri seti üzerindeki bölütleme aşamaları




Şekil 5. 3. Önerilen füzyon modelin NCI_ISBI-13 veri seti üzerindeki bölütleme aşamaları

5.3.1. Model 1'in PROMISE 12 veri setindeki performans değerlendirmesi

U-Net+ResNet 3B ve U-Net+Resnet2B modelleri, PROMISE 12 artırılmış veri kümesi üzerinde ayrı ayrı eğitilmiştir. Her modelin eğitim sonuçları, Şekil 5.4. ve Şekil 5.5.'deki geçerleme hassasiyeti ve geçerleme kaybı değerlerinden görülmektedir. Kaybı uygun şekilde azaltmada yeni bir yaklaşım olarak önerilen DDTOT kayıp fonksiyonunun etkisi de büyüktür. Hesaplama sınırlamaları nedeniyle, sırasıyla U-Net+ResNet 3B için parti büyüklüğü=1 ve U-Net+ResNet 2B için parti büyüklüğü=4 olarak seçilmiştir. Şekil 5.4. ve Şekil 5.5.'de görülebileceği gibi, donanım hesaplama sınırlamaları nedeniyle parti boyutu artırılamadığı için ilk 10 000 devir dalgalanma eğilimindedir. Ancak 10 000 adım sayısından sonra kayıp değeri istikrarlı bir şekilde azaldığı görülmüştür. Adım sayısının bu kadar yüksek tutulmasının nedeni hesaplama sınırlamalarından dolayıdır.




Şekil 5. 4. U-Net+ResNet 2B'nin geçerleme hassasiyeti ve kaybının PROMISE 12 veri seti üzerindeki sonuçları



Şekil 5. 5. U-Net+ResNet 3B'nin geçerleme hassasiyeti ve kaybının PROMISE 12 veri seti üzerindeki sonuçları

PROMISE 12 yarışmasındaki 30 test görüntüsünden 25. vakadaki test sonuçları Şekil 5.6.'da gösterilmektedir. Mavi çizgi ile gösterilen alan, önerilen füzyon modeli tarafından tahmin edilen prostat bölgesidir. PROMISE 12 eğitim veri seti, önerilen modeli optimize etmek için 40 eğitim ve 10 test setine bölünmüştür. Bu 10 test seti puanlanmış ve Çizelge 5.1.'de gösterildiği gibi PROMISE 12 yarışmasındaki en son modellerin sonuçlarıyla karşılaştırılmıştır.



Şekil 5. 6. PROMISE 12 yarışmasının 25. vaka test sonuçları

Şekil 5.7.'de PROMISE 12 eğitim setinin bölünmesiyle elde edilen 10 test senaryosundan biri olan 64 derinlikli 40. vakanın tahmin sonuçları (predicted result) ve temel gerçeği (ground truth) prostat görüntü kesitleri üzerinde gösterilmiştir. Kırmızı çizgi ile gösterilen alan temel gerçektir ve mavi çizgi ile gösterilen alan tahmin edilen bölütleme sonucudur.

Şekil 5.7.'de gösterildiği gibi, prostat görüntülerinin tahmin edilen test sonucu ve temel doğruluk sınırları birbirine çok yakındır. Burada eğitim setinden elde edilen test setlerinin her birinin 64 derinliğe sahip olduğuna dikkat edilmelidir. Yani tahmin zorluğu PROMISE 12 yarışması test setinden daha yüksektir.



Şekil 5. 7. PROMISE 12 yarışmasının 40. vakasının test sonuçları

Çizelge 5.1.' de koyu renkli yazılan puanlar PROMISE 12 veri setinden elde edilen en yüksek test puanlarıdır. Önerilen modelin en zorlu performans metriklerinden biri olan HM' yi başarılı bir şekilde azalttığı Çizelge 5.1.'de de görülebilmektedir. Kalın yazılan sayılar en iyi puanlardır. Ayrıca çizelge 5.1.'den görüldüğü gibi önerilen model 3 farklı metrikte de tüm prostat bezesinin bölütlenmesinde literatürdeki diğer modellere göre daha başarılı sonuçlar elde etmiştir.


Çizelge 5. 1. Önerilen model ile Promise12 veri setinde test edilen en son mimariler arasında karşılaştırmalı analiz

Mimariler	Performans metrikleri								
	SNAEKM(mm)			95%HM(mm)			(%)ZBK		
	whole	base	apex	whole	base	apex	whole	base	apex
CAMP-TUM2 [64]	2,97	3,42	3,15	6,98	7,01	6,86	78,05	74,3	70,76
UdeM [81]	1,95	2,2	1,89	5,89	6,29	4,56	87,42	84,93	84,16
CUMED [71]	1,71	1,96	1,56	5,13	5,22	4,17	89,43	86,42	86,81
WHU-ML [82]	1,61	1,59	1,43	5,31	4,64	3,8	90,26	89,15	88,36
DL-MBS[15]	1,49	1,73	1,73	4,49	4,9	4,68	90,46	88,51	85,29
3B APA-Net [83]	1,45	1,63	1,53	4,13	4,55	3,95	90,6	89,1	86,9
Z-Net [29]	1,43	1,68	1,49	4,41	4,99	3,98	90,5	88	87,27
HD-Net [84]	1,36	1,54	1,34	3,93	4,24	3,6	91,35	88,91	89,82
BOWDA-Net [70]	1,35	1,54	1,29	4,27	4,48	3,44	91,41	89,56	89,29
3B Resolution Aware U-Shaped[22]	1,27	1,36	1,44	4,06	3,58	4,4	91,89	88,77	90,3
Önerilen mimari	1,15	1,24	1,32	3,9	3,45	4,01	91,97	89,1	90,45


5.3.2. Model 1'in NCI_ISBI-13 veri seti üzerindeki performans değerlendirme

U-Net+ResNet 2B ve U-Net+ResNet 3B modelleri, artırılmış ISBI-PSC-13 veri setinde eğitilmiş ve puanlanmıştır. Şekil 5.8. ve Şekil 5.9., NCI_ISBI-13 veri seti eğitiminde önerilen füzyon mimarisini oluşturan modellerin eğitim kaybı ve doğrulama kayıplarını göstermektedir. Şekil 5.8. ve Şekil 5.9.'da görülebileceği gibi, donanım hesaplama sınırlamaları nedeniyle parti boyutu artırılmadığı için adım sayısı yüksek tutularak bu sınırlılığa çözüm bulunmuştur. Şekil 5.8. ve 5.9.'dan görülebileceği gibi ilk 10 000 devir dalgalanma eğiliminde olmuştur. Ancak 10 000 devirden sonra kayıp fonksiyonu istikrarlı bir şekilde azalmıştır. Ayrıca şekillerden de anlaşılabileceği üzere modeller DDTOT fonksiyonu sayesinde kayıpları istikrarlı bir şekilde azaltmaktadır. Şekil 5.10.'da, NCI_ISBI-13 test görüntülerine karşılık gelen gerçek ve tahmin edilen bölütleme sonuçları birlikte gösterilmektedir. Burada kırmızı çizgi ile gösterilen alan temel gerçek görüntü sınırlarını, mavi çizgi ile gösterilen alan ise tahmin edilen bölütleme sınırlarının sonucudur. Önerilen modelin ve NCI_ISBI-13 veri seti üzerindeki diğer son model modellerin karşılaştırmalı sonuçları Çizelge 5.2.'de gösterilmektedir. Kalın yazılan puanlar en iyi puanlardır. Önerilen modelin özellikle tüm ZBK (91.32) ve HM (5.576) değerlerinin literatürdeki diğer


çalışmalarla karşılaştırıldığında daha iyi performans gösterdiği Çizelge 5.2.'de görülmektedir.



Şekil 5. 8. U-Net+ResNet 3B’ nin geçerleme hassasiyeti ve kaybının PROMISE 12 veri seti üzerindeki sonuçları



Şekil 5. 9. U-Net+ResNet 3B’ nin geçerleme hassasiyeti ve kaybının NCI_ISBI-13 veri seti üzerindeki sonuçları




Şekil 5. 10. Önerilen modelin NCI_ISBI-13 bölütleme sonucu

Çizelge 5. 2. Önerilen model ile NCI_ISBI-13 veri kümesindeki en son mimariler arasındaki karşılaştırmalı analiz

Mimariler	Performans metrikleri								
	SNAEKM(mm)			HM(mm)			(%)ZBK		
	whole	base	apex	whole	base	apex	whole	base	apex
Tang [26]	-	-	-	-	-	-	90,3	-	-
V-Net [64]	3,562	-	-	-	-	-	76,2	-	-
3B GCN [85]	2,204	-	-	-	-	-	83,1	-	-
3B-U-Net [86]	1,435	0,786	0,903	7,815	6,378	6,319	89,3	86,6	81,4
VoxResNet [87]	1,375	0,729	0,826	6,401	5,490	5,355	89,0	85,9	82,8
3B APA-Net [83]	1,167	-	-	-	-	-	89,3	-	-
3B Resolution Aware U-Shaped Net [22]	1,145	0,604	0,716	5,721	5,452	5,230	91,04	88,7	85,0
Önerilen mimari	1,123	0,591	0,692	5,576	5,272	5,114	91,32	89,9	87,09


5.4. Model 2'nin Veri Setleri Üzerindeki Uygulama Detayları

ResU-Net 2B modeli ve ET-V-Net 3B, önerilen Üçlü füzyon mimarisinde birleştirilmiştir. Şekil 5.11.'de gösterildiği gibi, ResU-Net 2B ve ET-V-Net 3B modellerinin en az bağlantılı noktaları SimpleItk'in SimpleITK.connectedcomponent modülü kullanılarak çıkarılmıştır.




Şekil 5. 11. En az bağlantılı piksellerin çıkarılması

En az bağlantılı pikseller çıkarıldıktan sonra, modellerin bölütleme sonuçlarının örtüşen bölgeleri hesaplanmış ve kaydedilmiştir. Son olarak, Şekil 5.12. ve 5.13.'de gösterildiği gibi, nihai prostat bölütlemesi sonucunu oluşturmak için örtüşen alanlar ve en çok bağlantılı noktalar birleştirilmiştir.



Şekil 5. 12. Model 2'nin PROMISE 12 veri seti üzerindeki bölütleme aşamaları




Şekil 5. 13. Model 2'nin NCI_ISBI-13 veri seti üzerindeki bölütleme aşamaları


5.4.1. Model 2' nin PROMISE 12 veri seti üzerindeki performans değerlendirmesi

ResU-Net 2B ve ET-V-Net 3B modelleri, füzyon modelin eğitim için kullanılan iki veri kümesinden biri olan PROMISE 12 artırılmış veri kümesi üzerinde ayrı ayrı eğitilmiştir. Modellerin eğitim sonuçları Şekil 5.14. ve Şekil 5.15.'deki geçerleme doğruluğu ve geçerleme kaybı değerlerinden görülebilmektedir. Grafiklerden de görüleceği üzere üçlü modeli oluşturan her model, ilk 10 000 adım sayısından sonra kaybı istikrarlı bir şekilde azaltmaya başlamıştır. Yeni bir yaklaşım olarak önerilen hibrit AOT kayıp fonksiyonu, kaybın istikrarlı bir şekilde azaltılmasında dikkate değer bir etki göstermiştir. Kullanılan grafik kartının hesaplama sınırlamaları nedeniyle, ResU-Net 2B için parti boyutu=4 ve ET-

V-Net 3B için parti boyutu=1 olarak belirlenmiştir. Bundan dolayı Şekil 5.14. ve Şekil 5.15.’de görüldüğü gibi adım sayısı artırılarak bu sınırlılık çözülmüştür.




Şekil 5. 14. ET-V-Net 3B’ nin geçерleme hassasiyeti ve kaybının PROMISE 12 veri seti üzerindeki sonuçları



Şekil 5. 15. ResU-Net 2B’ nin geçерleme hassasiyeti ve kaybının PROMISE 12 veri seti üzerindeki sonuçları

PROMISE 12 yarışmasından 30 test görüntüsünden biri olan 3. vakadaki test sonuçları Şekil 5.16'da gösterilmektedir. Mavi çizgi ile gösterilen alan, önerilen füzyon modeli tarafından tahmin edilen prostat bölgesidir.



Şekil 5. 16. Önerilen modelin PROMISE 12 veri setinin 3. vakasındaki 64 dilimlik test sonuçları

PROMISE 12 eğitim veri seti, önerilen modeli optimize etmek için 40 eğitim ve 10 test setine bölünmüştür. Bu 10 test seti puanlanmış ve Çizelge 5.3.'te gösterildiği gibi PROMISE 12 yarışması için literatürde önerilen en son modellerin sonuçlarıyla karşılaştırılmıştır. Koyu renkli yazılan puanlar en yüksek puanlardır. Çizelge 5.3.'te görüldüğü gibi, önerilen model ortaya çıkan grafik kartından kaynaklanan sınırlamalara rağmen özellikle tüm(whole)


prostat bezesinin bölütlemesinde literatürdeki diğer çalışmalara göre daha yüksek başarı elde etmiştir.

Çizelge 5. 3. Önerilen model ile Promise12 veri setindeki en son mimariler arasında karşılaştırmalı analiz

Mimariler	Performans metrikleri								
	SNAEKM(mm)			95%HM(mm)			(%)ZBK		
	whole	base	apex	whole	base	apex	whole	base	apex
CAMP-TUM2 [64]	2,97	3,42	3,15	6,98	7,01	6,86	78,05	74,3	70,76
UdeM [81]	1,95	2,2	1,89	5,89	6,29	4,56	87,42	84,93	84,16
CUMED [71]	1,71	1,96	1,56	5,13	5,22	4,17	89,43	86,42	86,81
WHU-ML [82]	1,61	1,59	1,43	5,31	4,64	3,8	90,26	89,15	88,36
DL-MBS[15]	1,49	1,73	1,73	4,49	4,9	4,68	90,46	88,51	85,29
3B APA-Net [83]	1,45	1,63	1,53	4,13	4,55	3,95	90,6	89,1	86,9
Z-Net [29]	1,43	1,68	1,49	4,41	4,99	3,98	90,5	88	87,27
HD-Net [84]	1,36	1,54	1,34	3,93	4,24	3,6	91,35	88,91	89,82
BOWDA-Net [70]	1,35	1,54	1,29	4,27	4,48	3,44	91,41	89,56	89,29
3B Resolution Aware U-Shaped [22]	1,27	1,36	1,44	4,06	3,58	4,4	91,89	88,77	90,3
Önerilen mimari	1,22	1,42	1,25	3,98	3,60	4,17	91,92	88,89	90,38

Şekil 5.18.'de PROMISE 12 eğitim setinin bölünmesiyle elde edilen 10 test vakasından biri olan 64 derinliğe sahip 41. vakanın tahmin edilen sonuçları ve temel gerçeği MR prostat kesitleri üzerinde farklı renklerle gösterilmiştir. Mavi çizgi ile gösterilen alan temel gerçektir ve yeşil çizgi ile gösterilen alan tahmin edilen bölütleme sonucudur.


Şekil 5.18'de gösterildiği gibi, tahmin edilen test sonucu ve temel doğruluk sınırları birbirine çok yakındır. Burada eğitim setinden elde edilen test setlerinin her birinin 128x128x64 boyutunda olduğuna dikkat edilmelidir. Bu çözünürlük, PROMISE 12 meydan okuma test setine kıyasla daha düşüktür. PROMISE 12 Challenge test setindeki en yetersiz çözünürlük taramaları 320 x 320'dir.




Şekil 5. 17. Önerilen modelin PROMISE 12 yarışmasının 41. vakasındaki test sonuçları

5.4.2. Model 2' nin NCI_ISBI-13 veri seti üzerindeki performans deęerlendirmesi


ResU-Net 2B ve ET-V-Net 3B modelleri, artırılmıř NCI_ISBI-13 veri setinde eęitilmiř ve puanlanmıřtır. řekil 5.19. ve řekil 5.20., üçlü füzyon mimarisini oluřturan modellerin NCI_ISBI-13 veri setinde eęitimden elde edilen geęerleme hassasiyetini ve geęerleme kayıplarını göstermektedir. řekillerden de görüldüęü gibi önerilen üçlü model, AOT kayıp fonksiyonunun etkisiyle kayıpları istikrarlı bir řekilde azaltmaktadır. řekil 5.21., NCI_ISBI-13 test görüntülerine karřılık gelen temel geręek ve tahmin edilen bölütleme sonuçlarıyla birlikte göstermektedir. Burada kırmızı çizgi ile gösterilen alan temel geręek ve yeřil çizgi ile gösterilen alan ise tahmin edilen bölütleme sonucudur. řekil 5.21.'de görülebileceęi gibi, önerilen model prostat bölütlemesinde saęlamlıęını kanıtlamıřtır.



řekil 5.18. ET-V-Net 3B veri setinin NCI_ISBI-13 veri seti üzerindeki geęerleme hassasiyeti ve geęerleme kayıpları sonuçları



Şekil 5. 19. ResU-Net 2B veri setinin NCI_ISBI-13 veri seti üzerindeki geçerleme hassasiyeti ve geçerleme kayıpları sonuçları



Şekil 5. 20. Önerilen modelin NCI_ISBI-13 veri setindeki bölütleme sonucu

Önerilen modelin karşılaştırmalı analizi ve literatürdeki en son diğer yaklaşımlar Çizelge 5.4.'te gösterilmektedir. Kalın yazılanlar en iyi puanlardır. Çizelge 5.4.'den de anlaşılacağı gibi önerilen model 3 metrik ve 9 alt metrikte de en yüksek bölütleme puanlarını elde etmiştir.

Çizelge 5. 4. Önerilen model ile NCI_ISBI-13 veri kümesindeki en son mimariler arasında karşılaştırmalı analiz

Mimariler	Performans metrikleri								
	SNAEKM(mm)			HM(mm)			(%)ZBK		
	whole	base	apex	whole	base	apex	whole	base	apex
Tang [26]	-	-	-	-	-	-	90,3	-	-
V-Net [64]	3,562	-	-	-	-	-	76,2	-	-
3B GCN [85]	2,204	-	-	-	-	-	83,1	-	-
3B-U-Net [86]	1,435	0,786	0,903	7,815	6,378	6,319	89,3	86,6	81,4
VoxResNet [87]	1,375	0,729	0,826	6,401	5,490	5,355	89,0	85,9	82,8
3B APA-Net [83]	1,167	-	-	-	-	-	89,3	-	-
3B Resolution Aware U-Shaped Net[22]	1,145	0,604	0,716	5,721	5,452	5,230	91,04	88,7	85,0
Önerilen model	1,134	0,599	0,701	5,672	5,337	5,125	91,15	88,82	86,05

6. SONUÇ VE ÖNERİLER

Prostat taramalarının manuel olarak bölütlemesi çok zaman alıcı, zahmetli ve kurul onaylı uzmanlar gerektirmektedir. Bu sorunları çözmek için yeni bir yaklaşım olan derin öğrenme tabanlı bilgisayar destekli tanılama (BDT) sistemleri ön plana çıkmaktadır. Bu tez çalışmasında, bu sorunlara bir çözüm olması için iki farklı derin öğrenme tabanlı tam otomatik prostat bölütleme yöntemi önerilmiştir.

Birinci modelde, veri setlerindeki sınıf dengesizliklerine çözüm olarak mini parti boyutunu dikkate alan DDTOT kayıp fonksiyonu yeni bir yaklaşım olarak önerilmiştir. Model 1, halka açık iki zorlu veri kümesi olan PROMISE 12 ve NCI_ISBI-13 üzerinde eğitilmiş ve test edilmiştir. Etkileyici bir şekilde, önerilen Model 1 için önerilen kayıp işlevi, her iki veri kümesinde de eğitim kaybını tutarlı bir şekilde azaltmıştır.

Model 1, eğitim aşamasında olduğu kadar test aşamasında da başarılı olmuştur. Hem nicel hem de görsel karşılaştırmalar, Model 1'in son teknoloji mimarilere kıyasla daha iyi performans gösterdiğini ve sağlam bir mimari olduğunu göstermektedir. Ayrıca Model 1'in HM'yi (Hausdorff Mesafesi) başarıyla azalttığı da gözlemlenmiştir. Çalışmanın kısıtlılığı, GTX 1080TI ekran kartı ve bilgisayar donanım sınırlamalarının mini parti boyutu değerinin artmasını engellemesidir. Sorunların üstesinden gelmek için devir sayısı artırılmıştır.

Model 2'de ise ResU-Net 2B ve ET-V-Net 3B modelleri, tam otomatik olarak prostat görüntülerinin bölütlemesi için yeni bir yaklaşım olarak kaynaştırılmıştır. Ayrıca, her modelde kod çözücü ve kodlayıcı aşamalarında her evrişim katmanına artık bloklar eklenmiştir. AOT kayıp fonksiyonu, modelin eğitim ve test aşamalarındaki kayıpları tutarlı bir şekilde azaltmak için yeni bir yaklaşım olarak önerilmiştir. AOT, modele üstün bir performans kazandırmıştır. Model 2, halka açık iki önemli veri kümesi olan PROMISE 12 ve NCI_ISBI-13 üzerinde eğitilmiş ve test edilmiştir.

Model 2, eğitim aşamasında olduğu kadar test aşamasında da başarılı olmuştur. Hem nicel hem de görsel karşılaştırmalar, önerilen modelin son teknoloji DESA tabanlı yaklaşımlardan daha iyi performans gösterdiğini göstermektedir. Füzyon modelinin HM'yi (Hausdorff Mesafesi) başarılı bir şekilde azalttığı da gözlemlenmiştir. Çalışmalardan elde edilen bir

diğer sonuç ise eğitim veri setinin doğru hazırlanmasıdır. İyi bir eğitim veri seti ile ortalama bir modelin bile çok başarılı sonuçlar elde edebileceği düşünülmektedir.

ResU-Net 2B ve ET-V-Net 3B modelleri, bu çalışmada tam otomatik prostat bölütlemesi için yeni bir yaklaşım olarak birleştirilmiştir. Ayrıca, her modelde kod çözücü ve kodlayıcı aşamalarında her evrişim katmanına artık bloklar eklenmiştir. AOT kayıp fonksiyonu, modelin eğitim ve test aşamalarındaki kayıpları tutarlı bir şekilde azaltmak için yeni bir yaklaşım olarak önerilmiştir. AOT, modele üstün bir performans kazandırmıştır. Önerilen üçlü füzyon modeli, halka açık iki önemli veri kümesi olan PROMISE 12 ve NCI_ISBI-13 üzerinde eğitilmiş ve test edilmiştir.

Gelecekteki çalışmalarda;

HM'ye odaklanacak bir kayıp fonksiyonu üzerinde çalışılacaktır.

Önerilen füzyon modelleri ve kayıp fonksiyonları optimize edilerek böbrek, karaciğer, akciğer gibi insan vücudundaki diğer organların bölütlemesinde test edilecek ve sonuçları tartışılacaktır.

Ayrıca önerilen füzyon modelleri ve kayıp fonksiyonları tek bir model ve kayıp fonksiyonu haline getirilerek hesaplama süreleri dikkate değer bir şekilde düşürülmeye çalışılacaktır.

KAYNAKLAR

1. Siegel, R. L., Miller, K. D., Hannah, E.F.B.S., Jemal A.(2022). Cancer Statistics 2022. *CA Cancer Journal for Clinicians*, 69(1), 7–33. <https://doi.org/10.3322/caac.21654>
2. Lemaitre, G., Marti, R., Rastgoo, M., Meriaudeau, F.(2017). *Computer-aided detection for prostate cancer detection based on multi-parametric magnetic resonance imaging*. Annual International Conference IEEE Engineering Medical Biology Society, Jeju Island, 3138-3141. <https://doi.org/10.1109/EMBC.2017.8037522>.
3. Mohammed, Z. F., Abdulla, A. A. (2021). An efficient CAD system for ALL cell identification from microscopic blood images. *Multimedia Tools and Applications*, 80(1),6355–6368.
4. Shen, D., Zhan, Y., Davatzikos, C. (2003). Segmentation of prostate boundaries from ultrasound images using statistical shape model. *IEEE Transactions on Medical Imaging*, 22(4), 539-551. doi: 10.1109/TMI.2003.809057.
5. Guo, Y., Gao, Y., Shen, D. (2016). Deformable MR Prostate Segmentation via Deep Feature Learning and Sparse Patch Matching. *IEEE Trans Medical Imaging*, 35(4), 1077-89. doi: 10.1109/TMI.2015.2508280.
6. Ghose, S., Oliver, A., Martí, R., Lladó, X., Vilanova, J.C., Freixenet, J., Mitra, J., Sidibé, D., Meriaudeau, F. (2012). A survey of prostate segmentation methodologies in ultrasound, magnetic resonance and computed tomography images. *Comput Methods Programs Biomed*, 108(1), 262-87. doi: 10.1016/j.cmpb.2012.04.006.
7. Litjens, G., Toth, R., van de Ven, W., Hoeks, C., Kerkstra, S., van Ginneken, B., Vincent, G., Guillard, G., Birbeck, N., Zhang, J., Strand, R., Malmberg, F., Ou, Y., Davatzikos, C., Kirschner, M., Jung, F., Yuan, J., Qiu, W., Gao, Q., Edwards, P.E., Maan, B., van der Heijden, F., Ghose, S., Mitra, J., Dowling, J., Barratt, D., Huisman, H., Madabhushi, A. (2014). Evaluation of prostate segmentation algorithms for MRI: the PROMISE12 challenge. *Medical Image Analysis*, 18(2), 359-73. doi: 10.1016/j.media.2013.12.002.
8. Jia, H., Xia, Y., Song, Y., Cai, W., Fulham, M., Feng, D.(2018). Atlas registration and ensemble deep convolutional neural network-based prostate segmentation using magnetic resonance imaging. *Neurocomputing*, 275(1), 1358–1369. <https://doi.org/10.1016/j.neucom.2017.09.084>.
9. Huang, G., Liu, Z., Weinberger, K.Q., van der Maaten, L. (2017). Densely Connected Convolutional Networks. *Computer Vision and Pattern Recognition (CVPR)*, 2261-2269, doi: 10.1109/CVPR.2017.243.

10. Yao, W., Guoqing, L., Meiyan, H., Jiacheng, G., Jun, J., Wei, Y., Wufan C., Qianjin F.(2014). Prostate Segmentation Based on Variant Scale Patch and Local Independent Projection. *IEEE Transactions on Medical Imaging*, 33(6), 1290-1303. doi: 10.1109/TMI.2014.2308901.
11. Mahapatra, D., and Buhmann, J.M.(2014).Prostate MRI Segmentation Using Learned Semantic Knowledge and Graph Cuts. *IEEE Transactions on Biomedical Engineering*, 61(3), 756-764. doi: 10.1109/TBME.2013.2289306.
12. Tian, Z., Liu, L., Zhang, Z., Xue, J., and Fei, B. (2017). A supervoxel-based segmentation method for prostate MR images. *Medical physics*, 44(2), 558–569. <https://doi.org/10.1002/mp.12048>
13. Yan, L., Liu, D., Xiang, Q., Luo, Y., Wang, T., Wu, D., Chen, H., Zhang, Y., Li, Q.(2021). PSP net-based automatic segmentation network model for prostate magnetic resonance imaging. *Computer Methods and Programs in Biomedicine*, 207, 106-211. <https://doi.org/10.1016/j.cmpb.2021.106211>.
14. Salvaggio, G., Comelli, A., Portoghese, M., Cutaia, G., Cannella, R., Vernuccio, F., Stefano, A., Dispensa, N., La Tona, G., Salvaggio, L., Calamia, M., Gagliardo, C., Lagalla, R., Midiri, M.(2021). Deep Learning Network for Segmentation of the Prostate Gland With Median Lobe Enlargement in T2-weighted MR Images: Comparison With Manual Segmentation Method. *Current Problems in Diagnostic Radiology*, 51(3), 328-333. <https://doi.org/10.1067/j.cpradiol.2021.06.006>.
15. Brosch, T., Peters, J., Groth, A., Weber, F. M., Weese, J.(2021). Model-based segmentation using neural network-based boundary detectors: Application to prostate and heart segmentation in MR images. *Machine Learning with Applications*, 6(1), 100078. <https://doi.org/10.1016/j.mlwa.2021.100078>
16. Meyer, A., Chlebus, G., Rak, M., Schindele, D., Schostak, M., van Ginneken, B., Schenk, A., Meine, H., Hahn, H.K., Schreiber, A., Hansen C.(2021). Anisotropic 3D Multi-Stream CNN for Accurate Prostate Segmentation from Multi-PlanarMRI. *Computer Methods and Programs in Biomedicine*, 200(1), 105-821. <https://doi.org/10.1016/j.cmpb.2020.105821>.
17. Anas, E.M.A., Mousavi, P., Abolmaesumi, P.(2018). A deep learning approach for real-time prostate segmentation in freehand ultrasound-guided biopsy. *Medical Image Analysis*, 48(1), 107-116. doi: 10.1016/j.media.2018.05.010.
18. Jia, H., Xia, Y., Song, Y., Cai, W., Fulham, M., Feng, D.(2018). Atlas registration and ensemble deep convolutional neural network-based prostate segmentation using magnetic resonance imaging. *Neurocomputing*, 275(1), 1358–1369. <https://doi.org/10.1016/j.neucom.2017.09.084>.

19. Liu, C., Gardner, S.J., Wen, N., Elshaikh, M.A., Siddiqui, F., Movsas, B., Chetty, I.J.(2019). Automatic Segmentation of the Prostate on CT Images Using Deep Neural Networks (DNN). *International Journal of Radiation Oncology Biology Physics*, 104(4), 924-932. doi: 10.1016/j.ijrobp.2019.03.017.
20. Abraham, B., Nair, M.S.(2018). Computer-aided classification of prostate cancer grade groups from MRI images using texture features and stacked sparse autoencoder. *Computerized Medical Imaging and Graphics*, 69(1), 60-68. doi: 10.1016/j.compmedimag.2018.08.006. Epub 2018 Aug 25. PMID: 30205334.
21. Cheng, R., Lay, N., Mertan, F., Turkbey, B., Roth, H. R., Lu, L., Gandler, W., McCreedy, E.S., Pohida, T., Choyke, P., McAuliffe, M.J., Summers, R.M.(2017). *Deep learning with orthogonal volumetric HED segmentation and 3D surface reconstruction model of prostate MRI*. 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017), Melbourne, 749-753. doi: 10.1109/ISBI.2017.7950627.
22. Zhou, W., Tao, X., Wei, Z., Lin, L.(2019). Automatic segmentation of 3D prostate MR images with iterative localization refinement. *Digital Signal Processing*, 98(1), 102-649. <https://doi.org/10.1016/j.dsp.2019.102649>.
23. Yu, L., Yang, X., Chen, H., Qin, J., Heng, P. A.(2017). *Volumetric ConvNetswith mixed residual connections for automated prostate segmentation from 3D MR images*. in: Thirty-First AAAI Conference on Artificial Intelligence (AAAI), San Fransisco, 66–72.
24. Mun, J., Jang, W., Sung, D.J., Kim, C.(2017). *Comparison of objective functions in CNN-based prostate magnetic resonance image segmentation*. 2017 IEEE International Conference on Image Processing (ICIP). Beijing, 3859-3863. doi: 10.1109/ICIP.2017.8297005.
25. He, B., Xiao, D., Hu, Q., Jia, F.(2017). Automatic Magnetic Resonance Image Prostate Segmentation Based on Adaptive Feature Learning Probability Boosting Tree Initialization and CNN-ASM Refinement. *IEEE Access*, 6(1), 2005-2015. doi: 10.1109/ACCESS.2017.2781278.
26. Tang, Z., Wang, M., Song, Z.(2018). Rotationally resliced 3D prostate segmentation of MR images using Bhattacharyya similarity and active band theory. *Physica Medica*, 54(1), 56-65. doi: 10.1016/j.ejmp.2018.09.005.
27. Brosch, T., Peters, J., Groth, A., Stehle, T., Weese J.(2018). *Deep learning-based boundary detection for model-based segmentation with application to MR prostate segmentation*. 21 st Internetal Conference, Granada, 515–522. https://doi.org/10.1007/978-3-030-00937-3_59

28. Meyer, A., Mehrtash, A., Rak, M., Schindele, D., Schostak, M., Tempany, C., Kapur, T., Abolmaesumi, P., Federov, A., Hansen, C.(2018). *Automatic high-resolution segmentation of the prostate from multi-planar MRI*. 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), Washington, 177-181, doi: 10.1109/ISBI.2018.8363549.
29. Zhang, Y., Wu, J., Chen, W., Chen, Y., Tang, X.(2019). *Prostate Segmentation Using Z-Net*. 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), Venezia, 11-14. doi: 10.1109/ISBI.2019.8759554.
30. Jin, Y., Yang, G., Fang, Y., Li, R., Xu, X., Liu, Y., Lai, X.(2020). 3D PBV-Net: An automated prostate MRI data segmentation method. *Computers in Biology and Medicine*, 128(1), 104160. <https://doi.org/10.1016/j.compbiomed.2020.104160>.
31. Ocal, H., Barisci N.(2019). *Prostate Segmentation via Fusing the Nested-V-net3d and V-net2d*. 2019 1st International Informatics and Software Engineering Conference (UBMYK), Ankara, 1-4. doi: 10.1109/UBMYK48245.2019.8965456.
32. Vavilis, S., Ergina, K., Roberto, P., Kostas, S.(2011). A Hybrid Binarization Technique for Document Images. *Learning Structure and Schemas from Documents*, 375(1), 165–179.
33. Batenburg, K.J., Sijbers, J.(2009). Adaptive thresholding of tomograms by projection distance minimization. *Pattern Recognition*, 42 (10), 2297–2305. doi:10.1016/j.patcog.2008.11.027.
34. Batenburg, K.J., Sijbers, J.(2008). Optimal Threshold Selection for Tomogram Segmentation by Projection Distance Minimization. *IEEE Transactions on Medical Imaging*, 28(5), 676–686. doi:10.1109/tmi.2008.2010437.
35. Kashanipour, A., Milani, N., Kashanipour, A., Eghrary, H.(2008). *Robust Color Classification Using Fuzzy Rule-Based Particle Swarm Optimization*. IEEE Congress on Image and Signal Processing, Sanya, 110–114.
36. Barghout, L., Sheynin, J. (2013). Real-world scene perception and perceptual organization: Lessons from Computer Vision. *Journal of Vision*, 13 (9), 709. doi:10.1167/13.9.709.
37. Thomas, J., Brock, B. (2009). *Interactive Segmentation for Manipulation in Unstructured Environments*. IEEE International Conference on Robotics and Automation Kobe International Conference, Kobe, 1377-1382.
38. Mobahi, H., Rao, S., Yang, A., Sastry, S., Ma, Y. (2011). Segmentation of Natural Images by Texture and Boundary Compression. *International Journal of Computer Vision*, 95, 86–98. doi:10.1007/s11263-011-0444-0.

39. Rao, S., Mobahi, H., Yang, A., Sastry, S., Ma, Y. (2009). *Natural Image Segmentation with Adaptive Texture and Boundary Encoding*. Proceedings of the Asian Conference on Computer Vision (ACCV), Xi'an, 135-146.
40. Shapiro, L.G., Stockman, G.C.(2001). *Computer Vision*. (1. Baskı). New Jersey: Prentice-Hall, 609.
41. Ohlander, R., Reddy, R.P., Raj, D. (1978). Picture Segmentation Using a Recursive Region Splitting Method. *Computer Graphics and Image Processing*, 8 (3), 313–333. doi:10.1016/0146-664X(78)90060-6.
42. Kimmel, R., Bruckstein, A.M. (2003). Fast Edge Integration. *International Journal of Computer Vision*, 53(3), 225-243.
43. Osher, S., Paragios, N. (2003). *Geometric Level Set Methods in Imaging, Vision and Graphics*. (1.Baskı). New York: Springer, 513.
44. Barghout, L.(2014). *Visual Taxometric approach Image Segmentation using Fuzzy-Spatial Taxon Cut Yields Contextually Relevant Regions*. International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems (CCIS), Montpellier, 163-173.
45. Pedrycz, W., Skowron, A., Kreinovich, V.(2008). *Handbook of Granular Computing*. (1. Baskı). West Sussex: Wiley, 1148.
46. Barghout, L.(2003). *Global Conceptual Context Changes Local Contrast Processing Updated to include Computer Vision Techniques*. (1. Baskı). Chisinau:Scholars' Press, 136.
47. Barghout, L., Lee, L. (2003). *Perceptual Information Processing System*. Google Patents
48. Guberman, S., Maximov, V.V., Gestalt, A.P. (2012). Image Understanding. *Gestalt Theory*, 34(2), 143-166.
49. Staib, L.H., Duncan, J.S.(1992). Boundary finding with parametrically deformable models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14 (11), 1061–1075. doi:10.1109/34.166621. ISSN 0162-8828, (1992).
50. Barghout, L.(2014). *Visual Taxometric Approach to Image Segmentation using Fuzzy-Spatial Taxon Cut Yields Contextually Relevant Regions*. IPMU 2014, Montpellier, 163-173.

51. İnternet: Deeplab Image Segmentation Network. (2018). *Sthalles*, 20(11), Web: https://sthalles.github.io/deep_segmentation_network/ Erişim Tarihi: 20.04.2022.
52. İnternet: Image Segmentation Using DIGIT 5 . (2016). *Nvidia*, 1(1), Web: <https://devblogs.nvidia.com/image-segmentation-using-digits-5/> Erişim Tarihi: 20.04.2022
53. Hubel, D.H., Wiesel, T.N.(1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *Journal of Physiology*, 160(1), 106.
54. Fukushima, K., Miyake, S.(1982). *Lecture Notes in Biomathematics*. (1. Baskı), Berlin: Springer, 444.
55. Léculun, Y., Bottou, L., Bengio, Y., Haffner, P.(1998). Gradient-based learning applied to document recognition. *IEEE*, 86(1), 2278–2324.
56. Krizhevsky, A., Sutskever, I., Hinton, G.E.(2012). *Advanced Neural Information Processing Systems*. (1. Baskı). Boston: MIT, 1128.
57. İnternet: Zhu, X.J.(2005). Semi-Supervised Learning Literature Survey. *University of Winsconsin*, 60. Web: https://pages.cs.wisc.edu/~jerryzhu/pub/ssl_survey.pdf Erişim Tarihi: 20.04.2022.
58. Zeiler, M.D., Fergus, R.(2014). *Visualizing and understanding convolutional networks*. In Proceedings of the European Conference on Computer Vision, Zurich, 818–833.
59. He, K., Zhang, X., Ren, S., Sun, J.(2016). *Deep residual learning for image recognition*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 770–778.
60. İnternet: Simonyan, K., Zisserman, A.(2014). Very deep convolutional networks for large-scale image recognition. arXiv, 1409.1556. Web: <https://arxiv.org/abs/1409.1556> Erişim Tarihi: 20.04.2022.
61. Qiu, Z.; Yao, T.; Mei, T.(2017). *Learning spatio-temporal representation with pseudo-3d residual networks*. In Proceedings of the IEEE International Conference on Computer Vision, Venice, 5533–5541.
62. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A.(2015). *Going deeper with convolutions*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, 1–9.

63. Ronneberger, O., Fischer, P., Brox T.(2015). *U-net: Convolutional networks for biomedical image segmentation*. International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, 234–241.
64. Milletari, F., Navab, N., Ahmadi, S.A.(2016). *V-net: fully convolutional neural networks for volumetric medical image segmentation*. International Conference on 3D Vision (3DV), Prague, 565–571.
65. Bloch, N., Rusu, M., Huisman, H., Futterer, J.(2013). *NCI-ISBI 2013 challenge: automated segmentation of prostate structures*. International Symposium on Biomedical Imaging (ISBI), San Fransisco, 370. <http://dx.doi.org/10.7937/K9/TCIA.2015.zF0vIOPv>.
66. Ocal, H., Barisci, N.(2022). Prostate Segmentation via Dynamic Fusion Model. *Arabian Journal for Science and Engineering*, 9(2), 1-14. <https://doi.org/10.1007/s13369-021-06502-w>
67. Ioffe, S., Szegedy, C.(2015). *Batch normalization: Accelerating deep network training by reducing internal covariate shift*. ICML'15: Proceedings of the 32nd International Conference on International Conference on Machine Learning, Lille, 448-456.
68. Glorot, X., Bengio, Y.(2010). Understanding the difficulty of training deep feedforward neural networks. *Aistats*, 9(1), 249–256.
69. Kingma, D.P., Ba, J.(2015). *Adam: a method for stochastic optimization*. in: International Conference on Learning Representations (ICLR). San Diego, 1–11.
70. Zhu, Q., Du, B., Yan, P.(2019). Boundary-weighted domain adaptive neural network for prostate MR image segmentation. *IEEE Transactional Medical Imaging*, 39(3), 753-763.
71. Yu, L., Yang, X., Chen, H., Qin, J., Heng, P. A.(2017). *Volumetric ConvNetswith mixed residual connections for automated prostate segmentation from 3D MR images*. Thirty-First AAAI Conference on Artificial Intelligence (AAAI), San Fransisco, 66–72.
72. Lin, T., Goyal, P., Girshick, R., He, K., Dollár, P.(2020). Focal Loss for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 42(2), 318-327. doi: 10.1109/TPAMI.2018.2858826.
73. Wang, P., Chung, A.C.S.(2018). *Focal dice loss and image dilation for brain tumor segmentation*. International Workshop on Deep Learning in Medical Image Analysis, Granada, 119–127.

74. Abraham, N., Khan, N. M.(2019). *A novel focal Tversky loss function with improved attention U-net for lesion segmentation*. 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), Venice, 683–687.
75. Jiang, H., Shi, T., Bai, Z., Huang, L.(2019). AHCNet: An Application of Attention Mechanism and Hybrid Connection for Liver Tumor Segmentation in CT Volumes. *IEEE Access*, 7(1), 24898-24909. doi:10.1109/ACCESS.2019.2899608.
76. Ocal H, Barisci, N.(2022). A Novel Prostate Segmentation Method: Tripple Fusion Model with Hybrid Loss. *Neural Computing and Applications*, 19(1), 1-20. doi : 10.1007/s00521-022-07188-3
77. İnternet: Ba, J.L., Kiros, J.R., Hinton, G.E. (2016). Layer normalization. *arXiv*, 9. Web: <https://arxiv.org/abs/1607.06450v1> Erişim Tarihi: 20.04.2022.
78. İnternet: Ulyanov, D., Vedaldi, A., Lempitsky, V.(2016). Instance normalization: The missing ingredient for fast stylization. *arXiv*, 9. Web: <https://arxiv.org/abs/1607.08022> Erişim Tarihi: 20.04.2022.
79. Zhang, Z., Fu, H., Dai, H., Shen, J., Pang, Y., Shao L.(2019). ET-Net: A Generic Edge-aTtention Guidance Network for Medical Image Segmentation. *MICCAI 2019 international conference*, Shenzhen, 13-17.
80. İnternet: Jungiang Chen(2012). ET-Vnet 3D model. *Github*, 5, Web: <https://github.com/junqiangchen/VNetFamily/blob/master/assests/ETVNet.PNG>. Erişim Tarihi: 20.04.2022.
81. Drozdal, M., Chartrand, G., Vorontsov, E., Shakeri, M., Jorio, L.D., Tang, A., Romero, A., Bengio, Y., Pal, C., Kadoury, S.(2018). Learning normalized inputs for iterative estimation in medical image segmentation. *Medical Image Analysis*, 44(1), 1–13.
82. Zhu, Q., Du, B., Wu, J., Yan, P.(2018). *A Deep Learning Health Data Analysis Approach: Automatic 3D Prostate MR Segmentation with Densely-Connected Volumetric ConvNets*. 2018 International Joint Conference on Neural Networks (IJCNN) Rio, 1-6. doi: 10.1109/IJCNN.2018.8489136.
83. Jia, H., Xia, Y., Song, Y., Zhang, D., Huang, H., Zhang, Y., Cai, W.(2020). 3D APA-Net: 3D Adversarial Pyramid Anisotropic Convolutional Network for Prostate Segmentation in MR Images. *IEEE Transactions on Medical Imaging*, 39(2), 447-457. doi: 10.1109/TMI.2019.2928056.
84. Jia, H., Song, Y., Huang, H., Cai, W., Xia, Y.(2019). *HD-Net: Hybrid Discriminative Network for Prostate Segmentation in MR Images*. International Conference on Medical Image Computing and Computer-Assisted Intervention, Shenzhen, 110-118.

85. Peng, C., Zhang, X., Yu, G., Luo, G., Sun, J.(2017). *Large kernel matters – improve semantic segmentation by global convolutional network*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, 1743–1751.
86. Cicek, O., Abdulkadir, A., Lienkamp, S., Brox, T., Ronneberger, O.(2016). *3D U-net: learning dense volumetric segmentation from sparse annotation*. International Conference on Medical Image Computing and Computer-Assisted Intervention, Atina, 424–432. https://doi.org/10.1007/978-3-319-46723-8_49
87. Chen, H., Dou, Q., Yu, L., Qin, H., Heng, P.A.(2018). VoxResNet: deep voxelwise residual networks for brain segmentation from 3D MR images. *NeuroImage*, 170 (2018) 446–455. <https://doi.org/10.1016/j.neuroimage.2017.04.041>.





GAZİ GELECEKTİR...