

T.C.
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
DOKTORA TEZİ

Böbrek Tümörlerinin Derin Öğrenme Yoluyla Segmentasyonu

Fuat TÜRK

HAZİRAN 2021

ETİK BEYANI

Kırıkkale 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.

Fuat TÜRK

Bilgisayar Mühendisliği Anabilim Dalında Fuat TÜRK tarafından hazırlanan Böbrek Tümörlerinin Derin Öğrenme Yoluyla Segmentasyonu adlı Doktora Tezinin Anabilim Dalı standartlarına uygun olduğunu onaylarım.

(Unvanı, Adı ve Soyadı, İmzası)

Anabilim Dalı Başkanı

Bu tezi okuduğumu ve tezin **Doktora Tezi** olarak bütün gereklilikleri yerine getirdiğini onaylarım.

(Unvanı, Adı ve Soyadı, İmzası)

Ortak Danışman (Varsa)

(Unvanı, Adı ve Soyadı, İmzası)

Danışman

Jüri Üyeleri

Başkan : (Unvanı, Adı ve Soyadı, İmzası) _____

Üye (Danışman) : (Unvanı, Adı ve Soyadı, İmzası) _____

Üye : (Unvanı, Adı ve Soyadı, İmzası) _____

Üye : (Unvanı, Adı ve Soyadı, İmzası) _____

Üye : (Unvanı, Adı ve Soyadı, İmzası) _____

...../...../.....

Bu tez ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Doktora derecesini onaylamıştır.

(Unvanı, Adı ve Soyadı, İmzası)

Fen Bilimleri Enstitüsü Müdürü

Çok kıymetli aileme...



ÖZET

BÖBREK TÜMÖRLERİNİN DERİN ÖĞRENME YOLUYLA SEGMENTASYONU

TÜRK, Fuat

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı, Doktora tezi

Danışman: Doç. Dr. Murat LÜY

Ortak Danışman: Prof. Dr. Necaattin BARIŞCI

Haziran 2021, 111 sayfa

Dünya çapında her yıl yüz binlerce insana böbrek kanseri teşhisi konulmaktadır. Böbrek kanseri özellikle gelişmiş ve sanayileşmiş ülkelerde daha yaygın olarak görülmektedir. Günümüzde böbrek kanseri tanısı alan hastaların yaklaşık %30'u maalesef metastatik hastalık aşamasında (uzak organlara yayılmış) iken fark edilmektedir.

Böbrek tümörleri, ileri yaştaki insanlar da görülme olasılığı daha yüksek olan bir kanser türüdür. Bu nedenle yaşamın ilerleyen dönemlerinde dikkatli olmak ve tanısal testler yaptırmak son derece önemlidir. Tıbbi görüntüleme ve derin öğrenme yöntemleri bu anlamda giderek daha önemli hale gelmektedir. Bu sebeple doktorların tümörleri başarılı bir şekilde fark edebilmesine yardımcı olacak derin öğrenme modellerinin geliştirilmesi büyük önem taşımaktadır. Bununla birlikte, böbrek ve prostat gibi, kanser tespiti nispeten zor olan yumuşak doku organları için başarılı sistemler oldukça azdır.

Böbrek hastalıklarının bilgisayar destekli tedavi planlamasında segmentasyon önemli bir süreçtir. Doğru segmentasyon elde etmek için genellikle derin öğrenme tabanlı çalışmaların yapılması gerekir. Yapılan tez çalışmasında, böbrek tümörleri ile mücadele eden uzman kişilere yardımcı olunabilmesi için mevcut U-Net ve V-Net modelleri geliştirmiş ve yeni modeller önerilmiştir. Bilindiği üzere segmentasyonun zor olduğu pek

çok durumda çoğunlukla U-Net ve V-Net tabanlı modeller kullanılmaktadır. Tez çalışmasında ise U-Net ve V-Net modellerinin üstün özelliklerini kullanarak daha iyi sonuçlar üretebilen yeni modeller önerilmiştir. Önerilen modeller, daha önce uygulanmamış kodlayıcı ve kod çözücü aşamalarında iyileştirmelerle daha başarılı bir sistemi temsil etmektedir. Yeni modellerin, özellikle böbrek ve böbrek tümörü segmentasyonuna odaklanan hekimlere yardımcı olabileceği düşünülmektedir. Önerilen her iki model de segmentasyonda mevcut görüntüleme modellerine göre daha iyi performans göstermiş, esnek yapısı ve uygulanabilirliği sayesinde tüm sistemlere kolayca entegre edilebilir şekilde hazırlanmıştır.

Bu amaçla geliştirilmiş U-Net modeli böbrek ve tümörleri için sırasıyla %97,8 ve %85,6, Hibrit V-Net modeli ise sırasıyla %97,7 ve %86,5'lik ortalama zar katsayısına ulaşmıştır. Her iki modelde mevcut sonuçlar doğrultusunda yumuşak doku organ segmentasyonu için güvenilir bir yöntem olarak rahatlıkla kullanılabilir.

Anahtar kelimeler: Medikal görüntü segmentasyonu; Böbrek ve tümör segmentasyonu, Hibrit V-Net model; Böbrek Tümörleri; U-Net; U-Net+ResNet; V-Net

ABSTRACT

SEGMENTATION OF KIDNEY TUMORS BY DEEP LEARNING

TÜRK, Fuat

Kırıkkale University

Graduate School of Natural and Applied Sciences

Computer Engineering Department, Ph.D. thesis

Supervisor: Assoc. Prof. Dr. Murat LÜY

Joint Supervisor: Prof. Dr. Necaattin BARIŞCI

Jun 2021, 111 pages

Kidney cancer is a common disease, especially in developed and industrialized countries. Since renal tumors, noticed in the metastatic stage (spread to distant organs) in nearly 30% of patients with kidney cancer, are more likely to develop in the elderly, it is necessary to be cautious and to provide diagnostic tests for people of advanced age

Medical imaging and deep learning methods are increasingly becoming more important in this sense. However, not many successful systems exist for soft-tissue organs such as the kidney and prostate, where tumors are relatively difficult to detect.

Segmentation is an important process in the computer-aided treatment planning of kidney diseases. For this reason, deep learning-based studies are often required to achieve correct segmentation. As U-Net /V-Net- based models are mostly used for many difficult segmentation processes, this study focused on new models designed with the superior features of the existing U-Net and V-Net models. The proposed hybrid models represent more successful systems with improvements to the encoder and decoder stages that were not previously implemented. We believe that physicians who focus specifically on kidney and kidney tumor segmentation will find these new models helpful. The new

models performed better than existing imaging models in segmentation and were prepared to be easily integrated into all systems thanks to their flexible structure and applicability.

The hybrid U-Net model developed in this study reached average Dice coefficients of 97.8% and 85.6% for kidney and tumor segmentation, respectively. The Hybrid V-Net model designed here showed average Dice coefficients of 97.7% and 86.5% for kidney and tumor segmentation, respectively. Both architectures proved to be reliable methods for soft tissue organ segmentation.

Keywords: Medical image segmentation; Kidney and tumor segmentation; Hybrid V-Net model; Kidney Tumors; U-Net; U-Net + ResNet; V-Net

TEŐEKKÜR

Tezimin hazırlanması esnasında hiçbir yardımcı esirgemeyen, bilimsel deney imkânlarını sonuna kadar bizlerin hizmetine veren, tez yöneticisi hocalarım, Sayın Doç. Dr. Murat LÜY 'e ve Sayın Prof. Dr Necattin BARIŐCI 'ya, tezimin birçok aşamasında bana destek olan değerli hocam Sayın Doç. Dr. Aydın ÇİFTÇİ 'ye teşekkür ederim.



İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
SİMGE VE KISALTMALAR DİZİNİ	xi
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM	22
2.1. Böbrek Tümörleri.....	22
2.2. Yapay Zekâ Öğrenme Yöntemleri	23
2.2.1. Makine Öğrenimi.	24
2.2.1.1. Denetimli Öğrenme.....	24
2.2.1.2. Denetimsiz Öğrenme.....	25
2.2.2. Derin Öğrenme.....	25
2.2.3. Derin Öğrenme Mimarileri	32
2.2.3.1. Evrişimsel Sinir Ağları	32
2.2.3.2. Tekrarlayan Sinir Ağları.	44
2.2.3.3. Sınırlı Boltzmann Makineleri.....	45
2.2.3.4. Derin İnanç Ağları.....	46
2.2.3.5. Derin Otomatik Kodlayıcılar.....	47
2.2.3.6. Derin Öğrenme Sinir Ağlarının Eğitilmesi	47
2.2.3.7. Optimizasyon Yöntemleri	50
2.3. Derin Öğrenme Algoritmaları	54
2.3.1. LeNet Mimarisi.	54
2.3.2. AlexNet Mimarisi.....	55
2.3.3. VGG16 Mimarisi.	56
2.3.4. GoogleNet Mimarisi.....	57
2.3.5. ResNet Mimarisi.	58

2.3.6. R-CNN, Fast R-CNN ve Faster R-CNN Modelleri.	59
2.4. U-Net Mimarisi	62
2.5. U-Net+ResNet Mimarisi	64
2.6. U-Net++ Mimarisi	66
2.7. Geliştirilmiş U-Net Model Mimarisi	68
2.8. V-Net Mimarisi	70
2.9. Füzyon V-Net Mimarisi	72
2.10. ET V-Net Mimarisi	74
2.11. Hibrid V-Net Mimarisi	75
2.12. Zar Benzerlik Katsayısı	78
2.13. Görüntü Önleme	79
3. ARAŞTIRMA BULGULARI	83
3.1. U-Net Modelleri İçin Araştırma Bulguları.....	83
3.2. V-Net Modelleri İçin Araştırma Bulguları.....	87
4. SONUÇLAR ve TARTIŞMA	93
KAYNAKLAR	95
ÖZGEÇMİŞ	110

ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
2.1. Derin öğrenme metodolojisi.....	23
2.2. Makine Öğreniminin Aşamaları.....	24
2.3. İnsan nöronunun yapısı	26
2.4. Bir nöronun matematiksel modeli	26
2.5. YSA ve yitim fonksiyonunun sembolize edilmesi.....	28
2.6. Tek Katmanlı Algılayıcı modeli.....	29
2.7. ÇKA modeli	29
2.8. İleri beslemeli Yapay Sinir Ağı modeli	30
2.9. Geri beslemeli Yapay Sinir Ağı modeli	31
2.10. Derin öğrenme ağları.....	32
2.11. LeNet mimarisi.....	33
2.12. Evrişimsel Sinir Ağı mimarisi.....	34
2.13. Evrişim işlemi ve adım kaydırma	35
2.14. ReLU aktivasyon fonksiyonu.....	36
2.15. Sigmoid Fonksiyonu	37
2.16. Tanh fonksiyonu.....	38
2.17. Leaky ReLU aktivasyon fonksiyonu.....	39
2.18. En çok kullanılan aktivasyon fonksiyonları	40
2.19. ESA mimarisinde havuzlama katmanı	41
2.20. Tam bağlantılı katman yapısı	42
2.21. Bırakma katmanı uygulanması.....	42
2.22. Tekrarlayan sinir ağı modeli	45
2.23. Sınırlı boltzmann sinir ağı modeli.....	46
2.24. LeNet mimari yapısı.....	54
2.25. AlexNet mimari yapısı	55
2.26. VGG16 mimarisi	56
2.27. GoogleNet mimarisi	58
2.28. Microsoft ResNet mimarisi	59

2.29. R-CNN mimarisi	60
2.30. Fast R-CNN mimarisi	61
2.31. Faster R-CNN mimarisi	61
2.32. U-Net Mimarisi	62
2.33. ResNet Mimarisi	64
2.34. U-Net+ResNet mimarisi.....	65
2.35. U-Net++ Mimarisi.....	66
2.36. Geliştirilmiş U-Net Model Mimarisi.....	68
2.37. Klasik bir yapıdan oluşan V-Net mimarisinin şematik gösterimi	70
2.38. Füzyon V-Net mimarisinin şematik gösterimi	72
2.39. Geç Füzyon mimarisi	73
2.40. ET V-Net mimarisi.....	74
2.41. Hibrit V-Net mimarisinin şematik gösterimi	75
2.42. ResNet++ mimarisi	76
2.43. Zar benzerlik katsayısı	79
2.44. Manuel segmentasyon ile hazırlanmış bir böbrek görüntüsü.....	81
2.45. 3B böbrek görüntüsü Nifti formatı ve manuel segmentasyon görüntüsü ...	82
2.46. Sol: Segmentli bölgelerin 3B hacimsel gösterimi Sağ: 2B böbrek ve..... böbrek kanseri görüntüsü	82
3.1. U-Net Eğitim boyunca elde edilen zar katsayısı	83
3.2. Orijinal BT görüntüleri girişi ve onların böbrek segmente çıkış resimleri ..	86
3.3. Orijinal BT görüntüleri girişi ve onların böbrek tümör segmente çıkış... Resimleri	87
3.4. 5 kat çapraz doğrulamalı algoritma şeması	88
3.5. Böbrek ve tümör için zar katsayısı ve kayıp değerleri	89
3.6. Orijinal BT görüntüleri girişi ve onların böbrek segmente çıkış resimleri ..	91
3.7. Orijinal BT görüntüleri girişi ve onların böbrek tümör segmente çıkış... resimleri.....	92

ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
2.1. U-Net model yapısı.....	63
2.2. U-Net+ResNet model yapısı	66
2.3. U-Net++model yapısı.....	67
2.4. Geliştirilmiş U-Net model yapısı.....	69
2.5. V-Net model yapısı.....	71
2.6. Fusion V-Net model yapısı.....	73
2.7. ET V-Net model yapısı.....	75
2.8. Hibrit V-Net model yapısı.....	78
3.1. U-Net modelleri için test ve validation (doğrulama) zar katsayısı.....	84
3.2. Segmentasyon method karşılaştırılması (KiTS19 top 5 sonuçları.....	85
3.3. BT görüntüleri için böbrek segmentasyon sonuçlarının karşılaştırılması.....	85
3.4. V-Net modelleri için test ve validation zar benzerlik katsayısı.....	89
3.5. Böbrek ve tümör segmentasyon sonuçlarının literatür ile karşılaştırılması.....	90

SİMGELER DİZİNİ

Kt/V	Minimum diyaliz dozu
x	YSA giriş değeri
y	YSA çıkış değeri
w	YSA ağırlık değeri
b	Doğrulama katsayısı
R	Düzenleme değeri
σ	Standart sapma
β	Beta (ortalama) sembolü
γ	Gama sembolü

KISALTMALAR DİZİNİ

VKİ	Vücut Kitle İndeksi
BKO	Bel Kalça Oranı
RHK	Renal Hücreli Karsinom
ESA	Evrişimsel Sinir Ağları
2B	İki Boyutlu
BT	Bilgisayarlı Tomografi
GRSA	Genelleştirilmiş Radyasyon Sinir Ağları
RTSA	Radyal Tabanlı Sinir Ağları
3B	Üç Boyutlu
DVM	Destek Vektör Makinesi
KBH	Kronik Böbrek Hastalığı
GFH	Glomerüler Filtrasyon Hızı
KEYK	K en yakın komşu
ROC	Receiver Operating Characteristic
AUC	Area under curve

HN	Hidro nefrozlu
MR	Manyetik Rezonans
MKZH	Maksimum Kararlı Zamansal Hacim
PÖV	Pozitif Öngörücü Değer
NÖV	Negatif Öngörücü Değer
LPN	Laparoskopik Parsiyel Nefrektomi
TBK	Tam Bağlı Katman
SE	Squeeze-and-Excitation
HMYSA	Heterojen Modifiye Yapay Sinir Ağı
GY	Geri Yayılım
ÇKA	Çok Katmanlı Algılayıcı
LİTS	Karaciğer Tümör Segmentasyonu
SBT	Spiral Bilgisayarlı Tomografi
YSA	Yapay Sinir Ağı
TKA	Tek Katmanlı Algılayıcı
SGD	Stochastic Gradient Descent
SRN	Simple Recurrent Network
TSA	Tekrarlayan Sinir Ağı
SBM	Sınırlı Boltzmann makineleri
DİA	Derin İnanç Ağları
OK	Otomatik Kodlayıcılar
DOK	Derin veya yığılanmış otomatik kodlayıcılar
GYA	Geri Yayılım Algoritması
OKH	Ortalama Karesel Hata
BN	Batch Normalization
ReLU	Rectified Linear Unit
EGM	Edge Guidance Module
WAM	Weight Aggregation Module
DSC	Dice Smilarity Coefficient

1. GİRİŞ

Dünya nüfusunun hızlı artışı ve yaşlanmasıyla birlikte, kanser önde gelen bir ölüm nedeni olarak karşımıza çıkmaktadır. Tıp alanındaki gelişmeler sayesinde inme ve koroner kalp hastalıklarının ölüm oranlarındaki belirgin düşüşlerin de etkisiyle birçok ülkede kanser insidansı ve mortalitesi ilk sıraya yükselmiştir. Bununla birlikte, en sık teşhis edilen kanser ve kansere bağlı ölümlerin önde gelen nedeni, ekonomik gelişme derecesine ve ilgili sosyal ve yaşam tarzı faktörlerine bağlı olarak ülkeler arasında ve her ülke içinde de önemli ölçüde farklılık göstermektedir[1]. Küresel hastalık yükü veritabanı istatistiklerine göre kanser istatistikleri verileri, 2018 yılında dünya çapında 400.000'den fazla böbrek kanseri vakasının tespit edildiğini ortaya koymaktadır. 2018 ve 2030 yılları arasında böbrek kanseri vaka sayısının ortalama olarak yılda 475,4 binlere ulaşması beklenmekte ve vaka sayılarının 0-39 yaşları arasındaki kişilerde azalacağı tahmin edilmektedir [2].

Böbrek kanseri teşhisi konulan hastaların çoğu 60 ila 70 yaşları arasındadır ve istatistiklere göre asemptomatik (belirti göstermeyen) böbrek tümörlerinin sayısının arttığı görülmektedir. [3]. Vücut Kitle İndeksi (VKİ), Bel-Kalça Oranı (BKO) ve bel çevresi gibi kiloyla ilgili faktörler ile hipertansiyon ve sigara kullanımı gibi dış etkenler böbrek kanserinin başlangıcı ile doğrudan ilişkilendirilmiştir [4,5]. Kalsiyum, C vitamini, E vitamini ve lif yönünden zengin diyetlerin böbrek kanserine yakalanma olasılığını azaltabileceği ifade edilmiştir. [6-11]. Böbrek tümörleri genitoüriner kanserler arasında prostat ve mesane kanserlerinden sonra üçüncü sıklıkta görülmektedir. Daha anlaşılır bir ifadeyle solid tümörlerinin %3,5' ini oluştururlar [12]. Son dönemlerde tanıda özellikle ultrason ve bilgisayarlı tomografinin de kullanımının artmasıyla daha genç yaşta hastalarda fark edilmekte ve daha erken evrede tedavi edilebilmektedir [13].

Böbrek tümörleri iyi huylu ve kötü huylu olmak üzere iki ayrı gruba ayrılabilir. İyi huylu tümörler çoğunlukla zararsızdır, ancak bazıları kitle büyüdükçe kas ağrısı veya hematüri (idrarda kan görülmesi) gibi semptomlara neden olabilir [14,15]. İyi huylu böbrek tümörleri; kapsül ve parankim (görevli doku) gibi mezenkimal (kök hücre tipi) yapılardan köken aldığı gibi kortikal (kabuksal) dokulardan da köken alabilir [16]. Adenom, en sık görülen iyi huylu parankimal böbrek tümörüdür [17]. Onkositom, anjiomiyolipom,

leiomyom, lipom, hemangiom ve juxtaglomerular tümörler diğer iyi huylu böbrek tümörlerini oluşturmaktadırlar. Kötü huylu tümörler ise riskli kabul edilmektedir. Kötü huylu tümörlerin çoğu renal hücreli karsinom (RHK) olarak ifade edilmektedir [18]. Bunların tedavisinde genellikle böbrek veya tümörün çıkarılması önceki yıllarda kullanılan etkili bir tedavi yöntemi iken günümüzde mevcut olan ileri görüntüleme teknikleri sayesinde önleyici tedavi daha çok önem kazanmaktadır [19]. Onkolojik tedaviler göz ardı edilmemekle birlikte, gereksiz ameliyatların önlenmesine yönelik umut vadeden çalışmalar da dikkat çekmektedir [20]. Son yıllarda, derin öğrenme yöntemleri tıp alanında yerini bulmuş ve tıbbi segmentasyonda daha popüler hale gelmiştir. Bununla birlikte, literatürde böbrek ve böbrek tümör segmentasyonu ile ilgili yeterince çalışma bulunmamaktadır [21-23]. Bu nedenle, böbrek tümörlerinde kullanımları ile ilgili olarak derin öğrenme yöntemleri konusunda daha fazla araştırmaya ihtiyaç duyulmaktadır.

Bilgisayarlı görüntü tanıma konusundaki son araştırmalar, Evrişimsel Sinir Ağlarının (ESA) segmentasyon gibi zorlu görevlerle başa çıkmadaki başarısını vurgulamıştır. Bu başarı, ESA'ların insan müdahalesine ihtiyaç duymadan orijinal verileri kullanarak kendi başlarına öğrenmelerine dayanmaktadır [24]. Girişler, çıkarılan özelliklerden daha yüksek değerler sağlanarak ağ katmanları aracılığıyla işlenir. Daha derin katmanlar ise daha büyük veriler için kullanılan filtreler nedeniyle daha az miktarda yerel veri yakalayabilir [25]. Etkili ve doğru segmentasyon her zaman iyileştirilebilir, özellikle de küçük tıbbi hataların bile göz ardı edilmemesi gerektiği düşünüldüğünde bu durum oldukça önem arz etmektedir. Yeni araştırmalar, önceki çalışmaların eksikliklerini iyileştirirken gelecekteki çalışmalar için rehber özelliği taşımaktadır.

Böbreklerin ve böbrek tümörlerinin segmentasyonu, doktorlar için zorlu bir süreç olduğu için bu alanda daha fazla çalışmaya ihtiyaç duyulmaktadır. Böbrek kanserlerinin evrimini izlemek manuel segmentasyonda zor olduğu için çoğu böbrek görüntüsü analizi, böbrek tümörü ölçümünden ziyade böbrek segmentasyonuna dayanır.. Süreç sadece zaman alıcı olmakla kalmamakla birlikte aynı zamanda hesaplamalarda hatalara neden olabilmekte ve iki boyutlu (2B) tümör izlemede yanlış sonuçlara yol açabilmektedir [26]. Tümörde niteliklilik ve kistik dokular bulunabileceğinden, bazı böbrek kanserlerinin Bilgisayarlı Tomografi (BT) görüntülerinde farklı görünümlere sahip olduğu düşünülmelidir [27].

Problemi çözmek için otomatik ve manuel segmentasyona uygun olarak farklı yöntem ve teknikler kullanılabilir [28].

Tez çalışmasında geliştirilmiş olan U-Net ve V-Net modelleri segmentasyon ve yeni yöntemler açısından çok önemlidir; sadece böbrek ve tümörün aynı zamanda segmentasyonu için değil, segmentasyonun zor olabileceği tüm durumlarda kullanılmak üzere tasarlanmış esnek bir modeldir. Mevcut U-Net ve V-Net modellerinin temel eksiklikleri dikkate alınarak tasarlanmış olan yeni iki farklı model, lokal uygulama ve tüm uluslararası uygulama sistemlerine kolayca entegre edilebilmesinden dolayı tüm görüntü bölütleme modellerinde rahatlıkla kullanılabilir. Derin öğrenme yapay zekânın bir alt kolu olan makine öğrenmesinin bir bölümüdür. Bu sebeple literatür taraması yapılırken yapa zekâ ve makine öğrenmesinin tıp alanındaki çalışmaları üzerine yoğunlaşmıştır.

İlk olarak 2003 yılında Monika ve Uvais'in hemodiyaliz dozunu belirlemek için yaptıkları yapay zekâ çalışması incelenmiştir. Yapılan çalışmada son dönem böbrek hastalığında hemodiyalizin etkinliğinin yeterlilik hesaplanarak belirlendiği ifade edilmiştir. Son 20 yıldır bu yaşam sürdürücü tedavinin böbrek hastaları için ne kadar uygun olduğu ve diyalizin yeterliliği ve ölçümü konularındaki endişeler yetkililer tarafından tartışılmaya devam edilmektedir. Günümüzde, minimum diyaliz dozu olan Kt / V (Kütle / Hacim), üre kinetiğinin bilgisayarlı hesaplanmasıyla değerlendirilmektedir. Yöntem oldukça standart olmasına rağmen, nihai parametrik modelin geliştirilmesinde yapılan çeşitli varsayımlar nedeniyle hala kesin sonuçlar verebilen bir yöntem değildir. Çalışmada, Genelleştirilmiş Regresyon Sinir Ağları (GRSA) kullanarak Kt / V 'yi belirlemek için yeni bir algoritma yaklaşımı sunulmuştur ve araştırmalar bunun çok umut verici olduğunu göstermiştir. GRSA yöntemi, Kt / V 'yi belirlemek için genelleştirilmiş bir regresyon sinir ağını ifade etmektedir. $I = 1, 2, \dots, N$ şeklinde verilen eğitim girdisi için x_i ve Green fonksiyonu, (x, x_i) arasındaki bire bir ilişkiyi ifade ederken, büyük N değeri için hesaplamada uygulanması pahalı olabilecek bir düzenleme ağı üretmektedir. Ayrıca, matrisin boyutu arttığında başarısızlık olasılığı daha yüksektir. Hesaplama zorluklarının üstesinden gelmek için, ağın karmaşıklığının azaltılması gerekir ki bu da düzenli hale getirilmiş çözüme yaklaşık bir değer gerektirir. GRSA'nın mimarisi, Radyal Tabanlı Yapay Sinir Ağları (RTYSA) düzenlemesinden çok az farklılık göstermektedir. İlk olarak

yalnızca gizli katmanın önyargısı vardır. Giriş katmanının değeri, ağırlık vektörü ile gizli katmanın çıkışının çarpımına normalleştirme işlemi uygulanması ile elde edilmektedir. İkinci olarak, doğrusal katmanın ağırlıkları hedef vektöre ayarlanmaktadır. İki mimari arasındaki en büyük fark ise ağırlıkların seçildiği yöntemdir. GRSA, eğitim ağırlıkları yerine hedef değeri doğrudan giriş eğitim vektörü ve karşılık gelen çıktı vektörünün bir bileşeni ile ilişkili eğitim setinden ağırlıklara atamaktadır. GRSA mimarisi, hızlı öğrenmesi ve optimum regresyon yüzeyine yakınsaması nedeniyle seçilmiştir. GRSA modeli sayesinde hasta diyalizdeyken herhangi bir zaman aralığında, tüm diyaliz değerlerini o zaman aralığında toplamak ve analiz etmek için laboratuvara götürmek zorunda kalınmadan, çıkarılan üre miktarı bulunabilir. Daha fazla deneysel doğrulama ve daha büyük bir veri seti ile bulguları daha yüksek bir güven derecesiyle sonuçlandırmak gereklidir. Yazarlar, özellikle son dönem böbrek hastaları vakalarında doğru hesaplama yapılması ve hekime hemodiyaliz reçetesi için yol gösterici olan ayrıca ölüm oranını azaltan uygun algoritmik prosedür bulmak amacıyla açıklanan tekniği kullanarak başarılı sonuçlar elde etmişlerdir [29].

Roberto ve arkadaşları üç boyutlu (3B) ultrason görüntülerinde böbrekleri bölümlere ayırmak için makine öğrenmesi tabanlı bir yöntem sunmuşlardır. Bu çalışmada ultrasonun, böbrek muayeneleri için tercih edilen görüntüleme yöntemi olduğunu belirtmişlerdir. Düşük maliyeti, kolay ulaşılabilirliği ve radyasyon eksikliği bu tercihin başlıca nedenleri arasındadır. Günümüzde, böbreğin uzun ve kısa ekseninin ölçümlerini içeren muayeneler için en çok kullanılan yöntemin ultrason modeli olduğunu, ayrıca böbrek hacminin de tahmin edilebilir olduğunu söylemişlerdir. Ana zorlukların böbrek görünümündeki yüksek değişkenlik, artefaktların sık varlığı (gölgeler, benek gürültüsü, vb.) ve klinik kabul için hesaplama süresinde güçlü bir kısıtlama (10 saniyeden az) olduğundan bahsetmişlerdir. Algoritmaları, bir Destek Vektör Makinesi (DVM) tabanlı algılama algoritması ve ardından model tabanlı bir deformasyon tekniği aracılığıyla 480 adet 3B görüntüden oluşan bir veri tabanını kullanmaktadır. Şiddetli patolojiler böbreklerde güçlü deformasyonlara neden olduğu için önerilen yöntem, kullanıcının sonucu birkaç tıklama ile iyileştirmesine olanak tanıyan sezgisel etkileşim işlevlerini kapsamaktadır. Doğrulama 360 vaka üzerinde öğrenilerek ve 120 vaka üzerinde test edilerek yapılmıştır. Başarılı bir segmentasyon ile vakaların %50'-%90'ı arasında 3 işlemde daha azında otomatik olarak sonuca ulaşıldığını ifade etmişlerdir [30].

Chi-Jim ve arkadaşları, Kronik Böbrek Hastalığını (KBH) incelemek üzere makine öğrenmesi tabanlı bir sistem geliştirmişlerdir. Bu çalışmada dünyadaki insanların büyük bir kısmının kronik böbrek hastalığından rahatsız oldukları ve birçok hastanın son evreye gelene kadar durumlarından haberdar bile olmadıklarını ifade etmişlerdir. Cerrahi işlem gerektirmeyen ultrasonik görüntüleme teknikleriyle elde edilen tanılarda, KBH'yı saptamak için önemli klinik yaklaşımlar düzenlenebilir ve yüksek potansiyel veya riskli KBH hastaları için kan testi yoluyla enfekte olmaktan kaçınabileceğini ifade etmişlerdir. İyotlu kontrast madde olarak böbrek fonksiyonunda ani bozulma olasılığını azaltabileceği vurgulanmıştır. Bu araştırma, KBH teşhisini ve farklı aşamalarını kolaylaştırmak için bilgisayarla görme ve makine öğrenimi tekniklerine dayalı bir tespit sistemi kurmuştur. Hızlı tespit için yeni özellikler ve destek vektör makinesi uygulanmıştır. Farklı kümelenmiş gruplar üzerinde birkaç değerlendirme yapılmış ve tahmini Glomerüler Filtrasyon Hızlarına (GFH) göre karşılaştırılmıştır. Ek olarak önerilen sistem, her bir test senaryosu için özellik çıkarma ve sınıflandırma için ortalama 0,016 saniye gerektirmiştir. Sonuçlar, sistemin cerrahi işlem gerektirmeyen ultrasonografik yaklaşımlara dayalı tutarlı tanı üretebileceğini ve KBH hastaları için en uygun klinik tanı ve tıbbi tedavi olarak kabul edilebileceğini göstermiştir [31].

Matt ve arkadaşları böbrek kanserinin tahmini için makine öğrenmesi tabanlı bir sistem geliştirmişlerdir. Çalışmalarında böbrek kanserinin, modern tıpta önemli bir sorun olduğunu ifade etmişlerdir. Ayrıca hastanın hayatta kalma süresini tahmin etmenin, hasta farkındalığı ve uygun tedavi rejimleri geliştirmek için çok önemli olduğunu vurgulamışlardır. Etkili hayatta kalma süresi tahmininin hastalara değerli bir bakış açısı sağlayabileceğini ve doktorlarının bir tedavi rejimi geliştirmedeki eylemleri hakkında bilgi verebileceğini açıklamışlardır. Günümüzde böbrek kanseri sağkalım oranlarını tahmin etmek için birkaç farklı model mevcuttur. Moleküler özellik analizi üzerine inşa edilen önceki tahmin modelleri sadece gen ekspresyon verileriyle sınırlıdır. Bu çalışmada gen, ekson, bağlantı ve izoform modalitelerinden elde edilen verilerinin, tek modlu ve çok modlu analizi arasındaki beş yıllık sağkalımı tahmin etmedeki farkı araştırmışlardır. Ön bulgular, hem destek vektör makineleri hem de k-En Yakın Komşu (KEYK) yöntemleriyle tek modlu öğrenmeye kıyasla çok modlu öğrenme için Receiver Operating Characteristic (ROC) eğrisi altındaki alan ve Area Under Curve (AUC) olarak

isimlendirilen bölgenin ölçüldüğü daha yüksek tahmin doğruluğu bildirmektedir. Çalışmanın sonuçları daha büyük bir örneklem boyutu ve ek makine öğrenimi yöntemleri kullanarak diğer kanser türlerinin hayatta kalmasını tahmin etmek için çok modlu mevcut verilerinin kullanımının daha fazla araştırmayı haklı çıkardığını göstermektedir [32].

Armando ve arkadaşları Prenatal Hidro Nefrozlu (HN) bebeklerde cerrahi müdahaleyi tahmin etmek için ticari olarak temin edilebilen, bulut tabanlı bir makine öğrenimi platformuna uyumlu bir model geliştirmişlerdir. Prenatal HN veri tabanı, Microsoft Azure Machine Learning Studio'ya yüklenmiş ve veri yüklemesi için olasılık temelli bileşen analizi kullanılmıştır. Birincil sonuç olarak cerrahi müdahale kullanılarak, model eğitimi için iki sınıflı karar ormanına ve sinir ağına birden çok klinik değişken dahil edilmiştir. Modeller, verilerin yüzde olarak 70/30 oranında bölünmesinden sonra puanlanıp değerlendirilmiştir. Toplam 557 veri giriş olarak sisteme dahil edilmiştir. Optimize edilmiş model, ameliyatı tahmin etmek için 0,5'lik bir eşik kullanarak 0,9 eğri altında bir alan, 0,87 doğruluk ve 0,80 kesinlik elde etmiştir. Tahmine dayalı model, uygulama ve web sayfası geliştirme için benzersiz bir API anahtarı oluşturularak 35 saniyede bir web hizmeti olarak devreye alınmıştır. Dâhil edilen değişkenlere dayalı kişiselleştirilmiş tahmin, bir dakikadan kısa bir sürede web tabanlı ve toplu yürütme Excel dosyası olarak dağıtılmıştır. Bulut tabanlı makine öğrenimi teknolojisi, tahmine dayalı analitik çözümlerinin kolayca oluşturulmasına, devreye alınmasına ve paylaşılmasına olanak tanımaktadır. Böylelikle doğum öncesi HN 'yi örnek olarak kullanarak, mevcut standardın ötesine geçen yaratıcı bir çözümü rapor ederek veri analizi ile çağdaş zorlukları ele alma fırsatı sunmuşlardır [33].

Qiang ve arkadaşları, “Çocuklarda böbrek ve idrar yollarının doğuştan gelen (konjenital) anormalliklerinin tanısı için ultrason görüntüleme verilerine dayalı transfer öğrenimi” isimli çalışmalarında makine öğrenmesi ile ilgili yeni bir yöntem sunmuşlardır. Çalışmalarında, çocuklarda böbrek ve idrar yolunun konjenital anormalliklerinin teşhisi için ultrason böbrek görüntülerinin sınıflandırılmasının zorlu bir görev olduğunu ifade etmişlerdir. Geleneksel görüntü özellikleri üzerine inşa edilen mevcut model ile sınıflandırma modellerinin geliştirilmesi arzu edilmektedir. Çocuklarda idrar yolu hastalıklarının tanısını iyileştirmek için böbrek görüntülerinden görüntüleme özelliklerini çıkarmak için transfer öğrenmeye dayalı bir yöntem önermişlerdir. Özellikle orijinal

görüntüler, gradyan özellikleri ve mesafeli dönüşüm özellikleri dahil olmak üzere ultrason görüntülerinden hesaplanan 3 kanallı, özellik haritalarından aktarım öğrenmeye dayalı, özellik çıkarımı için önceden eğitilmiş bir derin öğrenme modeli (imagenet-caffe-alex) benimsemişlerdir. Destek vektör makinesi sınıflandırıcıları daha sonra, aktarım öğrenme özellikleri, geleneksel görüntüleme özellikleri ve bunların kombinasyonu dahil olmak üzere farklı özellik kümeleri üzerine inşa edilmektedir. Deneysel sonuçlar, transfer öğrenmesi ve geleneksel görüntüleme özelliklerinin kombinasyonunun, idrar yolu problemi olan hastaların ultrason böbrek görüntüleri ile değerlendirilen kontrollerden ayırmak için en iyi sınıflandırma performansını sağladığını göstermiştir [34].

Ahmed ve arkadaşları KBH'nın böbrek patolojisi veya azalmış böbrek fonksiyonlarının neden olduğu, yaşam boyu süren ciddi bir durum olduğunu ifade etmişlerdir. Erken tahmin ve uygun tedaviler muhtemelen kronik hastalığın son aşamaya ilerlemesini durdurabilir veya yavaşlatabilir; hastanın hayatını kurtarmanın tek yolunun diyaliz veya böbrek transplantasyonudur şeklinde bir hipotez ortaya koymuşlardır. Çalışmalarında kronik böbrek hastalığının erken tahmini için çeşitli makine öğrenme yöntemlerinin yeteneklerini incelemişlerdir. Metodoloji, veri parametreleri arasındaki ve hedef sınıf niteliği arasındaki ilişkiyi, incelenen tahmine dayalı analitiğin kullanımıyla desteklenmektedir. Tahmine dayalı analitik, bir dizi tahmine dayalı model oluşturmak için makine öğrenimini beslemeyen optimum parametre alt kümesini sunmayı sağlamıştır. Sınıf özelliğine ek olarak 24 parametre ile başlanmış ve bunların %30'u kronik böbrek hastalığını tahmin etmek için ideal alt küme olarak sona ermiştir. AUC 0.995, duyarlılık 0.9897 ve özgüllük 1'in en yüksek performans sonuçlarını elde eden, denetimli bir öğrenme ortamında toplam 4 makine öğrenimi tabanlı sınıflandırıcı değerlendirilmiştir. Deneysel prosedür, makine öğrenimindeki ilerlemelerin, tahmine dayalı analitik yardımıyla böbrek hastalığı alanında ve ötesinde tahmin etme yeteneğini kanıtlayan, akıllı çözümlerin tanınacağı, ümit verici ortam olduğunu göstermiştir [35].

Xin Yang ve arkadaşları derin öğrenme tabanlı böbrek segmentasyon çalışması gerçekleştirmişlerdir. Dinamik kontrastlı Manyetik Rezonans (MR) görüntülerinden elde edilen böbrek segmentasyonu, fonksiyonel değerlendirmede önemli bir görevdir. Segmentasyon yöntemlerindeki ilerlemeye rağmen çoğu çalışmada böbreğin tamamını BT görüntülerinde segmentlere ayırmaya odaklanılmıştır. Dinamik kontrastlı MR

görüntülerinden dahili renal yapıların (yani korteks, medulla ve renal pelvis) doğru segmentasyonu için hala etkili olduğu ve otomatik çözümlerinin olmadığı ifade edilmiştir. Çok çeşitli dinamik kontrastlı MR verileri için güçlü bir şekilde yüksek segmentasyon doğruluğu elde edebilen ve çok az manuel işlem ve parametre ayarı gerektiren renal bölme segmentasyonu için bir yöntem sunmuşlardır. Önerilen yöntem beş ana adımdan oluşmaktadır. İlk olarak, taramalar sırasında hastaların hareketinden kaynaklanan hareket artefaktlarını azaltmak ve böbrek bölgelerini iyileştirmek için görüntü zaman serisi önceden işlenmiştir. İkinci olarak, böbrek Maksimum Kararlı Zamansal Hacim (MKZH) konseptine göre bölümlere ayrılmaktadır. Önerilen MKZH, uzaysal alanda homojen ve zamansal dinamikler açısından kararlı olan anatomik yapıları tespit etmektedir. MKZH tabanlı böbrek segmentasyonu gürültüye karşı dayanıklıdır ve bir eğitim aşaması gerektirmemektedir. İlave olarak böbrek fonksiyon bozukluğunun neden olduğu böbrek şekli değişikliklerine iyi uyum sağlayabilmektedir. Üçüncüsü, bölümlenmiş böbrekteki vokseller, zamansal fazlalık ve gürültüleri ortadan kaldırmak için ana bileşenler (kişel bilgisayarlar gibi) tarafından tanımlanır. Daha sonra, vokselleri birden çok kümeye ayırmak için PC'lerin k-ortalama kümelenmesi uygulanır. Dördüncüsü, kümeler voksellerin geometrik konumlarına ve yoğunluk dağılımına göre otomatik olarak korteks, medulla ve pelvis olarak etiketlenir. Son olarak her bölümlü bölmedeki gürültüleri daha da gidermek için yinelemeli bir iyileştirme yöntemi tanıtılmıştır. 14 gerçek klinik böbrek veri kümesi ve 12 sentetik veri kümesi üzerinde yapılan deneyler, önerilen yöntem tarafından üretilen sonuçların, manuel olarak bölümlere ayrılanlarla çok iyi eşleştiğini ve yöntemin performansının mevcut diğer beş yöntemden daha üstün olduğunu göstermektedir [36].

Dehui Xiang ve arkadaşları, renal cortex segmentasyonunu hesaplamak için derin öğrenme tabanlı otomatik bir model geliştirmişlerdir. Çalışmalarında, en iyi rezeksiyon planını elde etmek için cerrahların, kesilecek böbrek kısmının yerini belirlemesi gerektiğini ve böbrek naklinin aynı zamanda hemodiyalizden daha iyi bilinen bir tedavi yöntemi olduğunu ifade etmişlerdir. Potansiyel böbrek vericilerinin radyolojik değerlendirmelerinin yapılmasının iyi işlev gören böbrekleri olan hastaları belirlemek için gerekli olduğunu vurgulamışlardır. Kontrastlı abdominal BT taramalarından böbrek ve korteks dokusunun tam otomatik olarak tanımlanması için model tabanlı bir yaklaşım sunmuşlardır. CorteXpert adlı önerilen çerçeve, böbrek dokusu tanımlaması için iki yeni

stratejiden oluşmaktadır: korteks model adaptasyonu ve tek tip olmayan grafik araması. CorteXpert, çapraz doğrulama değerlendirme stratejisi kullanılarak 58 BT taramasından oluşan bir klinik veri seti üzerinde doğrulanmıştır. Zar katsayısı olarak sırasıyla böbrek ve böbrek korteks tanımlamaları için $\%97,86 \pm \%2,41$ ve $\%97,48 \pm \%3,18$ olarak hesaplanmıştır [37].

Seda Arslan Tuncer ve arkadaşları, renal hücre kanserinin en yaygın böbrek kanseri türü olduğunu ve genellikle ileri yaşlarda ortaya çıktığını ifade etmişlerdir. Böbrek hücresi kanserinin hızlı yayılması ve hastalığın erken teşhis edilememesinden dolayı genellikle ölümlerle sonuçlandığını da belirtmişlerdir. Bu nedenle, böbrek anormalliklerinin hastalık ileri evreye gelmeden önce belirlenmesinin önemli olduğunu söylemişlerdir. Çalışmalarında, sağlıklı ve renal hücreli kanser dokularının abdominal görüntülerini kullanarak, renal hücre kanserini saptayan bir karar destek sistemi önermektedirler. Böbrek hücresi kanseri tespiti, segmentasyon ve kanser tespiti olarak iki ana aşamayı içermektedirler. İlk adımda kümeleme analizine dayalı olarak böbreklere segmentasyon yapılarak böbrek alanları elde edilmiştir. İkinci aşamada böbrek hücre kanserini tanımlamak için bilgisayar destekli tespit sistemi ile sınıflandırma yapılmıştır ve çalışmanın özgünlüğünü destekleyen özellik vektörleri oluşturulmuştur. Daha sonra destek vektör makineleri ile özellik vektörleri kullanılarak sınıflandırma yapılmıştır. Böbrek bozukluğunu saptamak için Fırat Üniversitesi Tıp Fakültesi Radyodiyagnostik Anabilim Dalı görüntü arşivleme sisteminden elde edilen 130 farklı görüntü veri seti kullanılmıştır. Bu görüntülerden otuz tanesi, K-ortalamları sınıflandırıcısını eğitmek için kullanılarak hem segmentasyon hem de sınıflandırma için performans değerlendirmeleri yapılmıştır. Segmentasyon başarısını ölçmek için yapılan işlem de zar benzerlik katsayısı $\%89,3$ olarak elde edilmiştir. Sınıflandırma performansını belirlemek için kullanılan Duyarlılık, Özgünlük, Doğruluk, Pozitif Öngörücü Değer (PÖD) ve Negatif Öngörücü Değer (NÖD) katsayıları sırasıyla $\%84$, $\%92$, $\%88$, $\%91,3$ ve $\%85,19$ olarak elde edilmiştir [38].

Guanyu Yang ve arkadaşları, böbrek kanserinin insanlarda görülen en yaygın on kanser türünden biri olduğunu ve Laparoskopik Parsiyel Nefrektomi (LPN)'nin, böbrek kanserinin tedavisinde ana terapötik yaklaşım haline geldiğini ifade etmişlerdir. Çalışmalarında BT görüntülerinde doğru böbrek ve tümör segmentasyonunun ameliyat

planlamasında ön koşul olan bir adım olduğunu, BT görüntülerinde doğru böbrek ve böbrek tümörü segmentasyonunun bir zorluk olmaya devam edeceğini ifade etmişlerdir. BT anjiyografi görüntülerinde böbrek ve böbrek tümörünün hassas bir segmentasyonunu gerçekleştirmek için yeni bir yöntem önermişlerdir. Bu yöntem, bir piramit havuzlama modülünü birleştiren üç boyutlu tam bağlantılı bir katmana (TBK) dayanmaktadır ve doğrudan 3B hacimsel görüntüler üzerinde uçtan uca bir öğrenme sistemi olarak uygulanmaktadır. Böbreğin segmentasyonunu ve tümör lezyonunu iyileştirmek için 3B uzaysal bağlamsal bilgiden yararlanılmaktadır. 140 hasta üzerinde yapılan deneyler, bu hedef yapıların yüksek bir doğrulukla bölümlere ayrılabilceğini göstermektedir. Böbrek ve böbrek tümörü için elde edilen sonuçlardaki ortalama zar katsayıları sırasıyla 0,931 ve 0,802'ye eşittir. Bu değerlerin çalışmaları için başarılı olduğunu ifade etmişlerdir [39].

Florent Marie ve arkadaşları, ESA yapısı ile deforme olmuş böbreklerin ve nefroblastomun segmentasyonu üzerine bir çalışma gerçekleştirmişlerdir. Çoğu zaman görüntü segmentasyonunun tam otomatik olmadığını ve doğru sonuçları elde etmek için bir kullanıcının süreci yönetmesi gerektiğini belirtmişlerdir. Tıbbi bağlamda segmentasyon cerrahlara daha fazla bilgi sağlayabilmekte ancak bu görev nadiren yerine getirilmektedir. Yapay Zekâ, tamamen otomatikleştirilmiş, tedaviye uygulanabilir bir çözüm önermek için güçlü bir yaklaşımdır. Çalışmada, nefroblastom ile deforme olmuş böbreklere odaklanılmıştır. Bununla birlikte, sistemi eğitmek için veri eksikliği durumunun çoğu zaman karşılaşıldığı vurgulanmıştır. Bu sebeple böbrekleri bölümlere ayırmak için iki yapay zekâ yöntemi kullanılmıştır. İlk olarak geri kazanılan değerlerin koordinatlarını değiştirmek amacıyla bir adaptasyon aşaması kullanarak deforme olmuş böbreklerin segmentasyonu için bölgelerin büyümesini artırabilen bir vakaya dayalı akıl yürütme yaklaşımı tanımlanmıştır. Bu yaklaşım 0,83 ortalama zar katsayısı ile böbrek için en iyi segmentasyonu gerçekleştirmeyi başarmıştır. Derin öğrenme, görüntü segmentasyonu için en son teknolojik yöntemleri içeren ve üstün performans gösteren ağlar olarak dereğerlendirilmiştir. Derin öğrenme ağlarının verimli olabilmesi için büyük veri seti olması gerektiği vurgulanmaktadır. Hastalardan elde edilen veriler, yalnızca belirli temsili dilimlerin manuel olarak bölümlere ayrılması ve ardından bunları bir ESA yapısının nasıl segmentlere ayrılacağını eğitmek için kullanılmıştır. Yazarlar manuel segmentasyonlarla farklı eğitim setlerini inceleyerek tıbbi görüntü segmentasyonu için bir ESA' nın değerlendirilmesini önermektedirler. Uygulama aşamasında küçük bir veri seti ile

güvenilir segmentasyonlar elde etmeyi başarmışlardır. Ayrıca 0,897 ortalama zar değeri ile tam segmentasyonunu başarabilmek için başlangıç aşamasındaki segmentlere ayrılmış dilimlerin yalnızca %26'sının gerekli olduğunu ifade etmişlerdir [40].

Couteaux ve arkadaşları, 2 boyutlu U-Net modeli ile böbrek segmentasyonu üzerine bir model üzerinde çalışmışlardır. Çalışmaları, böbrek korteksi çevresinde kırılmış olan koronal bilgisayarlı tomografi görüntülerinden segmentlere ayırmayı içermektedir. Tam evrişimli ağlardan oluşan bir model ile eğitim ve bölümlenmeyi gerçekleştirmek için test aşamasında tahminlerini toplamayı seçmişlerdir. Böylelikle 3 grup halinde bir görüntü veri tabanı oluşturabilmişlerdir. Algoritmanın segmentasyon sonuçları renal korteksi iyi bir hassasiyetle eşleştirmekte ve bu strateji 0,867'lik bir zar puanı katsayısı sağlamaktadır. Önerilen çözüm, BT görüntülerinde renal korteksin sağlam ve doğru otomatik segmentasyonlarını sağlamakta ancak sağlanan referans segmentasyonlarının kesinliği, sayısal performans üzerinde düşük bir üst sınır oluşturmuş gibi görünmektedir. Yapılan uygulama, ağları eğitmek için belirgin bir etiketleme çabası gerektiren böbrek korteks hacmini ölçmek için üç boyutlu olarak çalıştırılmaktadır [41].

Antoniya ve arkadaşları, BT görüntü dizilerinden böbrek kisti tanısının optimizasyonu için yeni bir hibrit segmentasyon yaklaşımı önermişlerdir. Böbreği otomatik olarak kistle segmentlere ayırarak ve analizlerini yaparak renal kist tanısı optimizasyonuna odaklanmışlardır. Böbrek kistlerinin böbreklerde oluşan sıvı keseleri olduğunu ve genellikle "basit" kistler olarak karakterize edildiğini ifade etmişlerdir. Kistlerin, böbreğin çevresinde toplam böbrek hacminin doğru tahminlerinin elde edilmesinde zorluğa neden olabileceğini belirtmişlerdir. Bu yaklaşım birkaç segmentasyon tekniğine dayanmaktadır. Değişken terimli seviye seti paradigmasına göre yerel olarak optimize edilmiş bir ön yayılma algoritması, böbreğin BT görüntü dizilerinden segmentasyonunun merkezinde yer alır. Bölme, birleştirme ve renk tabanlı k-ortalama kümeleme algoritmaları kist segmentasyonu için kullanılmaktadır. Böbrek segmentasyonunun zar benzerlik katsayısı %90,97 indeksi ile doğruluk değerlendirmesi tüm deneysel veri seti için yüksek sonuçları temsil etmiştir [42].

Leonarda Rundo ve arkadaşları, prostat kanseri üzerine derin öğrenme tabanlı bir model geliştirmişlerdir. Çalışmalarında erkeklerde en sık görülen kötü huylu tümörün prostat

kanseri olduğunu, MR Görüntüleme analizi ile tepitinin halen zorlu bir çalışma gerektirdiğini ifade etmişlerdir. Prostat zonal segmentasyon görevinin üstesinden gelmek için USE-Net adlı yeni bir konvolüsyonel sinir ağı önermişlerdir, Squeeze-and-Excitation (SE) bloklarının U-Net'e uygulama aşamasındaki en etkili bloklardan biri olduğunu ifade etmişlerdir. Özellikle SE blokları Encoder (Enc USE-Net) veya Encoder-Decoder bloğundan (Enc-Dec USE-Net) sonra eklenir. Bu çalışma ESA tabanlı mimarilerin, her biri farklı kurumlar tarafından toplanan farklı sayıda hasta ve heterojen görüntü özelliklerinden oluşan üç T2 ağırlıklı MR görüntü veri kümesi üzerinde genelleme yeteneğini değerlendirmektedir. Sonuçlar, veri kümelerinin birleştirilmesine ilişkin eğitimin genellikle her veri kümesi için ayrı ayrı eğitimden daha iyi performans gösterdiğini, hem veri kümesi içi hem de veri kümesi genellemesine izin verdiğini göstermektedir. Enc USE-Net herhangi bir eğitim koşulu altında iyi bir genel genelleme gösterirken, Enc-Dec USE-Net, tüm veri kümelerinde eğitildiğinde diğer yöntemlerden önemli ölçüde daha iyi performans göstermiştir. Bulgular SE bloklarının uyarlanabilir özelliğinin yeniden kalibrasyonunun, eğitim sırasında kullanılan veri kümelerinin örnekleri üzerinde test yapıldığında mükemmel çapraz veri kümesi genellemesi sağladığını ortaya koymaktadır. Bu nedenle, çoklu veri seti eğitimini ve SE bloklarını ağın performansını ortaya çıkarmak için karşılıklı olarak vazgeçilmez yöntemler olarak düşünmemiz gerektiğini vurgulamaktadır. Sonuç olarak uyarlanabilir mekanizmalar (özelliğin yeniden kalibrasyonu vb.), çoklu ortamları içeren tıbbi görüntüleme uygulamalarında değerli bir çözüm olabileceği ifade edilmiştir [43].

Fuzhe Ma ve arkadaşları, derin öğrenmeye dayalı, heterojen, modifiye edilmiş yapay sinir ağı kullanılarak kronik böbrek hastalığının tespiti ve teşhisi üzerine bir çalışma yapmışlardır. Mevcut araştırma senaryosunda kronik böbrek hastalığı prevalansı her yıl artmaktadır. İleri teşhis kaynaklarından biri olan makine öğrenimi teknikleri yüksek doğrulukta sınıflandırma yetenekleri sayesinde tıbbi tanıda daha önemli hale gelmiş ve özellikle KBH'nı daha başarılı bir şekilde tespit etmektedir. Yakın geçmişte, sınıflandırma algoritmalarının doğruluğu, veri boyutunu küçültmek için özellik seçimi algoritmaların doğru kullanımına bağlıdır. Çalışmada tıbbi nesnelerin interneti platformunda kronik böbrek yetmezliğinin erken tespiti, segmentasyonu ve teşhisi için Heterojen Modifiye Yapay Sinir Ağı (HMYSA) önerilmiştir. Ayrıca önerilen HMYSA, bir destek vektör makinesi ve geri yayılım (GY) algoritmasına sahip Çok Katmanlı

Algılayıcı (ÇKA) olarak sınıflandırılır. Önerilen algoritma, bir ön işleme adımı olarak belirtilen bir ultrason görüntüsüne dayalı olarak çalışır ve ilgilenilen böbrek bölgesi ultrason görüntüsünde bölümlere ayrılır. Böbrek segmentasyonunda önerilen HMYSA yöntemi yüksek doğruluk sağlamış ve konturu tanımlama süresini önemli ölçüde azaltmıştır [44].

Luana Batistada Cruz ve arkadaşları, böbreklerin ve böbrek tümörlerinin hassas segmentasyonunun tıp uzmanlarının hastalıkları teşhis etmesine ve klinik uygulamada oldukça gerekli olan tedavi planlamasını iyileştirmesine yardımcı olabileceğini ifade etmişlerdir. Böbreklerin manuel olarak segmentasyonu son derece zaman alıcı ve heterojen olmaları nedeniyle farklı uzmanlar arasında değişkenliğe eğilimli olabileceğini belirtmişlerdir. Derin evrişimli sinir ağları gibi hesaplama teknikleri, böbrek tümörlerinin erken teşhisine yardımcı olmak için böbrek bölümlene görevlerinde popüler hale gelmiştir. Bu çalışmada, yanlış pozitifleri en aza indirmek için görüntü işleme teknikleri ve derin evrişimli sinir ağları kullanarak bilgisayarlı tomografi görüntülerinde böbrekleri sınırlandırmak için otomatik bir yöntem önerilmektedir. Önerilen yöntemin dört ana adımı vardır: 1. adım KiTS19 veri setinin edinilmesi, 2. adım AlexNet kullanılarak kapsam küçültme, 3. adım 2 boyutlu U-Net kullanılarak ilk segmentasyon ve 4. adım en büyüğü korumak için görüntü işleme kullanılarak yanlış pozitif azaltma aşamalarından oluşmaktadır. Önerilen yöntem ile KiTS19 veri tabanından 210 BT'de değerlendirilmiş ve ortalama %96,33 zar benzerlik katsayısı, %93,02 ortalama Jaccard indeksi, %97,42 ortalama duyarlılık, %99,94 ortalama özgüllük ile en iyi sonuçlar elde edilmiştir. KiTS19 mücadelesinde ise ortalama %93,03'lük bir zar benzerlik katsayısı sunulmuştur. Çalışmalarında, BT' deki böbrek segmentasyon probleminin, problemin kapsamını tanımlamak, böbrekleri yüksek hassasiyetle segmentlere ayırmak ve yanlış pozitifleri azaltmak için görüntü işleme teknikleri ile derin sinir ağları kullanılarak verimli bir şekilde çözülebileceğini göstermişlerdir [45].

Chen li ve arkadaşları medikal görüntü segmentasyonu üzerine ANU-Net adını verdikleri derin öğrenme tabanlı bir mimari geliştirmişlerdir. Organ kanserinin yüksek ölüm oranına sahip olduğunu, doktorların organ lezyonunu teşhis ve tedavi etmesine yardımcı olmak için manuel olarak segmentasyonunun zaman alıcı ve hataya açık olduğunu, otomatik bir tıbbi görüntü segmentasyon modeline acilen ihtiyaç duyulduğunu dile getirmişlerdir.

Hedef organın tıbbi görüntülerden otomatik olarak bölümlere ayrılmasının organın düzensiz şekilleri nedeniyle zorlu bir iş olduğunu ifade etmişlerdir. ANU-Net adlı dikkat tabanlı bir iç içe geçmiş bölümlenme ağı önermişlerdir. Önerilen ağ modeli derinlemesine denetlenen bir kodlayıcı-kod çözücü mimarisine ve yeniden tasarlanmış yoğun atlama bağlantısına sahiptir. ANU-Net, farklı seviyelerde çıkarılan özelliklerin görevle ilgili bir seçimle birleştirilebilmesi için iç içe geçmiş evrişimli bloklar arasında dikkat mekanizması sunmaktadır. Tam çözünürlüklü özellik bilgilerinden doğru bir şekilde yararlanmak için üç tür değerle birleştiren hibrit yapıda kayıp işlevi mekanizmasını yeniden tasarlamışlardır. Önerilen modeli MICCAI 2017 Karaciğer Tümör Segmentasyonu (KTS) Zorluk Veri Kümesi ve ISBI 2019 Kombine Sağlıklı Karın Organ Segmentasyonu mücadelesi için değerlendirmişlerdir. ANU-Net, dört tür tıbbi görüntü bölümlenme görevi için çok rekabetçi bir performans elde etmiştir [46].

Nithya ve arkadaşları, ultrason görüntülerinden yararlanarak böbrek hastalığı tarama ve teşhisi için yapay sinir ağı tabanlı bir mimari sunmuşlardır. Sunulan makalenin temel amacı, kümeleme ve sınıflandırma yaklaşımının bir kombinasyonunu kullanarak böbrek hastalığı tespiti ve segmentasyonu için bir yaklaşım geliştirmektir. Günümüzde böbrek taşı tespiti ve segmentasyonu, ultrason görüntüleri için cerrahi ve tedavi planlamasında önemli prosedürlerden biridir ve günümüzde ultrason görüntülerinde böbrek taşı segmentasyonu klinik uygulamada çoğunlukla manuel olarak yapılmaktadır. Zaman alıcı olmasının yanı sıra manuel taş tanımlama zordur ve bireysel operatöre bağlıdır. Çalışmalarında yapay sinir ağını kullanarak böbrek taşı tespiti ve çok çekirdekli k-ortalama kümeleme algoritması kullanarak segmentasyon önermişlerdir. Normalde sistem, ön işleme, özellik çıkarma, sınıflandırma ve bölümlenme gibi dört modülden oluşmaktadır. Öncelikle medyan filtresi kullanarak giriş görüntüsünde bulunan gürültüyü ortadan kaldırmışlardır. Ardından önemli ağ özellikleri görüntüden çıkarılmıştır. Daha sonra sinir ağı sınıflandırıcısını kullanarak normal veya anormal olarak ayırt etme işlemi gerçekleştirilmiştir. Son olarak anormal görüntüler, çoklu kullanılarak taş ve tümör parçasını ayrı ayrı bölümlere ayırmak için bölümlenme aşamasına geçilmiştir. Kernel K-kümeleme algoritması anlamına gelir. Deney sonuçları lineer + kuadratik tabanlı segmentasyon olarak önerilen sistemin diğer tüm yöntemlerle karşılaştırıldığında %99,61'lik maksimum doğruluğa ulaştığını göstermektedir [47].

Wenshuai Zhao ve arkadaşları MSS U-Net adını verdikleri bir mimari tasarlamışlardır. Bu mimarinin böbreklerin ve böbrek tümörlerinin doğru segmentasyonu, radyomik analizinin yanı sıra gelişmiş cerrahi planlama teknikleri geliştirmek için önemli bir adım olduğunu ifade etmişlerdir. Klinik analizde segmentasyon günümüzde klinisyenler tarafından bilgisayarlı tomografi taraması yoluyla toplanan görüntülerin görsel incelemesinden gerçekleştirilmektedir. Süreç zahmetlidir ve başarısı önemli ölçüde önceki deneyimlere bağlıdır. BT görüntülerinden böbrekleri ve böbrek tümörlerini segmentlere ayırmak için çok ölçekli, denetimli bir 3B U-Net, MSS U-Net sunmuşlardır. Bu mimari, 3B U-Net ağında eğitim aşamasında verimliliği artırmak için derin denetimi mekanizmasını üstel logaritmik kayıpla birleştirmektedir. Ayrıca genel sürecin performansını artırmak için bağlantılı bileşen tabanlı bir son işleme yöntemi sunulmuştur. Elde edilen böbrek ve tümörün zar katsayısı sırasıyla 0,969 ve 0,805'e çıkmış, son teknoloji eserlerle karşılaştırıldığında üstün performans göstermiştir [48].

Fabian Isensee ve arkadaşları geliştirdikleri derin öğrenme tabanlı bir model ile böbrek ve tümörleri için başarılı bir segmentasyon yöntemi sunmuşlardır. Çalışmalarında biyomedikal görüntülemenin, derin öğrenme alanı tarafından teşvik edilen bilimsel keşif ve tıbbi bakımın temel bileşeni olduğunu vurgulamışlardır. Anlamsal bölümlenme algoritmaları birçok uygulamada 3B görüntü analizi ve nicelemeyi mümkün kılarken, ilgili özel çözümlerin tasarımının önemsiz olmadığı ve veri kümesi özelliklerine ve donanım koşullarına oldukça bağlı olduğunu belirtmişlerdir. Mevcut alan bilgisini yoğunlaştıran ve temel bir mimariyi farklı veri kümelerine ve segmentasyon görevlerine aktarmak için gereken temel kararları bağımsız olarak alan, bir derin öğrenme çerçevesi olan nnU-Net'i önermişlerdir. Sonuçlar derin öğrenme yöntemlerinin farklı veri kümelerine sistematik olarak uyarlanmasında büyük bir gizli potansiyel olduğunu göstermektedir. NnU-Net'i kutudan çıkar çıkmaz etkin bir şekilde kullanılabilen, son teknoloji segmentasyonunu uzman olmayanlar için erişilebilir hale getiren, otomatikleştirilmiş yöntem tasarımı için çerçeve olarak bilimsel ilerlemeyi katalize eden ve açık kaynaklı bir araç olarak kamuya açık hale getirmişlerdir [49].

Jamie ve arkadaşları geliştirdikleri Ensemble U-Net modeli ile böbrek ve böbrek tümörü segmentasyonu üzerine bir çalışma gerçekleştirmişlerdir. Çalışmada, otomatik tıbbi görüntü segmentasyonunun hesaplama yöntemleri için öncelikli bir araştırma alanı

olduğunu ifade etmişlerdir. Özellikle kanserli tümörlerin tespiti, gerçek dünyada etki potansiyeli olan bu alanda güncel bir meydan okumayı temsil etmektedir. Makale çalışması 2019 Böbrek Tümörü Segmentasyon Zorluğuna (KiTS19) yanıt olarak geliştirilen bir yöntemi açıklamaktadır. Eksenel bilgisayarlı tomografi görüntülerinden oluşan 210 adet görüntünün tam evrişimli ağ mimarilerinin mantıksal bir topluluğuna dayalı olarak işlenmesi, kullandıkları otomatik segmentasyon yöntemini geliştirmek ve değerlendirmek amacıyla kullanılması ve ardından hacimsel doğrulama yapılması ile çalışmaya başlamışlardır. Veriler geleneksel bilgisayarla görme teknikleri, eşikleme, histogram eşitleme, morfolojik işlemler, merkezleme, yakınlaştırma ve yeniden boyutlandırma kullanılarak önceden işlenmiştir. Sırasıyla böbrek ve tümörü ve yalnızca tümörü sınıflandırmak için üç ve ikili tam evrişimli ağ segmentasyon modeli eğitilmiştir. Model eğitilirken ilk olarak görüntüler 512 x 512 piksel olarak yeniden boyutlandırılmış ve 0 ile 255 arasındaki piksel değerlerine normalize edilmiştir. Sırasıyla 9 x 9 ve 15 x 15 boyutlu çekirdeklere sahip medyan ve ortalama filtreler, gürültüyü gidermek için bu ikili maske ile birleştirilmiştir. Ön plandaki delikleri doldurmak için bir taşma doldurma algoritması kullanılmış ve ardından daha küçük ön plandaki nesnelere kaldırmak için 99 x 99 çekirdek ile morfolojik açılma gerçekleştirilmiştir. İkili maske daha sonra tablo artefaktını ve diğer gürültü kaynaklarını ortadan kaldırmak için görüntü değeri ile çarpılmıştır. Elde edilen görüntü ortalanmış ve gövdeyi çevreleyen bir sınırlayıcı vasıtasıyla kutuya yakınlaştırılmıştır. Merkezleme ve yakınlaştırma değerleri hesaplanmış, ardından uygulanmadan önce bir polinom fonksiyonuyla düzeltilmiştir. Son olarak resimler 256 x 256 piksel boyutuna indirilmiş ve giriş katmanına hazır hale getirilmiştir. Ön işlemeden sonra, görüntüleri bölümlere ayırmak için üç ve iki boyutlu olmak üzere tam evrişimli "U-Net" modeli uygulanmıştır. Yani böbrek ve tümör bölgelerini tahmin etmek için iki model eğitilmiş fakat modellerden bir tanesi yalnızca tümörü tahmin etmek için eğitilmiştir. Gevşek böbrek ve tümör sınıflandırma modelinin çıktıları mantıksal bitsel AND işlemleri kullanılarak diğer iki modelin çıktılarıyla birleştirilmiştir. Ortaya çıkan segmentasyon maskeleri bir araya getirilmiştir. Böbrekleri 1, tümörleri 2 ve diğer her şeyi 0'a eşitleyerek etiketleme yapılmıştır. Standart 2B evrişimli katman dört havuzlama katmanı, iki %50 bırakma katmanının ve kodlayıcı aşamasından oluşan standart U-Net mimarileri kullanılmış, kod çözücü aşaması ise on üç evrişimli katmandan ve dört üst örnekleme katmanından oluşacak şekilde tasarlanmıştır. Girdi ve gizli katmanlar için etkinleştirme işlevleri, düzeltilmiş doğrusal birim olarak

ayarlanmış ve çıktı katmanı için ikili sınıflandırma için sigmoid fonksiyonu kullanılmıştır. Elde edilen bu verilerden alınan numuneler üzerinde uçtan uca üç model eğitilmiştir. Sıkı böbrek ve tümör modeli için yalnızca böbrekleri ve tümörleri içeren tüm BT çerçeveleri, rastgele kare sayısının dörtte biriyle birlikte dahil edilmiş ve model eğitim işlemi tamamlanmıştır. Açıklanan bu yöntem böbrekleri oldukça doğru bir şekilde bölümlere ayırabilmiştir. Tümörleri segmentlere ayırmak için 0,86 duyarlılık değerine ulaşmıştır. Kesinlik ölçüsü, yanlış pozitifin daha kötü olduğu durumlarda daha uygun iken hatırlatma ölçüsü yanlış negatifin daha kötü olduğu durumlarda daha uygundur. Bu nedenle sunulan yöntem, aşırı tahmin etme eğiliminin, tümörlerin varlığını olduğundan daha az tahmin etme eğiliminden daha az zararlı olan kanser tespiti uygulaması için uygun olabilir. Bir uzmanının doğrulamasını izleyen tarama prosedürü olarak bu yaklaşım, mevcut uygulamalar üzerinde verimlilik iyileştirmeleri sağlayabilir. Örneğin tümör olarak yanlış etiketlenen tümör olmayan bölgeler, bir operatör tarafından, belki de önceki tarama aşaması olmadan daha hızlı bir şekilde tanımlanabilir ve düzeltilebilir. Tümörü kaçırma tehlikesi hala devam edecek ve verimlilik iyileştirmesinin ölçülmesi gerekecektir. Sonuç olarak yöntemin performansı klinik uygulama için gerekli seviyenin altında olduğunu açıkça dile getirmişlerdir [50].

Sabarinathan ve arkadaşları böbrek tümör segmentasyonu üzerine Hyper Vision Net adını verdikleri bir çalışma gerçekleştirmişlerdir. Bu çalışmada bilgisayarlı tomografi görüntülerinde böbrek tümörünün segmentasyonun düzgün olmayan hareket, benzer görünüm ve çeşitli şekiller nedeniyle oldukça zorlayıcı bir görev olduğundan bahsetmişlerdir. Çalışmalarında Hyper Vision Net modeli olarak adlandırılan, derin öğrenme ağını kullanan, yeni bir böbrek tümörü segmentasyon yöntemi sunmuşlardır. Görüntü ön işleme aşamasında, tüm BT görüntüleri 256 x256 olarak yeniden boyutlandırılmıştır. Mevcut tüm U-Net modellerinin, böbrek tümörü bölgesini segmentlere ayırmak için U-Net'in değiştirilmiş bir versiyonunu kullandıklarından bahsetmişlerdir. Ağ, klasik V-Net'in kodlayıcı ve kod çözücü yapısının özelliklerine sahiptir. V-Net mimarisi tarafından önerildiği gibi, ilk olarak girdi görüntüsü koordinat evrişim katmanına geçirilir ve ardından Hyper Vision Net modelinin kodlayıcı kısmına aktarılır. Modelin genelleme kapasitesini doğaçlama yapmak için, ağın çeviri değişmezliği ile ilgili özellikleri seçmesine yardımcı olan koordinat evrişimli katman kullanılır. Ayrıca bu katmanın desteğiyle mekansal koordinatlar, ekstra koordinat

kanalları kullanılarak kartezyen koordinat alanıyla eşleştirilir. Bu tür bir eşleştirme modele tam veya değişen derecelerde çeviri özelliklerini kullanma gücü sağlamaktadır. Kodlayıcı aşamasında aşağı örnekleme sırasında kullanılan dört blok vardır. Her blokta ilk katman 3x3 evrişimli bir katmandır, ardından iki artık blok gelir ve sonunda 2x2 maksimum havuz katmanı eklenir. Mevcut ağ yapılarına bloğun ayrıntılarının gösterilmesi için derin bir artık blok eklemişlerdir. Birden fazla özellik elde etmek için artık bloğun derinliğini arttırmışlar ve bu da tümör segmentasyonunun performansını olumlu yönde etkilemiştir. Kodlayıcı fazına benzer şekilde, kod çözücü fazı da yukarı örnekleme ile değiştirilen maksimum havuzlama katmanları dışında aynı bloklardan oluşmuştur. Aşağı örneklemeden sonra daha sağlam özellik haritaları elde etmek için özellikleri kodlayıcı aşamasına geçirmeden önce bir 3x3 evrişimli katman ve artık blok eklemişlerdir. Toplu normalleştirme ve bırakma katmanları hem kodlayıcı hem de kod çözücü fazına dahil edilmiştir. Ağ, üstel doğrusal etkinleştirme işlevi ile eğitilmiştir. Kısacası önerilen mimaride, kod çözücü kısmına denetim katmanları eklenmiş ve bu eklenti, çıktıdaki minimum bölgeleri bile rafine edebilmiştir. Mevcut veri seti, 45964 görüntü dahil olmak üzere 300 hastanın gerçek arteriyel faz abdominal BT taramalarından oluşmaktadır. Önerilen modelin eğitimi ve doğrulanması için KiTS19'dan yararlanılmıştır. En son teknolojik yöntemlerin kullanıldığı segmentasyon yöntemleriyle karşılaştırıldığında elde edilen sonuçlar, tümör bölgesi ve böbrek bölgesinde sırasıyla 0,9552 ve 0,9633 olmuştur. Bu sonuçlar da yöntemlerinin üstünlüğünü açıkça göstermektedir [51].

Santini ve arkadaşları çok aşamalı topluluk yöntemi esasına dayanan bir derin öğrenme yaklaşımı ile böbrek tümör segmentasyonu gerçekleştirmişlerdir. Böbrek ve böbrek tümörünün kesin karakterizasyonu özellikleri böbrek kanseri tedavisi bağlamında, özellikle çıkarılacak dokuların tam olarak lokalizasyonunu gerektiren, nefron koruyucu cerrahi için son derece önemli olduğunu ifade etmişlerdir. Bu çalışmada KiTS19 verisetinin, segmentlere ayrılacak 300 BT taramasından oluşan, karakterize edilmiş bir veri seti olduğundan prognoz ve tedavi planlamasına yardımcı olmak ve araştırma ve geliştirmeyi hızlandırmayı amaçladığından tercih edildiğini belirtmişlerdir. Zorluğun üstesinden gelmek için Resnet yapılı bir U-Net çerçevesine dayalı otomatik, çok aşamalı, 2,5 boyutlu diyebileceğimiz bir derin öğrenme tabanlı bölümlenme yaklaşımı önermişlerdir. Görüntü ön işleme aşamasında veriler, farklılıkları hesaba katmak ve

mevcut taramalar arasındaki heterojenlikleri azaltmak için standartlaştırılmıştır. İlk olarak tüm hacimleri 3 mm'lik aynı dilim kalınlığına getiren yeniden dilimleme işlemi gerçekleştirilmiştir. Bu değer veri setinde gözlemlenen en yaygın aksel çözünürlükler arasında bir uzlaşma olarak seçilmiştir. Önerilen model üç farklı aşama ile karakterize edilmiştir. İlk aşama, böbrek bölgesinin odaklanacağı ilgi bölgesini kabaca bölümlere ayırmayı amaçlamaktadır. İkinci aşamada, böbreklerin ve kanserli dokunun segmentasyonu, çıkarılan görüntü alt bölümleri üzerinde çalışan iki farklı sinir ağı tarafından gerçekleştirilir. Sonuçlar son bölümlenmenin bir birleştirme işlemi kullanılarak elde edildiği son aşamada nihayet birleştirilir. Önceki aşamalardan gelen tahmin sonuçlarını birleştirmek için sona bir araya yerleştirme işlemi eklenmiştir. Burada bir diğer önemli hususta 2,5 boyutlu girişlerin kullanılmasıdır. Böylelikle koronal, aksel ve sagittal düzlemlerden gelen ağ 2B dilimleri etkin bir şekilde değerlendirmek mümkün olmuştur. Modele kanal boyutu boyunca bir araya yığılmış bir dizi bitişik aksel dilimin aktarılmasını ve ağın yalnızca merkezi dilime karşılık gelen bir maskeyi tahmin edebilmesini sağlamayı içermektedir. Nihai tahmin piksellerin böbreklere mi, tümöre mi yoksa arka plana mı ait olduğunu değerlendirmek için bir softmax işlevi ile gerçekleştirilmiştir. Üç etiketli bir maske üretilse bile son ikisini (böbrekler ve tümör etiketleri) tek bir meta-sınıfta birleştirmişler ve sonraki aşamada böbrek bölgesini lokalize etmek için kullanmışlardır. Test veri setinden 90 tanesi erişime kapalı olduğu belirtilmiştir. Bununla birlikte elde edilen sonuçlar göz önüne alındığında genel segmentasyon değerlendirmesinin, özellikle tümör tanımlamasına ilişkin umut verici olduğu vurgulanmıştır. Ancak bazen böbrek kistlerinde tespit edilen yanlış pozitif vakaların veya yanlış negatif değerlerin de olduğu ancak bu sonuçların oldukça düşük olduğunu ifade etmişlerdir. Önerilen derin öğrenme modeli segmentasyon algoritması, 90 görünmeyen test vakasında böbrek ve böbrek tümörleri için sırasıyla 0,96 ve 0,74'lük bir ortalama zar benzerlik skoruna ulaşmıştır. Elde edilen sonuçların umut verici olduğunu ve tümör segmentasyon sonuçlarını düzenli olarak azaltan iyi huylu kistler hakkında önceki bilgiler dahil edilerek geliştirilebileceğini ifade etmişlerdir [52].

Xiaoshuai ve arkadaşları böbrek tümörü segmentasyonu için üç kademeli bir derin öğrenme ağ modeli geliştirmişlerdir. Bu çalışmada böbrek tümörünün morfolojik özelliklerinin ve radyologların doğru tanı koymasının tedavi için çok önemli olduğunu dile getirmişlerdir. Ayrıca böbrek tümörü morfolojisi ile klinik sonuçların çok zor bir

süreç olduğunu çünkü böbrek tümörü boyutu, şekli, konumunun önemli ölçüde değiştiğini belirtmişlerdir. Otomatik olarak böbreğin ve tümörün anlamsal segmentasyonunun gelişmiş cerrahi planlama geliştirmeye yönelik araç teknikleri sayesinde umut verici olduğunu ifade etmişlerdir. Çalışmalarında, kendi kendine rehberli üç aşamalı bir böbrek tümörü segmentasyonu görevi için ağ yapısı tasarlamışlardır. Düşük çözünürlüklü ağ yapısı, ilgili hacmi kabaca bulabilir ancak aşağı örneklenmiş BT görüntülerinden, tam çözünürlüklü tümör bölgesini bulan ağ elde edebilmek için doğru sınırları çıkarabilir tam çözünürlüklü BT görüntülerine ihtiyaç vardır. Yenilik olarak genişletilmiş evrişim blokları önermişlerdir. Bloklar daha derin katmanlarda geleneksel havuzlama işlemlerini değiştirmek için U-Net mimarisinin ayrıntılı anlamsal bilgileri muhafaza etmesi işlemini daha iyi gerçekleştirmiştir. Ayrıca, melez bir zar kaybı ve ağırlıklı çapraz entropi, modele yakın voksellere odaklanmasına rehberlik etmek için kullanmışlardır. KiTS19 yarışmasında veri setini test etmişlerdir ve ortalama zar skorları 0,9674 böbrek segmentasyonu ayrıca 0,8454 böbrek tümör segmentasyonu değerleri ile kendilerine 2. sırada yer bulmuşlardır [53].

Gabriel, böbrek ve böbrek tümörü taraması için U-Net tabanlı 3B ağ modeli geliştirmiştir. Çalışmalarında KiTS19 veri seti üzerinde birtakım değişiklikler yapılmıştır. KiTS19 meydan okuması tarafından sağlanan ek açıklamaların üç sınıfa sahip olduğunu (arka plan, böbrekler ve böbrek tümörleri) ifade etmişlerdir. Önerilen modelin kolay uyarlanabilmesi için ek bir giriş formatı tanımlanmıştır. Böbrekler ve böbrek tümörleri sınıfını, giriş formatı 1 olarak adlandırılan, tek bir sınıf olarak birleştiren bir yapı oluşturmuştur. Görüntü ön işleme aşamasında bütün BT taramaları ve notlarını, $1 * 1 * 1$ mm (ince segmentasyon formatı 3 için) ve $4 * 4 * 4$ mm (kaba segmentasyon formatı 1 için) olacak şekilde çözünürlüklere yeniden örneklendirmiştir. Taramalar ve ek açıklamalar sırasıyla kübik ve en yakın komşu enterpolasyonu kullanılarak yeniden örneklendirilmiştir. Bu işlemlerin ardından her iki giriş farklı çözünürlüklerin segmentasyonlarını eşleştirmek için aynı ağırlık merkezini paylaşmış, yani $1 \times 1 \times 1$ mm girişin ağırlık merkezi, $4 \times 4 \times 4$ mm girişteki aynı ağırlık merkezi olarak ayarlanmıştır. $4 \times 4 \times 4$ mm giriş, böbreklerin lokalizasyonunu kabaca elde etmek için ağa daha geniş bir BT taraması bağlamı sağlamıştır. 4 mm'lik ağın çıktısı, 1 mm'lik ağın böbrekleri ve böbrek tümörlerini hassas şekilde bölümlere ayıracağı ilgi alanlarını tanımlamaktadır. Önerilen ağ, omurga olarak 3B U-Net'i esas almıştır. Düşük çözünürlüklü alt ağ aslında, 4

giriş yamasını kullanarak bölümlenme gerçekleştirmek için kullanılan bir U-Net modelidir. Bu modelde 32 yerine 16 filtrelili bir giriş tercih edilmiştir. Yüksek çözünürlüklü bölümlenme alt ağıda orijinal uygulama olarak 32 filtrelili bir 3B U-Net kullanılmaktadır. Düşük çözünürlüklü alt ağın çıktısı 4 kez yükseltilir ve eşleştirme işleminde fark olmaması için sıfırlarla doldurulmuştur. Maskelenmiş giriş, ince bölümlenme ağının atlama bağlantısından geçecek olan bir filtre dalı yaratan, ince bölümlenme ağına ek girdi olarak hizmet etmektedir. Ekstra sınıflandırma görevi, bir yamanın böbrek tümörü içerip içermediğini gösterir. 3x3x3 konvolüsyonlu 32 filtre ve ardından 3x3x3 konvolüsyonlu 16 filtre kullanılarak, 3B U-Net yüksek çözünürlüklü alt ağının altında bulunan özellik haritaları alınır. Daha sonra bu özellik haritaları tam bağlantılı bir 1024, 256 ve 256 nöron katmanına dönüştürülür. Bu arada yüksek çözünürlüklü segmentasyon alt ağının çıktısı sadece böbrek tümörü kanalını çıkarmak, düzleştirmek ve böbrek tümörü kanalının tahminlerini (yamadaki böbrek tümörü tahmini hacmi) özetlemek için alınır. Bu değer, sınıflandırma görevinin 256 nöronuna birleştirilir. Sonuç olarak böbrekleri ve böbrek tümörlerini bölümlere ayırabilen tek bir ağ sunulmuştur. Düşük çözünürlüklü bölümlenme alt ağı geniş bir bağlam sağlar ve böbrekleri içerebilecek ilgili bölgelerin adaylarını tanımlamasından dolayı yüksek çözünürlüklü alt ağ, yalnızca böbrek bölgesine odaklanmaktadır. Ayrıca ağ yapısına yamanın böbrek tümörü içerip içermediğini gösteren ekstra bir sınıflandırma görevi dahil edilmiştir. Çalışma sonucunda ortalama zar katsayısı 0,90 değerine kadar ulaşmıştır [54].

Bu tez çalışmasında önerilen U-Net ve V-Net modelleri ile yumuşak dokuya sahip böbreklerin yapısal özellikleri dikkate alınmıştır. Bu sebeple en doğru segmentasyon sonuçlarına ulaşmak amacıyla yeni teknikler sunulmuştur. Önerilen modellerin KiTS19 veri seti kullanılarak uygulaması yapılmıştır. Daha sonra uygulamalar akademik çalışmalarda kullanılacak biçimde hazır hale getirilmiştir. Önerilen modeller mevcut segmentasyon modellerinden farklılıklar göstermektedir. Tasarım aşamasındaki özgün bloklar mimariyi daha kararlı çalışacak şekilde desteklemektedir. 2. bölüm materyal ve yöntemleri içermektedir. 3. bölümde araştırma bulguları yer almaktadır. 4. bölüm ise sonuçlar ve tartışma kısımlarından oluşmaktadır.

2. MATERYAL VE YÖNTEMLER

2.1. Böbrek Tümörleri

Böbrek tümörleri malign (kötü huylu), benign (iyi huylu) veya enflamatuvar (iltihaplanma) karakterde olabilir. Kötü huylu olan tümörlerinin %85-%90'ını RHK'lar oluşturmaktadır. Ürolojik kanserler arasında en fazla görülen kanser türlerinden birisidir. Tüm kanser türlerinin yaklaşık %2-%3'ü böbrek kanserlerinden oluşmaktadır. Böbrek tümörü olan hastalarda son yıllarda dünya ortalamasına bakıldığında yıllık %2'lik artış dikkat çekmektedir. [55]. Tütün ürünlerinin kullanımı, obezite ve hipertansiyon RHK gelişmesinde en etkili risk faktörleridir.

RHK, böbreklerin doğal yerleşiminden dolayı çoğunlukla hastalığın ilerleyen evrelerine kadar neredeyse farkedilmez ve semptom göstermez [56]. Semptom gösteren, ağrı, makroskobik hematüri ve elle muayene ile teşhis edilebilen kitleye bağlı olan hali ise hastaların ortalama %6-10'unda görülmektedir [57-58]. Fiziki muayenenin RHK teşhisinde rolü oldukça azdır [59]. Metastatik hastalığa bağlı oluşan kemik ağrısı, inatçı öksürük gibi olan semptomatik şikâyetler ise hastaların ancak %20'sinde görülebilmektedir [60].

Böbrek tümörlerinin teşhis ve takibinde radyolojik görüntü yöntemleri oldukça önemli yer tutmaktadır. Renal kitlelerin %60'tan fazlası başka nedenlerle uygulanan abdominal görüntülemeler sırasında tesadufi olarak bulunmaktadır. Ultrason görüntüleme yönteminin, diğer görüntüleme yöntemlerine göre daha ekonomik olması nedeniyle hematüri şikâyeti ile başvuran hastalarda çoğunlukla tercih edilen bir durumdur. RHK'ların büyük çoğunluğu ultrason görüntülerinde katı lezyonlar olarak görüntülenirler.

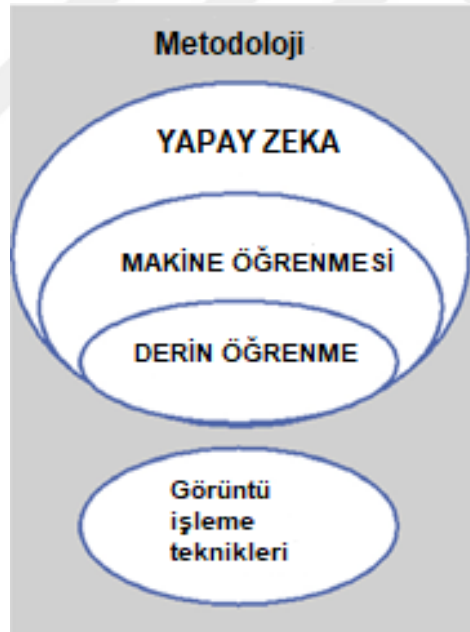
Spiral Bilgisayarlı Tomografi (SBT) ve takibinde çok hızlı ve volümetrik tarama yapabilen çok kanallı BT teknolojisinin keşfedilmesiyle küçük böbrek kitleleri bile karakterizasyon yapılarak tespit edilebilmektedir [61]. Primer tümörün böbrek dışı uzanımı, bölgesel lenf nodları ve adrenal bez ile aynı zamanda diğer böbreğin morfoloji ve fonksiyonu da göz önünde bulundurulabilir [62]. Magnetik rezonans görüntüleme

yöntemi alerji ya da böbrek yetmezliği olan hastalarda tercih edilmesi gereken öncelikli radyolojik tanı yöntemi olmalıdır.

2.2. Yapay Zekâ Öğrenme Yöntemleri

Yapay zekâ, insan gibi akıl yürütmenin yanı sıra hareket, konuşma ve ses algılama benzeri davranışları sergilemek için birçok yeteneklere sahip olacak şekilde geliştirilmiş, yazılım ve donanım sistemleri setinin bütününe verilen bir isimdir. Yani yapay zekâ, bilgisayarların insanlar gibi düşünmesini sağlamaktadır.

Yapay zekâyı tek başlıkta ele almak yanlış olur. Makine öğrenimi, derin öğrenme gibi kavramlar yapay zekâyı oluşturan terimlerdir. Yapay zekâ, makine öğrenimi ve derin öğrenme terimleri arasındaki farkı anlamak için Şekil 2.1’de gösterilen kronolojik sırayı analiz etmek daha faydalı olacaktır [63].



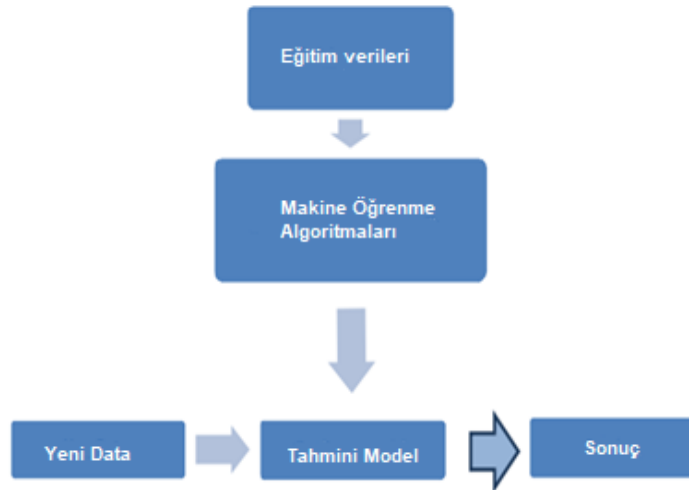
Şekil 2.1. Derin öğrenme metodolojisi

2.2.1. Makine Öğrenimi

Makine öğrenimi, problemi o problemin verilerine göre modelleyen bilgisayar algoritmalarına verilen genel isimdir. Var olan veri seti ve algoritma ile oluşturulan model en yüksek performansı sağlayacak biçimde tasarlanır [63-64]. Makine öğrenimindeki algoritma türleri genellikle Denetimli Öğrenme ve Denetimsiz Öğrenme olarak iki ana kategoride incelenebilir.

2.2.1.1. Denetimli Öğrenme

Denetimli öğrenme, sistemin girdi veri setinden çıkışta elde etmesi beklenen sonucu sağlayabilmesi için bir dizi görevin işlenmesidir. Denetimli öğrenmede etiketli eğitim verileri sisteme sunulur. Bir başka deyişle, her örnek için girdi ve çıktı değerleri bilinmelidir. Giriş ve çıkış arasında kuvvetli bir bağlantı olduğu düşünülebilir. Sistemin doğru çalışması için çalıştırılacak sistem hakkında toplanan gözlem değerleri, eğitim aşamasında giriş olarak ağı sunulur. Bu değerler kullanılarak girdi ve çıktı arasında bir ilişki kurulması istenir. Oluşturulan ilişki modeli sayesinde, ileride karşılaşılabilecek X gözlemlerine karşılık gelen Y çıktıları tahmin edilebilmektedir. Şekil 2.2'de makine öğrenmesinin aşamaları gösterilmiştir [63-64].



Şekil 2.2. Makine Öğreniminin Aşamaları

2.2.1.1. Denetimsiz Öğrenme

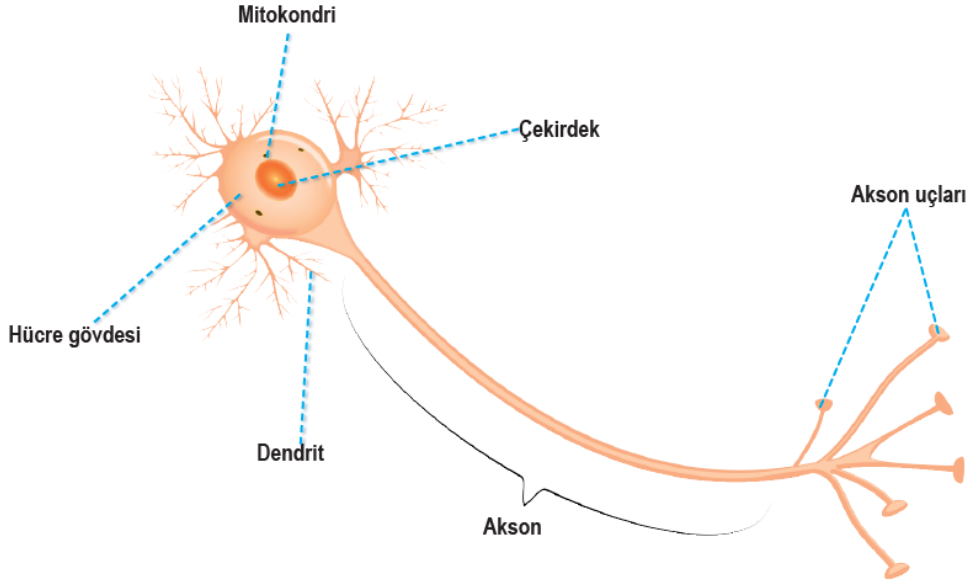
Denetimsiz öğrenmede yalnızca X giriş kümesi vurgulanır. X ile ilişkili bir Y seti olmadığından, Y çıkışı tahmin edilmeyecektir. Denetimli olmayan öğrenme, konu üzerinde çalışan kişilere sonuçları hakkında bilinmeyen problemlerin yapısı hakkında fikir sahibi olma imkânı sunmaktadır. Amaç mevcut ölçümler hakkında bilgi öğrenmektir [64].

Makine Öğreniminde kullanılan diğer ana algoritma türleri şunlardır:

- Bayes
- Karar ağaçları
- Kümeleme
- Derin öğrenme
- Topluluk (topluluk)
- Nöral ağlar
- Kural tabanlı sistem
- Regresyon

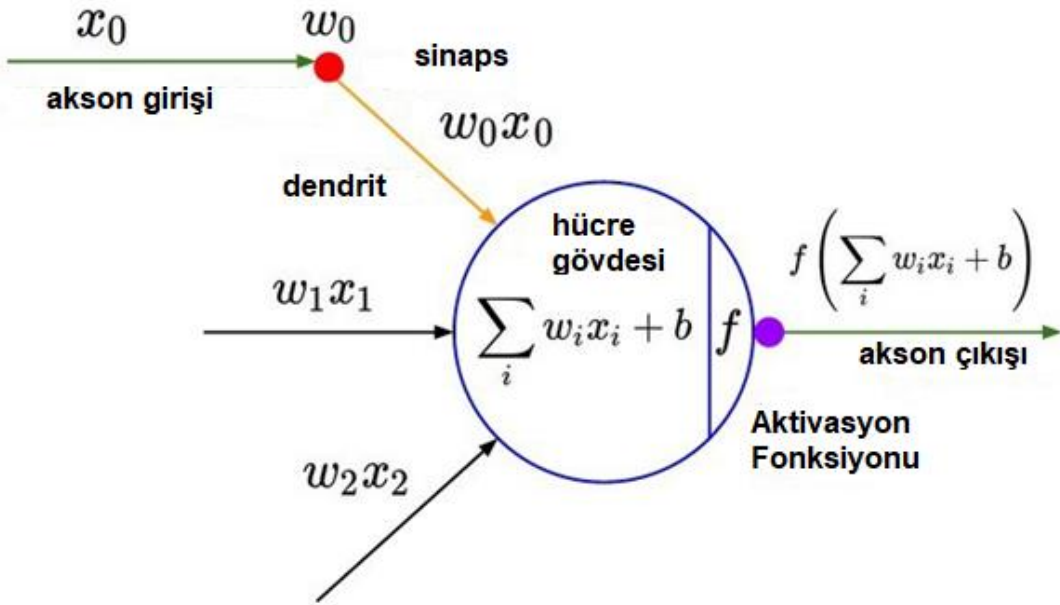
2.2.2. Derin Öğrenme

Derin öğrenmenin daha iyi anlaşılabilmesi için önce Yapay Sinir Ağlarının (YSA) bilinmesi gerekmektedir. Canlıların sinir sisteminin bilgi işleme tekniğinden yararlanılarak matematiksel modellenmesi yapay sinir ağlarının temelini oluşturur. YSA ile basit biyolojik sinir sisteminin çalışma şekli taklit edilmektedir. Diğer bir deyişle biyolojik nöron hücrelerinin ve bu hücrelerin birbirleri ile arasında kurduğu sinaptik bağın dijital olarak modellenmesi süreci gerçekleştirilmektedir. Makinelerin bu yöntem sayesinde insan beyni gibi bir öğrenme ve karar verme mekanizmasına sahip olması hedeflenmektedir [65-66]. Şekil 2.3' de insan beyindeki basit bir nöron yapısı gösterilmiştir.



Şekil 2.3. Temel bir nöron yapısı

Buradan yola çıkarak modellenen bir nöronun matematiksel ifadesi ise Şekil 2.4’ de gösterilmiştir.



Şekil 2.4. Bir nöronun matematiksel modeli

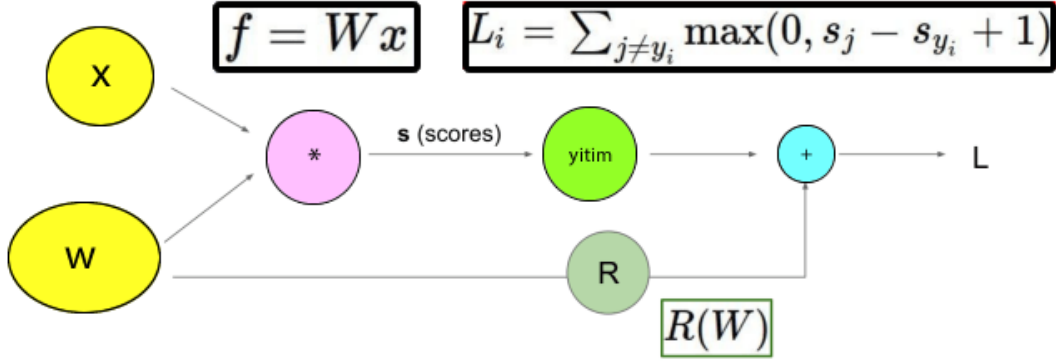
Dendritler sistemin giriři, aksonlar ise sistemin ıkıřı olarak ifade edilmektedir. Sinapslar, giriř ve ıkıřların birbirine baėlanmasını saėlayan ulardır. ekirdek, elektriksel iřaretin periyodik olarak retilmesini saėlayan merkezi bir sistemdir. Aksonlar aracılıėı ile tařınan iřaret, sinapslara kimyasal tařıyıcılar yardımıyla akatarılmaktadır. Hcre uyarılması iin belirli bir eřik deėerinin zerinde gerilim uygulanması gerekir, diėer durumlarda sinirde iletim iřlemi olmayacaktır. Bu yntemle hesaplanan ıkıř deėeri sinirsel hesaplama olarak ifade edilmektedir. Yapay sinir aėının en kk parası perseptron (algılayıcı), doėrusal bir fonksiyonla Eřitlik 2.1 'deki gibi ifade edilmektedir [67].

$$x = \sum_j w_j x_j + b \rightarrow y \begin{cases} 1, & x \geq 0 \\ 0, & x \leq 0 \end{cases} \quad (2.1)$$

Burada, “x” giriř deėeri, “w” aėırlık deėeri ve “b” de aktivasyon fonksiyonun saėa ve sola kaydırılmasını saėlayan deėer olarak ifade edilmektedir. Eėer $x \geq 0$ ise y ıkıř deėeri 1, aksi takdirde y ıkıř deėeri 0 olmaktadır. Klasik bir yapay sinir aėında bir katmanda bulunan nronların birbirleriyle iliřkileri yoktur, dahası bilgiler sadece bir nceki katmandan bir sonraki katmana ya da ıkıřa doėru aktarılmaktadır. Art arda gelen iki katmandaki nronlar birbirlerini ancak aktivasyon deėerinin etkisi kadar deėiřtirebilmektedir. Ayrıca katmanlarda bulunan nron sayıları sistemin performansını etkilemektedir. Fazla nron sayısı sistemin iřlem hacmini artıracak gibi az nron sayısı da modelin ėrenmesini olumsuz ynde etkileyebilmektedir.

Yapay sinir aėı modeli tasarlanırken aėırlık vektrlerinin bařlangı deėerlerinin alması gereken sayısal deėerler byk nem arz etmektedir. Aėırlıklar bařlangı ařamasında rastgele atanabileceėi gibi daha nceden eėitilmiř herhangi bir modelin aėırlıkları da bařlangı deėerleri olarak tercih edilebilir. Burada nemli olan husus deėerler atanırken (+) ya da (-) deėerlerden rastgele daėılımlı olarak seilmelidir. Sistemin btn zelliklerini dikkate alarak tasarlanan aė modelinin bařarımını belirleyen kayıp/yitim fonksiyonu (loss function) deėeri optimizasyon teknikleriyle 0'a yaklařacak şekilde


işlenmelidir [68]. Şekil 2.5’ de bir yapay sinir ağının öğrenmesi sırasında, yitim fonksiyonu işlemlerinin nasıl gerçekleştiği gösterilmektedir.



Şekil 2.5. YSA ve yitim fonksiyonunun sembolize edilmesi


Yitim fonksiyonuna ilave edilen düzenleme (regularization-R) değeri sayesinde yitim katsayısı ağırlık değerleri var olduğu sürece sıfır olmamaktadır. Bu değer zorunlu olmamakla beraber sisteme pozitif yönde etkisi olan bir hiper parametredir. Sistemin başarısı yitim fonksiyonunun minimize edilmesiyle doğru orantılı olarak değerlendirilmektedir [65]. Tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olarak yapay sinir ağları dört grupta incelenebilmektedir.

Tek Katmanlı Algılayıcılar: Tek Katmanlı Algılayıcılar (TKA) sadece girdi ve çıktı birimlerinden oluşan yapay sinir ağı modelidir. Tek katmanlı algılayıcılarda çıktı fonksiyonu doğrusal bir fonksiyondur ve 1 veya -1 değerlerini almaktadır. Eğer çıktı 1 ise birinci sınıfa, -1 ise ikinci sınıfa kabul edilmektedir [69]. Şekil 2.6’ da tek katmanlı algılayıcı modeli gösterilmektedir.




Şekil 2.6. Tek Katmanlı Algılayıcı modeli

Çok Katmanlı Algılayıcılar: Yapısal olarak doğrusal olmayan aktivasyon fonksiyonu olan ve birçok nöronun belli bir üstünlük içerisinde birbirleri ile bağlantılı olduğu yapıya ÇKA denilmektedir. Şekil 2.7’ de çok katmanlı algılayıcı modeli gösterilmektedir [69,70].



Şekil 2.7. Çok Katmanlı Algılayıcı Modeli


İleri Beslemeli Yapay Sinir Ağları: Tasarlanan sinir ağlarında nöronlar girişten çıkışa doğru düzenli bir şekilde katman katman olacak şekilde aktarılmaktadır. Bir katman sadece kendisinden önceki katmanlara ilişkilendirilmektedir. Yapay sinir ağının girişine gelen bilgiler herhangi bir değişime uğratılmadan gizli katmandaki hücrelere aktarılmaktadır. Bu işlemlerin ardından sırasıyla çıkış katmanından geçmekte ve ilgili birimlere gönderilmektedir [70]. Şekil 2.8. de ileri beslemeli yapay sinir ağı modeli gösterilmektedir.



Şekil 2.8. İleri beslemeli Yapay Sinir Ağı modeli

Geri Beslemeli Yapay Sinir Ağları: Bu ağlarda ileri beslemeli ağlardan farklı olarak nöronlardan elde edilen çıktılar sadece kendinden sonra gelen nöron katmanına değil, kendinden önceki katmanda veya kendi katmanında bulunan başka nöronlara da girdi olarak verilebilmektedir.

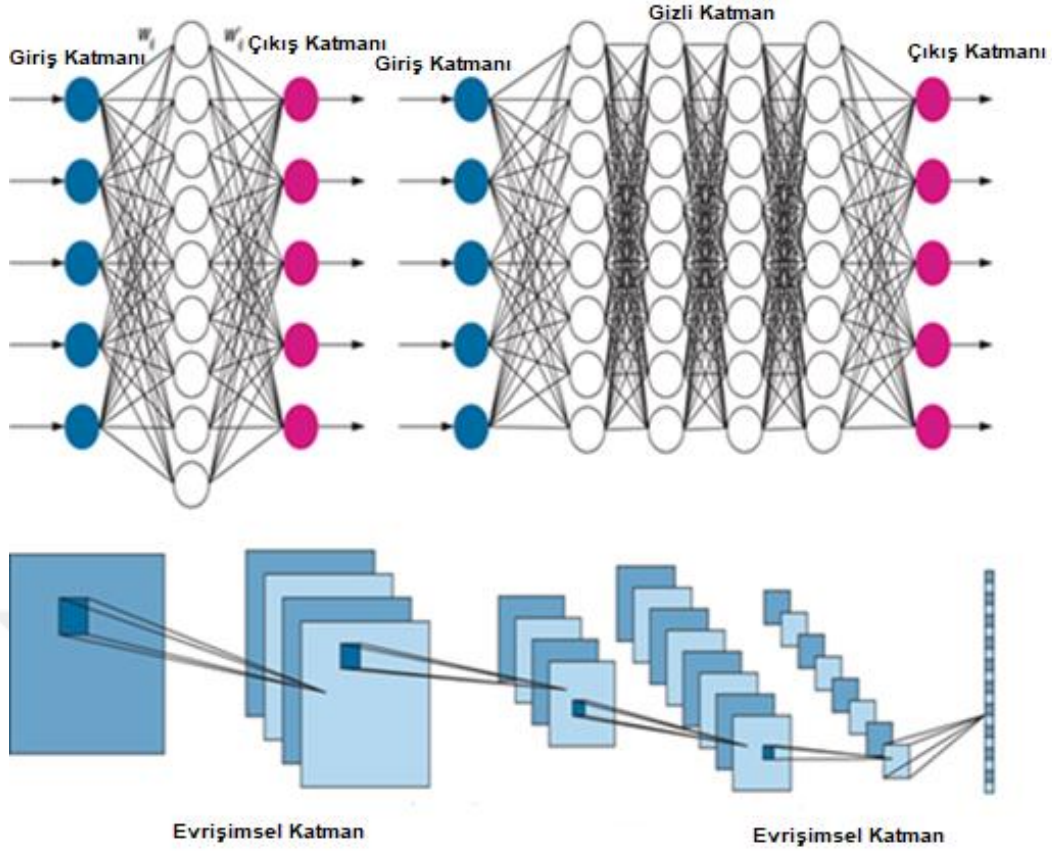
Bu işlem adımları uygulanacak şekilde tasarlanan geri beslemeli yapay sinir ağları doğrusal olmayan özellikleri gösterebilmektedir. Şekil 2.9' da geri beslemeli yapay sinir ağı modeli gösterilmektedir [71].



Şekil 2.9. Geri beslemeli Yapay Sinir Ağı modeli

Yapay sinir ağlarının bu özellikleri geliştirilerek katman sayıları ve yapıları değiştirilerek derin öğrenme algoritmaları geliştirilmiştir. Bu bilgilerden de anlaşılacağı gibi derin öğrenme, insan beynini büyük veriler arasında taklit ederek, minimum bir kuralla başlayarak ve bu büyük resimdeki kalıpları keşfederek yeni kalıplar oluşturan bir tür makine öğrenmesidir. Algoritma oluşturma sürecini otomatikleştirmektedir.

Verilerin incelenmesinde daha önce nereye bakılacağı veya neyin hesaplanacağı planlanmamaktadır. Verilerdeki tüm detaylara erişerek bu verileri anlamlandırmak için sinir ağları, istatistik, matematik ve fizik yöntemlerini kullanır. Şekil 2.10 konunun daha iyi anlaşılması için derin öğrenme ile ilgili bazı modelleri göstermektedir [63]. Burada derin öğrenme ağındaki giriş katmanı, ara katmanlar ve çıkış katmanı yapısı gösterilmiştir.



Şekil 2.10. Derin öğrenme ağları

2.2.3. Derin öğrenme Mimarileri

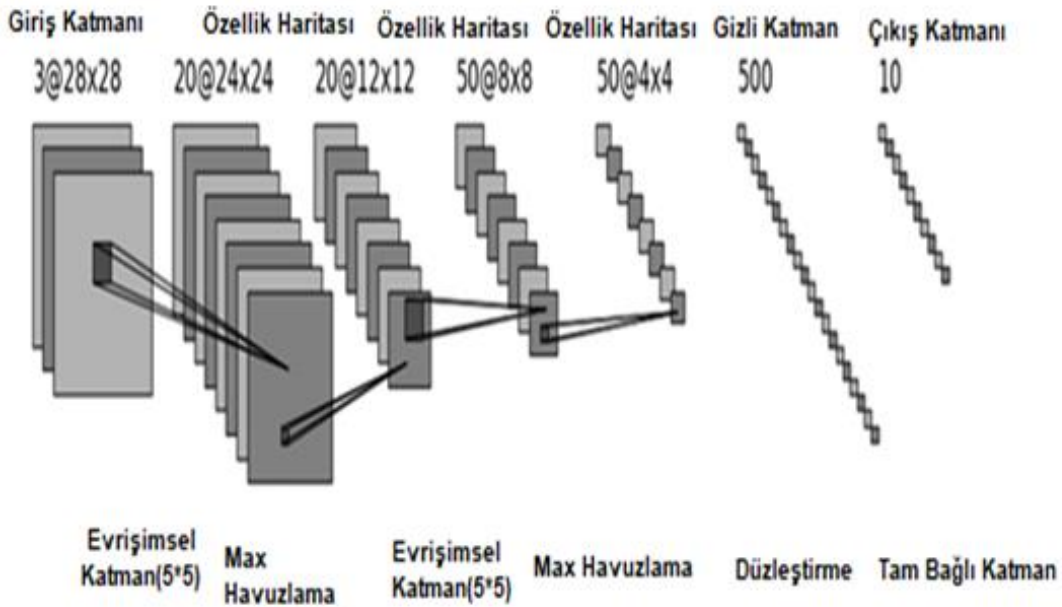
Bu bölümde derin öğrenme ağlarının temel mimarilerinden başlıcaları açıklanmaya çalışılmıştır.

2.2.3.1. Evrışimsel Sinir Ağları

Evrışimsel Sinir Ağları (ESA) çok katmanlı algılayıcıların bir türü gibi düşünülmektedir. ESA özellikle görüntü işleme alanında kullanılan ve girdi olarak görüntü değerlerini alan bir derin öğrenme algoritmasıdır. Değişik durumlarda görsellerdeki özellikleri yakalayan ve onları sınıflandıran algoritma yapısı ile farklı katmanlardan oluşmaktadır. İleri bir sinir ağı olan ESA algoritması, hayvanların görme merkezinden esinlenerek ortaya konmuştur.

Buradaki matematiksel evrişim süreci, bir nöronun uyarısına yanıt olarak gerçekleşmektedir [72-74].

Şekil 2.11’de verilen ilk ESA ağı, 1988 yılında Yann LeCun tarafından tasarlanan ve 1998’lere kadar iyileştirmeleri devam etmiş olan LeNet isimli mimaridir [75]. Burada ilk defa özellik haritaları, düzleştirme aşaması ve tam bağlı katman gösterilmiştir. LeNet ağında, alt katmanlar art arda yerleştirilmiş konvolüsyon ve maksimum havuzlama blokları ile desteklenmiştir. Devamındaki üst katmanlar tamamen birbirine bağlı geleneksel ÇKA’ya karşılık gelmektedir [76]. LeNet mimarisi hakkında detaylı bilgi sonraki bölümde açıklanmaktadır.



Şekil 2.11. LeNet mimarisi

ESA algoritmaları, doğal dil işleme, biyomedikal gibi birçok farklı alanda, özellikle görüntü ve ses işleme alanında uygulanmaktadır. Şekil 2.12’ de örnek bir ESA mimarisinin temeli görünmektedir. ESA modeli incelendiğinde giriş katmanı, konvolüsyon katmanları ve çıkış katmanı görülmektedir. Çıkış katmanında örnek olarak 4 farklı sınıf örneği görülmektedir.



Şekil 2.12. Evrişimsel Sinir Ağı mimarisi


ESA mimarisi temelde birçok katmandan oluşmaktadır. Bunları aşağıda ifade edildiği gibi belirli bir sırayla oluşan farklı katman yapıları olarak düşünebiliriz.

Giriş Katmanı: İsminden de anlaşılacağı üzere ESA'nın ilk katmanını oluşturmaktadır. Bu katmanda veri hiçbir işleme tabii olmadan ağı sunulmaktadır. Tasarlanacak modelin gerçekleştirilebilmesi için katmandaki verinin boyutu son derece önemlidir. Giriş katmanına sunulan görüntü boyutunun yüksek olması yüksek bellek ihtiyacının yanı sıra eğitim ve test süresini olumsuz olarak etkileyecektir. Ancak bunun yanı sıra ağ başarısını da arttırabilir. Ters bir durumda ise bellek ihtiyacı azalır ve eğitim süresi kısalsabilir. Fakat bu seferde ağın derinliği azalır ve performans kaybı yaşanabilir. Mevcut durumların tamamı göz önünde bulundurularak görüntü analizinde ağ derinliği ve donanımsal hesaplama maliyeti hesaplanmalı, ayrıca ağ başarısı için uygun bir giriş görüntü boyutu seçilmelidir.

Konvolüsyon Katmanı: ESA'nın temelini oluşturan bu katman dönüşüm katmanı olarak ifade edilebilir. Dönüşüm işlemi belirli bir filtre işleminin tüm görüntü üzerinde dolaştırılması esas ile çalışmaktadır. Filtreler katmanlı mimarinin önemli bir parçasıdır. 2x2, 3x3, 5x5 gibi farklı boyutlarda seçilebilir. Filtreler, bir önceki katmandan gelen

görüntülere konvolüsyon işlemini uygulayarak çıkış verisini oluşturmak amacıyla tasarlanmışlardır.

Yapılan konvolüsyon işlemi neticesinde aktivasyon haritası elde edilmektedir. Aktivasyon haritası, her bir filtreye özgü özelliklerin keşfedildiği bölgeler olarak düşünülebilir. ESA'ların eğitimi esnasında filtrelerin katsayıları, eğitim kümesindeki her öğrenme yinelemesiyle senkronize bir şekilde değişmektedir. Böylelikle ağ, özelliklerin belirlenmesi için verinin hangi bölgelerinin önem taşıdığını belirlemiş olur. Evrişim işleminde iki boyutlu veriye uygulanacak olan filtrenin x ve y eksenine göre simetriği hesaplanmaktadır. Filtre görüntü üzerinde adım uzunluğuna bağlı olarak dolaştırılırken her adımda çakışan değerler bire bir eleman olarak çarpılmakta ve tüm değerlerin toplamı çıkış matrisinin ilgili elemanı olarak tutulmaktadır. Filtrenin simetriğinin alınmadığı hallerde yapılan işlem korelasyon olarak ifade edilmektedir. Şekil 2.13' de evrişim katmanındaki adım kaydırma işlemleri gösterilmektedir [65].




Şekil 2.13. Evrişim işlemi ve adım kaydırma

Hesaplanan giriş verisinin yüksek frekanslı bölgelerini gösteren kenar bilgileri, bilgisayarlı görüntü uygulamalarında fazlasıyla gereksinim duyulan özniteliklerdendir. Kenar bilgisini yakalayabilmek için dikey ve yatay olmak üzere iki filtre ayrı ayrı kullanılmaktadır. Elde edilen çıkış, görüntünün kenar bilgilerini göstermektedir. Farklı kenar bulma filtreleri ile açılal kenarlar, koyu tonlardan açık tonlara ve açık tonlardan

koyu tonlara geçişler ayrı ayrı birer öznitelik olarak göz önünde bulundurularak hesaplanmaktadır.

Çoğunlukla kenarlar evrişimli ağ modelinin ilk katmanlarında hesaplanma işlemine tabi tutulmaktadır [77]. Ancak yapılan hesaplamalar sonucunda giriş ve çıkış boyutu arasında farklılık oluşabilmektedir. Örneğin; giriş görüntüsü 4×4 , kenar bulma filtresi 2×2 boyutlarında olduğu bir durumda evrişim işlemi sonucu elde edilen çıkış görüntüsünün boyutları $(n-f+1) \times (n-f+1)$ hesabından dolayı 3×3 olur. Çıkış boyutunun bu şekilde değişmesi istenmiyorsa yani giriş çıkış boyutu eşit olacaksa piksel ekleme (padding) işlemi yapılmaktadır. Böylece boyutlar arasındaki farklılıkların giderilmesi sağlanır. Diğer bir taraftan evrişim işleminde gerçekleştirilen kaydırma işleminin adım sayısı (stride) da çıkış boyutunu etkilemektedir.

Aktivasyon Katmanı: Aktivasyon işleminin gerçekleştiği katmandır. Bu katmanda elde edilen veriler aktivasyon fonksiyonunun da işlenerek yeni bir değer üretilmektedir. Bu aşamada tercih edilebilecek birden fazla aktivasyon fonksiyonu vardır. Bunlardan bazıları hiperbolik tanjant, sinüs, step, eşik değer gibi fonksiyonlardır. Derin öğrenme ağlarında kullanılan ve en çok tercih edilen aktivasyon fonksiyonu genellikle ReLU (Rectified Linear Unit) olarak isimlendirilir. ReLU fonksiyonu Şekil 2.14' te gösterilmektedir.



Şekil 2.14. ReLU aktivasyon fonksiyonu


ReLU fonksiyonu 0'dan büyükken x 'e, 0'a eşit ve 0'dan küçük iken 0'a eşittir. Bu durum Eşitlik 2.2. de gösterilmiştir.

$$F(x)=\max(0, x) \quad (2.2)$$

ReLU fonksiyonunun kendisi ve türevi tek düze bir fonksiyondur. Herhangi bir negatif değer ReLU tarafından sıfır olarak geri döndürülür. Tüm negatif değerlerin 0'a çevrilmesi modelin istenildiği gibi eğitilmesini engellemektedir. Bu yüzden modelin negatif değerler ile eğitilme işlemi gerçekleşmeyecektir.

Diğer aktivasyon fonksiyonları işe aşağıdaki gibidir.

Sigmoid (Lojistik) Aktivasyon Fonksiyonu




Şekil 2.15. Sigmoid Fonksiyonu

Şekil 2.15' de sigmoid fonksiyonu gösterilmiştir. Sigmoid aktivasyon fonksiyonun kullanılmasının en önemli sebebi değeri 0 ve 1 arasına yerleştirmesidir. Bu yüzden bir olayın gerçekleşme ihtimali bulunan modellerde sıklıkla kullanılmaktadır. Çünkü olasılık fonksiyonu 0 ile 1 arasında değer almaktadır. Sigmoid fonksiyonu, eğitim aşamasında modelin kilitlemesine neden olabilir. Bu yüzden karmaşık makine öğrenimi

modellerinde kullanımı çoğunlukla tercih edilmemektedir. Softmax aktivasyon fonksiyonu verileri üç veya daha fazla sayıda sınıfa ayırmak için tercih edilirken Sigmoid fonksiyonu iki sınıfa ayrılabilen durumlarda tercih edilir [78].

Tanh (Hiberbolik Tanjant) Aktivasyon Fonksiyonu



Şekil 2.16. Tanh fonksiyonu


Şekil 2.16’ da Tanh aktivasyon fonksiyonu gösterilmektedir. Tanh, sigmoid fonksiyonuna benzemekle birlikte -1 ile 1 arasında değer alır. Negatif sayılarda negatif değer, sıfırda sıfır ve pozitif sayılarda pozitif değer geriye döndürmesi önemli bir avantajdır.

Tanh fonksiyonunun türevi mevcut olmakla beraber kendisi monotondur ancak türevi monoton değildir. Tanh fonksiyonu çoğunlukla iki sınıflı problemlerde tercih edilmektedir. Hem sigmoid hem de tanh ileri beslemeli yapay sinir ağlarında ağırlıklı olarak tercih edilmektedir.

Leaky ReLU Aktivasyon Fonksiyonu

Leaky ReLU negatif değerlerin ReLU’da yok olmasını engellemek için geliştirilmiştir. Şekil 2.17’ de Leaky ReLU aktivasyon fonksiyonu gösterilmektedir. Leaky ReLU

grafisinde x' in 0'dan küçük olduğu kısımda bir sızıntı vardır. Bu sızıntı ReLU'nun aralığını arttırmaktadır. Burada belirtilen a değeri 0.01 gibi küçük bir sayıdır ancak a 'nın 0.01 olmadığı durumda fonksiyon Randomized ReLU olarak değişmektedir. Leaky ReLU ve Randomized ReLU monoton fonksiyonlardır. Diğer bir yandan bu fonksiyonların türevleri de monoton fonksiyonlardır [78-79].



Şekil 2.17. Leaky ReLU aktivasyon fonksiyonu

Step Fonksiyonu: Bir eşik değeri olarak ikili bir sınıflandırma çıktısı (0 ya da 1) üretir.

Softmax Fonksiyonu: İki'den fazla sınıflandırma durumlu problemler için kullanılan bu fonksiyon, verilen girdilerin bir sınıfa ait olma olasılığını gösteren $[0,1]$ arası değer üreterek çıkış için uygun sınıfı üretmektedir.


Softplus Fonksiyonu: Sigmoid ve Tanh gibi geleneksel aktivasyon fonksiyonlarına alternatif olarak tercih edilen softplus fonksiyonu $(0, +\infty)$ aralığında türevlenebilir bir çıkış değeri verebilmektedir.

ELU Fonksiyonu: Üstel lineer birim (Exponential Linear Unit-ELU), negatif girdiler hariç ReLU ile benzer niteliktedir. Exponential fonksiyondan dolayı ReLU fonksiyonu ile kıyas edildiğinde daha yavaş çalışır.

PReLU Fonksiyonu: Parametrik ReLU olarak bilinen bu aktivasyon negatif girdiler için extra alfa sabiti ile giriş değerinin çarpım sonucu ile elde edilen yeni çıkış değeri üretecek şekilde tasarlanmıştır.

Swish Fonksiyonu: Google araştırmacıları tarafından bulunan swish fonksiyonu mevcut girdiler ile sigmoid fonksiyonunun çarpımını çıktı olarak verebilmektedir.

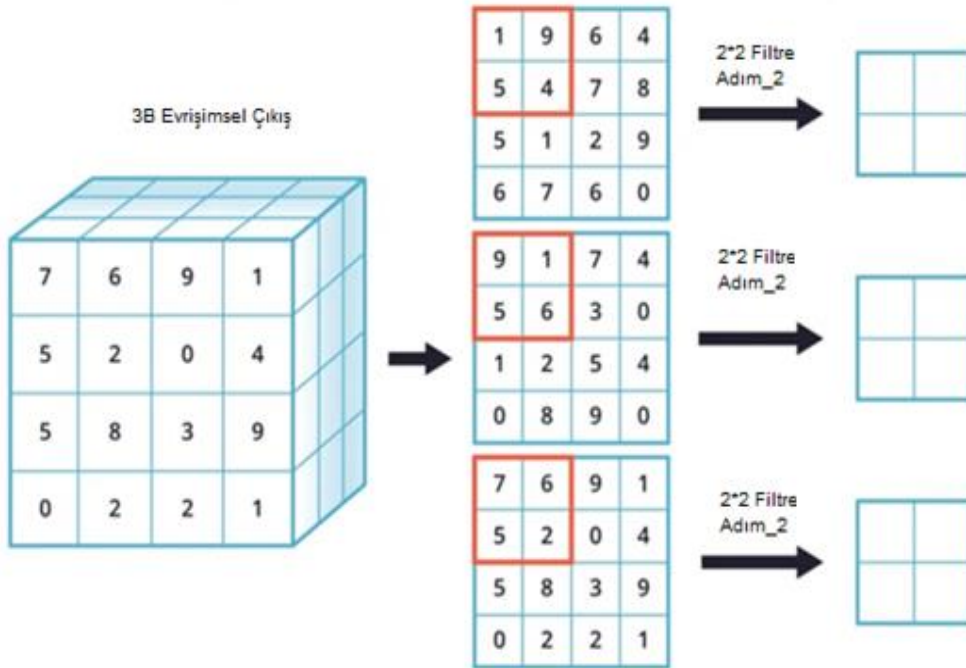
Şekil 2.18’ de hali hazırda kullanılan aktivasyon fonksiyonlarının derin öğrenme ağlarındaki öğrenme durumları ile ilgili fonksiyon çıktıları gösterilmektedir [79].



Şekil 2.18. En çok kullanılan aktivasyon fonksiyonları

Havuzlama (Maxpool) Katmanı: Havuzlama katmanı olarak bilinen katman genellikle konvolüsyon işlemi devamında mevcut olan bir yapıdır [80]. Bu katmanda, görüntüde tasarımcının tercihine göre (n)x(n) boyutundaki bir matris kullanılır. Boş matris, görüntü matrisi içerisinde gezdirilerek matris içerisinde yer alan en büyük değeri alır ve yeni bir görüntü matrisin yeni bir değerini üretir. Oluşturulan havuzlama yöntemi maxpool (en büyük havuzlama) diye adlandırılır. Şayet filtre gezdirildikten sonra değerlerin aritmetiksel ortalaması ile elde edilen değerler baz alınırsa avarage pool(ortalama havuzlama) işlemi gerçekleştirilmiş olur. 2x2 şeklindeki bir matris düşünülecek olursa Şekil 2.19 'da yer alan örnek değeri oluşturur. Elde edilen görüntü matrisi boyutu

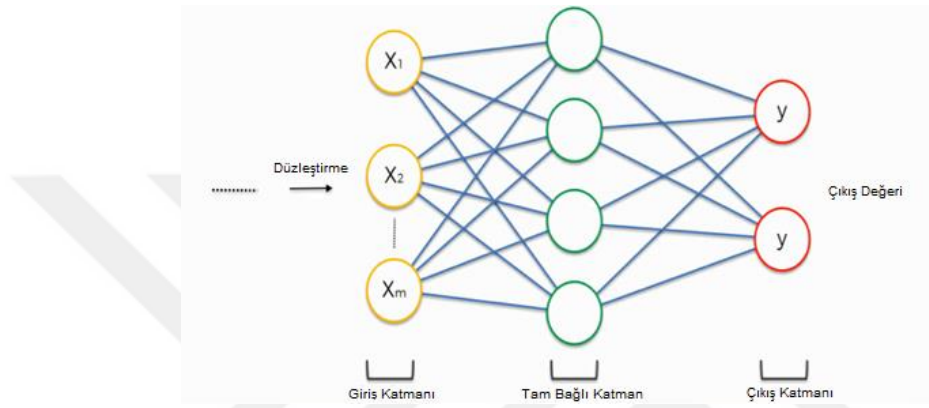
küçültülerek yeni görüntü matrisi üretilir. Böylelikle ağıdaki işlenen veri miktarı da azaltılmış olur. Katmanın temel amacı devamındaki evrimsel katmanı için giriş boyutunu düşürmektir. Bu işlem veride derinlik boyutunu etkilememektedir. Katmanda gerçekleştirilen işlem down sampling (aşağı örnekleme) olarak da adlandırılmaktadır ve katman sonucu boyuttaki küçülme bilgi kaybına neden olabilmektedir. Böyle bir kayıp ağı için iki nedenden dolayı faydalıdır. Birincisi, bir sonraki ağı katmanları için daha az hesaplama yükü oluşturur. İkincisi ise sistemin ezberlemesini önler. Ancak önemli bilgilerinde ihmal edilebileceği unutulmamalıdır. Bu katmanda çoğunlukla maksimum havuzlama, daha iyi performans gösterdiği için seçilmektedir. Havuzlama işlemi, konvolüsyon katmanı sonucu oluşan filtre sayısı kadar görüntülerin hepsi için icra edilmektedir [80]. ESA'larda havuzlama katmanı isteğe bağlıdır ve bazı mimariler bu işlemi tercih etmezler. Şekil 2.19' da havuzlama katmanı ile ilgili görsel yer almaktadır.



Şekil 2.19. ESA mimarisinde havuzlama katmanı


Tam Bağlı (Full-Connected) Katmanı: Havuzlama katmanından gelen veriler bu katmanda tek boyutlu bir matris şeklinde düzenlenerek işlenmektedir. Nöronlar bu katmanda tam bağlı olarak yer almaktadır. Her nöron kendinden sonra gelen nöronla

bağlanarak katman gerçekleştirildiği için tam bağlı katman olarak bilinir [81]. Bu katmandaki nöronların bağlantıları Şekil 2.20 'de görülmektedir. Her mimari için bu katmanın sayısı değişebilir. ESA mimarisinde son katmandan elde edilen matris boyutu $25 \times 25 \times 256$ ya da 160000×1 ve tam bağlantılı katmandaki matris boyutu 4096×1 olarak ayarlanırsa toplamda 160000×4096 ağırlık matrisi elde edilir. Bir başka deyişle her bir 160000 nöron 4096 nöron ile bağlanmaktadır. Bu bağ yapısı itibariyle mevcut katmana tam bağlantılı katman denilmiştir.



Şekil 2.20. Tam bağlantılı katman yapısı

Bırakma (DropOut) Katmanı: ESA mimarisinde büyük veriler ile eğitim işlemi yapıldığından dolayı bazen ağ ezberleme yapabilmektedir. Bu durumun önüne geçmek amacıyla bırakma katmanı kullanılmaktadır. [82]. Bu katmanda uygulanan temel mantık ağın bazı düğümlerinin kaldırılmasıdır. Şekil 2.21 de ağın orijinal yapısı ve dropout katmanından sonraki hali birlikte gösterilmiştir. Ancak burada atılacak katmanların oranı iyi seçilmelidir. Aksi takdirde ağdaki önemli bilgilerinde atılma ihtimali vardır.



Şekil 2.21. Bırakma katmanı uygulanması

Normalizasyon (Ölçeklendirme) Katmanı: ESA ağlarında, ağın normalize edilmesi ağın performansını olumlu bir şekilde etkilemektedir. Burada yapılan işlemler katmanlardan elde edilen verilerin düzenli hale getirilmesi işlemi gibi düşünülebilir. Katmana girdi şeklinde sunulan bilgiler çok büyük ya da çok küçük değerler içerebilirler. Bu değerlerin normalize edilerek arzu edilen bir aralığa getirilmesi en doğru durum olacaktır. Bu sayede hem ağın performansı hem de girdi verilerinin ölçeklenerek belirli bir aralıkta temsil edilmesi gerçekleştirilmiş olur [83].

Bir sinir ağının kararlılığını artırmak için toplu normalleştirme (batch normalization), toplu iş ortalamasını çıkararak ve toplu iş standart sapmasına bölerek önceki bir etkinleştirme katmanının çıktısını normalleştirir. Sonuç olarak toplu normalleştirme, her katmana iki eğitilebilir parametre ekler. Böylece normalleştirilmiş çıktı bir "standart sapma" parametresi (gama) ile çarpılır ve bir "ortalama" parametre (beta) eklenir. Başka bir deyişle toplu normalleştirme, Stochastic Gradient Descent (SGD) yönteminin tüm ağırlıkları değiştirerek ağın kararlılığını kaybetmek yerine her aktivasyon için yalnızca bu iki ağırlığı değiştirerek normalleştirmeyi yapmasına izin verir. Toplu normalleştirme işlemi Eşitlik 2.3 ve Eşitlik 2.4'te görüldüğü gibi katman girdisinin ortalamasını ve varyansını hesaplayarak başlamaktadır [80].

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (2.3)$$

$$\sigma^2_B = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (2.4)$$

Eşitlik 2.3. ve 2.4 de sırasıyla m; mini yığın için veri sayısını, x_i ;girdi verilerini, μ_B ; mini yığın ortalamasını, σ ; yığın varyansını göstermektedir. Eşitlik 2.5'te hesaplanan istatistikleri kullanarak katman girdilerini normalleştirme işlemi görülmektedir.

$$\hat{X} = \frac{X_i - \mu_B}{\sqrt{\sigma^2_B + \varepsilon}} \quad (2.5)$$

Eşitlik 2.5' de \hat{X} normalizasyon işlemini, ε ; çok küçük bir değeri ifade etmektedir. Son olarak Eşitlik 2.6' da gösterildiği üzere katmanın çıktısını elde etmek için ölçekleme ve kaydırma işlemi gerçekleştirilir.

$$y_i = \gamma \bar{x}_i + \beta \quad (2.6)$$

Eşitlik 2.6' da β ; kaydırma değerini, γ ; ölçeklendirme parametresini, y_i ise hesaplamalar sonucunda elde edilen çıkış değerini göstermektedir.


Entropi (Softmax) Katmanı: Kendisinden önce gelen katmanda hesaplanan değerleri olarak sınıflandırma işlemi içerisinde olasılıksal sonuçları elde etmeyi sağlayan katmandır. Sınıflandırma işlemi yapılırken elde edilen değerlerin hangi sınıfa daha yakın olduğuna karar verilen katmandır. Derin ağ yapısı içerisinde katmanda üretilen olasılıksal verileri hesaplama işlemi ile her bir sınıf için olasılık değeri şeklinde sunmaktadır [80]. Bu hesaplama yapılırken cross entropy (çapraz entropi) kullanır. Bu katman tam bağlantılı katmandan sonra gelir [84].

Ayrıca bu katmanın çıkış değeri sınıflandırma sonucu bulunacak nesne sayısı ile aynıdır. Diğer bir deyişle 10 farklı nesnenin sınıflandırılması için sınıflandırma katmanı çıkış değerinde aynıdır. Tam bağlantılı katmanda çıkış değeri 4096 olarak belirtilmişse, çıkış değerine göre sınıflandırma katmanı için 4096x10 ağırlık matrisi hesaplanmaktadır. Bu katmanda farklı sınıflandırıcılar bulunmaktadır. Diğer metotlara göre başarısından dolayı softmax sınıflandırıcı daha fazla kullanılmaktadır. Sınıflandırmada 10 farklı nesne, 0-1 aralığında belli bir değerde çıkış üretmektedir. 1'e yakın sonucu üreten çıkış, ağın tahmin ettiği nesne değeri gibi düşünülebilir.

2.2.3.2. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (TSA) Jeff Elman tarafından tasarlanmıştır. Elman'ın cümle yapısı simülasyonunda kullanılan her kelime için isim ve fiil kategorileri, gizli kalıplar üzerinde ortalama kalıp kümelenmesine göre temiz bir şekilde ayrılmıştır. Buna ek olarak isimler, hatta insan-hayvan, av-avcı, canlı-cansız ayrımları gibi kümeler de hayvanlar

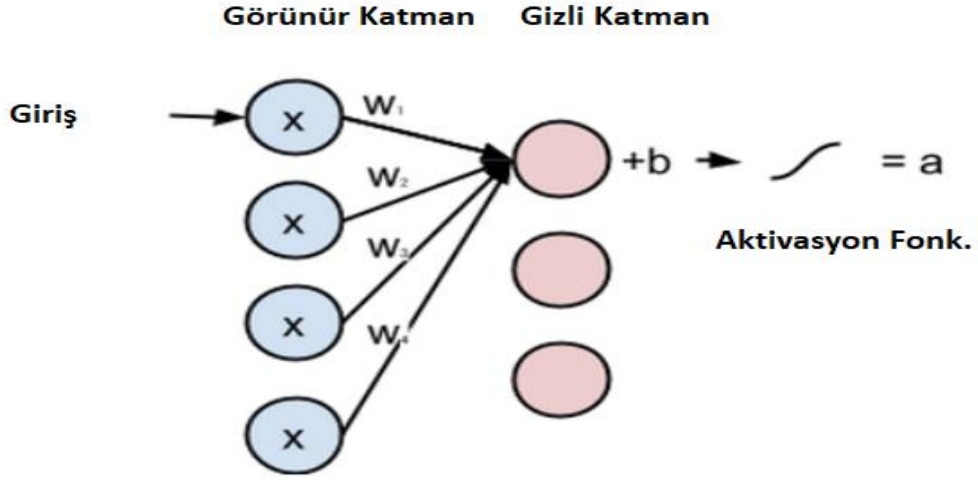
arasında bölünmüştür [85]. TSA, birimler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu bir yapay sinir ağları sınıfıdır. Bu döngü ile dinamik zamansal davranışı göstermesine izin veren bir ağ iç durumu yaratılmıştır. İleri beslemeli sinir ağlarının aksine, TSA' lar kendi girdi belleğini rastgele girdi dizilerini işlemek için kullanabilmektedir. Şekil 2.22'de örnek bir tekrarlayan sinir ağının modeli görünmektedir [86].



Şekil 2.22. Tekrarlayan sinir ağı modeli

2.2.3.3. Sınırlı Boltzmann Makineleri

Sınırlı Boltzmann Makineleri (SBM) ilk olarak 1986 yılında Harmonium tarafından önerilmiş, ancak uzun bir süre sonra 2006 yılında Geoffrey Hinton ve arkadaşları tarafından hızlı bir öğrenme algoritması olarak öne sürülmüştür [87]. SBM, girdi kümesindeki olasılık dağılımını öğrenebilen bir makine öğrenmesi türüdür. Mimari temelinde görünür ve gizli olmak üzere iki parçalı grafik yapısı vardır. Normal bir grafik yapısında düğümler arasında bağlantı yoktur [88-89]. Buna karşılık, SBM'de gizli birimler arasında bağlantı vardır. Bu sebeple, Boltzmann makinelerinin genel sınıfı için mevcut olan algoritmalarından daha etkili bir eğitim ortamına izin verebilmektedir [89]. SBM bu özellikleri sebebiyle filtreleme, özellik öğrenme ve sınıflandırma gibi problemlerde kullanışlıdır. Şekil 2.23'te örnek bir kısıtlı boltzmann sinir ağının modeli görünmektedir.



Şekil 2.23. Sınırlı boltzmann sinir ağı modeli

2.2.3.4. Derin İnanç Ağları

Geoffrey Hinton tarafından tanıtılan Derin İnanç Ağları (DİA), aslında SBM yığını olarak da ifade edilmektedir. Her SBM katmanı kendisinden önceki ve sonraki katmanlara bağlı olmak zorundadır. Bununla birlikte herhangi bir katmanın düğümlerle yatay düzlemde bir bağı yoktur. Son katman olarak bir softmax katmanı ile derecelendirme veya kontrolsüz öğrenme için kümeleme yapabilir.

SBM tarafından oluşturulmuş yığınlardaki nesne, video dizisi, hareket yakalama gibi alanlarda kullanılır. Kısıtlı boltzman makinelerinin sırasıyla eğitilerek öğrenilmesiyle gerçekleşir. DİA mimarileri, görüntü tanıma ve üretim için uygulanmıştır [90-92]. DİA'lar birden fazla alt dala ayrılmış ve her alt dalın kullanım amaçları farklı şekiller işlemektedir. Bu nedenle görüntü tanımlama, video dizileri, hareket yakalama, konuşma tanıma alanlarında sıklıkla kullanılmaktadır.

2.2.3.5. Derin Otomatik Kodlayıcılar

Diabolo ağı adı verilen Otomatik Kodlayıcılar (OK), denetimsiz öğrenme için kullanılan özel bir sinir ağ yapısıdır. Bu yapıda veri setinin boyutunu küçültmek için temsil (kodlama parçası) öğrenmeyi amaçlamaktadır. OK, giriş verilerinin sıkıştırılmış gösteriminden en iyi özellikleri öğrenmeyi amaçlayan ileri beslemeli bir sinir ağıdır. OK sisteminde giriş verisi, şifreleme-şifre çözme işleminden sonra çıktı olarak aynı giriş değerini elde edene kadar ağırlıklar güncellenebilir. Hedefe ulaşıldığı aşamada ise giriş verileri gizli katmandaki düğüm sayısı ile gösterilmektedir.

Derin veya yığınlanmış otomatik kodlayıcılar (DOK), her bir katmandaki çıktıların birbirini takip eden katmanların girişlerine bağlandığı birden fazla OK katmanından üretilen sinir ağ yapısıdır [93-94]. Giriş sırası ilk gizli katmanda kodlanır ve "1. özellik " dizisi üretilmiş olur. Bir sonraki gizli katmandan elde edilen özellik dizisi girdi olarak verilir ve şifreleme sonucunda "2. özellik" dizisi de üretilmiş olur. Özellik 2 dizisi, özellik vektörü olarak son katmandaki softmax sınıflandırıcısına girdi olarak aktarılır, sınıflandırma işlemi bu vektörle gerçekleştirilir [95].

2.2.3.6. Derin Öğrenme Sinir Ağlarının Eğitilmesi

Derin öğrenme ağlarının eğitilmesi, modeller arasında bazı farklılıklar göstermekle beraber temelde aynı adımlar izlenir. Burada ESA ağının eğitilmesi referans alınmaktadır. Oluşturulan derin öğrenme modeli yapılacak işleme göre seçilmelidir. Örneğin sınıflandırma ya da segmentasyon için kullanılacak modeller aynı özelliklere sahip değildirler. Seçim işlemi tamamen model tasarımcısının geçmiş deneyimleri ve tecrübesi ile çözülebilecek bir durumdur. Tasarlanacak modelde katman sayısı, havuzlama katman sayısı, tam bağlantılı katman sayısı ve sınıflandırma katmanı (çıkışta sınıflandırma yapılacaksa) belirlenir. Ayrıca hiper parametrelerin ayarlanması da son derece önemlidir. Bu katmanların sıralanması, adetleri ve hiper parametre ayarları yine tasarımcıya özgüdür.

Model oluşturulma aşaması bittikten sonra başlangıç değişkenlerinin atanması gerekmektedir. Bu değişkenler temel olarak filtre boyutları, filtre sayısı, adım kayma miktarı ve öğrenme katsayısı gibi parametreler olarak sıralanabilir. Ayrıca model ağırlık değerlerinin verilmesi, her bir filtre için 0-1 aralığında değerler atanması gerekir. Bu işlemler başlangıç aşamasında rastgele olarak yapılmaktadır.

Giriş katmanı normalleştirilmiş bilgileri içermektedir. Bir katmandaki her düzlem, önceki katman düzleminin küçük bir girdisini alır. Girdi bilgileri ağdaki katmanlardan iletilerek bir sonuç değeri üretilmiş olur. Bu işlemlere ileri besleme adı verilir. Bu aşamada katmanlarda her bir filtrenin ağırlıkları ile piksel değerleri çarpılıp ve toplamları alınarak bir sonraki katmana aktarılma işlemi gerçekleştirilir. Giriş katmanındaki işlemler Eşitlik 2.7' de gösterilmiştir [74].

$$Z_{i,j,k}^l = W_k^{l,t} x_{i,j}^l + b_k^l \quad (2.7)$$

Eşitlik 2.7' de l . katman ve k . özellik haritasındaki (i, j) lokasyonunun değerini gösterir ve $Z_{i,j,k}^l$ değeri hesaplanabilir. Burada W_k^l ilgili katmandaki ağırlık vektörünü ve b_k^l bias doğrulama katsayısını göstermektedir. Burada model karmaşıklığının azaltılması amaçlanmaktadır ve Ağın daha kolay eğitilmesi gerçekleştirilmektedir. Bütün bunlarla birlikte aktivasyon fonksiyonu ile ESA'nın doğrusal olmayan özellikleri tanınması sağlanabilir [96].

Konvolüsyon katmanındaki özellik $Z_{i,j,k}^l$ değeri için aktivasyon değeri Eşitlik 2.8'de gösterildiği gibi ifade edilebilir.

$$a_{i,j,k}^l = a(Z_{i,j,k}^l) \quad (2.8)$$

Eşitlik 2.8' de a değeri l . katman için k özellik haritasına göre aktivasyon değerini sembolize etmektedir. Daha önce de bahsedildiği gibi sıklıkla kullanılan tipik aktivasyon fonksiyonları; Sigmoid, Tanh ve ReLU aktivasyon fonksiyonlarıdır. [96]. Bu işlemlerin ardından ESA'ların son katmanı çıkış katmanı olan gelmektedir. Çıkış katmanında ise sınıflandırma görevleri için softmax operatörü yaygın olarak kullanılmaktadır.

N giriş-çıkış ilişkisi $\{(x^n, y^n); n \in N [1, \dots, N]\}$ şeklinde tanımlanır, x^n ; n ci girişi, y^n ; karşılık gelen etiketi, o^n ; ESA' nın çıkışı temsil eder ve tüm parametreler Θ ile ifade edilirse, ESA' da kayıp değeri L Eşitlik 2.9' da gösterildiği gibi hesaplanabilir.

$$L = \frac{1}{N} \sum_{n=1}^N l(\theta, y^n, o^n) \quad (2.9)$$

ESA'nın eğitimi bir hata-kayıp fonksiyonuna bağlı olarak icra edilmektedir. Verilen q örnekleri için $e = (x, y_b)$ varsayımında, $Y^q = F(x, w)$ şeklinde bir kayıp fonksiyonu temsil edilir. Bu yapıda w ayarlanabilir ağırlık değerini ifade etmektedir.

Daha sonra ağı'n ürettiği sonuçlar ile hedef sonuçların arasındaki fark değeri hesaplanarak toplam hata değeri bulunur. Elde edilen hata değerinin ağıdaki bütün ağırlıklara dağıtılması oldukça önemlidir. Bu işlem için Geriye Yayılım Algoritması (GYA) kullanılır. GYA'da her bir ağırlığın toplam hataya olan etkisinin hesaplanması amacıyla optimizasyon algoritmaları kullanılır.

Buradaki ağırlıkların güncellenmesiyle ağı'n çıkışında oluşan toplam hata Eşitlik 2.9 kullanılarak bir ESA mimarisi için (gerçek çıktı ile elde edilen çıktı arasındaki fark) hesaplanabilir. Eşitlik 2.10' da örnek olarak minimum Ortalama Karesel Hata (OKH) fonksiyonu hesabı gösterilmiştir. Diğer optimizasyon algoritmaları da detaylı bir şekilde açıklanmaktadır.

$$E^q(w) = D(|Y^q - y_b|, F(x, w)) \quad (2.10)$$

Eşitlik 2.10' da q değeri örnekleri temsil ederken x giriş değerini, w ağırlıkları, Ydeğeri q. çıkışı ve $E^q(w)$ de üretilen çıktı ile olması gereken çıktı arasındaki fark bulunmaktadır. Elde edilen hata değerleri de hesaba katıldıktan sonra, son olarak Eşitlik 2.11 'de çıkış değeri hesaplanmaktadır.

$$E^q(w) = \frac{1}{n} \sum_{q=1}^n (Y^q F(x, w)) + \log \left(e^{-j} + \sum_i e^{-y^q F(x, w)} \right) \quad (2.11)$$

Eşitlik 2.11' de y^q değeri q . ncu katman çıktısını, x giriş değerini, w model ağırlığını ifade ederken n adet girdi değeri için $E^q(w)$ değerinin hesaplanması gösterilmiştir.

2.2.3.7. Optimizasyon yöntemleri

Derin öğrenme ağları ile yapılan çalışmalarda, öğrenme işleminin etkili bir şekilde gerçekleştirilebilmesi için hata fonksiyonunun mutlak minimum değerinin hesaplanması gerekmektedir. Bu işlem optimizasyon yöntemleri kullanılarak mümkün olabilmektedir.

Optimizasyon algoritmaları, ağıın ürettiği çıkış değeri ile gerçek değer arasındaki farkı yani hatayı en küçük seviyelere getirmek için kullanılan yöntemler bütünüdür. Optimizasyon algoritmalarında öğrenme katsayısının hesaplanması modelin eğitimi aşamasında kritik bir öneme sahiptir. Fakat her algoritma ile her modeldeki öğrenme katsayısını doğru bir şekilde ayarlamak mümkün değildir. Modelin durumuna göre öğrenme algoritması da değiştirilebilmektedir. Genellikle derin öğrenme ağlarında optimizasyon aşamasında gradyan inişi yöntemlerinin çeşitli varyasyonları kullanılmaktadır. Bunların en çok tercih edilenleri aşağıda detaylı bir şekilde açıklanmıştır [97].

SGD Optimizasyon Algoritması: Derin öğrenme ağlarında birçok çalışmada Stochastic Gradient Descent algoritması tercih edilmektedir. SGD, tüm gradient'ler yerine geliş güzel bir şekilde bir kısım gradientle ağırlıkları değiştirilmektedir. Mevcut gradienti ($\partial L / \partial wt$), öğrenme katsayısı (a) ile çarparak mevcut ağırlığı (wt) ayarlanmaktadır. Eşitlik 2.12' de bu durum açıkça görülmektedir.

$$w_{t+1} = w_t - a \cdot \frac{\partial L}{\partial wt} \quad (2.12)$$

Batch gradyan iniş yöntemi, parametre değerleri güncellemesinden önce benzer durumlar için gradyanları yeniden hesapladığından, büyük veri kümeleri için yedek hesaplamalar elde edilir. SGD yöntemi ise tek seferde güncelleme adımları sayesinde işlem fazlalığını

ortadan kaldırmaktadır. Bu sebeple diğer algoritmalarından çok daha hızlıdır ve çevrimiçi öğrenmek için de tercih edilmektedir. İlave olarak, öğrenme hızını yavaşça düşürdüğümüzde, SGD'nin batch gradyan inişiyle aynı yakınsama davranışını gösterdiği, hatta dışbükey olmayan ve optimizasyon için neredeyse yerel ya da küresel bir asgariye yakınlığı da kanıtlanmıştır.

Momentum Optimizasyon Algoritması: SGD'de optimum nokta hesaplanırken çok fazla salınım gerçekleşir. Salınımları azaltmak ve hedefe gitme hızını arttırmak için momentum yöntemi tercih edilmektedir. Bu yöntemde mevcut gradient'ler yerine momentumlu gradient kullanılmaktadır. Bu durum Eşitlik 2.13 ve Eşitlik 2.14' de açıklanmıştır [97].

$$w_{t+1} = w_t - aV_t \quad (2.13)$$

$$V_t = \beta V_{t-1} + (1 - \beta) \frac{\partial L}{\partial W_t} \quad (2.14)$$

Burada V_t 'nin başlangıç değeri 0'dır. β , 0 ile 1 arasında olup geçmiş gradientlerin işleme ne kadar katılacağını ayarlamak için kullanılmaktadır. w_{t+1} , w_t ağırlığının güncellenmiş yeni değerini, a da öğrenme katsayısını göstermektedir. Böylece daha az salınım yaparak hedefe ulaşılması amaç edinilmektedir [97].

Adagrad Optimizasyon Algoritması: SGD ve Momentum yöntemlerindeki sabit öğrenme katsayısı problemini ortadan kaldırmak amacıyla tercih edilen bir algoritmadır. Her adımda farklı bir öğrenme katsayısı ile işlem yapmak için kullanılmaktadır. Bu sebeple öğrenme katsayısı geçmiş gradientlerin karelerinin kümülatif toplamının kareköküne bölünmektedir. Bu durum Eşitlik 2.15 ve Eşitlik 2.16' da gösterilmiştir.

$$w_{t+1} = w_t - \frac{a}{\sqrt{\hat{S}_t + \epsilon}} \frac{\partial L}{\partial w_t} \quad (2.15)$$

$$S_t = S_{t-1} + \left[\frac{\partial L}{\partial W_t} \right]^2 \quad (2.16)$$

Burada S başlangıçta 0, ϵ ise işlemi sıfıra bölme hatasından kurtarmak için genelde çok küçük bir sayı (10^{-7}) olarak alınır. Ayrıca a öğrenme katsayısını, S_t ise; S_{t-1} değeri ile geçmiş gradientlerin kümülatif toplamından elde edilen yeni değeri göstermektedir.

RMSprop Optimizasyon Algoritması: Adagrad yöntemine benzer şekilde sabit öğrenme katsayısı problemlerini çözmek için tercih edilmektedir. Aralarındaki fark adagrad yöntemindeki gradientlerin karelerini almak yerine momentumlu gradientlerin karelerini alma işlemi ile gerçekleştirilmektedir. Bu yöntem Eşitlik 2.17 ve Eşitlik 2.18’ de gösterilmiştir.

$$w_{t+1} = w_t - \frac{a}{\sqrt{\hat{S}_t + \epsilon}} \frac{\partial L}{\partial w_t} \quad (2.17)$$

$$S_t = \beta S_{t-1} + (1 - \beta) \left[\frac{\partial L}{\partial W_t} \right]^2 \quad (2.18)$$

Eşitlik 2.18’ de S başlangıçta 0, $a=0.001$, $\beta=0.9$ ve ϵ ise (10^{-6}) olarak tercih edilmektedir [97].

Adadelta Optimizasyon Algoritması: Adadelta algoritmasında adagrad ve RMSProp yöntemlerinden ziyade öğrenme katsayısı seçme isteğe bağlıdır. Bunun yerine geçerli ağırlıklar ile güncellenen ağırlıklar arasındaki farkı ifade eden delta değerlerinin karelerinin momentumlu toplamları tercih edilmektedir. Adadelta optimizasyon algoritması Eşitlik 2.19, 2.20, 2.21 ve 2.22’ de gösterilmiştir.

$$w_{t+1} = w_t - \frac{\sqrt{D_{t-1} - 1}}{\sqrt{\hat{S}_t + \epsilon}} \frac{\partial L}{\partial w_t} \quad (2.19)$$

$$D_t = \beta D_{t-1} + (1 - \beta) [\Delta W_t]^2 \quad (2.20)$$

$$S_t = \beta S_{t-1} + (1 - \beta) \left[\frac{\partial L}{\partial W_t} \right]^2 \quad (2.21)$$

$$\Delta W_t = W_t - W_{t-1} \quad (2.22)$$

Eşitlik 2.19’ da mevcut gradient değeri bir önceki w_t değeri arasındaki fark ile w_{t+1} değeri hesaplanmaktadır. Eşitlik 2.20 ve Eşitlik 2.21’ de görüldüğü üzere β değeri hesaba katılarak Eşitlik 2.22 ‘deki ΔW_t ile W_t , W_{t-1} ağırlıkları arasındaki fark değeri bulunmaktadır. Bu hesaplamalar esnasında S ve D değeri başlangıçta 0, $\beta=0.95$ ve ϵ ise 10^{-6} olarak tercih edilmektedir.

Adam Optimizasyon Algoritması: Rmsprop ve momentum yöntemlerinin avantajlı özelliklerinin bir araya getirilmesi ile önerilen gradient descent algoritmasıdır. Momentum yöntemindeki V ile rmsproptaki S ’i kullanmaktadır. Bu durum Eşitlik 2.23, 2.24, 2.25, 2.26, 2.27’ de gösterilmektedir [97].

$$w_{t+1} = w_t - \frac{a}{\sqrt{\hat{S}_t + \epsilon}} \hat{V}_t \quad (2.23)$$

$$\hat{V}_t = \frac{V_t}{1 - \beta_1^t} \quad (2.24)$$

$$\hat{S}_t = \frac{S_t}{1 - \beta_2^t} \quad (2.25)$$

$$V_t = \beta_1 V_{t-1} + (1 - \beta_1) \frac{\partial L}{\partial W_t} \quad (2.26)$$

$$S_t = \beta_2 S_{t-1} + (1 - \beta_2) \left[\frac{\partial L}{\partial W_t} \right]^2 \quad (2.27)$$


Eşitlik 2.23 de w değeri ağırlıkları, Eşitlik 2.24 ve Eşitlik 2.26. da V_t değeri momentum yönteminde olduğu gibi geçmiş gradientlerin hesaba katılma oranını Eşitlik 2.25 ve 2.27 de S_t Rmsprop yönteminde olduğu gibi gradientlerin hesaba katılma değerini göstermektedir. Burada S ve V başlangıç olarak 0 olarak tercih edilirken, $a=0.001$, $\beta_1=0.9$, $\beta_2=0.999$ ve ϵ ise 10^{-8} olarak tercih edilmektedir [97].

2.3. Derin öğrenme algoritmaları

Bu bölümde literatürde yer alan güncel derin öğrenme ağları ile beraber yeni çalışmalarda kullanılan algoritmalar mimari yapıları, kullanıldığı alanlar dikkate alınarak kapsamlı bir şekilde açıklanmaktadır.

2.3.1. LeNet Mimarisi

LeCun, banka çekleri üzerindeki sayıları tanımlamak amacıyla geliştirdiği ağa LeNet adını vermiştir. 0-9 arasındaki sayıları sınıflandırdığı için 10 sınıflı bir durum katmanı ile çalışmaktadır. LeNet mimarisi bünyesinde tam bağlı bir katman, ReLU aktivasyon katmanı, havuzlama katmanı, yumuşak bağlı katmanlar mevcuttur. Şekil 2.24 'te LeNet mimarisinin yapısı görülmektedir [74].



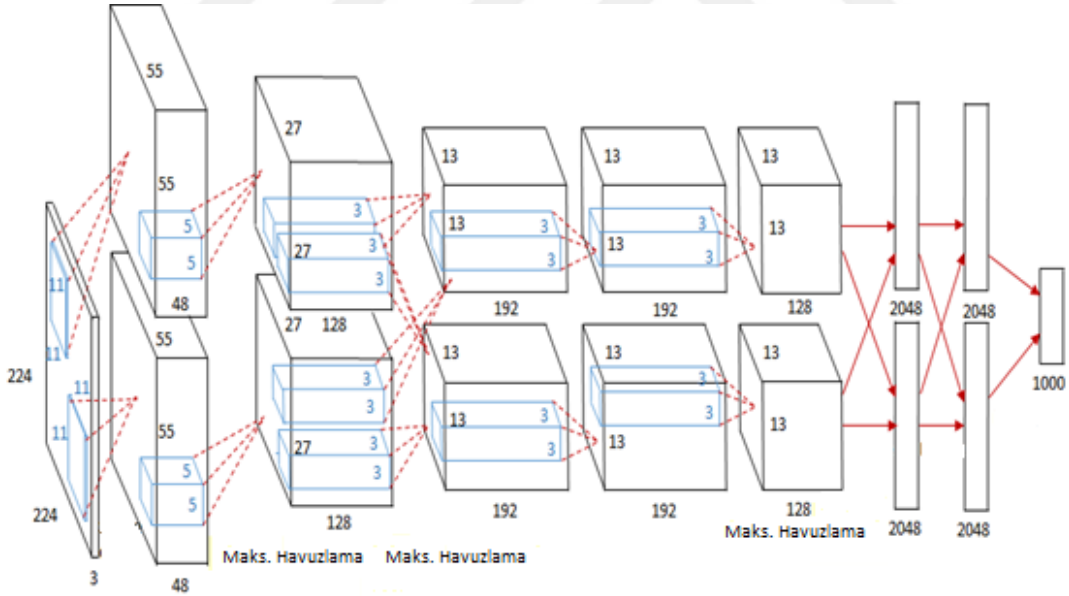
Şekil 2.24. LeNet mimari yapısı

2.3.2. AlexNet Mimarisi

AlexNet, evrişimli sinir ağı modellerinin ve derin öğrenmenin yeniden popüler hale gelmesini sağlayan bir mimaridir. Birbirini takip eden evrişimsel katmanları içermesi sebebiyle aslında LeNet modelini anımsatmaktadır.

ESA katmanlarında genel olarak ReLU aktivasyon fonksiyonu ve maksimum havuzlama katmanı tercih edilmektedir. Bu ağı modeli, paralel çift GPU (Grafik İşlem Birimi- Graphics Processing Unit) üzerinde çalışacak biçimde iki parçalı olarak tasarlanmıştır. Paralel GPU teknolojisini kullanan ilk çalışma olma özelliği de bu mimariye aittir.


Yaklaşık 60 milyon parametrenin hesaplandığı AlexNet mimarisi ile ImageNet ILSVRC yarışmasında sınıflandırma doğruluk oranı %74,3'ten %83,6'ya çıkarılmıştır [98]. Şekil 2.25 te AlexNet mimarisi gösterilmiştir.



Şekil 2.25. AlexNet mimari yapısı

2.3.3. VGG16 Mimarisi

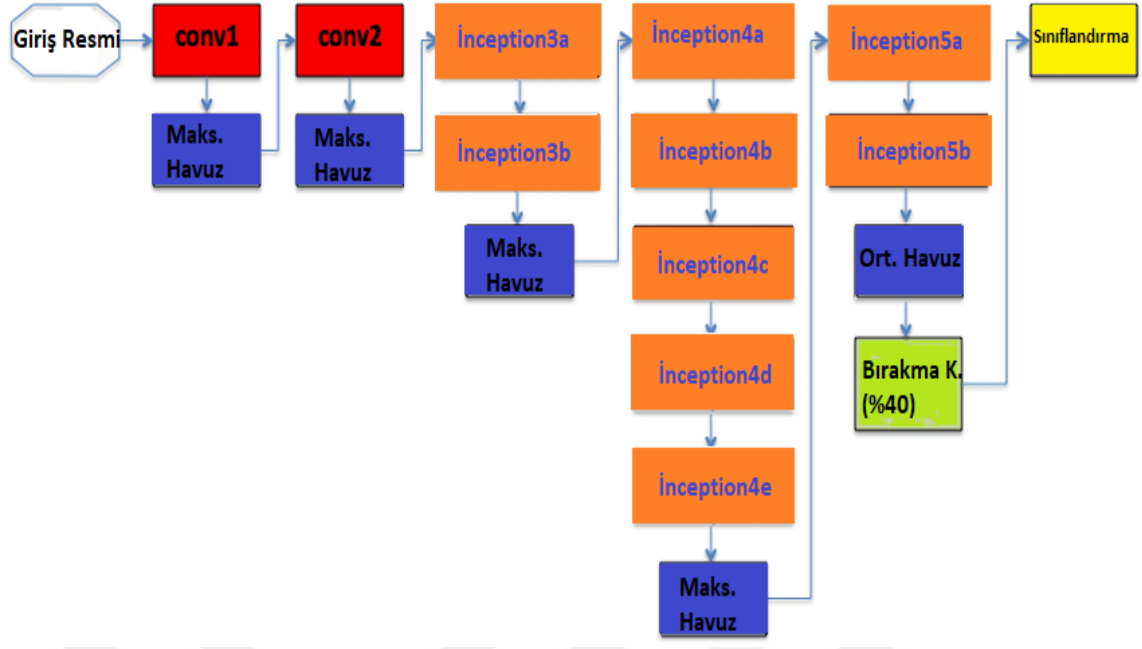
ImageNet 2014 yarışmasında %7,3 hata oranı ile iyi bir performans göstermiş ve bu sebeple popüler hale gelmiş bir derin öğrenme mimarisidir. Simonyan ve Zisserman tarafından Oxford üniversitesinde hazırlanan mimaride aslında 6 farklı mimari yapısı bir arada kullanılmıştır. Bu 6 farklı model 11, 13, 16, 19 konvolüsyon katmanı içermektedir [80]. Diğer mimarilerde bulunan konvolüsyonlardan farklı olarak burada 2x2 ve 3x3'lük filtreler tercih edilmiştir. VGG16 mimari yapısı art arda bağlı bulunan 3 tam bağlı katman içermektedir. Son tam bağlı katmanda 1000 nöron yer almakta olup çıkış için üretilecek sınıflandırma katmanında ise yumuşak bağlı (SoftMax) katmanı mevcuttur. Bu modelde diğer moodeller gibi girişten çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri (kanal sayısı) artmaktadır. Şekil 2.26' da VGG16 mimari yapısı gösterilmiştir.



Şekil 2.26. VGG16 mimarisi

2.3.4. GoogleNet Mimarisi

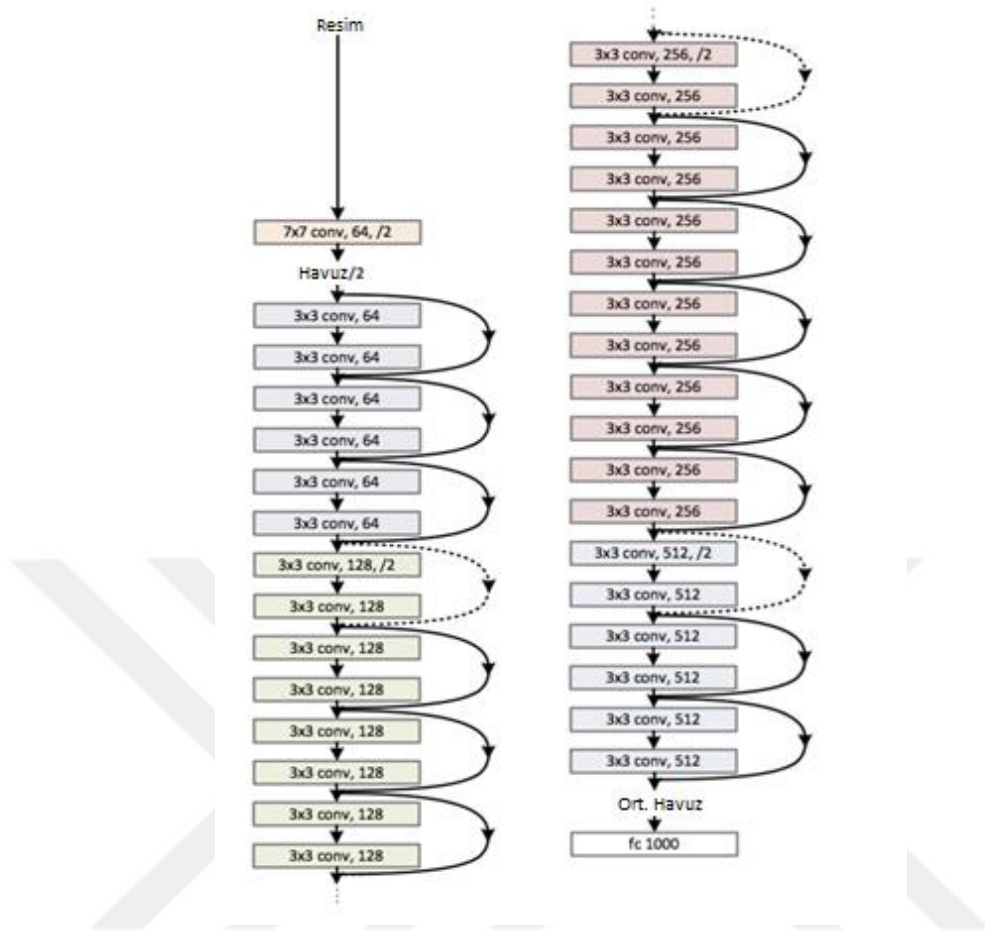
Google Net mimarisi, ESA mimarisindeki doğrusal filtrelerin doğrusal olmayan aktivasyon fonksiyonları ile öğrenme kabiliyetlerinin artırılabilceği teorisinden ortaya çıkmıştır. Aslında tasarlanan model, üç adet çok katmanlı algılayıcı yapısıyla ESA mimarisi ve ortalama havuzlama işlemlerinden ibarettir. Veri artırma (data augmentation) ve bırakma işlemleri uygulandıktan sonra ağ başarısının deneme yapılan veri kümeleri üzerinde arttığı görülmüştür. Inception modüllerindeki genişleme kavramı evrişim katmanlarındaki (1×1), (3×3), (5×5) filtrelerin ve (3×3) maksimum ortaklama işleminin paralel olarak gerçekleştirilmesiyle mümkün olmaktadır. Bu yapı “Naive Inception Module” olarak isimlendirilmektedir [98,99]. Inception ağ modelindeki modüller, farklı boyutlu evrişim ve maksimum ortaklama işlemlerinden oluşmuştur. Bütün evrişim ve maksimum ortaklama katmanlarını dikkate alarak hesaplama yapılmıştır. Hesaplamalar ilave olarak oldukça fazla bir işlem yükü getirmektedir. Szegedy ve ekibi her evrişim katmanından önce (1×1) evrişim katmanı kullanılarak işlem yükünü optimize etmeyi amaçlamıştır. Bu sayede karmaşık ağ modellerinin daha az hesap ve daha hızlı bir tasarım yapabilmesi hedeflenmiştir. Bu koşulda; (1×1) evrişim katmanında, $(28 \times 28 \times 16) \times (1 \times 1 \times 192) = 2,4$ milyon parametre ve (5×5) evrişim katmanında, $(28 \times 28 \times 32) \times (5 \times 5 \times 16) = 10$ milyon parametre olmak üzere toplamda 12,4 milyon parametre işlenmelidir. Başlangıç durumuna göre yaklaşık 10 kat daha az parametre hesabı son derece önemli bir etkiye sahip olmuştur. Bu (1×1) evrişim işlemini ‘darboğaz’ (bottleneck) olarak tanımlanmaktadır [98,99]. GoogleNet mimarisi ReLU aktivasyon fonksiyonu ile işlem görmektedir. Bütün ağ mimarisi, 9 inception modülünden oluşmakta ve toplamda 100’den fazla katman içermektedir. Böylece (7×7×1024) adet tensor (1×1×1024) boyutlu bir vektöre çevrilmiştir. Bu işlemler parametre maliyetinin azalması için büyük avantaj sağlanmaktadır. GoogLeNet 5 milyon parametre ile AlexNet’e göre 12 kat daha az işlem yüküne sahiptir [100,101]. Şekil 2.27’ de GoogleNet mimarisinin yapısı gösterilmiştir.



Şekil 2.27 GoogleNet mimarisi

2.3.5. ResNET Mimarisi


Microsoft Resnet mimarisi 2015 yılında gerçekleştirilen ILSVRC ImageNet yarışmasını kazanarak dikkatleri üzerine çekmeyi başarmıştır. Bu yarışmada %3,57 gibi bir hata oranı ile önemli bir başarı elde edilmiştir. Ortalama %5-%10 hata oranı ile görüntüler sınıflandırılırken %3,57'lik bir hata oranı insandan daha iyi görsel tanıma yaptığını kanıtlamıştır. Eski mimarilerden daha fazla bir derinliğe sahip olan bu mimarinin katman sayısı da yine aynı şekilde diğer derin öğrenme mimarilerindeki katman sayılarından fazladır [102]. Microsoft ResNet mimarisinde iki RELU ile doğrusal katman arasında bir kez kalıntı değeri (Residual Value) ile beslenen bir bloktan (Residual Block) oluşturulmuştur. Bu sayede öğrenme işleminin daha hızlı şekilde gerçekleşeceği ifade edilmiştir. Şekil 2.28' de bu kalıntı modülü görülmektedir.



Şekil 2.28. Microsoft ResNet mimarisi


2.3.6. R-CNN, Fast R-CNN ve Faster R-CNN Modelleri

Görüntü sınıflandırma işlemi büyük çoğunlukla görüntüdeki nesnenin tahmini üzerine icra edilmiştir. Nesnenin görüntünün hangi konumunda olduğu ve kapladığı sınırların tespiti ise nesne tanımlama işlemi ile mümkün olmaktadır [103]. Nesne tanımlama için kullanılan R-CNN mimarisi Şekil 2.29’ da verilmiştir.




Şekil 2.29 R-CNN mimarisi

R-CNN mimarisi temelde 4 bölümden oluşmaktadır. Birinci bölümde ise görüntüler alınırken ikinci bölümde bölge öneri işlemleri gerçekleştirilir. Üçüncü bölümde ise her bir bölge önerisi AlexNet benzer şekilde tasarlanmış ESA mimarisine sunulmuştur. Son olarak ESA çıktısı eğer bir nesne ise belirlenen bölge üzerinde bir düzenleme yapılarak kesin sonuç üretilir [104]. Bu durumların yanı sıra R-CNN'in bazı dezavantajları vardır. Öncelikle her bir görüntüdeki her bölge önerisi için ileri geçiş olmalıdır. Bu işlem test aşamasında zaman kaybına yol açmaktadır. İkinci olarak mimari ayrı ayrı üç farklı modeli eğitmek durumundadır. Bunlar görüntü özelliklerini oluşturmak için nesnenin sınıfını tahmin eden sınıflandırıcı ve sınırlayıcı çerçeveleri sıkıştırmak amacı içeren regresyon modelidir. Bu sorunları aşabilmek için Fast R-CNN modeli geliştirilmiştir. Bu mimaride öncelikle her bir görüntü için yaklaşık 2000 kez ESA' da çalıştırmak yerine tek bir kez ESA çalıştırıp 2000 öneri arasında bu hesaplamanın paylaşımının daha doğru olacağı düşünülmüştür. Bu işlemler sayesinde eğitim ve test süresi kısaltılmıştır. Şekil 2.30' da Fast R-CNN modeli için oluşturulan mimari gösterilmiştir [104].



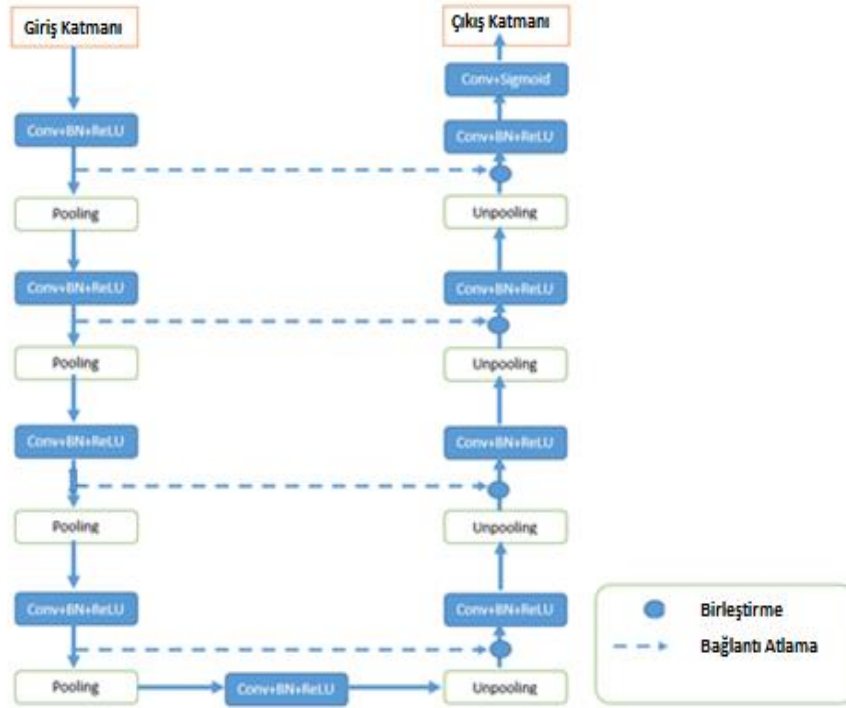
Şekil 2.30 Fast R-CNN mimarisi

Hem R-CNN hem de Fast R-CNN'nin sergilediği karmaşık eğitim hattını iyileştirmek için Faster R-CNN tasarlanmıştır. Bu işlem son konvolüsyon katmanından sonra bir bölge öneri ağı ekleyerek gerçekleştirmiştir. Şekil 2.31' de Faster R-CNN modeli için oluşturulan mimari gösterilmiştir [103].



Şekil 2.31. Faster R-CNN mimarisi

2.4. U-Net Mimarisi



Şekil 2.32. U-Net Mimarisi

Şekil 2.32, U-Net mimarisini göstermektedir. Burada “birleştirme” ifadesi katmanların birleştirilmesi ve “bağlantı atlama” ifadesi kodlayıcı fazından kod çözücü fazına veri özelliği aktarımı olarak ifade edilebilir. Mimari temel olarak iki yol içerir. Birincisi, kodlayıcı olarak da adlandırılan aşamadır. Görüntüdeki içeriği yakalayan kodlayıcı, geleneksel bir evrişim ve maksimum havuz katmanları yığıdır. İkincisi kod çözücü, simetrik genişleyen yoldur ve aktarılan evrişimleri kullanarak kesin lokalizasyonu sağlamak için kullanılır [105,106].

Önerilen U-Net modelinde, kodlayıcı fazında her biri iki 3×3 evrişimli katmandan oluşan dört blok kullanılmaktadır. Her bloğun çıkışı bir maksimum havuz katmanına bağlanır. Kodlayıcı fazına benzer şekilde kod çözücü fazı da yukarı örnekleme katmanları ile değiştirilen maksimum havuzlama katmanları dışında aynı blokları kullanır. Batch Normalization (BN) ve ReLU katmanları hem kodlayıcı hem de kod çözücü aşamalarına dahil edilir.

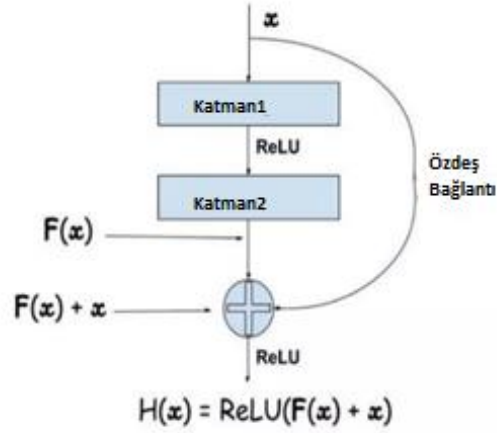
BN evrişimsel sinir ağına daha düzenli hale getirmek için kullanılan bir yöntemdir. Daha anlaşılır bir ifadeyle evrişimsel sinir ağını yeniden ölçeklendirerek giriş katmanını normalleştirir, böylece modeli daha hızlı ve daha kararlı hale getirmeye yardımcı olur. ReLU doğrusal olmayan bir fonksiyondur. ReLU fonksiyonu negatif girdiler için 0 değerini alırken, x pozitif girdiler için x değerini almaktadır.

Havuzlama (Pooling) katmanı kodlayıcı kısmında ağırlık parametrelerinin maksimum havuzlama yöntemi ile bir sonraki katmana iletilmesi, unpooling katmanı ise bu işlemin kod çözücü fazında gerçekleştirilmesi olarak ifade edilebilir [106]. İlk öznetelik haritalarının sayısı 32 olarak alınmış ve katman boyunca 64,128,256,512 olarak artacak şekilde model eğitimi gerçekleştirilmiştir. Çıkış katmanında en son olarak sigmoid fonksiyonu ile 0-1 arasında değer hesaplama işlemi gerçekleştirilmiştir. U-Net modeli ve katman yapıları Çizelge 2. 1'de gösterilmektedir.

Çizelge 2.1. U-Net model yapısı

Resim Boyutu	Operatorler
3*3*3*resim_kanalı*32	Giriş Resmi
3*3*3*32*32	Konv3d,BN, ReLU,maks. Havuz
3*3*3*64*64	Konv3d,BN, ReLU,maks. havuz,
3*3*3*128*128	Konv3d,BN, ReLU,maks. havuz,
3*3*3*256*256	Konv3d,BN, ReLU,maks. havuz,
3*3*3*512*512	Konv3d, BN, ReLU ,
3*3*3*256*256	Ters_konv3d, BN, ReLU ,kırp ve birleştir
3*3*3*128*128	Ters_konv3d, BN, ReLU ,kırp ve birleştir
3*3*3*64*64	Ters_konv3d, BN, ReLU ,kırp ve birleştir
3*3*3*32*32	Ters_konv3d, BN, ReLU ,kırp ve birleştir
1*1*1*32*n_sınıf	Konv 1*1*1,sigmoid (çıkış)

2.5. U-Net+ResNet Mimarisi

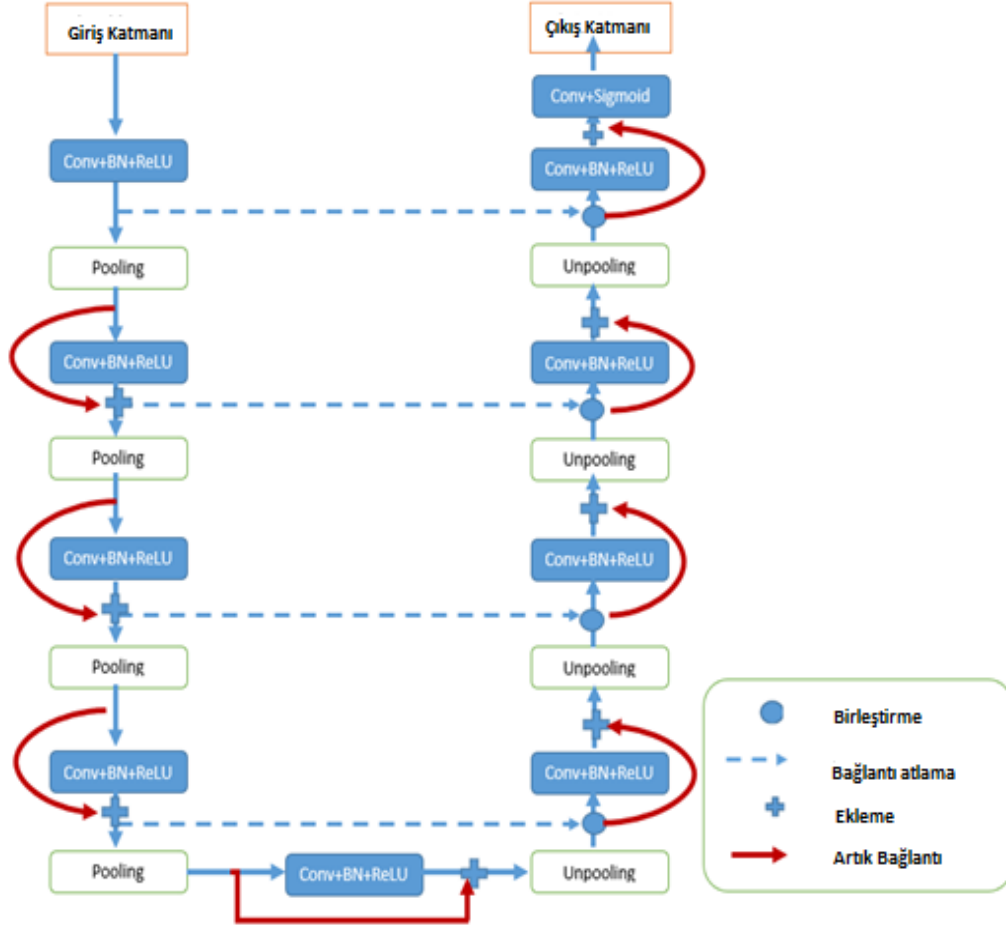


Şekil 2.33. ResNet Mimarisi

Şekil 2.33, ResNet mimarisinin yapısını göstermektedir. ResNet, önceki modellerinin aksine sonraki katmanlara artık değer blokların ekleme işlemi ile oluşturulmaktadır. [107]. ResNet, bu özelliği ile diğer klasik modellerden ayrılmaktadır. Lineer ve ReLU aktivasyon fonksiyonları ile katmanlar arasına iki katman halinde eklenen bu değer, sistem hesabını belirli bir düzeyde değiştirir. Normalde girişi çıkışa eşlemek için lineer olmayan bir $H(x)$ fonksiyonu kullanılabilir. Bununla birlikte ResNet mimarisinde $F(x)$ fonksiyonunun hesabı eşitlik 2.28 de verilmiştir.

$$F(x) = H(x) - x \quad (2.28)$$

$H(x)$ fonksiyonu, $F(x)$ değeri ile değiştirilerek kullanılmaktadır. Ayrıca girişten çıkışa kısayol bağlantısı yapılarak, x (giriş) değeri aritmetik olarak $F(x)$ fonksiyonuna eklenir. Daha sonra $F(x) + x$ değeri ReLU aktivasyonu uygulanarak bir sonraki bölüme aktarılır. Bu şekilde 2. katman sonuna girdi değeri eklenerek önceki katmanlardan gelen değerlerin sonraki bölümlere daha güçlü bir şekilde aktarılması amaçlanmaktadır. Deneyler sonucunda oluşturulan mimari yaklaşımlarında aynı işlevin başarıldığını, ancak ağır eğitim aşamasında kolaylık yönünden farklılıklar olduğu görülmüştür [107,108].



Şekil 2.34. U-Net+ResNet mimarisi

U-Net + ResNet mimarisi Şekil 2.34 'de gösterilmektedir. Bu mimaride temel bir U-Net ağ dizisinden farklı olarak, kodlayıcı aşamasında artık bloklar barındırılmıştır. En yüksek çözünürlükte sadece bir artık blokla başlanmış ve her aşağı örnekleme işleminden sonra artık blok sayısını artırılmıştır. Burada “ekleme” işlemi ile ResNet işlemi uygulanan katmanlar sembolize edilmiş olmaktadır.


Dekoder fazı, çözünürlük başına bir Conv + BN + ReLU içermektedir. U-Net modelinde ilk özellik haritalarının sayısını 32 olarak alınmıştır. Unet + ResNet modeli ve katman yapıları Çizelge 2.2’ de gösterilmektedir. Modelde görüldüğü gibi Unet modelinden farklı olarak katmanlar ResNet modeli ile bir sonraki katmana aktarılmıştır [107].

Çizelge 2.2. U-Net+ResNet model yapısı

Resim Boyutu	Operatörler
3*3*3*resim_kanalı*32	Giriş Katmanı
3*3*3*32*32	Konv3d,BN,ReLU,maks. havuz,ResNet
3*3*3*64*64	Konv3d,BN,ReLU maks. havuz,ResNet
3*3*3*128*128	Konv3d,BN,ReLU, maks. havuz,ResNet
3*3*3*256*256	Konv3d,BN,ReLU maks. havuz,ResNet
3*3*3*512*512	Konv3d, BN, ReLU ,ResNet
3*3*3*256*256	Ters_konv3d, BN, ReLU ,kırp ve birleştir, ResNet
3*3*3*128*128	Ters_konv3d, BN, ReLU , kırp ve birleştir, ResNet
3*3*3*64*64	Ters_konv3d, BN, ReLU , kırp ve birleştir, ResNet
3*3*3*32*32	Ters_konv3d, BN, ReLU , kırp ve birleştir, ResNet
1*1*1*32*n_class	Konv 1*1*1,sigmoid (çıkış)

2.6. U-Net++ Mimarisi

UNet ++ mimarisi Şekil 2.35' de gösterilmektedir.



Şekil 2.35. U-Net++ Mimarisi

U-Net ++, daha doğru görüntü bölümlenme için yeni bir genel amaçlı görüntü bölümlenme mimarisidir. U-Net ++, bir dizi iç içe geçmiş yoğun evrişimli blok aracılığıyla bağlanan kodlayıcı ve kod çözücünden oluşturulmaktadır. [107-110].

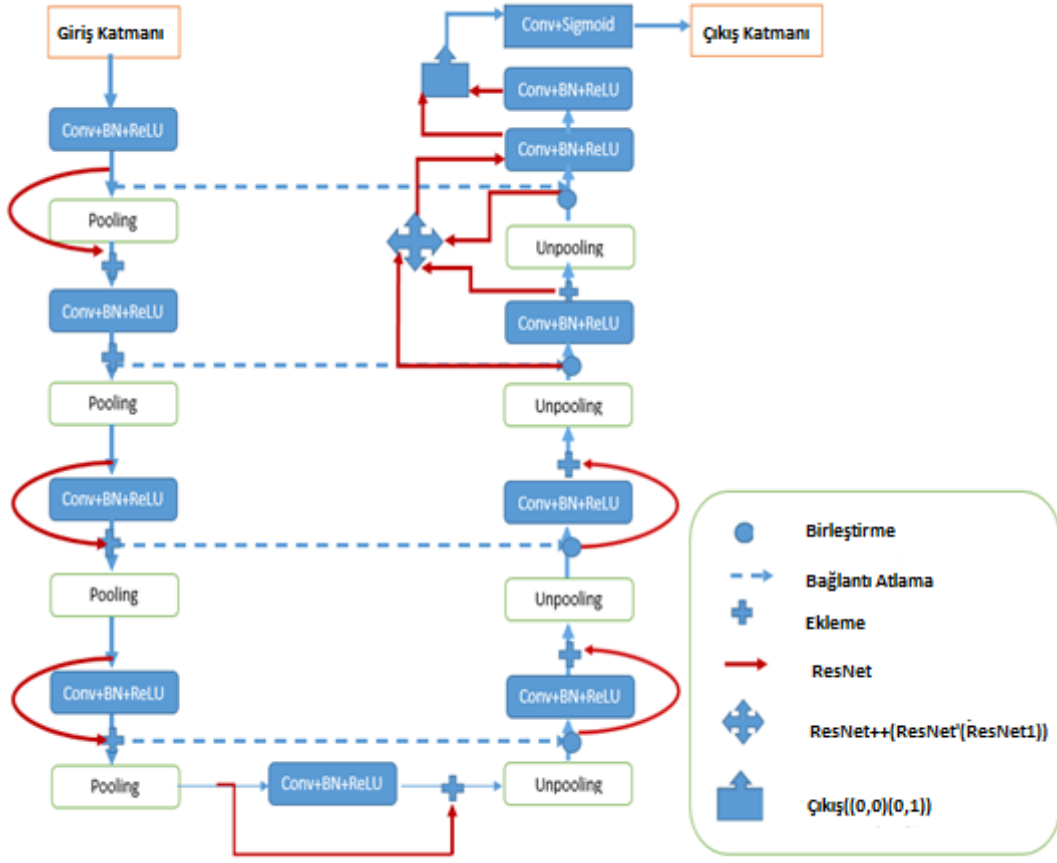
U-Net ++, kodlayıcı ve kod çözücü arasına yoğun blok ve evrişim katmanları ekleyerek bölümlenme doğruluğunu iyileştirmeyi amaçlamaktadır. Kodlayıcı aşamasında, birbiri ile iç içe geçmiş toplam dört blok kullanılır. Her blokta ilk katman, sonunda bir sonraki katmana bağlanan 3x3 evrişim katmanıdır.

Dekoder aşaması, birbirine bağlı blokların Conv + BN + ReLU işlemlerinin bir sonucu olarak ortaya çıkarmaktadır. Toplu normalleştirme ve bırakma katmanları hem kodlayıcı hem de kod çözücü fazına dahil edilir. Ağın performansını ve katman yoğunluğu dikkate alınarak ilk özellik haritalarının sayısını 16 olarak belirlenmiştir. Çizelge 2.3' de U-Net ++ model yapısı görülmektedir. Diğer U-Net modellerinden farklı olarak evrişim katmanlarının iç içe blok katmanları (Nested block) ile oluşturulmuş olduğu görülmektedir.

Çizelge 2.3. U-Net++ model yapısı

Resim Boyutu	Operatorler
3*3*3*resim_kanalı*16	Giriş Katmanı
3*3*3*16*16	Konv3d, aşağı örnekleme
3*3*3*32*32	Konv3d, aşağı örnekleme, Nested blok
3*3*3*64*64	Konv3d, aşağı örnekleme, Nested blok
3*3*3*128*128	Konv3d, aşağı örnekleme, Nested blok
3*3*3*256*256	Konv3d, aşağı örnekleme, Nested blok
3*3*3*128*128	Ters_konv3d, kırp ve birleştir, yukarı örnekleme Nested blok
3*3*3*64*64	Ters_konv3d, kırp ve birleştir, yukarı örnekleme Nested blok
3*3*3*32*32	Ters_konv3d, kırp ve birleştir, yukarı örnekleme Nested blok
3*3*3*16*16	Ters_konv3d, kırp ve birleştir, yukarı örnekleme Nested blok
1*1*1*16	Konv 1*1 sigmoid (Çıkış)

2.7. Geliştirilmiş U-Net Model Mimarisi



Şekil 2.36. Geliştirilmiş U-Net Model Mimarisi

Geliştirilmiş U-Net3D mimarisi Şekil 2.36’ da gösterilmektedir. Bu mimari, basit bir evrişim dizisinin aksine kodlayıcıda artık bloklar kullanılmaktadır. En yüksek çözünürlükte tek bir artık bağlantıyla başlamış ve her aşağı örnekleme işleminden sonra artık bağlantı sayısı artırılmıştır.

Kod çözücü, çözünürlük başına yalnızca bir Conv + BN + ReLU kullanılmaktadır. Normal ResNet blok yapısından farklı olarak U-Net modelinde ilk öznetelik haritalarının sayısı 32 olarak alınmış, ResNet ++ 'da ise yapı kendisine gelen son iki Convolution bloğunu eklemektedir. U-Net mimarisinin aksine OutConv adında yeni bir katman eklenmiştir.

Outconv katmanı, çıkış katmanına kendisinden önceki katman eklenerek elde edilmiştir (U-Net ++ 'da olduğu gibi). ResNet ++ yapısı Eşitlik 2.29' da ve OutKonv katmanı Eşitlik 2.30 'de gösterilmektedir. Konv (y) çıktı katmanı olarak dikkate alındığında, konv (y-1) bir önceki katman ve konv (y-2) dönüşümden iki önceki katman olarak ifade edilmektedir. [107].

$$\text{ResNet}++ = (\text{ResNet}(\text{ResNet}(\text{Ters_konv}(y-3), (\text{konv}(y-2))), \text{konv}(y-1))) \quad (2.29)$$

$$\text{OutKonv} = (\text{Nestedblok}(\text{konv}(y-2)), (\text{konv}(y-1))) \quad (2.30)$$

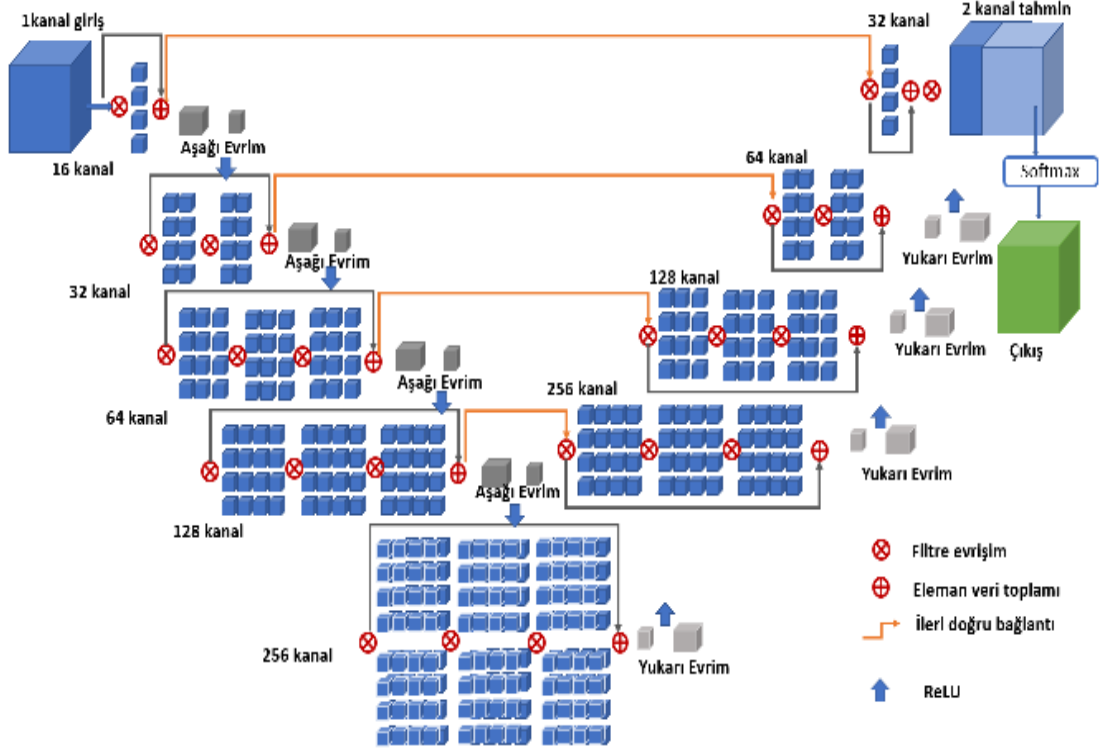
Eşitlik 2.29' dan görülebileceği gibi önce içerideki ResNet ağı çalışmaktadır ve buradan gelen parametreler dışarıdan ResNet mimarisine aktarılmaktadır. Bu sayede bir sonraki katmana iletilerek segmentasyon için en küçük detayların hesaplanması hedeflenir.

Eşitlik 2.30' da çıktı katmanından önce ek bir katman eklenilmiştir. Bu katman, U-Net ++ yapısında olduğu gibi önceki katmanla İç içe blok oluşturmak için tasarlanmıştır. Ve çıktı katmanında derinlik oluşumu hesaplanmıştır. Geliştirilmiş U-Net3D modeli ve katman yapıları Çizelge 2.4 'de gösterilmektedir.

Çizelge 2.4. Geliştirilmiş U-Net model yapısı

Resim Boyutu	Operatörler
3*3*3*resim_kanalı*32	Giriş Katmanı
3*3*3*32*32	Konv3d, BN,ReLU,maks. havuz,ResNet
3*3*3*64*64	Konv3d, BN,ReLU, maks. havuz,ResNet
3*3*3*128*128	Konv3d, BN,ReLU, maks. havuz,ResNet
3*3*3*256*256	Konv3d, BN,ReLU, maks. havuz,ResNet
3*3*3*512*512	Konv3d, BN, ReLU ,ResNet
3*3*3*256*256	Ters_Konv3d, BN, ReLU ,kırp ve birleştir, ResNet
3*3*3*128*128	Ters_Konv3d, BN, ReLU , kırp ve birleştir, ResNet
3*3*3*64*64	Ters_Konv3d, BN, ReLU , kırp ve birleştir, ResNet
3*3*3*32*32	Ters_Konv3d,BN, ReLU, kırp vebirleştir, ResNet++
3*3*3*32*32	Ters_Konv3d, kırp ve birleştir, Nested blok
1*1*1*32*n_class	Konv 1*1*1, sigmoid (Çıkış)

2.8. V-Net mimarisi



Şekil 2.37. Klasik bir yapıdan oluşan V-Net mimarisinin şematik gösterimi

Şekil 2.37, klasik V-Net mimarisinin ağ yapısını göstermektedir. Ağ mimarisi, temel U-Net mimarisinde olduğu gibi kodlama ve kod çözme bölümlerinden oluşmaktadır. BT görüntülemelerde organları ve tümörleri (prostat veya böbrek gibi) tanımlamanın zor olduğu dokularda, kullanım için uygun olan volumetrik tasarım haricinde, U-Net mimarisinin bir türevidir [111,112]. Her aşamanın girdisi, evrişimli katmanlarda kullanılır ve doğrusal olmayan unsurlar aracılığıyla işlenir. Daha sonra bir artık işlevi öğrenmeyi sağlayabilmek için o aşamadaki son evrişimli katman çıktısına eklenmektedir.

V-Net mimarisi, özellikleri çıkarmak ve doğru yolu izleyerek çözünürlüğü azaltmak için evrişimli bir yapıya sahiptir. Evrişimsel katmanlarda her bir aşama sürecinde kullanımı gerçekleştirilen volumetrik tanelerinin büyüklüğü, genelde 5*5*5 şeklindeki vokselardan oluşur. (Bir voksel, 3B uzayda normal bir ızgaradaki bir değeri temsil etmektedir). Klasik havuzlama yöntemleri bazen bölümlenme işlemi sırasında önemli ayrıntıları göz

ardı etmektedir. Bu nedenle V-Net evrişimleri alt örnekleme yoluyla bundan kaçınmak için kullanılır. Böylece girdi olarak iletilen verilerin boyutu azaltılır ve veriler bir sonraki bölümde hesaplanan alıcı özelliklere iletilir [112,113].

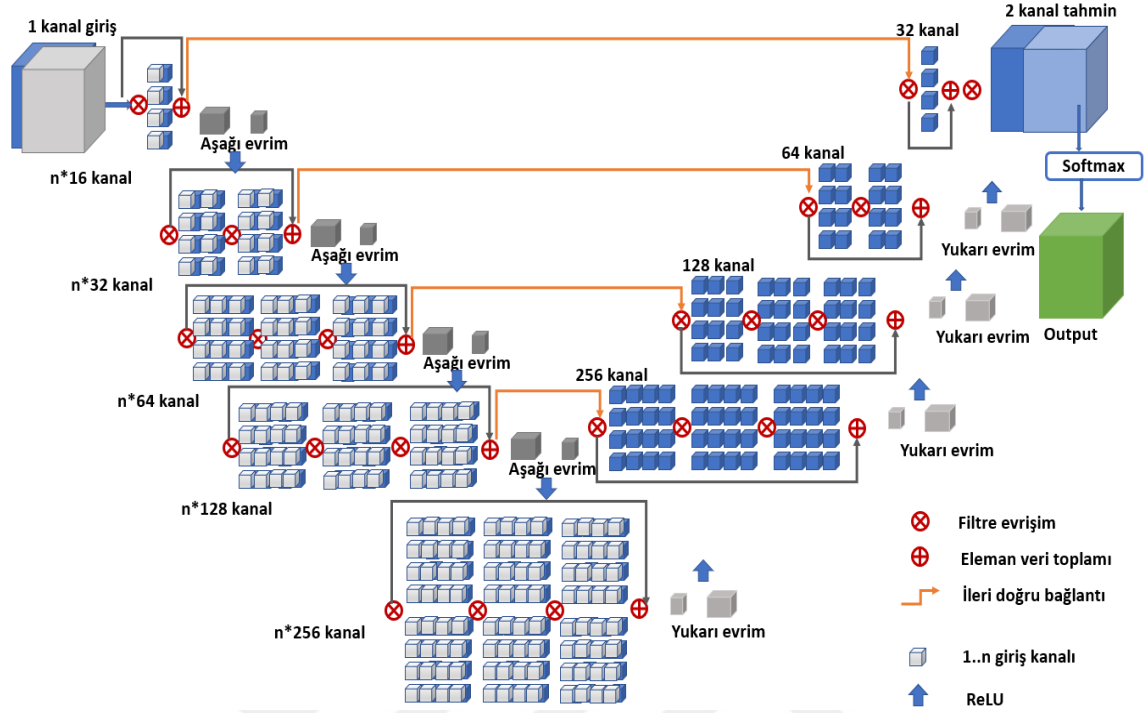
V-Net mimarisinin kodlayıcı tarafındaki her katman, bir önceki katmandan iki kat daha yüksek, özellik seti hesaplama bölümlerinden oluşur. Ağın dekoder bölümü, iki kanallı hacimsel bölümlere sağlamayı amaçlamaktadır. Bu nedenle gerekli bilgileri elde etmek için özellik haritaları sağlanır. Ağ mimarisinin kodlayıcı bölümündeki her katmandan sonra kod çözücü bölümündeki boyutları azaltmak için ters yönde gerçekleştirilen aynı işlemler ile girişlerin boyutunu artırmak için bir saptırma işlemi gerçekleştirilmektedir.

Kodlayıcı fazının her aşamasından çıkarılan sinir ağının özellikleri, kod çözücü fazına aktarılmaktadır. Kodlayıcı bölümünde kaybolacak küçük ayrıntılar toplanabilir ve böylece tahmini bölümlene kalitesi artırılabilir. Yatay bağlantılarla Şekil 2.36 da şematik olarak gösterilmiştir [114]. Çizelge 2.5’ de V-Net model yapısı gösterilmiştir.

Çizelge 2.5. V-Net model yapısı


Katman	Giriş Boyutu(x)	İşleçler	Katman	Giriş Boyutu(x)	İşleçler
S,Aşama1	3*3*3*kanal*16 (giriş)	Konv, ReLU, ResNet	S,Aşama1	3*3*3*256*128	Yukarı evrim, ReLU, ResNet
S,Aşama2	3*3*3*16*16	Aşağı evrim ReLU, ResNet	S,Aşama2	3*3*3*128*64	Yukarı evrim, ReLU, ResNet
S,Aşama3	3*3*3*32*32	Aşağı evrim, ReLU, ResNet	S,Aşama3	3*3*3*64*32	Yukarı evrim, ReLU, ResNet
S,Aşama4	3*3*3*64*64	Aşağı evrim, ReLU, ResNet	S,Aşama4	3*3*3*32*16	Yukarı evrim, ReLU, ResNet
S,Aşama5	3*3*3*128*128	Aşağı evrim, ReLU, ResNet	S,Aşama5	3*3*3*16*16	Yukarı evrim, ReLU, ResNet
S,Aşama6	3*3*3*256*256	Aşağı evrim, ReLU, ResNet	S,Aşama6	1*1*1*16*16	konv sigmoid (çıkış)

2.9. Füzyon V-Net Mimarisi



Şekil 2.38. Füzyon V-Net mimarisinin şematik gösterimi

Şekil 2.38, Fusion V-Net mimarisinin ağ yapısını göstermektedir. Kodlayıcı aşaması iki füzyon bloğundan oluşurken, kod çözücü aşaması klasik V-Net bloğundan oluşur. Amaç, daha az modalite kullanarak aynı sahnenin daha fazla özelliğini tespit etmektir. Mimari yapı için temel bilgilerin kodlanması, büyük miktarda verinin olmadığı bir öğrenme düzeyi sağlamakta bu nedenle küçük ölçekli bir veri setinin kullanılması performans açısından da başarılı sonuçlar sağlamaktadır. [115]. Bu fikre dayanarak fusion V-Net modelinde kodlayıcı kısmında ağa birden çok parametre girmektedir. Girdi parametrelerinin çoğaltılmasında herhangi bir sınır yoktur. Ancak gereksiz yere parametre sayısının artırılması ağ mimarisini bozabilir ve yorabilir. Girdi parametreleri belirli bir formatta artırılmalı ve gereksiz tekrarlardan kaçınılmalıdır. Şekil 2.39, basit bir geç füzyon mimarisi yapısını göstermektedir. Çizelge 2.6 da Fusion V-Net model yapısı gösterilmiştir.

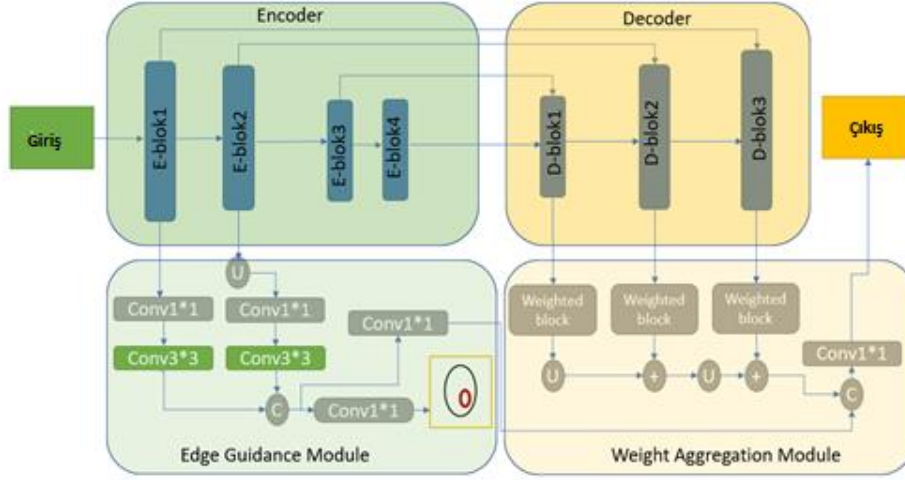


Şekil 2.39. Geç füzyon mimarisi

Çizelge 2.6. Fusion V-Net model yapısı

Katman	Giriş Resmi(x1,x2)	İşleçler	Katman	Giriş Resmi	İşleçler
S.Aşama1	3*3*3*kanal*16 (giriş)	Konv, ReLU, ResNet	S.Aşama1	3*3*3*256*128	Yukarı Evrim, ReLU, ResNet
S.Aşama2	3*3*3*(16*2)*16	Aşağı evrim ReLU, ResNet	S.Aşama2	3*3*3*128*64	Yukarı Evrim, ReLU, ResNet
S.Aşama3	3*3*3*(32*2)*32	Aşağı evrim, ReLU, ResNet	S.Aşama3	3*3*3*64*32	Yukarı Evrim, ReLU, ResNet
S-Aşama4	3*3*3*(64*2)*64	Aşağı evrim, ReLU, ResNet	S.Aşama4	3*3*3*32*16	Yukarı Evrim, ReLU, ResNet
S-Aşama5	3*3*3*(128*2)*128	Aşağı evrim, ReLU, ResNet	S.Aşama5	3*3*3*16*16	Yukarı Evrim, ReLU, ResNet
S-Aşama6	3*3*3*(256*2)*256	Aşağı evrim, ReLU, ResNet	S.Aşama6	1*1*1*16*16	Konv sigmoid (Çıkış)

2.10. ET V-Net Mimarisi



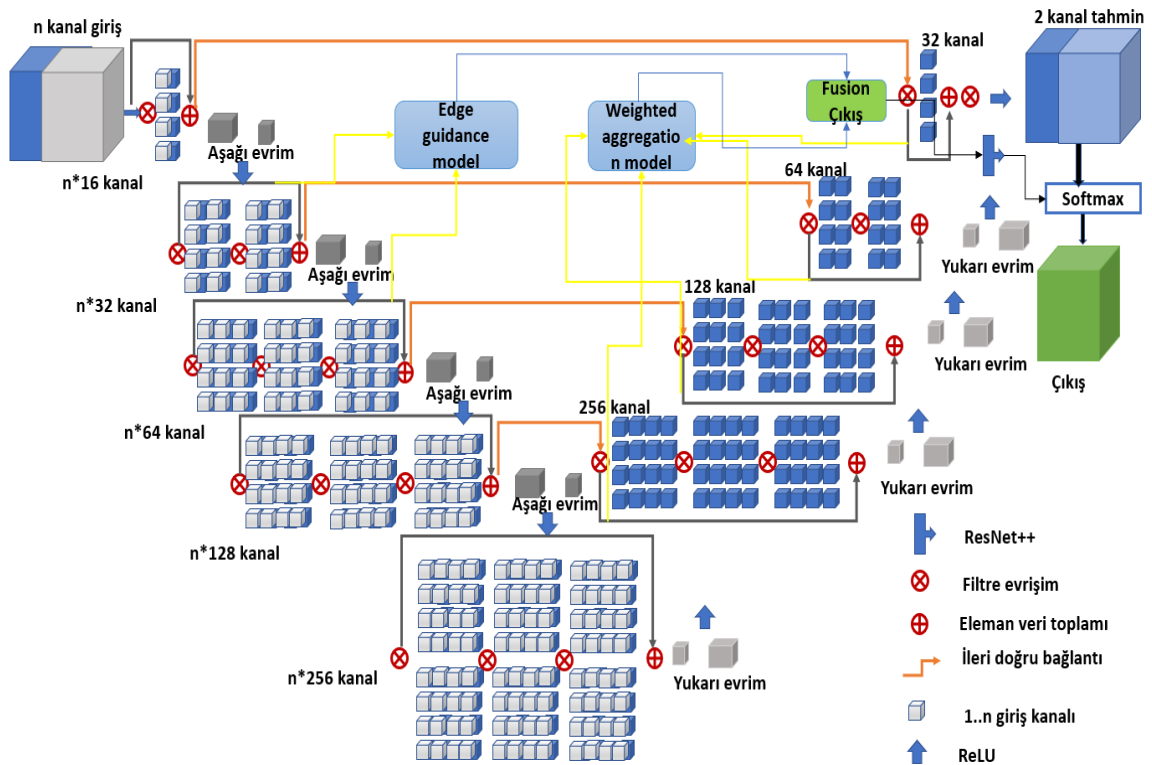
Şekil 2.40. ET V-Net mimarisi

Şekil 2.40'ta gösterilen mimaride, kenar göstergelerini belirlemek ve yerel kenar özelliklerini korumak için bir kenar kılavuz modülü (Edge Guidance Module-EGM) kullanılmaktadır. Kod çözme katmanlarından yan çıktıları toplamak için ağırlıklı bir toplama modülü (Weight Aggregation Module-WAM) kullanılmaktadır. ET V-Net mimarisi, iki farklı ağ yapısının birleştirilmesiyle oluşturulmuştur [116]. "Conv" evrişimli katmanı sembolize ederken, "U", "C" ve "+" sırasıyla yukarı örnekleme, birleştirme ve toplama anlamına gelir. Mimarinin temel amacı, kod çözücü aşamasından gelen çıktıyı iyileştirmek için üst katmanlara kenar dikkat izlenimlerini iletmeektir. Her kodlayıcı bloğu için ilk girişler, $1 \times 1, 3 \times 3, 1 \times 1$ evrişimli katman yığınyından oluşan özellik çıkarma bölümünden geçer ve daha sonra, istenen çıktıları elde etmek için girişlerin kısa yollarını toplayarak sistem çalıştırılır. Kalan bağlantı mimarinin sınıfa özgü özellikler üretmesine izin verir [117,118]. Kod çözme bloğu, düşük ve yüksek seviyeli özellikleri artırmak için derinlemesine bir evrişim kullanır. Ardından, 1×1 evrişim katmanı, kanal sayısını birleştirmek için işlenir. Çizelge 2.7 de ET V-Net model yapısı gösterilmiştir.

Çizelge 2.7. ET V-Net Model yapısı

Katman	Giriş boyutu(x1,x2)	İşleçler	Katman	Giriş Boyutu	İşleçler
S.Aşama1	3*3*3*kanal*16 (giriş)	Konv, ReLU, ResNet	S.Aşama1	3*3*3*256*128	Yukarı evrim, ReLU, ResNet
S.Aşama2	3*3*3*16*16	Aşağı evrim, ReLU, ResNet	S.Aşama2	3*3*3*128*64	Yukarı evrim, ReLU, ResNet
S.Aşama3	3*3*3*32*32	Aşağı evrim, ReLU, ResNet	S.Aşama3	3*3*3*64*32	Yukarı evrim, ReLU, ResNet
S.Aşama4	3*3*3*64*64	Aşağı evrim, ReLU, ResNet	S.Aşama4	3*3*3*32*16	Yukarı evrim, ReLU, ResNet
S.Aşama5	3*3*3*128*128	Aşağı evrim, ReLU, ResNet	S.Aşama5	3*3*3*16*16	Yukarı evrim, ReLU, ResNet++
S.Aşama6	3*3*3*256*256	Aşağı evrim, ReLU, ResNet	S.Aşama6	1*1*1*16*16	EGM, WAM, konv sigmoid (çıkış)

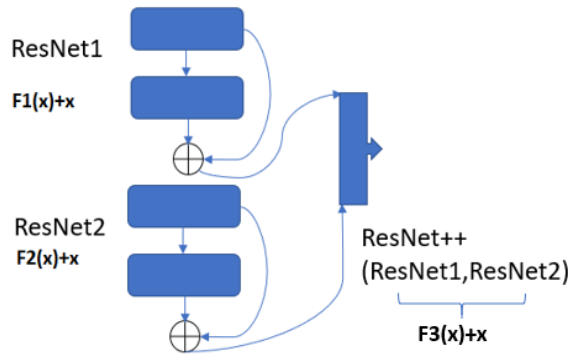
2.11. Hibrit V-Net Mimarisi



Şekil 2.41 Hibrit V-Net mimarisinin şematik gösterimi

Kodlayıcı aşaması iki füzyon bloğundan oluşurken, dekoder aşaması ETV-Net mimarisi ve çıktı katmanı ResNet ++ bloklarından oluşmaktadır. Şekil 2.41, klasik V-Net mimarisinde olduğu gibi kodlayıcı ve kod çözücü bloklarından oluşan, önerilen hibrit V-Net mimarisini göstermektedir. Kodlayıcı ve kod çözücü aşamalarında iki farklı V-Net modelini birleştiren hibrit mimari, daha önce benzersiz bir ResNet katmanı ile çıkış aşamasında desteklenmektedir.

Kodlayıcı bloğu, füzyon V-Net modeline göre oluşturulmuş ve giriş parametreleri input1 ve input2 olarak ayarlanmıştır. Kod çözücü bloğu, ET V-Net mimarisine dayalı olarak tasarlanmıştır. Kodlayıcı bloğunda segmentasyon sırasında tüm özellikleri yakalamak için giriş parametrelerinin, füzyon V-Net modelinden geçmesi amaçlanmıştır. ET V-Net sayesinde segmentasyon için en küçük kenar özelliklerini bile yakalanması hedeflenmiştir. Dekoder aşamasında mimarisi Şekil 2.42 'de gösterilen ve ResNet ++ bloğuna iletilen, ET V-Net modelinin kenar çıkarma özellikleri kullanılarak katmanlar birleştirilmiştir.



Şekil 2.42. ResNet++ mimarisi

Şekil 2.4 için gösterilen blok, iç içe geçmiş iki ResNet bloğu olarak düşünülebilir. Normal bir ResNet modelinden farklı olarak çıktı katmanını önceki iki katmanla birleştirir. Böylece, çıktıdan önceki küçük artık bloklar da yakalanabilir. Bu katmanın

tüm bloklara eklenmesi ağı çok yavaşlattığından dolayı bu nedenle doğru katmana eklemek son derece önemlidir.

ResNet1 ve ResNet2 yapıları Eşitlik 2.31 ve Eşitlik 2.32'de gösterilmektedir. Bu iki blok klasik ResNet mimarisini temsil etmektedir [119].

$$\text{ResNet1} = F1(x) + x \quad (2.31)$$

$$\text{ResNet2} = F2(x) + x \quad (2.32)$$

Eşitlik 2.31 ve Eşitlik 2.32'yi çıktı katmanı layer_n şeklinde gösterilmiştir. Önceki katman, katman (n-1) olarak temsil edilmiştir. Bu durum Eşitlik 2.33 ve 2.34' de gösterilmiştir.

$$\text{ResNet1} = (\text{layer}_{(n-2)} + \text{layer}_{(n-1)}) \quad (2.33)$$

$$\text{ResNet2} = (\text{layer}_{(n-1)} + \text{layer}_{(n)}) \quad (2.34)$$

Eşitlik 2.35 'de, ResNet ++ mimarisinin iki ResNet bloğunun birleştirildiği gösterilmiştir. ResNet1 mimarisi önce çalışmıştır, ardından ResNet2 mimarisi gelmiştir.

$$\text{ResNet}++ = (\text{ResNet1}) + (\text{ResNet2}) \quad (2.35)$$

Eşitlik 2.36, ResNet1 ve ResNet2 bloklarının dâhili yapısını göstermektedir.

$$\text{ResNet}++ = ((\text{layer}_{(n-2)} + \text{layer}_{(n-1)}) + (\text{layer}_{(n-1)} + \text{layer}_{(n)})) \quad (2.36)$$

Eşitlik 2.37, de $F3(x)$ işlevi en son çalıştırılmaktadır. Burada mimari tek bir blok yapısına dönüşür ve son iki katman ResNet ++ adı verilen iç içe bir mimari oluşturur.

$$\text{ResNet}++ = F3(x) + x \quad (2.37)$$

ResNet ++ bloğu, yalnızca kod çözme aşamasının son aşamasında uygulanırken, ResNet bloğu tüm aşamalarda uygulanmaktadır.


Çizelge 2.8’de ilk olarak 6 aşamadan oluşan katman yapısı gösterilmiştir. Devamında bu katmanlarda giriş olarak verilen resimlerin boyutları gösterilmiştir. Resim boyutlarından da anlaşılacağı gibi kullanılan mevcut mimarilerin özelliklerini destekleyecek biçimde ölçeklendirme yapılmıştır. Devamında kod çözücü ve çıkış aşamasında aynı şekilde resim boyutları ve kullanılan operatörler, modele dahil edilen V-Net mimarilerinin fonksiyonlarını icra edecek şekilde tasarlanmıştır.

Çizelge 2.8. Hybrid V-Net model yapısı

Katman	Giriş Boyutu(x1,x2)	İşleçler	Katman	Giriş Boyutu	İşleçler
S.Aşama1	3*3*3*kanal*16 (giriş)	Konv, ReLU, ResNet	S.Aşama1	3*3*3*256*128	Yukarı evrim, ReLU, ResNet
S.Aşama2	3*3*3*(16*2)*16	Aşağı evrim, ReLU, ResNet	S.Aşama2	3*3*3*128*64	Yukarı evrim, ReLU, ResNet
S.Aşama3	3*3*3*(32*2)*32	Aşağı evrim, ReLU, ResNet	S.Aşama3	3*3*3*64*32	Yukarı evrim, ReLU, ResNet
S.Aşama4	3*3*3*(64*2)*64	Aşağı evrim, ReLU, ResNet	S.Aşama4	3*3*3*32*16	Yukarı evrim, ReLU, ResNet
S.Aşama5	3*3*3*(128*2)*128	Aşağı evrim, ReLU, ResNet	S.Aşama5	3*3*3*16*16	Yukarı evrim, ReLU, ResNet++
S.Aşama6	3*3*3*(256*2)*256	Aşağı evrim, ReLU, ResNet	S.Aşama6	1*1*1*16*16	EGM, WAM, konv sigmoid (çıkış)

2.12. Zar Benzerlik Katsayısı

Zar benzerlik katsayısı (Dice Smilarity Coefficient-DSC), iki segmentasyon arasındaki uzamsal benzerliği veya örtüşmeyi ölçmektedir [120]. Tıbbi görüntülerde temel gerçeği ve segmentasyon performansını değerlendirmek için yaygın olarak bir ölçü olarak kullanılmaktadır. [121]. Şekil 2.43, DSC alan grafiğini göstermektedir.



Şekil 2.43. Zar benzerlik katsayısı

DSC hesaplaması Eşitlik 2.38'de gösterilmektedir.

$$DSC = \frac{2|S \cap R|}{|S| + |R|} \quad (2.38)$$

Burada S, segmentasyonun sonucunu temsil eder ve R, karşılık gelen kesin referans etmektedir. DSC, görüntü bölümlenme için tasarlanmıştır ve aynı görüntünün ikili bölümlenmesini karşılaştırmak amacıyla kabul edilen bir yöntemdir. Genel olarak segmentasyon doğruluğu ile otomatik veya yarı otomatik segmentasyon yöntemlerinin sonuçları arasında bir karşılaştırma yapılır [122].

2.13. Görüntü Önışleme

Segmentasyon işlemi için halkın erişimine açık olan ve kanser görüntüleme arşiv sayfasından indirilebilen, 210 BT görüntüsünden oluşan, KiTS19 veri seti kullanıma hazırlanmıştır [123]. Veri setinin yanı sıra etik komitelerin hazırlanmasına ilişkin ek açıklamalar KiTS19 veri setinin ana web sayfasında mevcuttur [124]. Veri seti ile ilgili başlıca özellikler aşağıda verilmiştir.


- Görüntünün yanı sıra kesin referans etiketleri, şekil (sayısal dilim, yükseklik, genişlik) ile anonimleştirilmiş bir NIFTI formatında sağlanmıştır. Burada, num_slices bir aksenal görünüme karşılık gelir ve dilim indeksi arttıkça üstten aşağıya ilerlemektedir. Her durumda hasta görüntü toplama sırasında sırtüstü yatmış ve bu nedenle yükseklik-genişlik boyutları hastanın sol ön tarafına gelecek şekilde hizalanmıştır. Dilim kalınlıkları 1 mm ile 5 mm arasında değişmektedir. Belirli bir durum için birden fazla niteleyici seri olduğunda, daha küçük dilim kalınlığına sahip olan seçilmiştir.
- Zemin Gerçeği Etiketleri: Manuel segmentasyon etiketleri, Dr. Christopher Weight gözetiminde tıp öğrencileri tarafından sağlanmıştır. Böbrek veya tümör dokusunu içeren ilk ve son dilimler kaydedilmiştir. Bunlara sırasıyla ön ve sonrası denilmektedir. Her böbrek için bir renal hilum (organa damar veya sinir girdiği bölge) içeren ilk ve son dilimler kaydedilmiştir. Bunları sırasıyla sol hilum başlangıcı, sol hilum sonu, sağ hilum başlangıcı ve sağ hilum sonu için lhb, lhe, rhb ve rhe olarak adlandırılmıştır. Ek açıklama için eşit aralıklı dilimler seçilmiştir.

Seçilen her dilim için, açıklayıcı bir veya daha fazla kontur çizilmiş, öyle ki konturlar içinde gösterilen tüm doku böbrek, tümör veya yağ olacak şekilde düzenlenmiştir. Bunlara böbrek konturları denmektedir. Renal hilumun bulunduğu dilimlerde, sinüs ve toplama sisteminin bir kısmı konturlarından çıkarılmış, böylece konturlarındaki en büyük içbükeylik hilum girişinde başlayıp sona ermiştir. Daha sonra, iç kısımlarında gösterilen tek dokunun böbrek olmadığı veya tümör olmadığı şekilde yeni bir kontur serisi çizilmiştir. Bunlara tümör konturları denilmiştir.

Açıklanmamış dilimler için böbrek konturları, her iki taraftaki en yakın açıklamalı dilimlerden enterpole (oranlama işlemi) edilmiştir. Bu işlem basit doğrusal dönüşümle yapılmıştır. Bir hilum içeren her kontur için, en büyük dışbükeylik eksikliği doldurulacak şekilde bir çizgi çizilmiştir. Tümör konturları da basit bir morf ile enterpole edilmiştir. Her tümör çevresi için kendi iç pikselleri ile eşikli böbrek arasında piksel bazlı bir AND (mantıksal çarpım işlemi) gerçekleştirilmiştir. Kalan pikseller tümör olarak kabul edilmiştir.

- Prosedür, vakaların büyük çoğunluğunda işe yaramış, ancak bazen hilumunkinden daha büyük olan başka çukurluklar da görünmüştür. Bu durumlarda, hilum hatlarının uç noktaları manuel olarak seçilmiştir. Açıklayıcılar, tümörlerin doğru bir şekilde lokalizasyonunu ve kistlerin dışlanmasını kolaylaştırmaya yardımcı olan cerrahi patolojinin sonucunun yanı sıra her vakanın katılan radyoloğun sonucuna erişebilmiştir. Tüm vakalar daha sonra hem aksenel hem de koronal düzlemde incelenmiştir.


Verilen bu bilgiler doğrultusunda da görüldüğü üzere özellikle uzman deneyimi olmadan yapılan manuel segmentasyon, böbrek veya tümörün izlenmesinde bir dizi hataya neden olabilir. Ayrıca zaman alıcıdır ve sistem performansını yavaşlatabilir. Bu olumsuz etkilere rağmen, literatürde mevcut veri setlerinin azlığı nedeniyle KiTS19 veri seti kullanılmıştır. Manuel segmentasyon yöntemi ile mevcut hastaların klinik özellikleri, görüntüleme verileri, böbrek ve tümör sınırları hazırlanmıştır. Şekil 2.44, manuel bölümlenme yöntemiyle hazırlanan örnek bir veri kümesini göstermektedir [125].




Şekil 2.44. Manuel segmentasyon ile hazırlanmış bir böbrek görüntüsü

Görüntüleme ve kesin referans etiketleri anonimleştirilmiş bir “nii” uzantılı dosyadan görüntüye (NIFTI) formatında sunulmuştur [125]. Veri kümesindeki BT görüntülerini $16 \times 256 \times 256$ olarak yeniden boyutlandırılmış ve piksel değerini 0 ile 1 arasında normalleştirmek için 255'e bölünerek hesaplama işlemi gerçekleştirilmiştir. Model parametreleri rastgele başlatılmış ve transfer öğrenimi kullanılmamıştır. $64 \times 128 \times 128$ boyutundaki yamalar, eğitim için yeniden örneklenen verilerden rastgele seçilmiştir. Eğitim veri seti, veri setinden 190 tane olacak şekilde ayrılmıştır. Kalan 20 tanesi test için

kullanılmıştır. Eğitim veri seti ile test veri seti rastgele düzenlenmiştir. Model, 0,001'e ayarlanmış bir öğrenme katsayısı ile Adam Optimizer Optimazasyon algoritması tarafından eğitilmiştir. Batch size (yığın boyutu) 3 olarak belirlenmiş ve toplam adım 100.000 olarak ayarlanmıştır. Modelin eğitimi, NVIDIA Tesla V100 (32 GB, NVLink) Grafik İşleme Birimi (GPU) üzerinde yaklaşık beş gün sürmüştür. Eğitim sırasında TensorFlow kütüphanesinin özellikleri kullanılmıştır. Şekil 2.45, 3B orijinal böbrek görüntülerini ve 2B manuel bölümlenme görüntülerini gösterirken, Şekil 2.45, segmentlere ayrılmış bölgelerin (mavi ve mor renkli böbrek ve böbrek kanseri) ve ayrıca 2B böbrek ve böbrek kanseri görüntülerinin 3B hacimsel sunumunu göstermektedir. Görüntü işleme aşamasında BT görüntüsü, dilim kalınlığı, pencere genişliği ve konum bilgisini bulmak için analiz edilir. Böbrek ve böbrek tümörü bölgeleri değişmeden korunur. Ayrıca bu bölgelerin orijinal resimleri ve maskeleri oluşturulur [112].



Şekil 2.45. 3B böbrek görüntüsü Nifti formatı ve manuel segmentasyon görüntüsü



Şekil 2.46 Sol: Segmentli bölgelerin (mavi ve mor renkli böbrek ve böbrek kanseri) 3B hacimsel gösterimi Sağ: 2B böbrek ve böbrek kanseri görüntüsü


3. ARAŞTIRMA BULGULARI

Bu bölümde U-Net ve V-Net modellerinden elde edilen sonuçlar kapsamlı bir şekilde açıklanmaktadır.

3.1. U-Net Modelleri İçin Araştırma Bulguları

Çalıştırılan tüm modeller ile sonuçları Tablo 3.1’ de gösterilmiştir. Diğer modellerden farklı olarak, geliştirilmiş U-Net3D modelinin ResNet ++ katmanının kod çözücü katmanının önünde oluşturulmuştur. Ayrıca artık blokların çıktı katmanı aktarılmadan ek bir evrişimli katmanla (U-Net ++ gibi) derinleştirilmiştir.

Böbrekler için zar katsayısı değerleri, bu yöntem hem gerçek böbrek etiketi hem de tümör etiketi dikkate alınarak hesaplanmıştır. KiTS19 zorluk değerlendirmesinde kullanılan yapıyla aynı modeldedir. Bu bölümde gösterilen sonuçlar, KiTS19 eğitim veri setindeki beş kat çapraz doğrulamaya dayalı olarak hesaplanmaktadır. Eğitim sürecinden elde edilen zar katsayısı değerleri Şekil 3.1’de gösterilmiştir. Dört U-Net modeli arasında, zar katsayısı değerleri eğitimin başında dalgalı bir grafik göstermiştir. Bu durum eğitimin ilk aşamasında kabul edilebilmektedir. Eğitimin sonraki aşamalarında klasik U-Net modellerinin zar katsayılarında hala büyük dalgalanmalar varken, geliştirilmiş U-Net modeli ile bu dalgalanmalar en aza indirilmiştir. Böylece eğitim aşamasında daha tutarlı bir duruma ulaşılmıştır.



Şekil 3.1.U-Net Eğitim boyunca elde edilen zar katsayısı

Çizelge 3.1’de doğrulama ve test sonuçlarından elde edilen Zar katsayılarını görülmektedir. Doğrulama ve test sonuçlarına bakıldığında geliştirilmiş U-Net3D, en yüksek ortalama zar puanına sahip olduğu için diğer modellerden daha esnek ve uygulanabilir olduğu görülmektedir.

Ek olarak, doğrulama ve test sonuçlarına bakıldığında geliştirilmiş U-Net3D modelinin birbirine yakın daha tutarlı sonuçlar verdiği görülmektedir. Bulgular KiTS19 veri seti üzerinde hazırlanan ağ mimarisinde elde edilmiştir.

Çizelge 3.1. U-Net modelleri için test ve validation (doğrulama) zar katsayısı

Model	Böbrek Zar Kats.		Tümör Zar Kats.		Birleşik Zar Kats.
	Zar Doğr.	Zar test	Zar Doğr.	Zar Test	Test
U-Net	0,807	0,931	0,902	0,811	0,871
U-Net+ResNet	0,871	0,940	0,917	0,822	0,881
U-Net++	0,886	0,804	0,894	0,807	0,805
Geliş. U-Net	0,949	0,978	0,927	0,856	0,917

Çizelge 3.2, KiTS19 Challenge'daki en iyi 5 yarışmacının sonuçları ile Geliştirilmiş U-Net modelinden elde edilen sonuçlarının karşılaştırmasını göstermektedir. Yarışmadaki 90 test seti erişime kapalı olduğu için değerlendirmeye tabii tutulamamıştır.

Çizelge 3.1’de gibi Geliştirilmiş U-Net zar puanının yarışmacıya (Issensee) ait zar puanına çok yakın ve diğer rakiplere göre ise daha yüksek olduğu görülmektedir. Ancak rakipler gibi veri setindeki yanlış etiketleme nedeniyle atıldığı söylenen verilerde kullanılmıştır. Ancak sonuçlarımızın gelecekteki diğer çalışmalarla karşılaştırılabilmesi için veri setini değiştirmeden uygulama işlemi gerçekleştirilmiştir.

Çizelge 3.2. Segmentasyon method karşılaştırılması (KiTS19 top 5 sonuçları)

Referans	Data Format	Method	Vaka Sayısı	Zar Katsayısı
Isensee	BT	U-Net3D	Train:210, Test:90	0,9793
Junma	BT	U-Net3D	Train:210, Test:90	0,9738
Isensee	BT	U-Net3D	Train:210, Test:90	0,9787
PingAnTech	BT	VB-Nets	Train:210, Test:90	0,9782
fgdhjdjhretgdfd	BT	U-Net3D	Train:210, Test:90	0,9784
Gelişt.U-Net3D	BT	U-Net3D	Train:200, Test:10	0,9789


Çizelge 3.3, literatürdeki böbrek segmentasyonu üzerine yapılan çalışmalar ile önerilen model sonuçlarının genel bir karşılaştırmasını göstermektedir. Farklı yöntemler ve veri kümeleri ile karşılaştırma yapıldığı da belirtilmektedir. Sadece Unet3D modeliyle değil, kabul gören diğer yapay zekâ yöntemleriyle de yapılan çalışmalarla karşılaştırma yapılmış ve elde edilen zar puanının başarısı gösterilmeye çalışılmıştır. Zar benzerlik katsayısının diğer modellere göre daha yüksek olması dikkat çekicidir.

Çizelge 3.3. BT görüntüleri için böbrek segmentasyon sonuçlarının karşılaştırılması

Referans	Method	Vaka Sayısı	Zar Katsayısı
Tuncer and Alkan	Decision support	100 images	0,893
Cuingnet et al.	Random forest	Train:233, Test:179	0,97
Zheng et al.	CNN+MSL	Train:370, Test:78	0,905
Milletari et al.	VNet	27(8-fold)	0,856
Chenglong et al.	FCN based	27(8-fold)	0,95
Guanyu Yang et al.	3DFCN-PPM	140 patients	0,931
Price Jackson et al.	CNN	89 images	0,91
Geliştirilmiş U-Net3D	Improved UNet3D	Train:200, Test:10	0,978

Şekil 3.2. böbrekler için dört modelin test sonuçlarını, her modelin temel gerçekliğini, orijinal maskeleri ve segmentasyon sonuçlarını göstermektedir. Sonuçlar incelendiğinde, 4 model, bazı bölümlerde yüksek oranlarda bölümlenmeyi tahmin edebilir. Ancak segmentasyonun tespit edilmesinin zor olduğu bölümlerde, geliştirilen U-Net3D modeli


diğer modellere göre daha başarılı segmentasyon zar katsayısına ulaşmıştır. Özellikle önerilen model, geliştirmeler sayesinde küçük farklılıkları bile yakalayabilmiş ve diğer modellere göre daha doğru segmentasyon yapabilmiştir. Böylelikle bu modelin dekoder kısmında yapılan ResNet ++ yapısı ve yeni bir katmanla desteklenen Outconv bloğu sayesinde, çıktı katmanında daha tutarlı görüntü segmentasyonu sağladığı söylenebilmektedir. Bu sayede çıktı katmanını daha başarılı bir şekilde segmentlere ayırma başarısının arttığı görülmektedir.



Şekil 3.2. Orijinal BT görüntüleri girişi ve onların böbrek segmente çıkış resimleri

Şekil 3.3. böbrek tümörleri için dört modelin test sonuçlarını, her modelin temel gerçekliğini, orijinal maskeleri ve segmentasyon sonuçlarını göstermektedir. Sonuçlar incelendiğinde, 4 model bazı bölümlerde yüksek oranlarda bölümlenmeyi tahmin edebilir. Ancak segmentasyonun tespit edilmesinin zor olduğu bölümlerde geliştirilen U-Net3D modeli diğer modellere göre daha gerçekçi segmentasyon başarısı elde etmiştir.

Özellikle model üzerinde yapılan geliřtirmeler sayesinde böbrek segmentasyonunda olduđu gibi tümör segmentasyonu içinde küçük farklılıkları bile yakalayabilmiş ve diđer modellere göre daha doğru segmentasyon yapabilmiştir. Ađın dekoder kısmında yapılan ResNet ++ yapısı ve yeni bir katmanla desteklenen Outkonv blođu sayesinde çıktı katmanında daha tutarlı görüntü segmentasyonu sağlanabilmiştir. Çıktı katmanının daha başarılı bir şekilde segmentlere ayırma özelliđi kazandıđı görölmektedir.

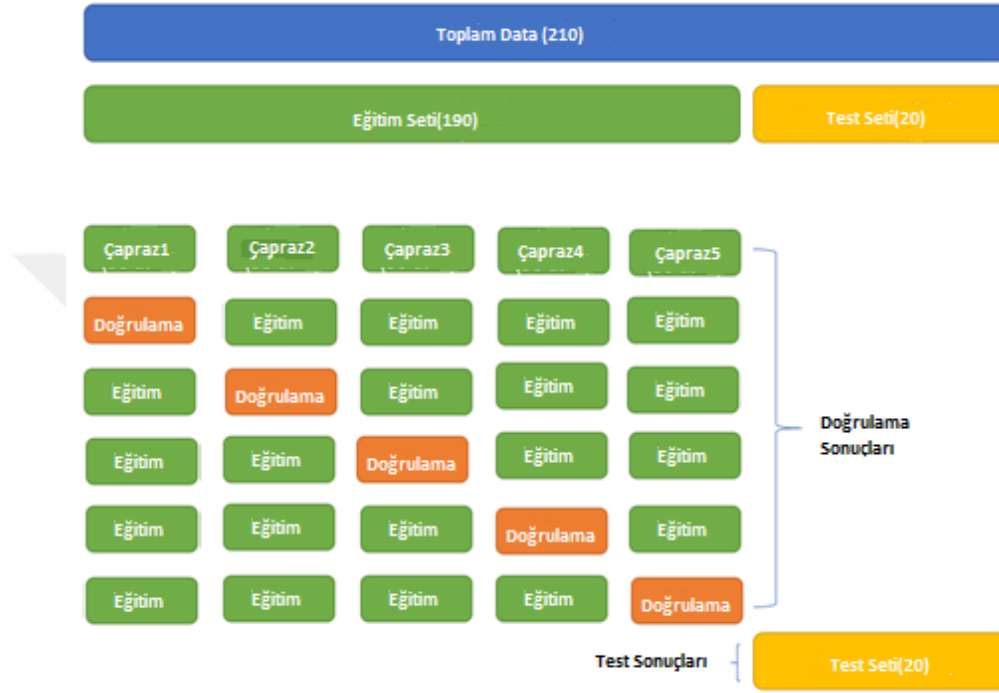


Şekil 3.3. Orijinal BT görüntüleri giriři ve onların böbrek tümör segmente çıkış resimleri

3.2. V-Net Modelleri İçin Arařtırma Bulguları

V-Net, Fusion V-Net, ETV-Net ve Hibrit V-Net modellerini çalıştırdıktan sonra elde edilen sonuçlar ařađıda ayrıntılı olarak tartıřılmıştır. Dört modelin tümü aynı hiperparametrelerle çalıştırılmıştır, ancak hepsinin farklı ađ mimarilerine sahip olduđunu da belirtmekte fayda vardır. Gerçek zemin deđerleri ve tümör etiketleri dikkate alınarak böbrekler için zar benzerlik katsayı deđerlerini hesaplanmıştır.


Bu bölümde gösterilen sonuçlar, eğitim veri setinden elde edilen beş katlı çapraz doğrulama sonuçlarının ortalamasına göre hesaplanmıştır. Şekil 3.4., beş katlı çapraz doğrulama algoritma şemasını göstermektedir. Her bölüm ayrı ayrı çalıştırılmış ve ortalama doğrulama sonuçları hesaplanmıştır. Bu sayede eğitim aşamasında daha yüksek bir doğrulama hassasiyeti elde edilmesi hedeflenmiştir.



Şekil 3.4. 5 kat çapraz doğrulamalı algoritma şeması

Şekil 3.5. eğitim süresi boyunca elde edilen böbrek ve tümör DSC grafiklerini göstermektedir. Segmentasyonun zorluk seviyesinden dolayı, eğitimin erken aşamalarında dalgalı bir eğri gözlemlenmiştir.

İlerleyen adımlarda DSC değerleri kademeli olarak sabitlenmiş ve istenilen seviyeye ulaşılmıştır. Doğrulama Zar Kaybı çizelgelerinde başlangıçta kısmi dalgalanmalar görülmüş, ancak daha sonra düşük ve makul seviyelerde kalmıştır.



Şekil 3.5. Böbrek ve tümör için zar katsayısı ve kayıp değerleri

Çizelge 3.4. doğrulama ve test sonuçlarından elde edilen DSC katsayılarını göstermektedir. Doğrulama ve test sonuçları, tüm V-Net modellerinin belirli bir başarı oranına ulaştığını göstermiştir. Böbrek segmentasyonu için klasik V-Net modeli, 0.940 DSC katsayısı ile en başarılı sonucu vermiştir. Tümör segmentasyonu için Hibrit V-Net modeli, 0.865'te en yüksek DSC katsayısına ulaşmıştır. Diğer modellere göre daha tutarlı ve daha yüksek bir DSC katsayısı elde eden Hibrit V-Net modeli hem böbrek segmentasyonu hem de tümör tespitinde daha başarılı görünmektedir. Bu sonuçlar, KiTS19 eğitim veri setini kullanarak, tasarlanan ağ mimarisinden elde edilmiştir.

Çizelge 3.4. V-Net modelleri için test ve validation zar benzerlik katsayısı

Model	Böbrek Zar Kats.		Tümör Zar Kats.		Birleşim
	Zar doğr.	Zar test	Zar doğr.	Zar test	Test
V-Net	0,940	0,951	0,919	0,823	0,887
Fusion V-Net	0,861	0,937	0,923	0,835	0,886
ETV-Net	0,925	0,886	0,905	0,818	0,852
Hibrit V-Net	0,937	0,977	0,931	0,865	0,921


Çizelge 3.5. literatürdeki diğer böbrek ve böbrek tümör segmentasyon çalışmalarından elde edilen sonuçların önerilen modelden elde edilen sonuçlarla genel bir karşılaştırmasını göstermektedir.

Veri kümeleri farklı olmasına rağmen, Hibrit V-Net modeli böbrek segmentasyonu hesaba katıldığında DSC katsayısını hesaplamada başarılı görünmektedir. Böbrek ve böbrek tümörü segmentasyonu için önerilen Hibrit V-Net modeli, KiTS19 mücadelesinde 1.olan model ile de karşılaştırılmıştır. Eğitim ve test setleri aynı olmasa da önerilen model böbrek tümör zarı katsayısını hesaplamada özellikle başarılı görünmektedir. Ancak KiTS19 mücadelesindeki 90 test setinin, halka erişimin açık olmadığı özellikle hatırlatılmaktadır.

Çizelge 3.5. Böbrek ve tümör segmentasyon sonuçlarının literatür ile karşılaştırılması.

Referans	Method	Vaka Sayısı	Böbrek -Tümör DSC
Tuncer ve Alkan	Decision support	100 images	0,893
Cuingnet et al.	Random forest	Train:233, Test:179	0,97
Zheng et al.	CNN+MSL	Train:370, Test:78	0,905
Milletari et al.	VNet	27(8-fold)	0,856
Chenglong et al.	FCN based	27(8-fold)	0,95
Guanyu Yang et al	3DFCN-PPM	140 patients	0,931
Price Jackson et al.	CNN	89 images	0,91-0,86 0,979-0,854
Luana B. da C. et. al.	CNN	Train:179, Test: 31	0,963
Wenshuai Zhao et. al.	U-Net	Train:168, Test:42	0,969-0,805 Birlş. (0,887)
Isensee et al.	nnU-Net	Train:210, Test:90	0,979-0,854 Birlş. (0,916)
Hibrit V-Net	V-Net	Train:190, Test:20	0.977-0.865 Birlş. (0.921)


Şekil 3.6. V-Net modellerinde böbrek segmentasyonu için kullanılan orijinal görüntüleri, maskeleri ve segmentasyon sonuçlarını göstermektedir. V-Net modelleri yüksek eğitim ve test başarısı gösterildiğinden dolayı sonuçlar çok benzer çıkmıştır. Ancak daha ayrıntılı incelendiğinde Hibrit V-Net modelinin küçük detayları tespit etmede mevcut V-Net modellerinden daha başarılı olduğu ve hibrit V-Net modelinde yapılan iyileştirmelerin olumlu sonuçlar verdiği görülmektedir.



Şekil 3.6. Orijinal BT görüntüleri girişi ve onların böbrek segmente çıkışı resimleri

Şekil 3.7. V-Net modellerinde renal tümör segmentasyonu için kullanılan orijinal görüntüleri, maskeleri ve segmentasyon sonuçlarını göstermektedir. Sonuçlar V-Net modellerinin böbrek tümörleri için kabul edilebilir bir başarı oranına ulaştığını göstermektedir.

Tümör tespiti için manuel segmentasyon sonuçları ile karşılaştıran hibrit V-Net modeli, birçok durumda keskin çizgilerle çizilse bile ayrıntıları başarılı bir şekilde göstermiştir. Hibrit V-Net modeli, füzyon V-Net modeli ile entegre edildiğinde kodlayıcı kısmında ve ET V-Net modeli ile kombinasyon halinde kod çözücü kısmında daha başarılı çıktılar üretmiştir.



Şekil 3.7. Orijinal BT görüntüleri girişi ve onların böbrek tümör segmente çıkış resimleri

Böbrek ve tümör segmentasyonunun zor olduğu durumlarda yumuşak dokular için geliştirilen hibrit V-Net modelinin diğer modellere göre daha başarılı sonuçlar vermesi hipotezi desteklenmiştir. Mevcut V-Net modellerini geliştirerek daha iyi sonuçlar veren bir model tasarlanmıştır.

Füzyon mimarisinden esinlenerek, kodlayıcı fazı iki ayrı kodlayıcı fazı olarak kullanılmış ve kod çözücü fazındaki katmanları kenar özelliklerini yakalamak için birleştirilmiştir. Sonuç olarak daha iyi performans gösteren bir model elde edilmiştir. Hesaplanan DSC katsayısı sonuçlarından, ResNet ++ bloğunun çıktı üzerindeki etkisi ile modelin küçük detayları bile yakalayabildiği görülmektedir. Ancak hibrit V-Net modelindeki gelişmelere rağmen eğitim ortalama beş gün sürmüştür. Bu modeldeki ek işlem hacmi (ResNet ++ gibi) dikkate alındığında, önerilen modelin mevcut modellerden daha hızlı çalıştığı düşünülebilir. Eğitim süresinin kısaltılması için yeni modellerin oluşturulması ilerideki çalışmalarda mümkün olabilecektir. Ayrıca tam otomatik segmentasyon sistemlerinin, işleme süresi ve segmentasyon sürecindeki hataların tespiti gibi manuel segmentasyon zorlukları göz önünde bulundurulduğunda, mevcut veri kümelerinde daha başarılı olabileceğini görülmektedir.

4. SONUÇLAR ve TARTIŞMA

Böbrek tümörlerini erken aşamada tespit etmek için çoklu görüntü segmentasyon teknikleri gereklidir. Yapılan tez çalışmasında, böbrek ve tümör bölgelerini segmentlere ayırmak için kullanılan dört farklı U-Net3D mimarisi ve dört farklı V-Net modelinin bir karşılaştırmasını sunmaktadır. Bahsi geçen bütün ağların eğitimi KiTS19 veri setinde gerçekleştirilmiştir. Mimari test için 0,978 ve doğrulama için 0,949 maksimum zar puanına ulaşan geliştirilmiş U-Net mimarisi, dört ağın en iyi sonuçlarını vermiştir. Aynı şekilde mimari test için 0,977 ve doğrulama için 0,985 maksimum DSC katsayısına ulaşan hibrit V-Net mimarisi, dört ağın en iyi sonuçlarını vermiştir.

Araştırma bulguları, basit bir U-Net mimarisinin yalnızca birkaç katman üzerinde daha iyi işlemler gerçekleştirebileceğini ve karmaşık ağ yapıları olmadan bile daha iyi sonuçlar verdiğini göstermektedir. Bu çalışmanın bir diğer katkısı, U-Net3D modellerinin KiTS19 veri setine uygulanabilirliğini göstermektir. Geliştirilmiş U-Net modeli göz önüne alındığında, mevcut ağlardan daha hızlı ve daha doğru modeller geliştirileceği ortaya çıkarılmıştır.

Tez çalışması, ResNet mimarisinin görüntü bölümlenme için karmaşık olmayan modellere doğru şekilde entegre edildiğinde daha başarılı olabileceğini gösterdiği için gelecekteki modeller için bir rehber olabilecektir. Özellikle önerilen U-Net modelinde ResNet ++ dediğimiz mimari ilk defa bu şekilde ResNet mimarisini kullanarak oluşturulmuştur. Ayrıca çıktı katmanına yalnızca bir evrişim katmanı ekleyerek ortalama zar katsayısının daha yüksek seviyelere ulaşabileceği de görülmüştür. Bir ağın karmaşıklığını, katman sayısını veya derinliğini (U-Net ++ gibi) artırmanın her zaman daha iyi sonuçlar veremeyeceği anlaşılmıştır. Hiper parametreler hakkında daha fazla araştırma, ağ başarısını artırmak için daha rasyonel bir yaklaşım olabilir.

Mevcut V-Net modelleri için sonuçlar incelendiğinde ise tüm V-Net modellerinin üstün özelliklerini kullanan yeni bir hibrit V-Net modeli önerilmiştir. Bu veri setinde Hibrit V-Net modeli dahil dört model çalıştırılmış ve böbrek ve tümör segmentasyonunu için işlemler ayrı ayrı gerçekleştirmiştir.

Tez çalışması, V-Net modellerinin bilgisayarlı görüntülerle organ ve tümör segmentasyonunu başarılı bir şekilde gerçekleştirdiğini, kodlama ve kod çözme aşamalarını ayrı ayrı ele alarak mevcut V-Net modellerinden daha başarılı modellerin geliştirilebileceğini göstermiştir. Tıbbi görüntüler kullanılarak çoklu organ segmentasyonu için daha uygun modeller tasarlanabilir. Tez çalışması, hibrit V-Net modelinin ilk kez uygulanmasının başarısı ResNet ++ mimarisinin olumlu katkısıyla gelecekteki hibrit modeller için bir kılavuz olarak da kullanılabilir. ResNet ++ mimarisi yalnızca çıktı katmanına uygulanmış ve böylelikle segmentasyondaki küçük ayrıntıları yakalamayı mümkün kılmıştır. Bu durum model tasarımı için son derece önemlidir çünkü her parametre ancak modelin uygun bloklarına eklendiğinde başarılı olabilir. Burada sunulan sonuçlar, bu modelin hiper parametreleri ile ilgili daha fazla araştırmanın uygun olduğunu göstermektedir.

Tez çalışmasının ardından önerilen Hibrit V-Net modelin eksikliklerinin araştırılması hedeflenmektedir. Eksiklikler ortadan kaldırarak, tıbbi görüntüleme böbrek veya diğer organ segmentasyonu için daha pratik sistemlerin geliştirmesi amaçlanmıştır. Özellikle tıbbi görüntüleme alanında derin öğrenme tasarımlarına ilişkin gelecekteki çalışmalar, karmaşık yapılara sahip sistemlere dayanmamalıdır. Aksine araştırma, mevcut modellerde küçük iyileştirmelerle (hiper parametrelerin değiştirilmesi gibi) daha iyi sonuçların elde edilebileceği alanlara odaklanmalı, böylece gereksiz yük ortadan kaldırılmalı ve mevcut model etkinliği iyileştirilmelidir. Gelecek çalışmalar, derin öğrenme modellerinin eğitim süresinin kısaltılmasına daha fazla odaklanmalıdır. Çeşitli alanlarda kullanılabilecek daha başarılı modeller geliştirmek için modellerin uygulanabileceği sistemleri basitleştirmek ve karmaşıklığı azaltmak gerekmektedir.

KAYNAKLAR

- [1] Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R.L., Torre, L.A., Jemal, A. Global cancer statistics 2018: “Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries” *CA: a cancer journal for clinicians*, 68: 394–424, 2018.
- [2] Zhebin, D., Wei, C., Xia, Q., Shi, O. and Chen, Q. Trends and projections of kidney cancer incidence at the global and national levels, 1990–2030: a Bayesian age-period-cohort modeling study, Du et al. *Biomarker Research*, 8:16, 2020.
- [3] Heller, N.C., Sathianathan, N., Kalapara, A., et al. The KiTS19 Challenge Data: “300 Kidney Tumor Cases with Clinical Context, CT Semantic Segmentations, and Surgical Outcomes”, 2019.
- [4] Wanga, S., Galbo, M.D., Blair, C., Thyagarajan, B., Anderson, K., Lazovich, D., Prizment, A. Diabetes and kidney cancer risk among post-menopausal women: The Iowa women’s health study, *Maturitas*, 143:190-196, 2020.
- [5] Pischon, T., Lahmann, P.H., Boeing, H., Tjønneland, A., Halkjaer, J., Overvad, K., Klipstein-Grobusch, K., Linseisen, J., Becker, N., Trichopoulos, A., Benetou, V., Trichopoulos, D., Sieri, S., Palli, D., Tumino, R., Vineis, P., Panico, S., Monninkhof, E., Peeters, P.H., Bueno de Mesquita, H.B., Buchner, F.L., Ljungberg, B., Hallmans, G., Berglund, G., Gonzalez, C.A., Dorronsoro, M., Gurrea, A.B., Navarro, C., Martinez, C., Quiros, J.R., Roddam, A., Allen, N., Bingham, S., Khaw, K.T., Kaaks, R., Norat, T., Slimani, N., E. Riboli. Body size and risk of renal cell carcinoma in the European Prospective Investigation into Cancer and Nutrition (EPIC) *Int. Cancer J.*, 118 (3) :728-738, 2006.
- [6] Nicodemus, K.K., Sweeney, C., Folsom, A.R., et al. Evaluation of dietary, medical and lifestyle risk factors for incident kidney cancer in postmenopausal women *Int. Cancer J.*, 108 (1) :115-121, 2004.

- [7] Hu, J., La, Vecchia C., Des Meules, M., Negri, E., L. Mery Nutrient and fiber intake and risk of renal cell carcinoma *Nutr. Cancer*, 60 (6) :720-728, 2008.
- [8] Van Dijk, B.A., Schouten, L.J., Oosterwijk, E., Hulsbergen-van de Kaa C.A., Kiemeny, L.A., Goldbohm, R.A., Schalken, J.A., P.A. van den Brandt Carotenoid and vitamin intake, von Hippel-Lindau gene mutations and sporadic renal cell carcinoma *Cancer Causes Control*, 19 (2) :125-134, 2008.
- [9] Lee, J.E., Giovannucci, E., Smith Warner, S.A., Spiegelman, D., Willett W.C., G.C. Curhan. Intakes of fruits, vegetables, vitamins A, C, and E, and carotenoids and risk of renal cell cancer *Cancer Epidemiol. Biomarkers Prev.*, 15 (12) :2445-2452, 2006.
- [10] Bertoia, M., Albanes, D., Mayne, S.T., Mannisto, S., Virtamo, J., M.E. Wright No association between fruit, vegetables, antioxidant nutrients and risk of renal cell carcinoma *Int. J. Cancer*, 126 (6):1504-1512, 2010.
- [11] Huang, T.B., Ding, P.P., Chen, J.F., Yan, Y., Zhang L., Liu H., Liu P.C., Che J.P., Zheng J.H., X.D. Yao Dietary fiber intake and risk of renal cell carcinoma: evidence from a meta-analysis *Med. Oncol.*, 31 (8) :125, 2014.
- [12] Acar, C., Sözen, S., Üre, İ., Batur, A.F., Gürocak, S., Küpeli, B. [Nephron-sparing treatments in small renal tumors: surgical and ablative procedures]. *Türk Üroloji Dergisi*; 35:87-95, 2009.
- [13] Teber, D., Erdoğan, T., Klein, J., Frede, T., Rassweiler, J. Laparoscopic Radical Nephrectomy: Surgical Outcomes and Longterm oncologic Follow-Up]. *Türk Üroloji Dergisi*; 31: 41-48, 2005.
- [14] Tangal, S., Önal, K.; Yiğman, M., Haliloğlu, A.H. Relation of neutrophil lymphocyte ratio with tumor characteristics in localized kidney tumors. *New J. Urol.*, 13: 12–15, 2018.

- [15] Sun, M., Abdollah, F., Bianchi, M., Trinh, Q.D., Jeldres, C., Thuret, R., Tian, Z., Shariat, S.F., Montorsi, F., Perrotte, P., et al. Treatment management of small renal masses in the 21st century: A paradigm shift. *Ann. Surg. Oncol.* 19: 2380–2387, 2012.
- [16] Campbell, S. C., Novick, A.C., Bukowski, R.M. Renal Tumors Chapter 47 in *Campbell-Walsh Urology Ninth Edition* Wein AJ, Kavaoussi LR, Novick AC, Partin AW, Peters CA. *Campbell-Walsh Urology*. 9. Philadelphia, Saunders, 1582, 2007.
- [17] Konety, BR., Williams, RD. Renal Parenchymal Tumors. Chapter 21, *Smith Urology Seventeen Edition* Tanagho EA, McAninch JW. Lange; 328, 2008.
- [18] Yang, G., Gu, J., Chen, Y., Liu, W., Tang, L., Shu, H.; Toumoulin, C. Automatic kidney segmentation in ct images based on multi-atlas image registration. In *Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Chicago, IL, USA; 5538–5541, 2014.
- [19] Mohanapriya, D., Kalaavathi, B. Adaptive Image Enhancement Using Hybrid Particle Swarm Optimization and Watershed Segmentation. *Intell. Autom. Soft Comput.*, 25, 663–672, 2019.
- [20] Melisai, J., Monoarfa, A., Tjandra, F. Profil Penderita Karsinoma Sel Ginjal (Renal Cell Carcinoma). *e-Clinic*, (4) :2, 2016.
- [21] Caliskan, S., Koca, O.M., Akyuz, M.I. Böbrek tümörü öntanısıyla radikal veya parsiyel nefrektomi yapılan hastalardaki benign tümörler. *New J. Urol.*, 9: 34–37, 2014.
- [22] Mir, M.C., Darwish, I., Porpiglia, F., Zargar, H.; Mottrie, A., Autorino, R. Partial nephrectomy versus radical nephrectomy for clinical t1b and t2 renal tumors: A systematic review and meta-analysis of comparative studies. *Eur. Urol.*, 71: 606–617, 2017.

- [23] YU, Q., Shi, Y.; Sun, J., Gao, Y.; Dai, Y., Zhu, J. Crossbar-net: “A novel convolutional network for kidney tumor segmentation in ct images”. arXiv, arXiv: 1804.10484, 2018.
- [24] Milletari, F., Nassir, N., Ahmadi, S.A. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. In Proceedings of the 2016 Fourth International Conference on 3D Vision (3DV), Stanford, CA, USA, 25–28 October; 565–571, 2016.
- [25] Zeiler, M.D., Fergus, R. Visualizing and understanding convolutional networks. In Computer Vision–ECCV; Springer: Cham, Switzerland, 818–833, 2014.
- [26] Lingurarua, M.G., Yaoa, J., Gautamb, R., Petersonb, J., Li, Z., Linehanb, W.M., Ronald, M.S. Renal tumor quantification and classification in contrast-enhanced abdominal CT. *Pattern Recognit.*, 42: 1149–1161, 2009.
- [27] Burkill, G. Allen, S., A’hern, R. Gore, M., King, D. Significance of tumour calcification in ovarian carcinoma. *Br. J. Radiol.*, 82, 640–644, 2009.
- [28] Rundo, L., Beer, L., Ursprung, S., Gonzalez, P.M., Markowetz, F., James, D.B., Ortuzar, M.C., Sala, E., Woitek, R. Tissue-specific and interpretable sub-segmentation of whole tumour burden on CT images by unsupervised fuzzy clustering. *Comput. Biol. Med.*, 120, 103751, 2020.
- [29] Ray M., Qidwai U., Artificial intelligence approach to determine minimum dose of haemodialysis. Proceedings of the International Joint Conference on Neural Networks, Portland, OR, USA. **DOI:** 10.1109/IJCNN.2003.1223314, 2003.
- [30] Roberto, A., Remi, C., Ketan, B., Vincent, A., 2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI) Conference Paper | Publisher: IEEE. **DOI:** 10.1109/ISBI.2015.7163865, 2015.

- [31] Chi-Jim, C., Tun-Wen, P., Hamido, F., Chien-Hung, L., Yang-Ting, C., Kuo-Su C., Yung-Chih C. Stage diagnosis for Chronic Kidney Disease based on ultrasonography, 2014 11th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD) | Conference Paper | Publisher: IEEE, DOI: 10.1109/FSKD.2014.6980889 , 2014.
- [32] Matt, S., Martin, P., John, H. P., May, D. W. Integration of multimodal RNA-seq data for prediction of kidney cancer survival, 2015 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), Washington, DC, USA DOI:10.1109/BIBM.2015.7359913, 2015.
- [33] Armando, J. L., Mandy, R., Luis, H., Braga, Y.G., and John-Paul, O. Predictive Analytics and Modeling Employing Machine Learning Technology: The Next Step in Data Sharing, Analysis, and Individualized Counseling Explored With a Large, Prospective Prenatal Hydronephrosis Database, *Pediatric Urology* , 123: 204-209, 2019.
- [34] Qiang, Z., Gregory, T., Yong, F. Transfer learning for diagnosis of congenital abnormalities of the kidney and urinary tract in children based on ultrasound imaging data, IEEE 15th International Symposium on Biomedical Imaging (ISBI) Conference Paper Publisher : IEEE, DOI: 10.1109/ISBI.2018.8363854, 2018.
- [35] Ahmed, A.J., Dhiya, A.J., Hussein, M.H., Mohamed, A., Thar, B., Abir, J., Jamila M. Early Prediction of Chronic Kidney Disease Using Machine Learning Supported by Predictive Analytics, 2018 IEEE Congress on Evolutionary Computation (CEC), Rio de Janeiro, Brazil, DOI: 10.1109/CEC.2018.8477876, 2018.
- [36] Xin, Y., Minh, H.L., Cheng, K.T., Sung, K.H., Liu, W. Renal Compartment segmentation in DCE-MRI images. *Med. Image Anal.* 32, 269–280, 2016.

- [37] Xiang, D., Ulas, B., Jin, C., Shi, F., Zhu, W., Yao, J., Sonka, M., Chen, X. CorteXpert: “A model-based method for automatic renal cortex segmentation”. *Med. Image Anal.*, 42, 257–273, 2017.
- [38] Tuncer, S.A., Alkan, A. A decision support system for detection of the renal cell cancer in the kidney. *Measurement*, 298-303, 2018.
- [39] Yang, G., Guoqing, T., Pan, Y., Kong, J., Wu, H. Shu, L. Automatic Segmentation of Kidney and Renal Tumor in CT Images Based on 3D Fully Convolutional Neural Network with Pyramid Pooling Module. In *Proceedings of the 2018 24th International Conference on Pattern Recognition (ICPR)*, Beijing, China, 2018.
- [40] Marie, F., Corbat, L., Chaussy, Y., Delavelle, T., Henriot, J. Christophe. J. Segmentation Of deformed kidneys and nephroblastoma using Case-Based Reasoning and Convolutional Neural Network. *Expert Syst.*, 127: 282–294, 2019.
- [41] Couteaux, V., Si-Mohamed, S., Renard-Penna, R., Nempont, O., Lefevre, T., Popoff, A., Pizaine, G., Villain, N., Bloch, I., Behr, J., et al. Kidney cortex segmentation in 2D CT with U-Nets ensemble aggregation. *Diagnostic Interv.* 100:211–217, 2019.
- [42] Antoniya, D., Mihaylova, M., Georgieva, P., Petrov, P.P., Aleksandar, T. Novel Algorithm for Segmentation of Renal cyst from CT Image Sequence. In *Proceedings of the 2019 14th International Conference on Advanced Technologies, Systems and Services in Telecommunications (TELSIKS)*, Nis, Serbia, 2019.
- [43] Rundo, L., Han, C., Nagano, Y., Zhang, J. Hataya, R., Militello, C., Tangherloni, A., Nobile, M.S., Ferretti, C., Besozzi, D., et al. USE-Net: Incorporating Squeeze-and-Excitation blocks into U-Net for prostate zonal segmentation of multi-institutional MRI datasets. *365*: 31–43, 2019.
- [44] Fuzhe, M., Sun, L., Liu, H., Jing, H. Detection and diagnosis of chronic kidney disease using deep learning-based heterogeneous modified artificial neural network. *Future Gener. Comput.* 111: 17–26, 2020.

- [45] CruzaJosé, L.B., Lima, D., Jonnison, A., Ferreira, L., Otávio, J., Dinizab, B., Corrêa, A., João, S., Sousade, D., Anselmo, A., et al. Kidney segmentation from computed tomography images using deep neural network. *Comput. Biol. Med.* 123, 103906, 2020.
- [46] Li, C., Tan, Y., Chen, W., Luo, X., He, Y., Gao, Y., Li, F. ANU-Net: Attention-based Nested U-Net To exploit full resolution features for medical image segmentation. *Comput. Graph.* 90, 11–20, 2020.
- [47] Nithya,A., Appathurai, A., Venkatadric, N., Ramjia, D.R., Anna Palagan, C. Kidney disease detection and segmentation using artificial neural network and multi-kernel k-means clustering for ultrasound images. *Measurement*, 149, 106952., 2020.
- [48] Zhao, W., Jiang, D., Queralta, J.P., Westerlund, T. MSS U-Net: 3D segmentation of kidneys and tumors from CT images with a multi-scale supervised U-Net. *Inform. Med.*, 19, 100357, 2020.
- [49] Isensee, F., Jäger, P.F., Kohl, S.A., Petersen, J., Maier-Hein, K.H. Automated Design of Deep Learning Methods for Biomedical Image Segmentation. *arXiv*, arXiv:1904.08128., 2019.
- [50] O'Reilly, J.A., Sangworasil, M., Matsuura,T. Kidney and Kidney Tumor Segmentation using a Logical Ensemble of U-nets with Volumetric Validation, *arXiv:1908.02625*, 2019.
- [51] Sabarinathan,D., Parisa, B.M., Mansoor, R. Hyper Vision Net: Kidney Tumor Segmentation Using Coordinate Convolutional Layer and Attention Unit. *arXiv:1908.03339*, 2019.
- [52] Santini,G., Moreau,N., Rubeaux,M. Kidney tumor segmentation using an ensembling multi-stage deep learning approach. A contribution to the KiTS19 challenge. *arXiv:1909.00735*, 2019.

- [53] Xiaoshuai, H., Chunmei, X., Fengyi, L., Jiaping, W., Chuanfeng, L., Guotong, X., Yang, N. A Triple-Stage Self-Guided Network for Kidney Tumor Segmentation, IEEE 17th International Symposium on Biomedical Imaging (ISBI) April 3-7, 2020.
- [54] Gabriel, E. KITS19: Kidney and kidney tumor segmentation in CT scans using a 3D U-Net based network with additional task, 1 Radboud University Medical Center, Nijmegen, The Netherlands, 2019.
- [55] Gül, Ü. Böbrek Hücreli Karsinomda Risk Faktörleri ve Etyoloji, Üroonkoloji Bülteni,13:135-138, 2014.
- [56] Ferlay, J., Steliarova, E., Lortet, J. Cancer incidence and mortality patterns in Europe estimates for 40 countries in 2012 Eur J Cancer, 49:1374-1403, 2013.
- [57] Patard, JJ., Rodriguez, A., Rioux, N. Prognostic significance of the mode of detection in renal tumours. BJU Int, 90:358-363, 2002.
- [58] Kato, M., Suzuki, T., Suzuki, Y. Natural history of small renal cell carcinoma: evaluation of growth rate, histological grade, cell proliferation and apoptosis. J Urol 172:863-866, 2004.
- [59] Çelik, O., İpekçi,T., Bilgehan,M.Y. Renal hücreli kanserde güncel tanı ve tedavi yöntemleri,researchgate, 2014.
- [60] Novick, A.C., Campbell, S.C., Renal Tumors. In: Walsh PC, Retik AB, Vaughan ED, Wein AJ, editors. Campbell's Urology. Philadelphia: WB Saunders, 2672-731, 2002.
- [61] Sheth, S., Scatarige, J.C., Horton, K.M., Fishman, E.K. Current concepts in the diagnosis and manegement of renal cell carcinoma: role of multidetector CT and three-dimensional CT. Radiographics, 21: 237-54, 2001.

- [62] Hricak, H., Demas, B.E., Williams, R.D., Mc Namara, M.L., Hedgcock, M.W., Amparo, E.G., Tanagho, E.A. Magnetic resonance imaging in the diagnoses staging of renal and perirenal neoplasms. *Radiology*, 154: 709-15, 1985.
- [63] Türk, F., Lüy, M., Barışçı, N. Machine Learning of Kidney Tumors and Diagnosis and Classification by Deep Learning Methods. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, UMAGD*, 11(3): 802-812. **DOI:**10.29137/umagd.640667, 2019.
- [64] Raffaele, C., Marta, T., Giuseppina, P., Antonella, P., Fabio, F. Artificial Intelligence and Machine Learning Applications in Smart Production: Progress, Trends, and Directions, *MDPI Sustainability*, 2020.
- [65] Kızrak, M.A., Polat, B. Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma, *Bilişim Teknolojileri Dergisi* 11(3):263 – 286, 2018. **DOI:** 10.17671/gazibtd.419205
- [66] Alpaydın, E. Yapay Öğrenme, Boğaziçi Üniversitesi Yayınevi, Türkiye, 2011.
- [67] Cohen, S. The basics of machine learning: strategies and techniques, *Artificial Intelligence and Deep Learning in Pathology*, 13-40, 2021.
- [68] Rumelhart, D.E., Hinton, G.E., Williams, R.J. “Learning Representations by Back-Propagating Errors”, *Nature*, 323, 533-536, 1986.
- [69] Öztemel, E. Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2012.
- [70] Öztürk, K., Ergin, M. Yapay Sinir Ağları ve Yapay Zekâ’ya Genel Bir Bakış, ISSN: 2148-0087, (6) : 2, 25-36, 2018.
- [71] Atalay, M., Çelik, E Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları, Mehmet Akif Ersoy Ü. *Journal of Social Sciences Institute*, 9(22): 155-172, 2017.

- [72] Fukushim, K.N. “A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position.” *Biol. Cybern.*, 36(4):193–202, 1980.
- [73] Hubel, D.H. and Wiesel, T.H. “Receptive fields and functional architecture of monkey striate cortex”, *J. Physiol.*, Vol. 195, No. 1, pp. 215–243. 1968.
- [74] Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P., “Gradient-based learning applied to document recognition”, *Proc. IEEE*, 86 (11): 2278–2324, 1998.
- [75] Y. Le Cun et al., —Handwritten digit recognition: applications of neural network chips and automatic learning, *IEEE Commun. Mag.*, 27(11): 41–46, Nov. 1989.
- [76] Şeker, A., Diri, B., Balık, H.H. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, *Gazi Mühendislik Bilimleri Dergisi*, 3(3): 47-64, 2017.
- [77] Gonzalez, R.C., Woods, R.E. *Digital Image Processing*, Pearson Publication, 1977.
- [78] Ser, G., Batı, C.T. Derin Sinir Ağları ile En İyi Modelin Belirlenmesi: Mantar Verileri Üzerine Keras Uygulaması, *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi Cilt 29, Sayı 3*, 2019.
- [79] Karakus, B. Derin sinir ağları için aktivasyon fonksiyonları <http://buyukveri.firat.edu.tr/2018/04/17/derin-sinir-aglari-icin-aktivasyon-fonksiyonlari/>, (Erşim Tarihi: 01.07.2021)
- [80] Doğan, F. Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması, *Sakarya Üniversitesi Journal Of Computer And Information Sciences*. (1), id. Saucis-1-2018, 2018.
- [81] Lin, M., Chen, Q., & Yan, S. Network in network. *arXiv preprint arXiv:1312.4400*, 2013.

- [82] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. Dropout: A simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929- 1958, 2014.
- [83] Li, H., Lin, Z., Shen, X., Brandt, J., & Hua, G. A convolutional neural network cascade for face detection. In *Proceedings of the IEEE Conference on Computer Vis*, 2015.
- [84] Tang, Y. Deep learning using linear support vector machines. arXiv preprint arXiv:1306.0239, 2013.
- [85] Mikolov, T., “Recurrent neural network-based language model,” in *Interspeech*, 2010.
- [86] Doğan, F., Türkoğlu, İ. Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi* 10 (2): 409-445, 2019.
- [87] Smolensky, P. “Information Processing in Dynamical Systems: Foundations of Harmony Theory,” 1986.
- [88] Hinton, G. E. and Salakhutdinov, R. R. “Reducing the Dimensionality of Data with Neural Networks,” *Science* 313, (5786):504–507, 2006.
- [89] Salakhutdinov, R. and Hinton, G. “Deep Boltzmann Machines,” in *International Conference on Artificial Intelligence and Statistics*, (3):11, 2009.
- [90] Carreira, M. A. and Hinton, G. E. “On Contrastive Divergence Learning,” *Artif. Intell. Stat.*, Vol. 10, 2005.
- [91] Hinton, G. E., Osindero, S. and Teh, Y.-W. “A Fast-Learning Algorithm for Deep Belief Nets,” *Neural Comput.* 18 (7): 1527–1554, 2006.

- [92] Ranzato, M., Huang, F. J., Boureau, Y.L. and LeCun, Y. “Unsupervised Learning of Invariant Feature Hierarchies with Applications to Object Recognition,” in 2007 IEEE Conference on Computer Vision and Pattern Recognition, 1–8, 2007.
- [93] Bengio Y., Lamblin P., Popovici D., and Larochelle, H. “Greedy layer-wise training of deep networks,” Proceedings of the 19th International Conference on Neural Information Processing Systems. MIT Press, 153–160, 2006.
- [94] Krizhevsky A. and Hinton G. E., “Using Very Deep Autoencoders for Content Based Image Retrieval,” in European Symposium on Artificial Neural Networks, 489–494, 2011.
- [95] Seker, A. and Gürkan, Y. “Stacked Autoencoder Method for Fabric Defect Detection,” Sci. Sci. J., 38: (2), 2017.
- [96] Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Chen, T., Recent advances in convolutional neural networks. Pattern Recognition, 2017.
- [97] Seyyarer, E., Ayata, F., Uçkan, T., Karcı, A. Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması ve Kıyaslanması, Anatolian Journal of Computer Sciences , Anatolian Science, 5(2): 90-98 ISSN:2548-1304, 2020.
- [98] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. “Going Deeper with Convolutions”, In IEEE Conference on Computer Vision and Pattern Recognition (CVPR’15), 1-9, 2015.
- [99] Krizhevsky, A., Sutskever, I., & Hinton, G. E. Imagenet classification with deep convolutional neural networks. In Advances in neural information processing systems 1097-1105, 2012.
- [100] Szegedy, C., Ioffe, S., Vanhoucke, V., Alemi, A. “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning”, Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17), 4278-4284, 2016.

- [101] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. "Rethinking the Inception Architecture for Computer Vision", In IEEE Conference on Computer Vision and Pattern Recognition (CVPR'16), 2818-2826, 2016.
- [102] He, K., Zhang, X., Ren, S., Sun, J. "Deep Residual Learning for Image Recognition", In IEEE Conference on Computer Vision and Pattern Recognition (CVPR'15), 770-778, 2015.
- [103] İnik, Ö., Ülker, E. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, Gaziosmanpaşa Journal of Scientific Research, 6(3:) 85-104, 2017.
- [104] Girshick, R., J. Donahue, T. Darrell and J. Malik. "Rich feature hierarchies for accurate object detection and semantic segmentation." 2014 Ieee Conference on Computer Vision and Pattern Recognition (Cvpr): 580-587, 2014.
- [105] Stanislav, D.G., Victor, P.s, Artem, A.B. Comparative Analysis of the Usage of Neural Networks for Sound Processing, 2020 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIconRus), 2020.
- [106] Turk, F., Luy, M., Barıscı, N. "Böbrek tümör segmentasyonu için U-Net ve U-Net+ResNet modellerinin karşılaştırılması", 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies, **DOI:** 2010.1109/ISMSIT.2019.8932725, 2019.
- [107] Turk, F., Luy, M., Barıscı, N. " Renal segmentation with an improved U-Net3D model", Journal of Medical Imaging and Health Informatics ISSN: 2156-7018, accepted date: dec., 2020.
- [108] Vununu, C., Lee, S., Khown, S.H. "A Dynamic Learning Method for the Classification of the HEP-2 Cell Images", IEEE, 2017.

- [109] Giovanni, M, UNetPlusPlus:
<https://github.com/MrGiovanni/UNetPlusPlus> (Erişim tarihi: 01.07.2021)
- [110] Zhou, Z., Rahman M., et al, "Unet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation", 2019.
- [111] Milletari, F., Nassir N., Ahmadi, S.A. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation, 2016 Fourth International Conference on 3D Vision (3DV), IEEE. 565–571, 2016.
- [112] Turk, F., Luy, M., Barisci, N Turk, F., Luy, M., Barisci, N. " Kidney and Renal Tumor Segmentation Using a Hybrid V-Net-Based Model, *MDPI Mathematics*, 8(10), 1772; 2020.
- [113] Zeiler, M.D., Fergus, R. Visualizing and understanding convolutional networks. In: *Computer vision–ECCV*, 818–833, 2014.
- [114] Ronneberger, O., Fischer, P., Brox, T. U-net: Convolutional networks for biomedical image segmentation. In: *Medical Image Computing and Computer-Assisted Intervention–MICCAI*, 234–241, 2015.
- [115] Yifei, Z., Olivier, M., Blanchon, M., Seulin, R., Rastgoo, M., Sidibé, D. Exploration of Deep Learning-based Multimodal Fusion for Semantic Road Scene Segmentation, 2019.
- [116] Zhang, Z., Huazhu, F., Dai, H.; Shen, J., Pang, Y., Shao. L. ET-Net: A Generic Edge-Attention Guidance Network for Medical Image Segmentation. Open Access: arXiv:1907.10936v1, 2019.
- [117] Fu, H., Cheng, J., et al.: Joint Optic Disc and Cup Segmentation Based on Multilabel Deep Network and Polar Transformation. *IEEE TMI*, 2018.

- [118] Wang, W., Shen, J., Ling, H. A deep network solution for attention and aesthetics aware photo cropping. IEEE PAMI, 2019.
- [119] Kaiming, H., Xiangyu, Z., Shaoqing, R., Jian, S. Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778, 2016.
- [120] Sudre, C.H., Li W.; Vercauteren, T., Ourselin, S., Cardoso, M.J. Generalized Dice overlap as a deep learning loss function for highly unbalanced segmentations, Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. DLMIA 2017, Lecture Notes in Computer Science, 10553, 240–248, 2017.
- [121] Chen, S., Holger, R., Hirohisa O., Masahiro, O., Yuichiro, H., Kazunari, M., Kensaku, M. On the influence of Dice loss function in multi-class organ segmentation of abdominal CT using 3D fully convolutional networks. Open access: arXiv:1801.05912v1, 2018.
- [122] Andrews, S., Hamarneh, G. Multi-Region Probabilistic Dice Similarity Coefficient using the Aitchison Distance and Bipartite Graph Matching. Open Access: arXiv:1509.07244v3, 2015.
- [123] The Cancer Imaging Archive (TCIA), Open Access:
<https://wiki.cancerimagingarchive.net/pages/viewpage.action?pageId=61081171>,
(Erişim Tarihi: 01.07.2021)
- [124] The KiTS19 Grand Challenge), Open Access:
[https:// kits19.grand-challenge.org/data/](https://kits19.grand-challenge.org/data/), (Erişim Tarihi: 01.07.2021)
- [125] Heller, N., Isensee, F., Klaus, H., et al. The state of the art in kidney and kidney tumor segmentation in contrast-enhanced CT imaging: Results of the KiTS19 Challenge, 2019.

ÖZGEÇMİŞ

Adı Soyadı :FUAT TÜRK
Doğum Tarihi :.....
Yabancı Dil : İngilizce

Eğitim Durumu : (Kurum ve Yıl)
Lisans : Gazi Üniversitesi-2004
Yüksek Lisans : Kırıkkale Üniversitesi-2012

Çalıştığı Kurum/Kurumlar ve Yıl/Yıllar: Millî Eğitim Bakanlığı / 2004-...

Yayımları (SCI) :

Turk F., BARIŞCI N. , Ciftci A., Ekmekci Y. Comparison of Multi-Layer Perceptron and Jordan Elman Neural Networks for Diagnosis of Hypertension, Intelligent Automation and Soft Computing, cilt.21, ss.123-134, 2015.

Turk, F., Luy, M., Barıscı, N Turk, F., Luy, M., Barıscı, N. " Kidney and Renal Tumor Segmentation Using a Hybrid V-Net-Based Model, MDPI *Mathematics*, 8(10), 1772; 2020.

Turk, F., Luy, M., Barıscı, N. " Renal segmentation with an improved U-Net3D model", Journal of Medical Imaging and Health Informatics ISSN: 2156-7018, accepted date: dec., 2020.

Yayımları (Diğer) :

Turk F., BARIŞCI N., Ciftci A, Comparison of Principal Component Analysis and Radial Basis Function Network for Diagnosis of Hypertension, 9TH International Conference on Electronics, Computer and Computation, 01-03 Aralık 2012.

TÜRK F., LÜY M., BARIŞCI N. Böbrek Tümör Segmentasyonu İçin Unet ve Unet-ResNet Modellerinin Karşılaştırılması, 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT-2019), 11- 13 Ekim 2019.

TÜRK F., LÜY M., BARIŞCI N. Machine Learning of Kidney Tumors and Diagnosis and Classification by Deep Learning Methods, Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 2019

TÜRK F., LÜY M., BARIŞCI N. Multi Depth V-Net model ile 3 boyutlu böbrek ve tümör segmentasyonu, Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 2020.

Araştırma Alanları : Yapay Zekâ, Derin Öğrenme, Bilgisayarda Öğrenme ve Örüntü Tanıma, Programlama Dilleri (Python, C#, Mysql, Oracle)

