



T.C.

BARTIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME TABANLI SEGMENTASYON MODELLERİNİN
PANKREAS GÖRÜNTÜLERİ ÜZERİNDE KARŞILAŞTIRMALI
ANALİZİ

AZİM USLUCUK

DANIŞMAN

DOÇ. DR. HAKAN ÖCAL

BARTIN-2026



T.C.

BARTIN ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

AKILLI SİSTEMLER MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME TABANLI SEGMENTASYON MODELLERİNİN PANKREAS
GÖRÜNTÜLERİ ÜZERİNDE KARŞILAŞTIRMALI ANALİZİ**

YÜKSEK LİSANS TEZİ

Azim USLUCUK

JÜRİ ÜYELERİ

Danışman : Doç. Dr. Hakan ÖCAL

Üye : Dr. Öğr. Üyesi Serkan AKSU

Üye : Dr. Öğr. Üyesi Ümit ŞENTÜRK

BARTIN-2026

KABUL VE ONAY

Azim USLUCUK tarafından hazırlanan “PANKREAS GÖRÜNTÜLERİ ÜZERİNDE DERİN ÖĞRENME TABANLI SEGMENTASYON MODELLERİNİN KARŞILAŞTIRMALI ANALİZİ” başlıklı bu çalışma, 08.01.2026 tarihinde yapılan savunma sınavı sonucunda oy birliği ile başarılı bulunarak jürimiz tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Başkan : Doç. Dr. Hakan ÖCAL

Üye : Dr. Öğr. Üyesi Serkan AKSU

Üye : Dr. Öğr. Üyesi Ümit ŞENTÜRK

Bu tezin kabulü Lisansüstü Eğitim Enstitüsü Yönetim Kurulu’nun/...../20... tarih ve 20...../.....-..... sayılı kararıyla onaylanmıştır.

Prof. Dr. Zafer CEYLAN
Enstitü Müdürü

BEYANNAME

Bartın Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre Doç. Dr. Hakan ÖCAL danışmanlığında hazırlamış olduğum “DERİN ÖĞRENME TABANLI SEGMENTASYON MODELLERİNİN PANKREAS GÖRÜNTÜLERİ ÜZERİNDE KARŞILAŞTIRMALI ANALİZİ” başlıklı yüksek lisans tezimin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

08.01.2026

Azim USLUCUK



YAPAY ZEKÂ KULLANIMINA İLİŞKİN BEYAN

☐ Tez yazım sürecinde yapay zekâ tabanlı araçlardan **faydalanmadım**.

☒ Tez yazım sürecinde yapay zekâ tabanlı araçlardan **faydalandım**. Bu kapsamda, yapay zekâ destekli araçların kullanımına ilişkin aşağıdaki hususları beyan ederim:

1. Bu çalışmada, yalnızca bilimsel üretim sürecini desteklemek amacıyla yapay zekâ tabanlı araçlardan yararlanılmış olup; kullanılan araçların işlevi, katkı düzeyi ve sınırları açık biçimde eklerde belirtilmiştir. Bu kapsamda kullanılan yapay zekânın kapsamı hipotez geliştirme, teorik tartışma ve yorumlama gibi üst düzey beceri, deneyim ve uzmanlık gerektiren aşamaları içermemektedir.
2. Yapay zekâ kullanımı, çalışmanın özgünlüğüne, bilimsel etik kurallarına ve ilgili mevzuata aykırı olmayacak biçimde gerçekleştirilmiştir.
3. Usulsüz yapay zekâ kullanımı (örneğin: kaynak göstermeksizin metin üretimi, otomatik içerik üretiminin özgün eser gibi sunulması, yanıltıcı kaynak gösterimi vb.) tarafımdan kesinlikle yapılmamıştır.
4. Çalışmanın hazırlanmasında kullanılan yapay zekâ araçları ve işlevleri ekte sunulan tabloda ayrıntılı olarak belirtilmiş olup bu kullanım danışman öğretim üyesinin bilgisi dahilinde gerçekleştirilmiştir.
5. Yukarıda yer alan beyanımın gerçeğe aykırı olduğunun tespiti hâlinde, yükseköğretim mevzuatı, ilgili etik kurallar ve Bartın Üniversitesi disiplin mevzuatı çerçevesinde hakkımda yaptırım uygulanabileceğini bildiğimi ve bu sonuçları kabul ettiğimi taahhüt ederim.

08.01.2026

Azim USLUCUK

ÖN SÖZ

Bu tez çalışmasının tamamlanmasında emeği geçenlere gönülden teşekkür ederim.

Öncelikle, hayatımda her zaman en büyük desteği sağlayan, yanımda olan ve desteğiyle bana güç veren sevgili eşim Ayten Uslucuk’a teşekkür ederim. Onun anlayışı ve sevgisi, bu süreci daha katlanabilir kıldı.

Tezimin asıl konusu, ne yazık ki aramızdan ayrılmış olan annem Şazimet Uslucuk'un hastalığına dair bir çalışmadır. Annemin yoğun ve zorlu geçen hastalık süreci, bu çalışmanın ana ilham kaynağıdır. Kendisine bu vesileyle bir kez daha Allah'tan rahmet diliyor, her an onu sevgi ve özlemle anıyorum.

Ayrıca, bu tezin ortaya çıkmasında büyük katkıları olan değerli danışman hocam Sayın Hakan Öcal'a sonsuz teşekkürlerimi sunmak isterim. Hocamın engin bilgi birikimi, yol göstericiliği ve her daim sunduğu destek, tezimin şekillenmesinde çok önemli bir rol oynamıştır. Onun sabrı, rehberliği ve akademik katkıları olmadan bu çalışmayı tamamlamak mümkün olamazdı.

Bu tezi, sevgili annem Şazimet Uslucuk’a adıyor, bu süreçte destek olan herkese en içten teşekkürlerimi sunuyorum.

Saygılarımla,

Azim USLUCUK

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME TABANLI SEGMENTASYON MODELLERİNİN PANKREAS GÖRÜNTÜLERİ ÜZERİNDE KARŞILAŞTIRMALI ANALİZİ

Azim USLUCUK

Bartın Üniversitesi

Lisansüstü Eğitim Enstitüsü

Akıllı Sistemler Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Hakan ÖCAL

Bartın-2026, sayfa: 75

Pankreas, özellikle lipaz enzimiyle besinlerdeki yağı parçalayan ve diğer birçok hormonal görevi de olan vücudun hayati organlarından biridir. Endokrin işlevindeki rolü, hormonlar üreterek kan şekeri seviyelerini kontrol etmektir. İnsülin belki de en önemli örnektir ve ayrıca sindirim sisteminin bazı bölgelerinde normal hormon salınımını sağlar. Bu iki işlev bir arada iyi gitmediğinde ciddi sağlık sorunları ortaya çıkabilir. Pankreas patolojileri kanser, diyabet, pankreatit, hormonal düzensizlik veya sindirim sorunlarıdır.

Çoğu pankreas bozukluğu yaşamı tehdit edici olduğundan, hekimler tarafında öncelik verilen tetkikler arasında. Pankreas hastalıklarının tespitinde ilk olarak kan ve idrar testleri yapılır. BT (Bilgisayarlı Tomografi), MRG (Manyetik Rezonans Görüntüleme), EUS (Endoskopik Ultrasonografi) gibi ek görüntüleme teknikleri, hastanın ihtiyaç duyması durumunda daha ileri incelemeler için kullanılır. Bu teknikler, pankreasın yapısını ve işlevini ayrıntılı olarak incelemek için kullanılır. Pankreas görüntüleri üzerinde tanımlama ve hatlarının belirlenmesi işlemlerine "pankreas segmentasyonu" denir. Segmentasyon süreci, doğru pankreas değerlendirmesi için gereklidir. Pankreas, bir kişiden diğerine büyük ölçüde boyut ve şekil açısından farklılık gösterir. Manuel segmentasyon zaman alır ve tüm hekimler için aynı şekilde çalışmaz. Bu görev deneyim gerektirir ve uzun, zahmetli bir süreç olabilir.

Segmentasyon sürecinde hekime ön değerlendirme olarak segmente edilmiş bir görsel sunmak, değerlendirme sürecinin hızlanmasına ve hekimin dikkatinin daha uzun süre korumasına destek olacaktır.

Son yıllarda, bu zorlu sorunları çözmek ve daha doğru sonuçlar elde etmek için derin öğrenme tabanlı organ segmentasyon yöntemlerine ilgi artmıştır. Derin öğrenme, teşhis verileri ve tıbbi görüntülerin yüksek doğruluk oranlarıyla sınıflandırılması gibi işlemlerde detay seviyesini artırmak için yüksek potansiyelli makine öğrenimi uygulaması olduğunu kanıtlamıştır. Derin Öğrenmeye dayalı mevcut segmentasyon teknikleri, insan çabasına kıyasla daha iyi tutarlılık ve hız sunarak burada yaygın olarak uygulanmaktadır.

Bu çalışmada kamuya açık veri seti kullanılarak pankreas segmentasyonu için iki ayrı çalışma gerçekleştirilmiştir.

Birinci çalışmada U-net ve V-net mimarileri karşılaştırılmıştır. Veri seti eğitim için %80 ve doğrulama için %20 olarak ayrılmıştır. Elde edilen bulgularda U-net mimarisi doğrulama duyarlılığı 99.78 eşitti ve 0.041 doğrulama kaybı elde ettik. V-net mimarisinin doğrulama duyarlılığı 99.75, doğrulama kaybı 0.046 olarak elde edilmiştir.

İkinci çalışmada aynı veri seti eğitim için %80, doğrulama için %10 ve test için %10 olarak ayrılmış ve U-Net, V-Net2B, Dikkat tabanlı UNet2B, TransUNet2B, Swin-UNet2B ve Focal-UNet2B derin öğrenme mimarileri karşılaştırılmıştır. Elde edilen bulgularda Dice skoru; U-Net2B 86.55, V-Net2B 82.09, Dikkat tabanlı UNet2B 85.47, TransUNet2B 85.28, Swin-UNet2B 85.63, ve Focal-UNet2B için 84.55 olarak elde edilmiştir. Mimarilerin yüksek doğruluk oranları, derin öğrenme yaklaşımlarının pankreas segmentasyonunda başarılı olduğunu kanıtlamaktadır.

Pankreas segmentasyonu, özellikle pankreas hastalıkları için cerrahi bağlamda son derece önemlidir. Cerrahi, pankreas kanseri gibi ölümcül hastalıkların tedavisinde en etkili yöntemlerden biri olarak kabul edilir. Ancak cerrahi sırasında başarılı olmak için pankreasın doğru bir şekilde belirlenmesi, hasta ve hekimler açısından çok önemlidir. Sadece cerrahi müdahale için değil, aynı zamanda hastalık tedavisinin değerlendirilmesi ve tedavinin etkinliğinin analizi için de hekimler açısından önemlidir.

Bu nedenle, teşhis ve tedavide hem hız hem de doğruluk açısından segmentasyonun doğruluğu ve hızı esastır. Hastanın bakış açısından hastalığın teşhisinde büyük önem taşıdığı not edilmelidir. Bu süreçlerdeki hataların giderilmesini kolaylaştıran derin öğrenme algoritmalarına dayalı bu metodolojiler, hastalıkların daha erken ve daha doğru bir şekilde tespit edilmesine yardımcı olur.

Anahtar Kelimeler: Derin Öğrenme, Pankreas, Segmentasyon, Yapay Sinir Ağları, Yapay Zeka.

Bilim Alanı Kodu: 92432 - (Bilgisayar Bilimleri ve Mühendisliği Yapay Zeka), 92418 - (Bilgisayar Bilimleri ve Mühendisliği Görüntü İşleme), 92414 - (Bilgisayar Bilimleri ve Mühendisliği Büyük Data)

ABSTRACT

M. Sc. Thesis

COMPARATIVE ANALYSIS OF DEEP LEARNING–BASED SEGMENTATION MODELS ON PANCREATIC IMAGES

Azim USLUCUK

Bartın University

Graduate School

Department of Intelligent Systems Engineering

Thesis Advisor: Assoc. Prof. Dr. Hakan ÖCAL

Bartın-2026, pp: 75

The pancreas is one of the vital organs of the human body, responsible for breaking down dietary fats through the lipase enzyme and performing various hormonal functions. Its endocrine role involves producing hormones that regulate blood glucose levels. Insulin is perhaps the most significant example, and additionally, the pancreas facilitates normal hormonal secretion in certain parts of the digestive system. Serious health problems may arise when these two functions do not work in harmony. Pancreatic pathologies include cancer, diabetes, pancreatitis, hormonal disorders, and digestive complications.

Since most pancreatic disorders are life-threatening, they are among the investigations prioritized by physicians. Initial detection of pancreatic diseases is performed using blood and urine tests. Additional imaging techniques such as CT (Computed Tomography), MRI (Magnetic Resonance Imaging), and EUS (Endoscopic Ultrasonography) are utilized for further examination if necessary. These methods allow detailed evaluation of the pancreas in terms of its structure and function. The identification and delineation of pancreatic boundaries on medical images are called “pancreatic segmentation.” The segmentation process is essential for accurate pancreatic assessment. The pancreas can vary significantly in size and shape from one individual to another. Manual segmentation is time-consuming

and does not yield uniform results across all physicians. This task requires experience and may be prolonged and labor-intensive. Providing a pre-segmented visual representation to clinicians during the assessment process may accelerate evaluation and help maintain longer concentration.

In recent years, interest in deep learning-based organ segmentation methods has increased in order to address these challenges and to obtain more accurate results. Deep learning has proven to be a high-potential machine learning application that enhances precision in tasks such as diagnosis and classification of medical images with high accuracy. Existing segmentation techniques based on deep learning are widely used due to their improved consistency and speed compared to human effort.

In this study, two separate experiments were conducted for pancreatic segmentation using a publicly available dataset.

In the first experiment, U-Net and V-Net architectures were compared. The dataset was split into 80% for training and 20% for validation. The findings showed that the U-Net architecture achieved a validation accuracy of 99.78 with a validation loss of 0.041. The V-Net architecture achieved a validation accuracy of 99.75 and a validation loss of 0.046.

In the second experiment, the same dataset was divided into 80% for training, 10% for validation, and 10% for testing. The U-Net, V-Net2D, Attention-based U-Net2D, TransU-Net2D, SwinU-Net2D, and FocalU-Net2D deep learning architectures were compared. The Dice score results were obtained as follows: U-Net2D 86.55, V-Net2D 82.09, Attention-based UNet2D 85.47, TransUNet2D 85.28, Swin-UNet2D 85.63, and Focal-UNet2D 84.55. The high accuracy rates of the architectures demonstrate the success of deep learning approaches in pancreatic segmentation.

Pancreatic segmentation is extremely important, especially in the surgical context of pancreatic diseases. Surgery is considered one of the most effective treatments for life-threatening conditions such as pancreatic cancer. However, the successful completion of surgery requires accurate delineation of the pancreas, which is essential for both patients and clinicians. In addition to surgical intervention, segmentation is also critical for evaluating disease progression and analyzing treatment effectiveness.

Therefore, the accuracy and speed of segmentation are crucial for both diagnosis and treatment. From the patient's perspective, segmentation plays a significant role in disease identification. Methodologies based on deep learning algorithms, which help minimize errors in these processes, enable earlier and more accurate diagnosis of diseases.

Keywords: Artificial Intelligence, Artificial Neural Networks, Deep Learning, Pancreas, Segmentation.

Scientific Field Code: 92432 – Computer Science and Engineering (Artificial Intelligence), 92418 – Computer Science and Engineering (Image Processing), 92414 – Computer Science and Engineering (Big Data)



İÇİNDEKİLER

KABUL VE ONAY.....	ii
BEYANNAME	iii
YAPAY ZEKÂ KULLANIMINA İLİŞKİN BEYAN	iv
ÖN SÖZ	v
ÖZET	vi
ABSTRACT	ix
İÇİNDEKİLER.....	xii
ŞEKİLLER DİZİNİ.....	xiv
TABLolar DİZİNİ.....	xvi
EKLER DİZİNİ.....	xvii
SİMGELER VE KISALTMALAR DİZİNİ.....	xviii
1. GİRİŞ.....	1
1.1 Pankreas Segmentasyonunun Önemi.....	2
1.2 Yapay Zeka ve Derin Öğrenme	3
1.3 Pankreas Segmentasyonu ve Derin Öğrenme	3
1.4 Derin Öğrenme Modelleri	4
1.4.1 U-Net.....	5
1.4.2 V-Net.....	5
1.4.3 TransUNet.....	6
1.4.4 Swin-UNet	6
1.4.5 Focal-UNet	7
1.5 Kamuya Açık Veri Setleri	8
1.6 Zorluklar ve Sınırlamalar	8
1.7 Sonuç ve Gelecek Yönelimler.....	8
2. LİTERATÜR ÖZETİ.....	10
3. MATERYAL VE METOT	18
3.1 Derin Öğrenme Mimarisinin Kavramları	18
3.1.1 Yapay Sinir Ağları (Artificial Neural Networks, ANN)	18
3.1.2 Katmanlar (Layers)	19
3.1.2.1 Giriş Katmanı (Input Layer).....	20

3.1.2.2 Kodlayıcı Bloğu (Encoder Block).....	20
3.1.2.3 Çözücü Bloğu (Decoder Block)	36
3.1.2.4 Çıkış Katmanı	40
3.2 Veri Seti Seçimi ve Verilerin Hazırlanması.....	41
3.2.1 NIH-CT82 Veri Seti: Hazırlanma Süreci ve İçeriği.....	41
3.2.2 U-Net ve V-Net Modellerinin NIH-CT82 ile Kullanımı	42
3.2.3 NIH-CT82 Veri Setinin Seçilmesinin Önemi.....	43
3.2.4 Sonuç	43
3.3 Yapılan Çalışma 1.....	44
3.3.1 Temel U-Net Derin Öğrenme Ağı.....	44
3.3.2 Temel V-Net Derin Öğrenme Ağı.....	46
3.3.3 Performans Ölçütü.....	47
3.4 Yapılan Çalışma 2.....	48
3.4.1 Dikkat tabanlı UNet2B (Attention UNet).....	48
3.4.2 TransUNet2B	50
3.4.3 Swin-UNet2B.....	52
3.4.4 Focal-UNet2B.....	53
3.4.5 Performans Ölçütü.....	54
4. BULGULAR VE TARTIŞMA	56
4.1 Yapılan Çalışma 1.....	56
4.1.1 Modelin uygulama ayrıntıları	57
4.1.2 Modelin uygulama sonuçları.....	57
4.2 Yapılan Çalışma 2.....	58
4.2.1 Modelin uygulama ayrıntıları	59
4.2.2 Modelin uygulama sonuçları.....	61
5. SONUÇ VE ÖNERİLER	64
5.1. Araştırma Sonuçları	64
5.2. Araştırma Bulgularına Dayalı Öneriler	64
KAYNAKLAR.....	66
BİBLİYOGRAFYA	72
EKLER	73
ÖZGEÇMİŞ	74

ŞEKİLLER DİZİNİ

Şekil No	Sayfa No
1.1: Amerikan Kanser İstatistik Merkezi Verileri 2025	2
3.1: Yapay Sinir Ağının Matematiksel Modeli	19
3.2: Derin Öğrenme Ağı.....	19
3.3: Giriş Katmanı	20
3.4: Evrişim işleminin 2B'de görselleştirilmesi.....	21
3.5: Örnek 2B Konvolüsyon Tensorflow kütüphanesinde kullanımı.....	22
3.6: Evrişim işleminin 3B'de görselleştirilmesi.....	23
3.7: 3B Konvolüsyon kullanımı	24
3.8: Yaygın Kullanılan Aktivasyon Fonksiyonları Grafiği	24
3.9: ReLU Aktivasyon Fonksiyonu.....	25
3.10: PReLU Aktivasyon Fonksiyonu.....	27
3.11: PReLU Aktivasyon Fonksiyonunun Kullanımı	27
3.12: GELU Aktivasyon Fonksiyonu.....	28
3.13: GELU Aktivasyon Fonksiyonunun Kullanımı.....	29
3.14: Maksimum Havuzlama İşlemi	30
3.15: Maksimum Havuzla Yönteminin Kullanımı	31
3.16: Aşağı Örneklemede Maksimum Havuzlama Kullanımı	32
3.17: Aşağı Örneklemede 2B Evrişim Kullanımı	32
3.18: Transformer Mimarisi	33
3.19: Geri Yayılım.....	38
3.20: Optimizasyon Algoritmaları.....	39
3.21: NIH-CT82 Veri Seti Örnekleri.....	42
3.22: U-Net.....	45
3.23: V-Net.....	47
3.24: Dikkat Tabanlı U-Net.....	49
3.25: TransUNet	51
3.26: Swin-UNet.....	52
3.27: Focal-UNet.....	54
4.1: Temel Unet Eğitim Doğruluğu	57
4.2: Temel Vnet Eğitim Doğruluğu	58

4.3: Segmentasyon Sonuçları	63
--	-----------



TABLÖLAR DİZİNİ

Tablo No	Sayfa No
3.1: Yaygın Kullanılan Aktivasyon Fonksiyonları Tablosu.....	24
3.2: Optimizasyon Algoritmaları.....	40
4.1: Modellerin karşılaştırmalı performans sonuçları çalışma 1	58
4.2: Modellerin karşılaştırmalı performans sonuçları çalışma 2	62



EKLER DİZİNİ

Ek	Sayfa
No	No
Ek 1. Yapay zekâ kullanım tablosu.....	76



SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER


KISALTMALAR

YZ	: Yapay Zeka
TEA	: Tam Evrişimli Ağlar
ESA	: Evrişimli Sinir Ağları
2B	: 2 Boyutlu
BT	: Bilgisayarlı Tomografi
3B	: 3 Boyutlu
MR	: Manyetik Rezonans

1. GİRİŞ

Pankreas, sindirim sistemi ve endokrin sistemlerde kritik bir rol oynayan hayati bir organdır. Sindirim sistemi açısından, pankreas gıdaların sindirilmesine yardımcı olan enzimleri salgılar. Endokrin sistemde ise insülin gibi hormonların üretiminden sorumludur. Bu nedenle pankreasın doğru bir şekilde incelenmesi ve tıbbi görüntülerde doğru segmentasyonunun yapılması hastalıkların teşhis ve tedavisinde büyük önem taşır.

Pankreas segmentasyonu, tıbbi görüntülerde pankreasın sınırlarının belirlenmesi ve diğer organlardan ayrılması için yapılan işleme verilen isimdir. Tıbbi görüntüleme, hastalıklara invaziv olmayan bir yaklaşımla tanı koyma amacıyla sıkça kullanılan bir tekniktir ve laboratuvar testlerinden sonra en yaygın tanı yöntemi olarak kabul edilir (Aljabri ve AlGhamdi, 2022; Kasban vd. 2015). Segmentasyon işlemi, özellikle pankreas gibi karmaşık, bireyler arasında büyük anatomik varyasyonlar gösteren bir organ olduğu için oldukça zorlayıcı bir süreçtir. Bu zorlukların üstesinden gelmek için YZ teknolojileri ve son yıllarda popüler hale gelen derin öğrenme algoritmalarından yararlanılmaktadır. Derin öğrenme, tıbbi görüntü işlemlerinde segmentasyon sürecini otomatikleştirerek doğruluğu artırmakta ve manuel segmentasyonun neden olduğu zaman kaybı ile hata riskini azaltmaktadır. Bu derinlemesine incelemede, pankreas segmentasyonu süreçlerinde kullanılan derin öğrenme tabanlı yöntemleri ve bu alandaki en güncel literatür incelemelerini detaylandıracağız.



Şekil 1.1: Amerikan Kanser İstatistik Merkezi Verileri 2025

Pankreas kanseri, tanı anında genellikle ileri evrede olması nedeniyle kötü prognoza sahip bir hastalıktır. Amerikan Kanser Derneği'nin (American Cancer Society, 2023) verilerine göre (şekil 1.1), pankreas kanserinde tüm evreleri kapsayan 5 yıllık sağkalım oranı yaklaşık %11 seviyesindedir. Erken evrede (lokalize hastalık) teşhis konulan hastalarda bu oran %39'a kadar çıkarken, ileri evrede (metastatik hastalık) ise %3 civarına düşmektedir. Bu durum, pankreas kanserinin erken tanısının kısıtlı olması ve agresif seyri nedeniyle sağkalım oranlarının genel olarak düşük kalmasına neden olmaktadır (*Facts About Pancreatic Cancer*, t.y.).

1.1 Pankreas Segmentasyonunun Önemi

Pankreas, sindirim enzimleri ve insülin gibi kan şekeri düzenleyici hormonların salgılanmasında da önemli bir rol oynar. Pankreasın anatomisi ve bölümleri hakkında yapılan hatalı segmentasyon, teşhis ve tedavi süreçlerinde ciddi sorunlara yol açabilir. Pankreatit ve pankreas kanseri gibi ciddi hastalıkların erken teşhis ve tedavisi için pankreasın doğru bir şekilde görüntülenmesi ve analiz edilmesi son derece önemlidir. 2022 yılında bildirilen pankreas kanseri vakalarının %52'sinin dördüncü aşamada olduğu dikkate alındığında, yapay zeka tekniklerinin kanserin erken tespit ve analizi üzerindeki önemi daha da belirginleşmektedir (Chhikara vd. 2024). Pankreas segmentasyonu, özellikle bu süreçlerde etkin bir araçtır.

Pankreas segmentasyonu süreci, belirgin anatomik varyasyon farklılıkları, düşük kontrast ve komşu organlar ile karmaşık ilişkiler nedeniyle zor bir görevdir. Manuel segmentasyon bu zorluklar nedeniyle zaman alıcı ve hata yapma olasılığı yüksek bir işlem olabilir (Oktay vd. 2018). Farklı hastaların pankreas yapıları arasında önemli farklılıklar olabildiği için, bu işleme olan ihtiyaç daha da ön plana çıkmaktadır. Derin öğrenme tabanlı yöntemler, bu sorunların üstesinden gelmek amacıyla geliştirilmeye çalışılmaktadır. Bu alanda devrim niteliğinde ilerlemeler kaydedilmiştir.

1.2 Yapay Zeka ve Derin Öğrenme

YZ, bilgisayar sistemlerinin insan benzeri öğrenme ve problem çözme yeteneklerini geliştirmeye yönelik çalışmaları kapsar. Yapay zekanın tarihi 1950'li yıllara kadar uzanıyor. Ancak, teknolojinin çeşitli kış dönemlerinden geçmesi ve veri işleme kapasitesinin sınırlı olması nedeniyle bu alandaki gelişmeler yavaş ilerlemiştir. 2000'li yıllardan sonra, büyük veri kümeleri analiz edilebilir hale gelmiştir. İşlem gücündeki artış ve algoritmalarındaki gelişmeler sayesinde YZ hızlı bir ivme kazanmıştır. Bu dönemde, en dikkat çeken YZ alt dallarından biri olan derin öğrenme tıbbi görüntü işleme alanında öne çıkmıştır (Şentürk ve Latifoğlu, 2023).

Derin öğrenme, katmanlı yapay sinir ağları aracılığıyla büyük veri setlerinden özellikler çıkarma yeteneğine sahiptir. Görüntü analizinde, derin öğrenme modelleri veriler arasındaki karmaşık ilişkileri öğrenerek daha doğru ve hızlı sonuçlar elde edebilmektedir. Özellikle tıbbi görüntüleme, organ segmentasyonu gibi karmaşık görevlerde yüksek başarı oranlarıyla öne çıkmaktadır (Ayhan vd. 2020).

1.3 Pankreas Segmentasyonu ve Derin Öğrenme

Pankreas segmentasyonu için manuel yöntemlerin zorlukları göz önüne alındığında, derin öğrenme tabanlı algoritmalar avantajlar sunmaktadır. Bu algoritmalar, pankreasın sınırlarını ve diğer organlarla olan temaslarını hassas bir şekilde belirleyerek, teşhis ve tedavi süreçlerine katkıda bulunur. Ayrıca, her hastanın anatomik farklılıklarına uyum sağlayabilir ve farklı şekil ve boyutlardaki pankreaslarda daha başarılı segmentasyon sonuçları elde edebilirler.

Derin öğrenme, büyük veri kümelerini çok hızlı ve verimli bir şekilde analiz etme yeteneğine sahiptir. Manuel segmentasyon işlemleri için uzun vakitler ayırmak gerekirken, derin öğrenme tabanlı algoritmalar bu işlemleri dakikalar içinde tamamlayabilir. Bu da klinik pratikte önemli ölçüde zaman tasarrufu sağlar.

Ayrıca, manuel segmentasyon insan hatalarına açık bir süreçtir. Aynı görüntüyü farklı kişiler analiz ettiğinde farklı sonuçlar elde edilebilirken, derin öğrenme algoritmaları aynı tekrarlanabilir sonuçlar üretir. Bu durum, tıbbi teşhis ve tedavi süreçlerinde güvenilirliği artırır (Wang vd. 2021). Derin öğrenme yöntemleri, yalnızca pankreasın sınırlarını değil dokusu ve yoğunluğu gibi ek özellikleri de çıkarabilir. Bu da pankreas hastalıklarının tanı ve tedavisinde daha fazla bilgi sağlar.

1.4 Derin Öğrenme Modelleri

Pankreas segmentasyonu için kullanılan popüler derin öğrenme mimarileri arasında U-Net ve V-Net gibi modeller ile varyasyonları öne çıkar.

2B dilimler, organların hacimsel yapısını değerlendirmek için sınırlı bilgi sağlar, bu da pankreas gibi organ segmentlerinin detaylı anlaşılması için önemli bir özelliktir. Bu nedenle, 3B ESA tabanlı modeller hacimsel veri işleme alanında yaygın olarak kullanılmaktadır. Üç boyutlu modellerle, 3B evrişimli sinir ağları daha hassas ve doğru segmentasyon sunar ve görüntülerin üç boyutlu yapısını dikkate alacak şekilde tasarlanmıştır. Bu yöntem, pankreas ile komşu organlar ve dokular arasındaki sınırların belirlenmesi için önemli avantajlar sağlar.

3B ESA'lar, pankreasın BT görüntülerinden elde edilen üç boyutlu veriler üzerinde çalışarak hacimsel segmentasyon sağlar. Bu modeller, 2B yöntemlere kıyasla daha büyük veri setlerine ihtiyaç duyabilir. Ancak pankreasın küçük boyutlu ve düzensiz yapısı göz önüne alındığında, 3B evrişimli sinir ağları daha doğru sonuçlar vermektedir. Hesaplama maliyeti ve yüksek kapasite ihtiyaçları sistemin dezavantajlarından biridir.

Tam evrişimli ağlar, görüntü segmentasyonunda derin öğrenme tabanlı ilk yaygın kullanılan mimarilerden biridir. TEA, geleneksel Evrişimli sinir ağlarının son katmanındaki tam bağlantılı (fully connected) katmanları çıkararak, tüm görüntü üzerindeki her pikselin sınıflandırılmasını sağlar. Bu yöntem, pankreas segmentasyonu için kullanılan ilk derin

öğrenme yaklaşımlarından biri olmuştur ve özellikle 2B BT dilimleri üzerinde başarılı sonuçlar vermektedir. Ancak TEA tabanlı modellerin, pankreas gibi farklı boyutlarda ve düzensiz şekilli organlarda, özellikle sınır tespitinde sınırlamaları bulunur.

1.4.1 U-Net

U-Net, tıbbi görüntü segmentasyonu alanında geliştirilmiş bir tür ESA yaklaşımıdır. Kodlayıcı-kod çözücü (Encoder-decoder) mimari yapısına sahip olan U-Net, görüntülerin özelliklerini çıkarırken yüksek çözünürlükte sonuçlar da üretir. Bu modelin en büyük avantajı, küçük veri kümeleriyle bile başarılı sonuçlar elde edebilmesidir. Kodlayıcı kısmı, görüntülerin temel özelliklerini çıkarırken, kod çözücü kısmı bu özellikleri birleştirerek segmentasyonu gerçekleştirir (Ayhan vd. 2020). U-Net'in başarısı, her seviyede elde edilen özelliklerin simetrik bir şekilde genişletilmesine (upsampling) ve segmentasyon sonucunun daha keskin sınırlarla üretilmesine dayanır. Pankreas segmentasyonu çalışmalarında, U-Net'in çeşitli modifikasyonları da sıkça kullanılmaktadır. Attention U-Net, pankreasın çevresindeki organlardan daha iyi ayrılabilmesi için dikkat mekanizmalarını kullanır. Residual U-Net ise, daha derin katmanlarda bilgi kaybını azaltmak ve öğrenme sürecini hızlandırmak amacıyla artık bağlantılar (residual connections) ekler. Bu tür varyasyonlar, pankreas gibi çevresel organlarla sınırları belirlemenin zor olduğu yapılar için oldukça etkilidir.

1.4.2 V-Net

V-Net, U-Net'e benzer bir yapıya sahip olup, segmentasyon için özel olarak optimize edilmiştir. Özellikle organ segmentasyonu gibi üç boyutlu görüntülerde belirgin bir performans sergiler. Pankreas gibi organların segmentasyonu, organın tüm hacmi hakkında daha doğru bilgiler sunarak tedavi planlamasında önemli avantajlar sağlar (Zhu vd. 2022).

Pankreas segmentasyonu için kullanılan önemli derin öğrenme mimarilerinden biri V-Net'tir. V-Net, özellikle 3B volümetrik tıbbi görüntü segmentasyonu amacıyla tasarlanmış bir derin öğrenme modelidir ve 3B U-Net'e benzer bir kolayıcı - çözücü (encoder-decoder) yapısını benimser. Ancak, V-Net'in en büyük farkı, volümetrik verileri işlemek üzere özel olarak geliştirilmiş olmasıdır. Hacimsel derinlik bilgisi içeren tıbbi görüntülerde daha başarılı sonuçlar elde edebilmektedir.

V-Net, giriş olarak 3B volümetrik tıbbi görüntüleri alır. Çıkış olarak her bir vokselin (3B piksel) hangi sınıfa ait olduğunu belirler. Bu özellik, pankreas segmentasyonu için büyük bir avantaj sunar çünkü pankreasın çevresindeki organlarla olan karmaşık sınırlarını daha net bir şekilde ayırt edebilir. V-Net ayrıca, artık (residual) bloklar kullanarak öğrenmeyi hızlandırır ve daha derin katmanlardaki bilgi kaybını azaltır.

V-Net'in sağladığı en önemli avantajlardan biri, zar kaybı (dice loss) fonksiyonunu kullanarak segmentasyonun doğruluğunu optimize etmesidir. Zar kaybı fonksiyonu, sınıflar arası dengeyi sağlayarak, küçük organlar (örneğin pankreas) üzerinde daha iyi performans gösterir. Pankreas gibi organların segmentasyonu sırasında sınıf dengesizliği (organın görüntüdeki alanının küçük olması) önemli bir sorun olabilir ve zar kaybı fonksiyonu bu sorunu minimize eder.

1.4.3 TransUNet

TransUNet, tıbbi görüntü segmentasyonu alanında U-Net mimarisine dönüştürücü (Transformer) tabanlı yaklaşımların üç boyutlu olarak birleştirildiği bir modeldir. Bu mimari ESA (Convolutional Neural Network) tabanlı katmanlar ile dönüştürücü katmanların uzun menzilli bağlantıların modelleme yeteneklerini birleştirir. Özellikle tıbbi görüntülerde organ veya lezyonların pozisyonlarını koruyarak daha hassas segmentasyonlar üretir. Modelin kodlayıcı kısmında, ESA katmanlarıyla temel öznitelikler çıkarır. Dönüştürücü kodlayıcı (Transformer Encoder) modülleri ESA katmanlarında elde edilen öznitelikler arasındaki küresel ilişkileri öğrenir. Kod çözücü (decoder) kısmında ise U-Net benzeri simetrik yapıya sahiptir. Çok ölçekli öznitelik haritalarını birleştirerek nihai segmentasyon çıktısını oluşturur (Chen vd. 2021).

TransU-Net'nin öne çıkan özelliği bağlamsal farkındalığı kullanarak özellikle küçük ve düzensiz şekilli organların segmentasyon performansını geliştirmesidir. Pankreas gibi üç boyutlu organ segmentasyonu çalışmalarında, TransUNet'nin klasik U-Net mimarisine kıyasla daha yüksek Dice benzerlik katsayısı elde ettiği gösterilmiştir.

1.4.4 Swin-UNet

Swin-UNet, Kaydırılabilir Pencereli Dönüştürücü (Swin Transformer) mimarisi U-Net

varyasyonudur. Kaydırılabilir pencere (shifted window) mekanizması kullanarak çok ölçekli dikkat (multi-scale attention) işlemlerinde verim artışı sağlamaktadır. Bu sayede model hem lokal hem de genel bağlam bilgisini dengeli biçimde işleyebilir.

SwinUNet'in kodlayıcı kısmı, volümetrik veriler üzerinde bölgesel pencereler aracılığıyla öznitelik çıkarımı yapar. Bu öznitelikler, Swin Transformer blokları tarafından işlenerek farklı çözünürlüklerde yeniden düzenlenir. Kod çözücü aşamasında, U-Net mimarisinde ki gibi atlama bağlantısı (skip connection) yapılarıyla bilgi akışı korunur (Cao vd. 2021).

Bu mimarinin öne çıkan özelliği, yüksek performanslı ve hesaplama verimliliğidir. Özellikle yüksek çözünürlüklü MR ve BT görüntülerinde, SwinUNet; sistem üzerinde düşük bellek tüketimiyle birlikte ayrıntı kaybını azaltarak segmentasyon sağlar. Pankreas segmentasyonu alanındaki zorluklardan düşük kontrastlı ve karmaşık anatomik yapılar problemlerine SwinUNet'nin dikkat mekanizması sayesinde sınır belirleme doğruluğu artmaktadır.

1.4.5 Focal-UNet

Focal-UNet, Odaklanmalı Dönüştürücü (Focal Transformer) yapısının U-Net mimarisiyle birleştirilmiş halidir. Farklı çözünürlükteki bilgiler arasındaki etkileşimleri optimize etmeyi amaçlayan gelişmiş bir modeldir. Focal Transformer, geleneksel dikkat (self-attention) mekanizmasını iyileştirmeyi amaçlayarak hem lokal hem de genel bağlamları odaklı (focal) biçimde işler.

Modelin kodlayıcı kısmında, diğer ESA tabanlı katmanlar da olduğu gibi temel özellikleri çıkarır. Ardından daha anlamlı öznitelikler oluşturmak için Focal Transformer blokları bu özelliklerin çoklu ölçeklerdeki ilişkilerini modeller (Naderi vd. 2022). Kod çözücü kısmında, bu çok ölçekli öznitelikler birleştirilerek keskin segmentasyon sınırları elde edilir.

Focal-UNet, özellikle hesaplama karmaşıklığı düşük ve küresel bağlam sağlayabilmesi sayesinde dikkat çeker. Büyük hacimli volümetrik tıbbi verilerde bellek verimliliğini korurken ve ince anatomik detayların segmentasyon artırır. Pankreas, karaciğer ve akciğer nodülleri gibi düzensiz sınır hatlarına sahip organlarda klasik U-Net ve TransUNet mimarilerine göre daha iyi sonuçlar verdiği bildirilmiştir.

1.5 Kamuya Açık Veri Setleri

Pankreas segmentasyonu üzerine yapılan çalışmalar genellikle geniş veri setlerine dayanır. Araştırmacılar algoritmalarını eğitmek ve test etmek için genelde The Cancer Imaging Archive (TCIA), Medical Segmentation Decathlon (MSD) ve Kaggle'dan Pancreas-CT veri seti gibi kamuya açık veri setlerini kullanırlar.

Kamuya açık veri setleri, tıbbi görüntüleme alanında yapılan çalışmaların karşılaştırılabilirliğini artırır. Farklı yöntemlerin avantajlarını ile dezavantajlarını değerlendirmeye olanak tanır. Bu veri setleri sayesinde çalışma yapan araştırmacılar, segmentasyon algoritmalarını gerçek klinik vakalarda test etme fırsatı bulurlar.

1.6 Zorluklar ve Sınırlamalar

Pankreas segmentasyonunda derin öğrenme tabanlı modeller, belirli bir etkileşim alanında önemli gelişmeler kaydetmiş olsa da bu alanda hala uygulanması zor bazı engellerle karşı karşıyadır. Özellikle, pankreasın küçük ve düzensiz yapısı, çevresindeki organlarla belirsiz sınırları ve tıbbi görüntülerin gürültülü olması, segmentasyon odaklı modellerin kesinliğini bozabilir. Ayrıca, derin modelleri eğitmek için yeterli sayıda etiketlenmiş veri genellikle sınırlıdır, bu da eğitim sürecinin başka bir engelidir. Model performansının geliştirilmesi, derin derin modelleri eğitmek için daha geniş ve çeşitli veri kümelerinin ve veri artırım stratejilerinin daha yaygın bir şekilde kullanılmasını gerektirir. Aynı zamanda, daha zayıf denetimli ve tamamen denetimsiz segmentasyon çözümleri, genelde tıbbi alan için sıkı olmayan veri senaryolarıyla iyi sonuçlar verebilecektir.

1.7 Sonuç ve Gelecek Yönelimler

Derin öğrenme tabanlı yaklaşımlar, organ segmentasyonu için potansiyel bir araç olarak keşfedilmiştir. DL sistemlerinin gelişimiyle birlikte, klinik ve pratik ortamlarda uygulamalar daha uygulanabilir hale gelebilir. V-Net ve U-Net, özellikle pankreasın 2B ve 3B görüntü işleme ile hassas segmentasyonu için tercih edilmektedir.

Bu modellerin doğruluğu, hızı ve verimliliği, küçük ve düzensiz organlar için hastalık destekli segmentasyonun tanı ve tedavi tarafına büyük katkılar sağlamaktadır. Daha büyük veri setleri ve yeni öğrenme teknikleriyle, bu alandaki ilerleme yalnızca hız kazanmalıdır.

Ancak bu tekniklerin klinik kullanımı yaygınlaştığında, doktorlara daha güvenilir ve hızlı tanı araçları sağlayabilir. Ayrıca, pankreas segmentasyonu için daha büyük veri ve daha güçlü model mimarileri oluşturarak daha iyi sonuçlar elde etmeyi amaçlayan gelecekteki çalışmalar da bulunmaktadır. Özellikle daha gelişmiş hacimsel segmentasyon stratejileri (V-Net gibi) organın hacimsel yapılarının daha hassas segmentasyonu için avantajlı olacaktır. Ayrıca, yöntemlerin hibritliği, klasik görüntü işleme yaklaşımlarının derin öğrenme yaklaşımlarıyla entegre edilmesini sağlayacaktır.

Klinik kullanım için özel olarak tasarlanmış hafif, hızlı modellerle birlikte bu gerçek zamanlı segmentasyonlar, klinik uygulamada pankreas segmentasyonunun işlevsel bir bileşen olarak uygulanmasını destekleyebilir. Tıbbi görüntüleme için derin öğrenme destekli segmentasyon algoritmaları, yalnızca pankreas için değil, aynı zamanda diğer organ sistemlerinin hastalık tanısı ve segmentasyonu için de yüksek bir vaat taşımaktadır. Yapay zekanın hasta bakımına entegrasyonu ile yüksek hassasiyetli ve otomatik segmentasyon, tedavi prosedürünü derinden değiştirebilir.

2. LİTERATÜR ÖZETİ

Pankreas segmentasyonu, tıbbi görüntü analizinde özellikle zor bir problem olarak öne çıkmaktadır. Pankreasın düzensiz şekli, küçük boyutu ve çevresindeki organlarla olan belirsiz sınırları, bu süreci karmaşık hale getirir. Bilgisayarlı tomografi (BT) ve manyetik rezonans (MR) gibi tıbbi görüntüleme yöntemlerinde, pankreasın otomatik olarak doğru bir şekilde segmentasyonu, özellikle pankreas kanseri gibi hastalıkların teşhisinde ve tedavi sürecinde hayati bir rol oynamaktadır.

Wolz vd. (2013) yaptıkları çalışmada, BT gibi tıbbi karın görüntülerinin otomatik segmentasyonundaki zorlukları aşmak amacıyla, birden fazla referans görüntü kullanarak çoklu atlas kaydı ve yama tabanlı segmentasyon yöntemi ile yüksek doğruluk sağlanmıştır. Geliştirilen bu yöntemde pankreas için dice örtüşme değerinin %70 olduğu bildirilmiştir.

Ronneberger vd. (2015) yaptıkları çalışmada, mevcut etiketli verilerin daha verimli bir şekilde kullanılmasını sağlamak için güçlü veri artırma tekniklerine dayanan bir ağ mimarisi ve eğitim stratejisi geliştirmişler. Bu mimari, bağlamı yakalamak için daralan bir yol ve hassas konumlandırma için simetrik genişleyen bir yol içeriyor. Ağ, az sayıda görüntü ile uçtan uca eğitilerek, elektron mikroskobu verilerindeki nöral yapıların segmentasyonu konusunda önceki en iyi yöntemi geride bırakıyor. Faz kontrast ve DIC ışık mikroskobu görüntüleri ile eğitilen ağ, 2015 ISBI hücre izleme yarışmasını kazanmış. Ağın hızlı çalıştığı ve 512x512 boyutundaki bir görüntüyü bir saniyeden kısa sürede segmente edebildiği belirtiliyor.

Roth vd. (2015) uyguladıkları çalışmada, abdomen BT görüntülerinden Basit Doğrusal Tekrarlayan Kümeleme yöntemiyle süper pikseller çıkararak olasılık haritaları oluşturulmuştur. Olasılık haritalarını Evrişimli Ağ yapısı kullanarak pankreas segmentasyonu gerçekleştirilmiştir. 82 adet BT görüntüsünden oluşan veri seti, 60 eğitim, 2 doğrulama ve 20 test olarak ayrılmış ve sonuçta %68 Dice benzerlik oranı elde edilmiştir.

(Roth, Lu, vd. 2015) başka bir çalışmasında ise tıbbi görüntü analizi alanında zorlu bir problem olan otomatik organ segmentasyonuna odaklanmaktadır. Pankreas, yüksek anatomik değişkenliği nedeniyle geleneksel yöntemlerle yüksek doğruluk elde etmekte zorluk yaratmaktadır. Yöntemimiz, derin öğrenme ile elde edilen organ içi ve sınır

haritalarından elde edilen orta düzey ipuçlarını rastgele orman kullanarak entegre eden bütünsel bir öğrenme yaklaşımı sunmaktadır. 82 hastanın BT taramaları üzerinde gerçekleştirilen 4 katlı çapraz doğrulama ile test aşamasında 78.01 ± 8.2 Dice Benzerlik Katsayısı (DSC) elde edilmiştir. Bu, önceki en iyi yöntemin 71.8 ± 10.7 değerini önemli ölçüde aşmaktadır.

Zografos vd. (2016) yaptıkları çalışmada, bir atlas kullanarak kayıt gerektirmeyen 3 boyutlu (3B) abdomen BT görüntülerinde çoklu organların segmentasyonu için yeni bir yapı geliştirmişlerdir. Bir dizi 3B hacimsel özellik üzerinde eğitilmiş ayırt edici sınıflandırıcılar kullanarak, ilgilendikleri organların görünümünü örtük bir şekilde modellemişlerdir. Her seviyedeki eğitilmiş sınıflandırıcının, bir sonraki seviyeye ek özellikler sağlamak amacıyla görüntüye geri uygulandığı hiyerarşik bir otomatik bağlam sınıflandırma şeması kullanmışlardır. Çoklu organ segmentasyonu yaptıkları bu çalışmada pankreas için %42 Jaccard benzerlik oranını elde etmişlerdir.

Milletari vd. (2016) Evrişimli Sinir Ağları (ESA'lar) genellikle 2B görüntülerle çalışırken, klinik uygulamalarda kullanılan tıbbi verilerin çoğunun 3B hacimlerden oluştuğu gözlemlenmiştir. Bu çalışmada, 3B MRI hacimlerinde prostat segmentasyonu için hacimsel ve tamamen evrişimli bir sinir ağı önerilmektedir. Modelin eğitimi, Dice katsayısına dayalı yeni bir hedef fonksiyonu ve veri artırımı için rastgele dönüşümler ile histogram eşleştirme kullanılarak optimize edilmiştir. Önerilen yöntem, sınırlı eğitim verisi ile etkili bir şekilde çalışabilmekte ve diğer yöntemlere göre daha az işlem süresiyle yüksek performans sağlamaktadır.

Roth vd. (2016) yaptıkları çalışmada, tıbbi görüntü analizi alanında önemli bir zorluk olan otomatik organ segmentasyonuna odaklanmaktadır. Pankreas, yüksek anatomik değişkenliği nedeniyle geleneksel yöntemlerle yüksek doğruluk elde etmekte zorluklar yaratmaktadır. Ekibin önerdiği yöntemde, derin öğrenme ile elde edilen organ içi ve sınır haritalarından yararlanarak rastgele orman kullanımıyla bütünsel bir öğrenme yaklaşımı sunulmaktadır. 82 hastanın BT taramaları üzerinde gerçekleştirilen 4 katlı çapraz doğrulama ile test aşamasında 78.01 ± 8.2 Dice Benzerlik Katsayısı (DSC) elde edilmiştir. Bu sonuç, önceki en iyi yöntemin 71.8 ± 10.7 değerini önemli ölçüde aşmaktadır.

Yu vd. (2017) yaptıkları çalışmada, karın BT görüntülerinde küçük organların (pankreas

gibi) segmentasyonu için Zhou ve arkadaşlarının 2016 önerisine karşılık Dikkat Dönüşüm Ağı sunulmaktadır. Karmaşık arka planları yönetmek amacıyla önerilen yöntem, kaba ve ince aşamalı segmentasyon ağlarını ortak bir şekilde optimize ederek çok aşamalı görsel ipuçlarından faydalanır. NIH pankreas segmentasyon veri setinde gerçekleştirilen deneyler, bu yaklaşımın kaba-iyiden inceye yinelemeyle mevcut en iyi yöntemi %2'nin üzerinde bir farkla geride bıraktığını göstermiştir. Ayrıca, bu yöntem daha hızlı yakınsama özellikleri sergileyerek pratik uygulamalarda daha güvenilir hale gelmiştir. Bu strateji, ince aşamada yalnızca sınır kutusu değil, aynı zamanda tamamlayıcı bilgiler de sağlar.

Zhou vd. (2017) yaptıkları çalışmada,, karın BT görüntülerindeki küçük organların segmentasyon doğruluğunu artırmak için sabit nokta modeli kullanan bir yöntem önerilmektedir. Karmaşık arka plan bölgelerini azaltmak amacıyla tahmin edilen segmentasyon maskesi ile giriş alanı küçültülmektedir. Eğitim aşamasında gerçek anotasyonlar kullanılarak ağ ağırlıkları optimize edilirken, test aşamasında parametreler sabit tutulup segmentasyon iteratif olarak güncellenmektedir. NIH pankreas veri setinde gerçekleştirilen deneylerde, yöntemimiz mevcut en iyi yöntemi %4'ten fazla bir farkla geçerek ortalama Dice Benzerlik Katsayısı (DSC) ile %62,43 en kötü durum performansı göstermiştir.

Farag vd. (2017) gerçekleştirdikleri çalışmada, girişte kullandıkları BT görüntüleri süperpiksel haritası ve Rastgele Orman olasılık haritası şeklinde iki bölümden oluşan haritalar olarak elde edilmiştir. Dört farklı yöntemle yaptıkları çalışmada, en kayda değer sonucu Evrişimli Sinir Ağı yapısıyla birlikte kaskat yapı kullanarak %70.7 Dice oranı elde etmişlerdir.

Oktay vd. (2018) yaptıkları çalışmada, tıbbi görüntülemelerde hedef yapılar üzerine odaklanmayı otomatik olarak öğrenen yeni bir dikkat kapısı (AG) modeli tanıtılmaktadır. AG'ler, CNN mimarilerine (örneğin, U-Net) minimal ek yük ile entegre edilerek modelin hassasiyetini ve doğruluğunu artırır. AG'ler sayesinde, katmanlı CNN'ler kullanarak dış dokuların ve/veya organların açıkça yerleştirilmesine gerek kalmaz. İki büyük CT karın veri seti üzerinde gerçekleştirilen deneyler, AG'lerin farklı veri setleri ve eğitim boyutlarında U-Net'in performansını artırdığını ve hesaplama verimliliğini koruduğunu göstermektedir. Önerilen mimarinin kaynak kodu ise halka açıktır.

Kurnaz ve Ceylan, (2020) çalışmalarında, pankreasın segmentasyonu için Konvolüsyonel Sinir Ağları (KSA) yöntemlerinden U-Net modeli kullanılarak bir yaklaşım geliştirilmiştir. Bu çalışma, The Cancer Imaging Archive (TCIA) veri tabanından elde edilen 82 hastaya ait pankreas bilgisayarlı tomografi (BT) görüntüleri üzerinde gerçekleştirilmiştir. Elde edilen segmentasyon sonuçları, Dice benzerlik katsayısında 0.78 ve Jaccard benzerlik katsayısında 0.66 olarak rapor edilmiştir.

Xuan ve You, (2020) yaptıkları çalışmada, pankreas tümörü tespiti için derin öğrenme tabanlı bir Hiyerarşik Konvolüsyonel Sinir Ağı (HCNN) modeli sunulmaktadır. Pankreas kanseri tanısında bilgisayar destekli tarama (CAD) ile birlikte radyoloji görüntüleri kullanılarak otomatik segmentasyon gerçekleştirilmektedir. Yinelemeli Sinir Ağı (RNN) kullanılarak, ardışık görüntü dilimlerindeki mekansal uyumsuzlukların giderilmesi ve segmentasyonun düzgünlük ve şekil açısından iyileştirilmesi hedeflenmiştir. Deneyler, bu yöntemin sınıflandırıcı performansını artırarak tıbbi nesnelerin interneti (IoMT) platformlarındaki maliyetleri düşürebileceğini göstermektedir.

Kurnaz, (2021) de yaptığı çalışmada, pankreas segmentasyonu için Pascal üçgeni dizilimine dayanan ve U-Net modelini temel alan "Pascal U-Net" adlı yeni bir derin öğrenme modeli tanıtılmıştır. Modelin performansı, The Cancer Imaging Archive Pankreas-BT veri seti ile Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden elde edilen abdomen BT görüntüleri üzerinde test edilmiştir. Her iki veri setinde de U-Net ve Pascal U-Net modelleri kullanılarak segmentasyon gerçekleştirilmiş ve sonuçlar karşılaştırılmıştır. Pascal U-Net, her iki veri setinde de geleneksel U-Net modeline göre Dice Benzerlik Katsayısı açısından yaklaşık %1'lik bir avantaj sağlamıştır.

Wang vd. (2021) yaptıkları çalışmada, pankreas segmentasyonu için çift girişli bir v-mesh tam konvolüsyonel ağ (FCN) modeli geliştirilmiştir. Bu model, BT taramalarında düşük kontrasta sahip pankreası daha belirgin hale getirmek amacıyla orijinal görüntülerle grafik tabanlı görsel belirginlik (GBVS) algoritmasıyla işlenmiş görüntüleri kullanmaktadır. Ayrıca, dikkat mekanizması ve mekansal dönüşüm/füzyon modülü ile bağlamsal ve geometrik bilgi yakalama kapasitesi artırılmıştır. NIH veri setinde gerçekleştirilen deneylerde, modelin Dice benzerlik katsayısı (DSC), pozitif kestirim değeri (PPV), duyarlılık (SEN), ortalama yüzey mesafesi (ASD) ve Hausdorff mesafesi (HD) gibi metriklerde üstün performans sergilediği ve önceki yöntemleri geride bıraktığı belirtilmiştir.

Derin vd. (2022) yaptıkları çalışmada, Bilgisayarlı Tomografi (BT) görüntülerinden pankreasın otomatik segmentasyonunu hedeflemişlerdir. 82 hastaya ait NIH-CT82 veri seti ile bir çalışma gerçekleştirmişlerdir. Çalışmalarında U-Net ve farklı versiyonları olan Attention U-Net, Residual U-Net, Attention Residual U-Net ve Residual U-Net++ test edilmiştir. En iyi performansı, 0.903 zar skoru, 0.823 IoU, 0.898 duyarlılık, 1.000 özgüllük, 0.908 kesinlik ve 0.999 doğruluk ile Residual U-Net sergilemiştir.

Li vd. (2022) yaptıkları çalışmada, pankreatik duktal adenokarsinom (PDAC) ve kronik pankreatitin (KP) insan histolojik örneklerinde otomatik tespit yapabilen ve grafik sinir ağları (GSS) kullanan bir analiz hattı sunulmuştur. Hematoksilen ve eozin (HveE) ile İkinci-Harmonik Üretim (SHG) görüntüleri kullanılarak kolajen liflerinin morfolojik ve topolojik özellikleri çıkarılmıştır. 786 çekirdekten oluşan mikro-dizi veri setinde %86,4 doğruluk ve 0,954 Eğri Altındaki Alan (AUC), 268 görüntüden oluşan doku bölgesi veri setinde ise %91,3 doğruluk ve 0,962 AUC elde edilmiştir.

Lim vd. (2022) yaptıkları çalışmada, pankreas segmentasyonunun lezyonları gözlemleme, anatomik yapıları analiz etme ve hasta prognozunu tahmin etmedeki önemi vurgulanmaktadır. 1006 katılımcı üzerinde dört farklı üç boyutlu derin öğrenme tabanlı segmentasyon ağı kullanılarak iç ve dış doğrulama işlemleri gerçekleştirilmiştir. İç doğrulamada ortalama kesinlik, hatırlama ve Dice benzerlik katsayıları sırasıyla 0.869, 0.842 ve 0.842; dış veri seti için ise bu değerler 0.779, 0.749 ve 0.735 olarak elde edilmiştir. Çalışmanın, pankreas segmentasyonu ve ilgili kantitatif verilerin elde edilmesi yoluyla klinik kararların desteklenmesine katkı sağlaması beklenmektedir.

Bayram vd. (2022) yaptıkları çalışmada, yapay zeka destekli pankreas kanseri segmentasyonu için UNet, LinkNet, SegNet, SQ-Net, DABNet, EDANet ve ESNet gibi en son teknoloji segmentasyon ağları kullanılmıştır. Karşılaştırmalı analizde en yüksek segmentasyon performansı SQ-Net ile elde edilmiştir. Bu model, 0.917 Dice puanı, 0.847 Kesişim Üzerine Birleşim (IoU) puanı, 0.920 duyarlılık, 1.000 özgüllük, 0.914 kesinlik ve 0.999 doğruluk değerleri elde etmiştir. Bu sonuçlar doğrultusunda yapay zeka tabanlı bir karar destek sistemi geliştirilmiştir.

Yin vd. (2023) yaptıkları çalışmada, sistematik bir inceleme gerçekleştirilmiştir. Endoskopik

ultrasonografi (EUS) kullanılarak pankreas hastalıklarının tanısında derin öğrenme (DL) algoritmalarının rolü araştırılmıştır. Sınıflandırma odaklı beş çalışmada basit sinir ağları, on iki çalışmada ise konvolüsyonel sinir ağları (CNN) kullanılmıştır. Bu çalışmalar, EUS görüntüleri ve videolarında başarılı sonuçlar elde etmiştir. Uluslararası Tıp ve Diş Hekimliği Görüntüleme Dergisi (IJMEDI) kontrol listesine göre, altı çalışma yüksek kalite ile değerlendirilmiştir. Sonuç olarak, derin öğrenme (DL) algoritmaları pankreas hastalıklarının tanısında önemli bir potansiyele sahipken, örnek boyutları ve veri ön işleme gibi alanlarda geliştirme yapılması gerekmektedir.

Ni vd. (2023) yaptıkları çalışmada, AX-Unet modeli kullanılarak pankreatik duktal adenokarsinom (PDAC) hastalarının kontrastlı Bilgisayarlı Tomografi (BT) görüntülerinden elde edilen radyomik özelliklerin güvenilirliği incelenmiştir. 205 PDAC hastası üzerinde eğitilen AX-Unet modeli, bağımsız bir test setinde 64 hastada %85,9 doğrulukla pankreas segmentasyonu gerçekleştirmiştir. Radyomik özelliklerin, lenf nodu metastazı, rezeksiyon durumu ve serum CA 19-9 seviyeleri gibi klinik özelliklerle anlamlı ilişkileri tespit edilmiştir. Ayrıca, cerrahiden sonra nüks tahmini için nomogramın Eğri Altındaki Alan (AUC) değeri 0.92, C indeksi (modelin tahmin performansı) ise 0.62 olarak bulunmuştur. Sonuçlar, AX-Unet'in nüks risk faktörlerini analiz etmede ve onkologlara daha doğru prognostik değerlendirmeler sağlamada potansiyel taşıdığını göstermektedir.

Mukherjee vd. (2023) yaptıkları çalışmada, kullanıcı rehberliğinde pankreas duktal adenokarsinom (PDA) segmentasyonu için kutu tabanlı 3D konvolüsyonel sinir ağı (CNN) geliştirilmesi hedeflenmiştir. Toplam 1151 hasta üzerinde gerçekleştirilen analizlerde, modelin referans segmentasyonlarına karşı Dice benzerlik katsayısı (DSC) ortalaması 0.84 ± 0.06 olarak belirlenmiştir. Model, 0.93 konsensüs korelasyon katsayısı (CCC) ile referans tümör hacimleriyle benzer sonuçlar elde etmiştir. Ayrıca, modelin performansı farklı veri setlerinde (MSD: 0.82, TCIA: 0.84) genel geçerliği ile kanıtlanmıştır. Sonuç olarak, model klinik varyasyonlara dayanıklılık gösterirken, küçük ve izodens tümörlerin segmentasyonunda da yüksek doğruluk sağlamaktadır.

Paithane ve Kakarwal, (2023) yaptıkları çalışmada, LMNS-net adlı bir derin öğrenme modelinin pankreas segmentasyonundaki doğruluk ve hassasiyet sonuçları incelenmiştir. LMNS-net, klinik abdominal bilgisayarlı tomografi (BT) görüntülerinde pankreası otomatik olarak segmentlemek amacıyla geliştirilmiştir. Model, 12 katmandan oluşmakta ve 4

konvolüsyon katmanı içermektedir. Akut pankreas segmentasyonu için farklı BT açıları kullanılmakta ve model %99.78 doğruluk ile 88.68 ± 57.49 Dice benzerlik indeksi puanı elde etmiştir. Segmentasyon süresi 1 ila 3 saniye arasında değişmekte ve hesaplama süresi, diğer mevcut yöntemlere göre daha kısa bir süre gerektirmektedir. LMNS-Net, pankreas ve böbrek segmentasyonunu doğru bir şekilde tespit etmekte ve derin öğrenme yaklaşımının eğitim süresini kısaltmaktadır.

Juwita vd. (2024) yaptıkları çalışmada, Bilgisayarlı Tomografi (BT) tarama görüntülerindeki pankreas segmentasyonunu geliştirmek amacıyla M3BUNet adında yeni bir model önerilmektedir. M3BUNet, MobileNet ve U-Net sinir ağlarının bir kombinasyonudur ve yeni bir Ortalama-Maks (MM) dikkat mekanizması ile güçlendirilmiştir. Model, pankreas BT görüntülerini iki aşamada, önce kaba sonra ince bir şekilde segmentlemek için maske rehberliği kullanmaktadır. Önerilen yaklaşım, NIH pankreas veri setinde 89.53 ± 1.82 Dice Benzerlik Katsayısı (DSC) ve 81.16 ± 0.03 kesişim birleşim oranı (IOU) elde etmiştir. MSD pankreas veri setinde ise 88.60 ± 1.48 DSC ve 79.90 ± 2.19 IOU değerlerine ulaşılmıştır. Ayrıca, dış kontur segmentasyonu, segmentasyon sürecini desteklemek için bir ön işleme adımı olarak kullanılmıştır. Bu yöntem, mevcut segmentasyon modellerinin performansını önemli ölçüde artırmaktadır.

Chhikara vd. (2024) yaptıkları sistematik incelemede, 2020-2023 yılları arasında yayımlanan makaleler incelenerek derin öğrenme stratejilerinin görüntü analizi alanındaki uygulamaları, en yaygın kullanılan bilgisayarlı tomografi yöntemleri ve üç veri seti üzerinde durulmuştur. Araştırmada, çok modlu tespit, veri seti oluşturma ve klinik uygulamaları geliştirme önerileri sunulmuş ve hastalığın tespiti için en iyi uygulama gereksinimleri belirlenmiştir. Bu inceleme, gelecekteki deneyler için araştırmacılara, akademisyenlere ve bilim insanlarına rehberlik etmeyi amaçlamaktadır.

Li vd. (2024) yaptıkları çalışmada, CausegNet adında bir derin nedensel öğrenme modeli önerilmiştir. CausegNet, pankreas ile tümör arasındaki anatomik nedensel ilişkileri anlamak için nedensellik farkındalığı modülü ve karşı olgusal kayıp modülü kullanmaktadır. Elde edilen nedensel özellikler sayesinde CausegNet, arka plan etkilerini azaltarak pankreas ve tümörü daha doğru bir şekilde tespit etmektedir. Çalışma, kamu ve klinik veri setlerinde en yüksek Dice katsayılarına (86.67 ve 84.28) ulaşarak üstün bir segmentasyon performansı sergilemiştir. Bu yaklaşım, pankreas kanseri risk değerlendirmesinde doğruluğu 12.50 ve

duyarlılığı %50.00 artırarak umut verici klinik uygulamalara olanak tanımaktadır.



3. MATERYAL VE METOT

Bu bölümde kullanılan veri seti ve kullanılan derin öğrenme mimarilerinin detaylı bilgilerine yer verilmiştir.

3.1 Derin Öğrenme Mimarisinin Kavramları


Yapay zeka (YZ), bilgisayarların insan benzeri zekaya ihtiyaç duyan görevleri yerine getirmesine yardımcı olan geniş bir bilim alanıdır. Bu bağlamda önemli bir alt alan olan derin öğrenme, büyük veri ve hesaplama gücü sayesinde son yıllarda hızlı bir büyüme göstermiştir (LeCun vd. 2015).

Derin öğrenme, çok katmanlı (derin) modeller kullanarak veri analizine yapay sinir ağlarını uygulayan bir tekniktir. Derin öğrenme modelleri, geleneksel makine öğrenme tekniklerinden farklı olarak, verideki yapılar gibi karmaşıklıkları otomatik bir şekilde bulabilir (Goodfellow, 2016).

Derin öğrenme tabanlı sistemler, büyük ve karmaşık veri setlerinden doğrudan desenler ve özellikler çıkararak veriyi otomatik olarak keşfedebilir. Bu, genellikle geleneksel yöntemlerde elle yapılan özellik mühendisliği gereksinimini azaltır (LeCun vd. 2015).

3.1.1 Yapay Sinir Ağları (Artificial Neural Networks, ANN)

İnsan beynindeki sinir hücrelerinin yapısını taklit eden matematiksel modellere dayanan sistemlerdir. Bu ağlar, giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanından oluşur (Schmidhuber, 2015). Şekil 3.1 de örnek görsel sunulmaktadır.




Yapay Sinir Ağı

Şekil 3.1: Yapay Sinir Ağı'nın Matematiksel Modeli

3.1.2 Katmanlar (Layers)

Derin öğrenmede, birden fazla gizli katmanın olması modelin ‘derin’ olarak adlandırılmasını sağlar. Şekil 3.2 de derin öğrenme ağı katmanlarının temsili görseli bulunmaktadır.




Katmanlar

Şekil 3.2: Derin Öğrenme Ağı

Bu çalışmada kullanılan derin öğrenme modellerinin temel katman tabloları aşağıdaki gibidir.

3.1.2.1 Giriş Katmanı (Input Layer)

Modelin dış dünyadan aldığı ilk veri girişlerinin işlendiği katmandır. Şekil 3.3 de verilen görseldeki gibi genelde resim, ses veya metin verisi bu katmanda modele aktarılır. Genellikle boyutu sabitlenmiş bir 2B medikal görüntü yer alır (Örneğin 256x256x3 boyutlarında).



Şekil 3.3: Giriş Katmanı

U-Net, TransUNet, Swin-UNet, Focal-UNet: 2B medikal görüntülerle çalışır (Castro vd. 2023).

V-Net, 3B hacimsel veriler (örneğin MRI) için optimize edilmiştir (Peng et al. 2023).


3.1.2.2 Kodlayıcı Bloğu (Encoder Block)

Kodlayıcı kısmında ardışık evrişim (convolution) ve maksimum havuzlama (max pooling) katmanları kullanılır. Her bir katmanda şu adımlar uygulanır:

- 2B Evrişim (2D Convolution): Giriş verisine (genellikle bir görüntü) kaydırılan küçük bir filtre (kernel) uygulayarak öznelik haritaları (feature maps) çıkaran bir katmandır. Bu süreçte kullanılan evrişim filtresi, görüntüdeki kenarları ve dokuları belirler. Filtre matrisinin görüntü üzerinde kaydırılarak (örneğin 3x3 veya 5x5) çarpılmasıyla özellik haritaları oluşturulur. Şekil 3.4'de bir görüntü ile 3×3 çekirdek gibi iki boyutlu bir

sinyal durumunda evriřim iřleminin grselleřtirmesi yer almaktadır (Vakalopoulou vd. 2023). İki boyutlu evriřim iřlemi řu řekilde tanımlanabilir.

$$(I * K)(x, y) = \sum_i \sum_j I(x + i, y + j) \cdot K(i, j)$$



řekil 3.4: Evriřim iřleminin 2B'de grselleřtirilmesi

Teknik Detaylar

- Filtre Sayısı (Filters): Katmanda kullanılan filtre sayısı, ıkıřta elde edilen znitelik haritalarının sayısını belirler.
- Filtre Boyutu (Kernel Size): Filtrenin ykseklięi ve geniřlięini belirler, genellikle (3x3), (5x5) gibi deęerler kullanılır.
- Stride: Filtrenin giriř zerinde kaydırılma adımıdır. rneęin stride=1, filtre her seferinde bir piksel kayar.
- Padding: Giriřin boyutunu korumak iin kullanılan sıfır eklemeleridir. "valid" padding kullanılırsa padding yapılmaz, "same" padding kullanılırsa giriř ve ıkıř boyutları aynı tutulur.

řekil 3.5'de rnek tensorflow ktphanesinde 2B evriřim katmanı (Conv2D) Kullanımı bulunmaktadır. Bu rnek, 32 adet 3x3 boyutunda filtre kullanılarak girdiyle aynı boyutta bir ıktı oluřturulmaktadır. Aktivasyon fonksiyonu olarak ReLU

kullanılmıştır.


```
from tensorflow.keras.layers import Conv2D

conv_layer = Conv2D(filters=32, kernel_size=(3,3), strides=
(1,1), padding='same', activation='relu')
```

Şekil 3.5: Örnek 2B Konvolüsyon Tensorflow kütüphanesinde kullanımı

- 3B Evrişim (3D Convolution): İki boyutlu evrişim yerine, derinlik, yükseklik ve genişlik boyunca 3B filtrelerle evrişim uygulanır. Bu yöntem, görüntünün hacimsel özelliklerini daha etkili bir şekilde ortaya çıkarmayı sağlar. 3B evrişim işlemi, her bir vokselle için hacimsel bir filtre kullanılarak gerçekleştirilir ve özellik haritaları derinlik, genişlik ve yükseklik boyunca kaydırılır: V-Net, 2B ve 3B evrişim işlemleriyle görüntüdeki düzlemsel ve hacimsel verileri işler. 3B evrişim işlemi, U-Net'teki 2B evrişime benzer, ancak her bir filtre 3B olarak yapılandırılmıştır. Medikal görüntüleme gibi üç boyutlu veriler üzerinde kullanılan evrişim katmanı 3B uzamsal bilgiyi (örneğin yükseklik, genişlik ve derinlik veya zaman) aynı anda işleyerek öznitelikler çıkarır. Bu katman, Conv2D'nin uzantısıdır ve 3B veri kümelerinde (örneğin 3 boyutlu tıbbi görüntüler, video kareleri) kullanılır. 3B evrişim işlemi şu şekilde tanımlanabilir. Şekil 3.6'da 3B evrişim işleminin matematiksel ifadesinin görseli oluşturulmuştur.

$$(I * K)(x, y, z) = \sum_i \sum_j \sum_k I(x + i, y + j, z + k) \cdot K(i, j, k)$$



Şekil 3.6: Evrişim işleminin 3B'de görselleştirilmesi

Burada I giriş verisini, K ise 3B filtreyi temsil eder.

Teknik Detaylar:

- Filtre Boyutu (Kernel Size): Örneğin (3,3,3) gibi, burada üç sayı yükseklik, genişlik ve derinlik (ya da zaman) boyutlarını ifade eder.
- Filtre Sayısı (Filters): Çıkışta elde edilecek öznetelik haritalarının sayısını belirtir.
- Stride: Her üç boyutta da kaydırma adımını belirler, örneğin (1,1,1).
- Padding: Giriş ve çıkış boyutlarının korunması için "same", kaydırma nedeniyle küçülme için "valid" seçilebilir.

Conv3D katmanı, 3 boyutlu verilerde uzamsal ve zamansal (veya derinlik) ilişkileri yakalamaya olanak sağlar.

Örnek TensorFlow Kütüphanesinde Conv3D Kullanımı şekil 3.7 de gösterilmiştir. Burada, 32 adet 3x3x3 boyutunda filtre kullanılarak aynı boyutta çıktı üretilir. Aktivasyon fonksiyonu olarak ReLU seçilmiştir.


```
from tensorflow.keras.layers import Conv3D

conv3d_layer = Conv3D(filters=32, kernel_size=(3,3,3),
strides=(1,1,1), padding='same', activation='relu')
```

Şekil 3.7: 3B Konvolüsyon kullanımı

➤ Aktivasyon Fonksiyonları

Sinir ağındaki nöronların çıkışını belirleyen fonksiyonlardır; yaygın örnekleri ReLU, sigmoid ve tanh fonksiyonlarıdır (Goodfellow, 2016). Bu fonksiyonların grafiklerine şekil 3.8’de matematiksel ifadeleri ile açıklamalarına tablo 3.1 yer verilmiştir.



Aktivasyon Fonksiyonları

Şekil 3.8: Yaygın Kullanılan Aktivasyon Fonksiyonları Grafiği

Tablo 3.1: Yaygın Kullanılan Aktivasyon Fonksiyonları Tablosu

Fonksiyon Adı	Matematiksel İfade	Açıklama
ReLU (Rectified Linear Unit)	$\text{ReLU}(x) = \max(0, x)$	Negatif değerleri sıfırlar, pozitifleri olduğu gibi geçirir. Hesaplama açısından hızlıdır.
Sigmoid	$\sigma(x) = \frac{1}{1 + e^{-x}}$	Çıktıyı 0 ile 1 arasında sıkıştırır. Olasılık yorumları için uygundur.
Tanh (Hiperbolik tanjant)	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Çıktıyı -1 ile 1 arasında sıkıştırır. Sigmoid’e göre daha güçlü gradyan sağlar.


U-Net, V-Net ReLU veya PReLU ara katmanlarda; Sigmoid/Softmax çıkışta kullanılır (Zhang vd. 2021).

- ReLU (Rectified Linear Unit), derin öğrenmede en yaygın kullanılan aktivasyon fonksiyonlarından biridir. Girdi değerini sıfır ile karşılaştırır ve negatif değerleri sıfıra indirgerken, pozitif değerleri ise aynen geçirir. Bu şekilde, modelin non-lineer ilişkileri öğrenmesini sağlar ve hesaplama açısından da oldukça verimlidir. Özellik haritalarına doğrusal olmayan bir fonksiyon olan ReLU (Düzleştirilmiş Doğrusal Birim) uygulanır (Ali F. Khalifa ve Eman Badr, 2023). Bu sayede modelin daha karmaşık özellikleri öğrenmesi sağlanır:

Matematiksel olarak ReLU şu şekilde tanımlanır:

$$f(x) = \max(0, x)$$

Şekil 3.9 da görüldüğü gibi giriş (x) sıfırdan küçükse çıktı 0, büyük veya eşitse (x) değeri çıkış olur.



Şekil 3.9: ReLU Aktivasyon Fonksiyonu

Teknik Özellikler ve Avantajları:

- Basitlik: Hesaplaması kolaydır, bu sayede geri yayılım algoritması sırasında hızlı gradient hesaplanır.
- Sparse Aktivasyon: Negatif değerleri sıfırladığı için ağda sadece bazı nöronlar aktif olur, bu da modelin daha hızlı ve verimli öğrenmesini sağlar.
- Graydanların Yokolma Probleminin Azaltılması: Sigmoid veya tanh fonksiyonlarına kıyasla, ReLU özellikle derin ağlarda gradyanların yok olma (vanishing gradient) problemine karşı daha dayanıklıdır.

Dezavantajları

- Dying ReLU Problemi: Çok yüksek öğrenme oranlarında bazı nöronlar sürekli sıfır verir ve güncellenmez hale gelebilir.


Keras/TensorFlow'da ReLU Kullanımı genellikle Conv2D ya da Dense katmanlarının hemen ardından aktivasyon fonksiyonu olarak eklenir

- PReLU (Parametric Rectified Linear Unit), ReLU aktivasyon fonksiyonunun geliştirilmiş bir versiyonudur. ReLU'nun negatif girişlerde sıfıra sabitlendiği durumun aksine, PReLU negatif bölge eğimini öğrenilebilir bir parametre olarak tanımlar. Bu sayede model, negatif değerlerde ne kadar bilgi aktarılacağını veriye göre otomatik olarak ayarlayabilir. Şekil 3.10' PReLU aktivasyon fonksiyonun grafiksel ifadesi bulunmaktadır.

Matematiksel olarak PReLU şu şekilde ifade edilir:

$$f(x) = \begin{cases} x, & \text{eğer } vex > 0 \\ ax, & \text{eğer } vex \leq 0 \end{cases}$$

Burada (a) öğrenilen bir parametredir (genellikle küçük bir pozitif sayı).



Şekil 3.10: PReLU Aktivasyon Fonksiyonu

Teknik Özellikler ve Avantajları:

- Öğrenilebilir Negatif Eğri: Negatif girdilerdeki aktivasyon eğimi model tarafından optimize edilir, böylece ReLU'nun “ölü nöron” probleminin önüne geçilebilir.
- Daha Esnek Yapı: Negatif aktivasyonları tamamen yok saymak yerine, bu değerlerin üstünde ince ayar yapılarak modelin daha iyi performans göstermesi sağlanır.
- Derin Ağlarda Performans İyileştirme: Özellikle derin sinir ağlarında PReLU, ReLU'ya göre daha iyi sonuçlar verebilir.

Şekil 3.11'de Keras/TensorFlow'da bir katman olarak eklenebilir. Burada PReLU, önce conv katmanından çıkan çıktıya uygulanır ve negatif eğim otomatik olarak öğrenilir.

```
from tensorflow.keras.layers import PReLU, Conv2D

conv = Conv2D(32, (3,3), padding='same')(input_tensor)
prelu = PReLU()(conv)
```

Şekil 3.11: PReLU Aktivasyon Fonksiyonunun Kullanımı

- GELU (Gaussian Error Linear Unit), ReLU ve diğer geleneksel aktivasyon fonksiyonlarıyla karşılaştırıldığında daha yumuşak ve sürekli bir geçiş sağlayan aktivasyon fonksiyonudur. Bu fonksiyon genellikle Transformer mimarisine sahip modellerde (örn. BERT, GPT vb.) yaygın olarak kullanılmaktadır. GELU aktivasyonunda, giriş değerleri olasılık temelli ölçeklendirilir. Girdinin aktifleştirilmesi, o girdinin normal dağılıma göre “pozitif olma olasılığı”yla çarpılmasına dayanır. Bu sayede model daha hassas ve bağlama duyarlı bir öğrenme gerçekleştirebilir (Hendrycks ve Gimpel, 2023).


Matematiksel olarak GELU şu şekilde tanımlanır:

$$f(x) = x \cdot \Phi(x)$$

Burada $\Phi(x)$, standart normal dağılımın kümülatif dağılım fonksiyonudur. Yaklaşık ifade ise şu şekildedir:

$$f(x) \approx 0.5x(1 + \tanh(\sqrt{2/\pi}(x + 0.044715x^3)))$$

Bu formül, ReLU gibi keskin bir eşik yerine olasılık tabanlı yumuşak bir aktivasyon sağlar. Grafiksel ifadesi şekil 3.12’de gösterildiği gibidir.



Şekil 3.12: GELU Aktivasyon Fonksiyonu

Teknik Özellikler ve Avantajları

- Yumuşak Geçiş: ReLU’daki ani kesme yerine girdilere olasılıksal bir ağırlık

verir. Bu, özellikle küçük pozitif değerlerde daha etkili bir öğrenme sağlar.

- Daha Doğru Temsil: Özellikle büyük veri ve karmaşık modellerde, girdilerin normal dağılıma yakın olduğunu varsayarak daha doğal bir aktivasyon davranışı sunar.
- Gelişmiş Performans: Transformer tabanlı NLP modellerinde, görüntü işleme ağlarında ve büyük ölçekli derin öğrenme projelerinde doğruluğu artırdığı gözlemlenmiştir.
- ReLU'ya Göre Daha Akıllı Eleme: Negatif değerleri tamamen yok etmek yerine, olasılıksal olarak azaltılmış katkılar sunar.

Dezavantajları

- Hesaplama Maliyeti: ReLU'ya göre daha karmaşık matematiksel işlemler içerdiği için işlem maliyeti yüksektir.
- Donanıma Bağımlılık: Yüksek hesaplama talepleri nedeniyle bazı düşük güç tüketimli sistemlerde tercih edilmeyebilir.

Keras / TensorFlow'da GELU Kullanımı

GELU aktivasyonu genellikle Dense veya Transformer tabanlı özel katmanlardan sonra kullanılır:

```
from tensorflow.keras.layers import Dense
from tensorflow.keras.activations import gelu


layer = Dense(128, activation=gelu)
```

Şekil 3.13: GELU Aktivasyon Fonksiyonunun Kullanımı

- Maksimum havuzlama (MaxPooling), konvolüsyonel sinir ağlarında (CNN) sıkça kullanılan bir havuzlama (pooling) yöntemidir. Girdi feature map'ı üzerinde belirli bir bölgedeki en büyük (maksimum) değeri seçerek, uzamsal boyutların küçültülmesini sağlar. Bu sayede model, hesaplama yükünü azaltır ve önemli özelliklerin öne çıkmasını sağlar. 2x2 pencere ile özellik haritaları boyut olarak küçültülür ve en belirgin özellikler korunur (Albawi vd. 2017). Bu

işlem, şekil 3.14'deki gibi gösterilebilir. Maksimum havuzlama, özellik haritalarının boyutlarını azaltırken en belirgin özellikleri korur:

$$y = \max(x_1, x_2, x_3, x_4)$$



Şekil 3.14: Maksimum Havuzlama İşlemi

Teknik Detaylar

- Havuzlama Penceresi (Pool Size): Örneğin (2x2) boyutunda bir pencere, görüntü üzerinde kayan bir blok gibi işler.
- Adım (Stride): Havuzlama penceresinin giriş üzerinde kaydırılma miktarıdır. Genellikle havuzlama penceresi boyutuna eşittir.
- Padding: Genellikle "valid" (pencere giriş sınırları içinde kalır) olarak kullanılır; bu durumda çıkış boyutu küçülür.

MaxPooling operasyonu, girdideki özniteliklerin mekânsal boyutlarını (yükseklik ve genişlik) azaltırken, önemli özniteliklerin korunmasına olanak sağlar.

Şekil 3.15'de örnek TensorFlow kütüphanesinde 2B maksimum havuzlama (MaxPooling2D) kullanımı verilmiştir. Bu örnekte, (2x2) boyutunda filtre kullanılarak girişin yüksekliği ve genişliği yarı yarıya azaltılır.

```
from tensorflow.keras.layers import MaxPooling2D

max_pool = MaxPooling2D(pool_size=(2,2), strides=(2,2),
padding='valid')
```

Şekil 3.15: Maksimum Havuzla Yönteminin Kullanımı

- 3D Maksimum Havuzlama (3D Max Pooling): Havuzlama işlemi, 3D yapıda gerçekleştirilir ve bu süreçte belirli bir alandaki en yüksek değer seçilir. Maksimum havuzlama, her 2x2x2 bölgeden en yüksek değeri alarak boyutları küçültür. 3D havuzlama, bir 2x2x2 bölgedeki en yüksek değeri seçerek özellik haritasını küçültme işlemi yapar:

$$y = \max (x_1, x_2, \dots, x_8)$$

Bu işlemler sonunda özellik haritaları küçülürken, her bir filtre daha fazla özellik çıkarır.

- Downsampling, bir sinyalin, görüntünün veya veri kümesinin çözünürlüğünü veya boyutunu azaltma işlemidir. Derin öğrenmede özellikle görüntü işleme ve evrişimsel sinir ağlarında, genellikle uzamsal boyutları küçültmek amacıyla kullanılır. Bu işlem, modelin hesaplama yükünü azaltır, özniteliklerin daha özet bir temsilini sağlar ve aşırı öğrenmeyi (overfitting) önlemeye yardımcı olabilir.

Derin Öğrenmede Downsampling Yöntemleri

- Havuzlama (Pooling) Katmanları: En yaygın yöntemlerden biri maksimum havuzlama (max pooling) veya ortalama havuzlama (average pooling) gibi havuzlama işlemleridir. Örneğin, (2x2) maksimum havuzlama, görüntü boyutlarını yarıya indirirken en büyük değerleri korur.
- Adımlı Evrişim (Strided Convolution): Özellikle Conv2D veya Conv3D katmanlarında adım (stride) değeri 1'den büyük alındığında, çıkış boyutu küçültülür ve böylece aşağı örnekleme (downsampling) gerçekleştirilmiş olur.
- Genleştirilmiş Evrişim (Dilated Convolution): Bu yöntem doğrudan boyut

küçültme de, alan hissini büyüterek dolaylı şekilde özellik çıkarımı yapar.

Teknik Detaylar

- Boyut Azaltma: Aşağı örnekleme sonucunda görüntü veya öznitelik haritalarının yükseklik ve genişlik gibi uzamsal boyutları küçülür.
- Bilgi Yoğunluğu: Boyut küçültme, bilgiyi yoğunlaştırma (feature aggregation) sağlar; ancak çok agresif aşağı örnekleme özgün bilgilerin kaybına yol açabilir.
- Genellikle Havuzlayıcıyla veya Adım ile Uygulanır; Havuzlama katmanları genellikle non-lineerliği koruyarak özetleme yaparken, adım artırılan evrişimler parametre öğrenimi ile birlikte aşağı örnekleme sağlar.

Şekil 3.16 ve şekil 3.17 de aşağı örneklemenin TensorFlow'da örnek kullanımı gösterilmiştir.

Maksimum havuzlama ile:

```
from tensorflow.keras.layers import MaxPooling2D

downsample_layer = MaxPooling2D(pool_size=(2,2), strides=
(2,2))
```

Şekil 3.16: Aşağı Örneklemede Maksimum Havuzlama Kullanımı

Adım artırarak Conv2D ile:


```
from tensorflow.keras.layers import Conv2D

downsample_conv = Conv2D(filters=64, kernel_size=(3,3),
strides=(2,2), padding='same')
```

Şekil 3.17: Aşağı Örneklemede 2B Evrişim Kullanımı

- Transformer mimarisi, doğal dil işleme başta olmak üzere sıralı verilerde başarıyla kullanılan bir modeldir. Vaswani vd. (2017) tarafından önerilen bu yapı, tamamen dikkat (attention) mekanizmalarına dayanır ve Tekrarlayan sinir ağları (RNN) ya da ESA gibi sıralı yapıyı işlemek için geleneksel yöntemleri kullanmaz. Şekil 3.1 de örnek transformer mimarisi gösterilmiştir. İki temel bileşenden oluşur: kodlayıcı

(encoder) ve çözücü (decoder). Kodlayıcı, girdi dizisini alır ve zenginleştirilmiş, bağlam bilgisi içeren bir ara temsile dönüştürür.



Şekil 3.18: Transformer Mimarisi

Kodlayıcı Katmanı Yapısı

Bir Transformer kodlayıcı katmanı genellikle şu alt bileşenlerden oluşur:

1. Çok Başlıklı Kendine Dikkat (Multi-Head Self-Attention) Mekanizması: Girdideki her bir pozisyonun diğer pozisyonlarla olan ilişkisini değerlendirir ve bağlam bilgisini çıkarır.
2. Normalize ve Residual Bağlantılar (Layer Normalization ve Skip Connection):

Model kararlılığını ve öğrenme hızını artırır.

3. Beslemeli Sinir Ağı (Feed-Forward Neural Network): Pozisyona bağımsız olarak uygulanan, genellikle iki katmanlı ve ReLU aktivasyonlu tam bağlantılı ağı.
4. Yine Normalize ve Residual Bağlantılar: Bu yapı katmanlar halinde üst üste konularak daha derin ve güçlü modeller elde edilir.

Teknik Detaylar

- Girdi: Pozisyonel kodlama eklenmiş sıra vektörleri (embedding)
 - Çıkış: Bağlam bilgisi içeren aynı uzunluktaki dizi
 - Çok Başlıklı Kendine Dikkat: Birden çok farklı dikkat başlığının çıktıları birleştirilerek farklı bağlam ilişkilerinin yakalanmasını sağlar.
 - Normalize ve Residual Bağlantılar: Stabilite ve gradyan akışını kolaylaştırır.
- ❖ Swin Transformer (Shifted Window Transformer), Liu vd. (2021) tarafından önerilen bir görsel transformer mimarisidir. Geleneksel Vision Transformer (ViT) modellerine kıyasla, Swin Transformer, bilgisayar görüşü görevlerinde daha verimli ve ölçeklenebilir olarak tasarlanmıştır. Özellikle evrimsel ağların başarısını dikkate alıp, yerel dikkat mekanizmasını ve kaydırılmış pencere (shifted window) yaklaşımını entegre eder.

Temel Özellikleri:

- Kaydırılmış Pencere (Shifted Window) Çok Başlıklı Kendine Dikkat (SW-MSA): Görüntü üzerinde sabit boyutlu pencereler içinde dikkat hesaplanır; pencere pozisyonları kaydırılarak komşu pencereler arasındaki ilişki yakalanır.
- Hiyerarşik Yapı: Swin Transformer, öznitelik haritalarını aşağı örnekleyerek hiyerarşik temsiller oluşturur. Böylece hem yerel hem de küresel bağlam bilgisi elde edilir.
- Düşük Hesaplama Maliyeti: Sadece küçük alanlar üzerinde dikkat hesaplandığından, geleneksel global dikkat hesaplamasına göre daha az hesaplama gücü gerektirir.

Mimari Bileşenleri:

1. Küçük Parçalara Ayırma (Patch Partition): Girdi görüntü, küçük yamalara (örneğin 4x4 piksellik) bölünür.

2. Doğrusal Gömme (Linear Embedding): Bu yamalar, embed boyutuna dönüştürülür.
3. Swin Transformer Blokları: Her blok, aşağıdaki modülleri içerir:
 - Pencere Tabanlı Çoklu Başlıklı Öz-Dikkat (W-MSA): Sabit boyutlu pencerelerde dikkat
 - Kaydırılmış Pencere Tabanlı Çoklu Başlıklı Öz-Dikkat (SW-MSA): Pencerelerin kaydırılmasıyla komşu bölge ilişkilerinin yakalanması
 - İleri Beslemeli Katman (MLP): İki katmanlı tamamen bağlı ağ.
 - Katman Normlaştırma ve Artık (Residual) Bağlantılar
4. Parça Birleştirme (Patch Merging): Hiyerarşik yapı için boyut küçültme / kanal genişletme

Teknik Detaylar ve Avantajlar:

- Global dikkat yerine, sabit boyutlu bölgesel dikkat sayesinde hesaplama karmaşıklığı $O(N^2)$ seviyesinden $O(M^2 \cdot (N / M^2)) = O(N \cdot M^2)$ 'ye düşer; burada (N) tüm pikseller, (M x M) pencere boyutudur.
- Kaydırılmış pencereler sayesinde sadece izole pencerelerde değil, pencereler arası da bilgi alışverişi sağlanır.
- Yüksek performans ve ölçeklenebilirlik; ImageNet ve COCO gibi kıyaslama testlerinde evrimsel yöntemlerle rekabet eder veya onları aşar.

Swin Transformer, PyTorch, TensorFlow gibi birçok derin öğrenme kütüphanesinde çeşitli açık kaynaklı (open source) uygulamalarda mevcuttur.

- ❖ Focal Attention, dikkat (attention) mekanizmasını daha etkili ve verimli hale getirmeyi amaçlayan bir modüldür. Özellikle uzun dizi modelleme ve görüntü işleme gibi alanlarda, dikkat hesaplamaları yüksek hesaplama ve bellek maliyetlerine neden olur. Focal Attention, bu problemi çözmek için dikkat hesaplamasını çoklu ölçeklerde (multi-scale) ve bölgesel olarak odaklandırarak, hem yakın hem de uzak bağlamları yakalamaya çalışır.

Temel Fikir ve Çalışma Prensipleri:

- Yerel (Local) ve Uzamsal (Spatial) Dikkat: Hesaplama karmaşıklığını azaltmak

için dikkati, önce küçük yerel bölgelerde odaklar. Böylece detaylı yerel ilişkilere yoğunlaşılır.

- Odaklanmış Dikkat (Focal Focus): Daha geniş ölçeklerde (büyük bölgelerde) az detaylı ama genel bağlam bilgisi yakalanır. Bu sayede hem kısa hem uzun menzilli ilişkiler modelde temsil edilir.
- Çok Ölçekli Özellik Kombinasyonu: Farklı çözünürlük ve ölçeklerdeki dikkat çıktıları birleştirilerek güçlü ve kapsamlı bağlam yaratılır. Bu yaklaşım, örneğin görüntüde bir pikselin hem yakın çevresini hem de daha geniş alandaki bağlamını gözönünde bulundurmasına imkan tanır.

Teknik Detaylar:

- Karmaşıklık Azaltma: Geleneksel öz-dikkat (self-attention) $O(N^2)$ hesaplama yaparken, Focal Attention bölgesel dikkat ile bu maliyeti azaltır.
- Modüler Tasarım: Farklı ölçeklerde dikkat blokları kurularak, bunların çıktıları dikkatlice birleştirilir.
- Uygulama Alanları: Özellikle dil modelleri, video işleme ve görsel transformerlarda kullanılır.

Yang vd. (2021) tarafından önerilen "Focal Transformer" modeli, çok ölçekli odak dikkat mekanizması (multi-scale focal attention) yaklaşımını kullanarak, görsel transformerlarda hem yerel hem global bağlamı etkili şekilde modellemiştir. Kod örneği referanslarında farklı ölçeklerde lokasyonlara dikkat veren katmanlar bulunur ancak hazır kütüphanelerde bazı varyantları mevcuttur. Focal-UNet ESA + Odaklı Dikkat (Focal Attention) modülü ile odaklanmış öznetelik çıkarımı sağlar (Naderi vd. 2025).

3.1.2.3 Çözücü Bloğu (Decoder Block)

Kodlayıcı bölümünde elde edilen düşük çözünürlüklü özellik haritaları, çözücü bloğunda yüksek çözünürlüğe geri döndürülür. Burada aşağıdaki işlemler yapılır:

- Yukarı Örnekleme (Up-sampling): Görüntünün çözünürlüğünü artırmak için, kodlayıcıdaki havuzlama işlemine ters olarak yukarı örnekleme yapılır. Bu


aşamada,"transpoz evrişim (transpose convolution)", interpolasyon veya basit bir yukarı örnekleme (örneğin, nearest-neighbor interpolation) kullanılır.

- Kopyalama ve Bağlantı (Copy and Crop Connections): Kodlayıcıdan gelen aynı seviyedeki özellik haritaları ile çözücüdeki haritalar birleştirilir. Bu bağlantı işlemi, detay kaybını engelleyerek daha iyi bir segmentasyon sağlar.
- Rezidüel Bağlantılar (Residual Connections): Kodlayıcıdan gelen benzer seviyedeki bilgiler, çözücüdeki bilgiyle bir araya getirilir. Bu bağlantılar sayesinde, çözücü bölgesinde detay kaybı en aza indirilir ve daha net bir segmentasyon sağlanır. Her katmandaki çıktıyı bir önceki katmana geri besleyen bağlantılar kullanılarak öğrenme süreci daha verimli hale getirilir. Bu bağlantılar, bilgi kaybını önler ve her katmanda daha hassas segmentasyon yapılmasına olanak tanır. Bu bağlantıların matematiksel ifadesi ise şu şekildedir:

$$H(x) = F(x) + x$$

Burada $F(x)$ öğrenilen fonksiyonu, x ise giriş verisini temsil eder. Bu işlem, modelin daha hızlı ve verimli öğrenmesine katkı sağlar.


- Geri Yayılım, Modelin hatasını minimize etmek için ağırlıkların güncellenmesini sağlayan algoritmadır. Şekil 3.19 da gösterildiği gibi tüm mimarilerde hata türevleriyle ağırlık güncellemesi yapılır. Bu süreç klasik geri yayılım algoritması ile gerçekleştirilir (Goodfellow, 2016). Bu yöntem, derin öğrenme modellerinin temel öğrenme mekanizmasını oluşturur.



Şekil 3.19: Geri Yayılım

- Optimizasyon Algoritmaları, modelin öğrenme sürecini yöneten yöntemlerdir. U-net, V-net ve türevlerinde Adam, SGD ve Momentumlu SGD önde gelen optimizasyon algoritmaları arasındadır. U-Net, V-Net: Adam veya SGD algoritmaları kullanılır(Kingma ve Ba, 2014). TransUNet, Swin-UNet, Focal-UNet: AdamW tercih edilir; Transformer mimarilerde daha kararlıdır (Loshchilov ve Hutter, 2019). Şekil 3.20 de ve tablo 3.2’de örnek optimizasyon algoritmaları grafikleri ile bu grafikerin matematiksel ifadeleri verilmiştir.

Optimizasyon Algoritmaları



$$w = \bar{\eta} \cdot \eta \frac{\partial E}{\partial w}$$

w : Ağırlık
 η : Öğrenme oranı
 E : Hata fonksiyonu

Şekil 3.20: Optimizasyon Algoritmaları

Tablo 3.2: Optimizasyon Algoritmaları

Algoritma Adı	Formül	Açıklama
Gradient Descent	$w = w - \eta \cdot \frac{\partial E}{\partial w}$	Tüm veri üzerinden hata türevi alınarak ağırlıklar güncellenir.
Stochastic Gradient Descent (SGD)	$w = w - \eta \cdot \frac{\partial E_i}{\partial w}$	Her örnek için ayrı ayrı güncelleme yapılır; daha hızlı ama daha gürültülüdür.
Mini-Batch Gradient Descent	$w = w - \eta \cdot \frac{\partial E_{\text{batch}}}{\partial w}$	Küçük veri gruplarıyla güncelleme yapılır; denge sağlar.
Momentum	$v = \gamma v + \eta \cdot \frac{\partial E}{\partial w}, w = w - v$	Önceki gradyan yönünü dikkate alarak daha kararlı güncelleme sağlar.
Adam	$m = \beta_1 m + (1 - \beta_1) \cdot \frac{\partial E}{\partial w}$ $v = \beta_2 v + (1 - \beta_2) \cdot \left(\frac{\partial E}{\partial w}\right)^2$ $w = w - \eta \cdot \frac{m}{\sqrt{v} + \epsilon}$	Momentum ve adaptif öğrenme oranını birleştirir; genellikle en etkili yöntemdir.
w: Ağırlık η: Öğrenme oranı E: Hata fonksiyonu γ: Momentum katsayısı m: İlk moment (ortalama gradyan) v: İkinci moment (gradyan karesi) β_1, β_2: Adam algoritmasındaki katsayılar ϵ: Sayı bölmelerde sıfır hatasını önlemek için küçük sabit		

3.1.2.4 Çıkış Katmanı


Modelin öğrenme sürecini yöneten yöntemlerdir. U-net, V-net ve türevlerinde Adam, SGD ve Momentumlu SGD önde gelen optimizasyon algoritmaları arasındadır.

3.2 Veri Seti Seçimi ve Verilerin Hazırlanması

Derin öğrenme modelleri son yıllarda tıbbi görüntü işleme alanında ilerlemeler kaydetmiştir. Bu, organ segmentasyonu gibi zorlu görevlerde başarı elde edilmesine yol açmıştır. Pankreas gibi daha küçük, düzensiz organ şekillerinin doğru ayrılması, tıbbi tedavi ve teşhiste çok önemlidir. Uygun veri setlerinin belirlenmesi, bu zorluğun üstesinden gelmek için önem ve başarı faktörüne sahiptir. NIH-CT82 veri seti, dünya genelinde pankreas segmentasyonu üzerine yapılan birçok çalışmada en çok tercih edilen veri setlerinden biri olarak öne çıkmaktadır. Derin öğrenme modellerinde neden NIH-CT82 veri setinin tercih edildiğini, veri setinin özelliklerini ve neden U-Net ve V-Net gibi modellerin genellikle bu veri setiyle kullanıldığını vurgulayacağız.

3.2.1 NIH-CT82 Veri Seti: Hazırlanma Süreci ve İçeriği

NIH-CT82 veri seti, Ulusal Sağlık Enstitüleri Klinik Merkezi (NIH) tarafından oluşturulmuş olup, şekil 3.21'deki gibi karın bölgesine ait bilgisayarlı tomografi (BT) görüntülerini içermektedir. Bu veri seti, pankreas segmentasyonu araştırmalarında en yaygın olarak kullanılan veri setlerinden biridir. Toplamda 82 adet kontrastlı bilgisayarlı tomografi (BT) taraması bulunmaktadır ve her bir taramada pankreasın manuel olarak segmentlenmiş referans etiketleri (ground truth) yer almaktadır (Roth, Lu, vd. 2015). 181-466 arasında değişen tarama dilimleri 512x512 piksel boyutlarındadır ve dilim kalınlığı 1,5mm ile 2,5mm arasında değişmektedir (Dogan, 2021). Veri %80 eğitim, %20 doğrulama için ayrılmıştır. Pankreasın hacmi genellikle küçük dilimlere yayılmış bir şekilde bulunur ve organ segmentasyonu için çeşitli zorluklar sunar. Pankreasın şekli oldukça değişken olup, boyutları küçüktür ve çevresindeki organlarla olan sınırları sıklıkla belirsizdir. NIH-CT82, bu zorlukları kapsadığı için derin öğrenme tabanlı pankreas segmentasyonu için zorlu ama gerçekçi bir test alanı sağlar. BT görüntüleri 160x160x160 boyutlarına yeniden boyutlandırılmış ve bu süreçte Region of Interest (ROI) bölgesi kırılıp genişletilmiştir.



Şekil 3.21: NIH-CT82 Veri Seti Örnekleri

3.2.2 U-Net ve V-Net Modellerinin NIH-CT82 ile Kullanımı

Pankreas segmentasyonu gibi zorlu görevlerde derin öğrenme modellerinin etkinliğini artırmak için doğru ağ yapılarının seçimi son derece önemlidir. U-Net ve V-Net gibi derin öğrenme mimarileri, tıbbi görüntü segmentasyonu için özel olarak tasarlanmıştır ve bu tür veri setleri üzerinde oldukça iyi performans sergilemektedir. Özellikle U-Net, kodlayıcı-çözücü yapısı sayesinde giriş görüntülerinden son derece hassas segmentasyon haritaları oluşturma yeteneğine sahiptir. Ronneberger ve ekibi tarafından geliştirilmiş U-Net, az sayıda veri ile bile yüksek doğrulukta segmentasyon yapabilme yeteneği ile dikkat çekmektedir (Ronneberger vd. 2015). Bu yapı, özellikle NIH-CT82 veri seti gibi sınırlı sayıda etiketli görüntü içeren veri setlerinde oldukça etkili olmuştur.

V-Net ise, volumetrik görüntü verilerini üç boyutlu olarak işleyebilmesiyle öne çıkar. Milletari ve arkadaşları tarafından geliştirilen bu model, özellikle pankreas gibi küçük ve düzensiz şekilli organların segmentasyonunda başarı göstermektedir (Milletari vd. 2016). NIH-CT82 veri seti, BT görüntülerini içermesi nedeniyle U-Net2B ve V-Net2B’de doğrudan

uygulanması için ideal bir ortam sunar. Veri setinde her hasta için çok sayıda 2D BT kesiti bir araya getirilerek 3B CT hacmi de elde edilebilir. V-Net'in 3B veriler üzerindeki segmentasyon başarısı, pankreasın ince detaylarını ve çevre organlarla olan karmaşık ilişkilerini daha doğru bir şekilde öğrenmesine olanak tanır. Hem U-Net hem V-Net, NIH-CT82 veri setindeki zorluklara başarılı bir şekilde uyum sağlayabilen güçlü mimariler olarak öne çıkmaktadır.

3.2.3 NIH-CT82 Veri Setinin Seçilmesinin Önemi

V-Net'in 3B ve 2B veriler üzerindeki segmentasyon başarısı, pankreasın ince detaylarını ve çevre organlarla olan ilişkilerini daha iyi bir şekilde öğrenmesine olanak tanır.

Ek olarak, NIH-CT82 veri seti, literatürde sıkça başvurulmuş bir kaynak olduğundan, araştırmacılar arasında bir kıyaslama standardı oluşturur. Örneğin, Gibson ve ekibinin çalışmalarında olduğu gibi, pankreas segmentasyonu için bu veri seti ile eğitilmiş modeller, diğer araştırmalarda da referans olarak kullanılmaktadır (Gibson vd. 2018). U-Net ve V-Net'in bu veri setinde sıkça tercih edilmesi, araştırmacılar arasında yaygın bir eğilim haline gelmiştir. Zhou ve ekibinin gerçekleştirdiği çalışmalarda, NIH-CT82 veri seti ve U-Net mimarisi kullanılarak pankreas segmentasyonu alanında çarpıcı sonuçlar elde edilmiştir (Zhou, Xie, Fishman, vd. 2017). NIH-CT82 üzerindeki bu modellerle yapılan çalışmalar, bu modellerin diğer veri setlerinde de başarılı sonuçlar verdiğini göstermiştir.

3.2.4 Sonuç

NIH-CT82 veri seti 53 erkek 27 kadın denekten kontrastlı 3B BT görüntüleri içermektedir (URL-2, 2020). Pankreas segmentasyonu için uygun bir zorluk seviyesi ve geniş bir çeşitlilik sunan bir veri seti olarak dikkat çekmektedir. U-Net ve V-Net tabanlı mimariler, bu veri seti üzerinde yüksek performans gösteren mimariler olarak tercih edilmiştir. Derin öğrenme tabanlı tıbbi görüntü segmentasyonu çalışmalarında, doğru veri seti ve model kombinasyonu, klinik uygulamalarda güvenilir sonuçlar elde edilmesi açısından kritik bir öneme sahiptir. NIH-CT82'nin bu tür çalışmalarda sıkça kullanılması, veri setinin kalitesini ve genel kabul görmüş bir kıyaslama aracı olduğunu göstermektedir.

3.3 Yapılan Çalışma 1

Bu çalışmada iç organ segmentasyonu için kullanılan popüler derin öğrenme mimarilerinden U-Net ve V-Net tabanlı modellerinin NIH-CT82 veri seti üzerindeki doğruluk (ACC) skorları incelenmiştir. Pankreas görüntülerini segmentlere ayırmak için 16 ile 256 filtre arasında değişen bir Unet mimarisi kullanılmıştır. ReLU, verileri normalleştirmek için her iki mimaride de toplu normalleştirme ve aktivasyon işlevi olarak kullanıldı. CT görüntüleri 512x512 piksel boyutundadır. İlk olarak veri seti %80 eğitim ve %20 doğrulamaya bölünür. CT görüntüleri 160x160x160 olarak yeniden boyutlandırıldı. Yeniden boyutlandırma sırasında ROI bölgesi kırıldı ve genişletildi.

3.3.1 Temel U-Net Derin Öğrenme Ağı


U-Net, derin öğrenme ağlarında görüntü segmentasyonu problemlerini çözmek için yaygın olarak kullanılan bir modeldir. 2015 yılında Ronneberger ve arkadaşları tarafından biyomedikal görüntü segmentasyonu için önerilen bu model, tıbbi görüntüleme gibi alanlarda yüksek doğrulukta segmentasyon sonuçları sunabilmektedir. Şekil 3.22’de gösterilen U-Netin yapısı, ‘U’ şeklinde bir katmanlar dizilimi oluşturacak biçimde simetrik olduğu için bu adı almıştır. Özellikle, sınırlı sayıda eğitim verisi olan problemlerde de yüksek performans göstermesiyle öne çıkar (Asgari Taghanaki vd. 2021; Dorgham vd. 2022). U-Net, FCNet üzerine inşa edilmiş Kodlayıcı (Encoder) ve Çözücü (Decoder) adı verilen iki ana bileşenden oluşur (Lakshmipriya vd. 2023):

- Kodlayıcı Bloğu: Bu bölümde, girdi (input) görüntülerinden bilgi çıkarılır ve katmanlar boyunca boyutu küçültülür. Bu da görüntünün düşük çözünürlüklü ancak yüksek sayıda özellik haritası (feature map) ile temsil edilmesi sağlar.
- Çözücü Bloğu: Kodlayıcıdan gelen bilgilerle görüntü yüksek çözünürlükte yeniden oluşturulur. Her aşamada yukarı örnekleme gerçekleştirilir ve boyut büyütülerek özellik haritaları daha geniş bir alana yayılır. Bu işlemler sonucunda görüntü orijinal boyutuna geri döner, ancak segmentasyon bilgisiyle zenginleştirilmiş bir özellik haritası elde edilir.

U-Net’in temel olarak yaptığı işlem her pikselin sınıflandırılmasını sağlamaktır. Bu sayede görüntünün her bölgesi ayrı ayrı etiketlenmiş olur.

U-Net'in avantajlarını aşağıdaki gibidir:

- Kopyalama-bağlantı katmanları sayesinde, kaybedilen detayları geri kazanarak daha verimli ve hassas segmentasyon sağlar.
- U-Net, veri kıtlığı olan tıbbi uygulamalarda daha az veri ile başarılı sonuçlar elde edilir.(Koç ve Akgün, 2021)
- U-Net'in yapısı, eğitim ve tahmin süreçlerinde hızlı ve etkili olarak verimlilik sağlar.
- U-Net, biyomedikal görüntüleme dışında çeşitli alanlarda da yaygın olarak kullanılır. Uydu Görüntülerini İşlemede, Otomotiv Endüstrisinde ve Tarım sektörü vb. (Jurado-Rodríguez vd. 2022)



Şekil 3.22: U-Net

U-Net, görüntü segmentasyonu problemlerinde öne çıkan güçlü bir derin öğrenme modelidir. Kodlayıcı ve çözücü blokları arasındaki bağlantılar sayesinde, her seviyede daha fazla detayın korunmasına olanak tanır ve bu sayede daha başarılı sonuçlar elde edilir. Özellikle sınırlı veri setleriyle çalışılması gereken tıbbi görüntüleme alanında yüksek

doğruluk oranları sağlama yeteneği ile dikkat çeker.


3.3.2 Temel V-Net Derin Öğrenme Ağı

V-Net, özellikle medikal görüntülemelerde hacimsel segmentasyon amacıyla kullanılan bir derin öğrenme modelidir. Tomografi ve manyetik rezonans (MR) gibi 3B görüntülerden segmentasyon yapmak için geliştirilmiştir. U-Net'in 2B yapısını üç boyutlu bir yapıya dönüştüren V-Net, 3B veriyi girdi olarak alır ve 3B evrişim işlemleri kullanarak modelin hacimsel verilerle çalışmasını sağlar. Şekil 3.23'de Milletari vd. (2016) önerdiği V-net mimarisinin modeli görülmektedir. V-Net'in genel yapısı da U-Net'e benzerdir ve iki ana bloktan oluşur:

- Kodlayıcı Bloğu: 3B evrişim işlemleriyle özellik haritalarını küçültür ve önemli özellikleri çıkarır. Bu sayede, görüntüdeki hacimsel veriler düşük çözünürlükteki özellik haritalarına indirgenir.
- Çözücü Bloğu: Kodlayıcıdan gelen özellikleri yeniden yüksek çözünürlüğe getirerek görüntüyü geri oluşturur. Her seviyede yukarı örnekleme yapılır, bu sayede görüntü boyutları orijinal haline döner.

V-Netin avantajları aşağıdaki gibidir:

- V-Net, üç boyutlu tıbbi görüntüler üzerinde çalışmak üzere özel olarak geliştirilmiştir ve bu alanda etkileyici bir performans sergilemektedir.
- Rezidüel bağlantılar, V-Net'in derin yapısına rağmen öğrenme sürecini hızlandırır.
- Derinlik boyutunu da dikkate alan 3B segmentasyon yeteneği, özellikle tıbbi görüntülemelerde ayrıntılı analiz yapma imkanı sunar.
- Görüntüdeki her bir vokselin sınıflandırılması gereken diğer alanlarda da kullanılabilir.



Şekil 3.23: V-Net

V-Net, 3B görüntü segmentasyonunda öne çıkan bir derin öğrenme modelidir. Hem 2B hem 3B verileri işleyebilme yeteneği ve derin yapısındaki rezidüel bağlantılar sayesinde detayları koruyarak segmentasyon yapabilmesi, V-Net'i tıbbi uygulamalarda son derece değerli bir araç haline getirir. U-Net'in 2B görüntülerdeki başarısını 3B görüntülere uyarlayan V-Net, özellikle sınırlı eğitim verileri ile çalışılması gereken segmentasyon görevlerinde yüksek doğruluk oranları sunar.

3.3.3 Performans Ölçütü

Derin öğrenme ağlarında doğruluk metriği, modelin tahminlerinin ne kadar doğru olduğunu ölçmek için kullanılan temel performans ölçütlerinden biridir. Bu metrik, özellikle sınıflandırma modellerinde yaygın olarak kullanılır. Mantığı, modelin doğru tahmin ettiği örneklerin toplam örnek sayısına oranını hesaplamaktır. Başka bir deyişle, modelin ne kadar doğru tahminde bulunduğunu yüzdesel olarak gösterir. Bu metrik, basit ve etkili bir yöntemdir. Özellikle veri sınıflarının dengeli olduğu durumlarda oldukça işe yarar. Matematiksel olarak ifade edersek:

$$"Doğruluk" = \frac{(Doğru\ Tahmin\ Sayısı)}{(Toplam\ Tahmin\ Sayısı)}$$

Doğruluk metriği (ACC), görüntü tanımlama, metin sınıflandırma ve tıbbi teşhislerde yaygın olarak kullanılmaktadır. Model geliştirme süreçlerinde, modelin performansını izlemek ve eğitim sürecini optimize etmek için sıkça başvurulur. Doğruluk metriğinin denklemi ve tanım açıklamaları aşağıda verilmiştir.

- TP (True Positive) : Pozitif sınıfa ait bir örneğin doğru şekilde tahmin edilmesi.
- TN (True Negative): Negatif sınıfa ait bir örneğin doğru şekilde tahmin edilmesi.
- FP (False Positive): Negatif sınıfa ait örneğin yanlış şekilde tahmin edilmesi.
- FN (False Negative): Pozitif sınıfa ait örneğin yanlış şekilde tahmin edilmesi.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}$$


3.4 Yapılan Çalışma 2

Bu çalışmada U-Net, V-Net2B, Attention UNet2B, TransUNet2B ve Swin-UNet2B ve Focal-UNet2B derin öğrenme mimarilerinin kamuya açık NIH-CT-82 pankreas veri kümeleri üzerinde eğitim için %80 (5505), doğrulama için %10 (688) ve test için %10 (689) oranında kullanılarak toplam 6882 örnek kullanılarak karşılaştırmalı analizleri yapılmıştır. Görüntüleri segmentlere ayırmak için 32 ile 512 filtre arasında değişen mimariler kullanılmıştır.

3.4.1 Dikkat tabanlı UNet2B (Attention UNet)

Dikkat tabanlı UNet, tıbbi görüntü segmentasyonu için derin öğrenme sınıflandırıcı tabanlı bir modeldir. U-Net modelinin segmentasyon başarısını artıran derin öğrenme tabanlı bir yaklaşım önerdiler. Geleneksel U-Net mimarisinin yanı sıra, model bir "dikkat" yöntemi uygulanır. Yerleşik bir yapı ile ağ, artık görüntünün daha önemli alanlarında uzmanlaşabilir

ve nihayetinde görüntüleri daha doğru bir şekilde segmentleyebilir. Organ sınırlarının belirsiz veya gürültülü olduğu tıbbi görüntülerde benzersiz bir fayda sağlamayı amaçlamaktadır (Oktay vd. 2018).



Şekil 3.24: Dikkat Tabanlı U-Net

Dikkat tabanlı U-Net, U-Net'in kodlayıcı - çözücü yapısını korur. Ancak, kodlayıcıdan gelen atlama bağlantı sinyalleri dikkat kapıları adı verilen özel yapılarla filtrelendir ve doğrudan çözücüye beslenir. Bu kapılar hangi özelliklerin bulunması gerektiğini belirler ve modele alakasız bilgilerin aktarılmasını engeller. Sonuç olarak, model görüntünün ilgili alanlarını seçici olarak vurgular. Şekil 3.24 de dikkat tabanlı u-net mimari örneği gösterilmektedir.


Geleneksel U-Net'e benzer şekilde, kodlayıcı bloğu çok katmanlı konvolüsyonlar, aktivasyon fonksiyonları ve havuzlama fonksiyonlarından oluşur. Görüntü, özellik katmanları eklenerek küçültülür ve filtrelendir. Ancak, dikkat tabanlı U-Net'te burada oluşturulan özellikler daha sonra dikkat filtresine aktarılacağından, bilgi kaybı en aza indirilir. Çözücü bloğu kodlayıcıya uygulanır ve buradan gelen bilgiler yukarı örnekleme işlemleriyle başlangıç bölgesine yükseltilir. Detay kaybının en aza indirildiği atlama bağlantı yapıları entegre edilmiştir. Geleneksel U-Net'in aksine, bu bağlantılar başlangıçta dikkat kapılarından geçer ve önemlerine göre ölçeklenir. Böylece model, doğru tahminler yapmaktan kaçınır ve bunun yerine küçük bölgelere odaklanır. Bu odaklanma süreci, modelin küçük hedef yapıları ayırmada avantaj sağlar. Bu mimari piksel etiketi ile

segmentasyon yapar. Modelde her pikselin sınıf bilgisini tahmin etmenin yanı sıra, sınıflandırma için önemli olan bölgelere göre ağırlıklandırılmış ağırlıklar eklenir. Bu, bitişik dokuların oluşturduğu gürültüyü azaltır. Ayrıca, gereksiz özellikleri kaldırarak model, daha az eğitim verisiyle iyi performans gösterebilir ve daha hızlı öğrenme sağlar. Düşük kontrastlı veya küçük alanlı konumlar, tümörler, organların kenarları ve vasküler yapılar gibi tıbbi yapılar için özellikle uygundur.

Bu çalışmada, dikkat tabanlı U-Net'in dikkat mekanizmasının yardımıyla seçici ve odaklı öğrenme için daha iyi olduğunu ve U-Net'in güçlü segmentasyon yeteneğini koruduğunu gösterir. Gürültülü ve sınırlı tıbbi görüntüleme verilerinde sağladığı yüksek doğruluk oranları, bu modeli daha gelişmiş derin öğrenmenin ortaya çıkışında kilit bir düğüm haline getirmiştir.

3.4.2 TransUNet2B

TransUNet, görüntü segmentasyon problemlerinde klasik U-Net yapısının başarısını Transformer tabanlı dikkat mekanizmalarıyla birleştiren bir derin öğrenme modelidir. Chen vd. (2021) tarafından tanıtılan bu model, tıbbi görüntüleme uygulamalarında yüksek doğrulukta segmentasyon performansı elde etmeyi amaçlamaktadır. TransU-Net'in yapısı, temelde U-Net mimarisinden ilham almış olup, "ESA + Transformer" birleşimi sayesinde hem yerel hem de küresel bağlamı aynı anda öğrenme yeteneği sunar. Klasik U-Net'in yalnızca evrişim katmanlarına dayanan yapısından farklı olarak, bu mimaride "Transformer encoder" katmanları da bulunmaktadır. Bu sayede model, verilerde daha geniş ölçekli ilişkileri öğrenme kapasitesine sahip olur. Şekil 3.25 de mimari örneği sunulmaktadır.




Şekil 3.25: TransUNet

TransUNet2B mimarisi genel olarak Kodlayıcı ve Çözücü bölümlerinden oluşmaktadır. Kodlayıcı bloğu ESA tabanlı katmanlar ile giriş görüntülerinden özellik çıkarılır. Daha sonra transformer tabanlı katmanlara aktarılır ve böylece görüntüdeki uzun menzilli ilişkilerin öğrenilmesi gerçekleşir. Sonuç olarak hem düşük çözünürlükte hem de daha semantik açıdan zengin özellik haritaları elde edilir. Çözücü bloğunda kodlayıcıda elde edilen derin özellik haritaları, klasik U-Net'te olduğu gibi yeniden yapılandırılır. Her aşamada yukarı örnekleme işlemi gerçekleştirilir. Segmentasyonun daha yüksek çözünürlükte elde edilmesi sağlanır. Böylece görüntü detaylı ve anlamlı bölütlenmiş hâlde yeniden oluşturulur. Bu mimarinin temel görevi, her pikselin sınıflandırılmasını sağlamak ve görüntüdeki yapıları ayırmaktır. Tıbbi görüntülerde organ ve tümör gibi farklı bölgelerin doğru şekilde etiketlenmesini mümkün kılar. Özellikle karmaşık anatomik yapıların bulunduğu tıbbi görüntülerde yüksek doğruluk sağlar (Yuan vd. 2023). Veri miktarı arttıkça performansı geleneksel modellere göre daha hızlı iyileşir.

3.4.3 Swin-UNet2B

Swin-UNet, U-Net mimarisinin kaydırılabilir pencere dönüştürücü tabanlı halidir. Cai ve arkadaşları tarafından 2023 yılında sunulan bu model, verilerin segmentasyonunda daha fazla bağlamsal bilgi yakalamayı hedeflemektedir (Cai vd. 2023). Swin-UNet'in temel farkı, klasik evrişim yerine pencere-kaydırmalı (shifted window) mekanizmasıyla çalışan Transformer katmanlarının kullanılmasıdır.



Şekil 3.26: Swin-UNet

Şekil 3.26 de Swin-UNet mimarisi bulunmaktadır. Kodlayıcı bloğu girdi hacmini Swin Transformer bloklarıyla işlenerek küçük parçalara (patch'lere) ayrılır. Bu işlem, modelin hem düşük hem yüksek çözünürlüklü yapısal ilişkileri öğrenmesini sağlar. Organ boşlukları ve karmaşık dokular bu blok sayesinde daha doğru tahmin edilir. Kodlayıcıdan gelen hacimsel özellik haritaları, kademeli olarak genişletilir ve farklı çözünürlük seviyelerindeki bilgiler kopyalama-bağlantılarıyla bir araya getirilir. Böylece görüntü, 2B hacim olarak yeniden oluşturulur ve segmentasyon maskesi elde edilir.


Swin-UNet diğer mimarilere göre verilerde yüksek doğruluk elde eder. Kaydırılabilir pencere dönüştürücü sayesinde uzun menzilli ilişkiler veri boyutundan bağımsız olarak öğrenilebilir. Tıbbi görüntülerde daha net ve tutarlı segmentasyon sağlar. Küçük parça (Patch) tabanlı öğrenme sayesinde büyük veri hacimlerinin işlenmesini kolaylaştırır.

Swin-UNet, görüntü segmentasyonunda önemli başarılar sunar. U-Net benzeri yapısı detay kaybını azaltırken, kaydırılabilir pencere mekanizmasıyla daha derin bağlam ilişkilerini modelleyerek tıbbi görüntüleme güçlü bir alternatif oluşturur.

3.4.4 Focal-UNet2B

Focal-UNet, tıbbi görüntü segmentasyonunda Transformer tabanlı modellerde görülen bloklama (patch artefact) ve kenar bozulmalarını azaltmayı hedefleyen bir U-Net türevidir. Bu model Naderi ve arkadaşları tarafından 2022 yılında önerilmiştir. Modelde klasik kendi içinde dikkat (self-attention) katmanları yerine odak modülü (Focal Modulation) adı verilen bir yöntem kullanılır (Naderi vd. 2022). Bu yöntem yerel ve küresel özelliklerin aynı anda dikkate alınmasını mümkün kılar. Focal-UNet mimarisi de U-Net yapısına benzer şekilde kodlayıcı ve çözücü bloklarından oluşur.

Kodlayıcı bloğunda girdi görüntüsündeki özellikler odak modülü aracılığıyla çıkarılır. Odak modülü, her bölgenin yalnızca çevresi ile olan ilişkilerini değil, daha uzak bölgelerle olan ilişkilerini de hesaba katarak daha dengeli ve semantik açıdan zengin özellik haritaları sunar. Bu işlem sonucunda özellik haritaları zenginleşir ve detay kaybı azaltılır.



Şekil 3.27: Focal-UNet

Çözücü bloğunda yukarı örnekleme işlemleriyle görüntü çözünürlüğü yeniden artırılır. Kopyalama-bağlantıları ile kodlayıcıda kaybedilen detaylar geri kazanılır. Odak katmanları ile segmentasyon haritası daha düzgün, kenar hataları daha az ve bloklaşma artefaktları minimize edilmiş biçimde elde edilir.

Focal-UNet piksel bazlı sınıflandırmanın yanında, segmentasyon maskesinin bütünlüğünü de korur. Organların sınırlarının net ve yumuşak biçimde tanımlanmasını hedefler. Küçük veri setlerinde dahi klasik Transformer U-Net modellerinden daha iyi doğruluk sunabilir (Bao vd. 2023). Küçük parça kaynaklı bloklaşma artefaktlarını azaltır, segmentasyon bütünlüğünü artırır. Kenar hataları ve maske bozulmalarını minimize eder. Şekil 3.27 de mimariye ait görsel şema sunulmuştur.

Focal-UNet'in amacı özellikle kenar bütünlüğünün önemli olduğu tıbbi görüntüleme uygulamalarında dikkat çekmektedir. Odak modül ile hem küresel hem de yerel bilgiyi işleyerek daha düzgün ve güvenilir segmentasyon maskeleri üretebilmektedir.

3.4.5 Performans Ölçütü

Bu çalışmada önerilen modelin segmentasyon başarısını değerlendirmek için performans metrikleri kullanılmıştır. Literatürde bulunan en yaygın kriterler kullanılmış ve eğitim ve test aşamalarında kamuya açık veri seti kullanılmıştır. Kullanılan performans metriklerinin matematiksel ifadeleri aşağıda yazılmıştır.

Bu denklemdeki kısaltmalar şunlardır:

- TP (True Positive): Pozitif sınıfa ait bir örneğin doğru şekilde tahmin edilmesi.
- TN (True Negative): Negatif sınıfa ait bir örneğin doğru şekilde tahmin edilmesi.
- FP (False Positive): Negatif sınıfa ait örneğin yanlış şekilde tahmin edilmesi.
- FN (False Negative): Pozitif sınıfa ait örneğin yanlış şekilde tahmin edilmesi.

Bu metriklerin matematiksel karşılıkları aşağıda verilmiştir:

$$\text{Thresh-DSC} = \frac{2TP}{2TP + FP + FN} > 0.3$$

$$\text{Thresh-IoU} = \frac{TP}{TP + FP + FN} > 0.3$$

$$\text{ACC} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{REC} = \frac{TP}{TP + FN}$$

$$\text{PREC} = \frac{TP}{TP + FP}$$

Bu formüllere göre; Doğruluk (ACC) genel başarı oranını ifade ederken, Duyarlılık (REC) modelin gerçek pozitif değerleri ne kadar iyi tahmin ettiğini göstermektedir. Kesinlik (PREC) ise pozitif olarak tahmin edilen örneklerin ne kadarının doğru olduğunu ifade etmektedir. Bu metrikler birlikte değerlendirildiğinde, model performansı daha sağlıklı bir şekilde anlaşılabilmektedir.

4. BULGULAR VE TARTIŞMA

Çalışmanın ilk bölümünde, U-Net ve V-Net mimarileri pankreas organının segmentasyonuna uygulandı. Bu noktadaki segmentasyon, 2B tıbbi görüntüler üzerinde gerçekleştirildi ve her iki modelin performansı doğruluk metriği ve elde edilen segmentasyon çıktıları kullanılarak karşılaştırıldı. Bu yöntem, iki boyutlu kesitlerde hacimsel bir yapıya sahip bir organı segment etme olasılığı daha yüksek olan mimarinin hangisi olduğunu değerlendirdi.

Bu tezin ikinci aşamasında, modellerin hacmi artırılarak segmentasyon performansı daha ayrıntılı bir şekilde incelendi. Bu bağlamda, U-Net2B, V-Net2B, Dikkat Tabanlı UNet2B, TransUNet2B, Swin-U-Net2B ve Focal-UNet2B mimarileri aynı veri kümesi üzerinde 2B görüntü formatında değerlendirildi. Önceki çalışmadan farklı olarak, bu veri kümesinde model performansını iyileştirmek için Thresh-DSC, Thresh-IoU, Doğruluk (ACC), Kesinlik (PREC) ve Duyarlılık (REC) gibi çeşitli metrikler uygulandı. Sonuç olarak, her bir mimarinin pozitif örnekleri tanımlama duyarlılığı, genel başarı oranı ve segmentasyon doğruluğu daha nicel bir şekilde belirlendi.

Bu iki aşamalı yapı sayesinde, hem temel U-Net ve V-Net karşılaştırması sağlanmış hem de daha gelişmiş derin öğrenme yaklaşımlarının performansı detaylı olarak incelenmiştir. Bölümün devamında her iki çalışmaya ait detay bulguları sunulacaktır.

4.1 Yapılan Çalışma 1


1. çalışmada; modeller U-net ve V-net şeklinde 16 ila 256 filtreli olarak tasarlandı. Veri seti boyutu daha da küçültülerek model boyutu artırıldığında eğitimin başarısız olduğu görülmüştür. Yapılan çalışmalarda Unet için bırakma değerleri 0,5 ila 0,9 olarak belirlenmiş ve eğitimde ideal değer olarak 0,8 seçilmiştir. Vnet için 0,1'den 0,9'a kadar olan bırakma değerleri uygulandı ve 0,2'nin mükemmel bırakma değeri olduğu belirlendi.

4.1.1 Modelin uygulama ayrıntıları


Seçilen modellerin eğitimi ve validasyonu NVidia RTX 4000 grafik kartı üzerinde gerçekleştirildi. Modeller için, batch_size 1'dir, optimize edici ADAM'dir ve öğrenme oranı 0,001'dir. Önerilen modeller veri seti üzerinde 250 dönem boyunca eğitilmiştir. Modellerin algoritmaları Anaconda ekosisteminde Python 3.8 programlama dili ve Tensorflow_gpu 2.5 kütüphanesi ile hayata geçirildi. Modellerin kaybını hesaplamak için Seyrek Kategorik Çapraz entropi kaybı kullanıldı.

4.1.2 Modelin uygulama sonuçları

Unet ve Vnet mimarilerinin karşılaştırmalı analiz sonuçları tablo 4.1'de gösterilmektedir. Analiz sonucunda 22,1 milyon parametreye sahip olan Vnet , 2,94 milyon parametreye sahip olan Unet'e göre biraz daha iyi performans göstermiştir. Parametrelerin sayısı nedeniyle Vnet'in eğitimi neredeyse dört kat daha uzun sürdü. Her iki mimarinin Eğitim doğrulukları şekil 4.1 ve şekil 4.2 de gösterilmektedir



Şekil 4.1: Temel Unet Eğitim Doğruluğu



Şekil 4.2: Temel Vnet Eğitim Doğruluğu

Tablo 0.1: Modellerin karşılaştırmalı performans sonuçları çalışma 1

Mimariler	Yöntemler	Prm(M)	Eğitim Doğruluğu (%)	Doğrulama Doğruluğu (%)	Dönem
Temel Unet	CT görüntüleri	2.94	99.78	99.78	250
Temel Vnet	CT görüntüleri	22.1	99.6	99.82	

4.2 Yapılan Çalışma 2

2. çalışmada; modeller U-Net2B, V-Net2B, Attention UNet2B, TransUNet2B, Swin-UNet2B ve Focal-UNet2B modelleri için 32 ila 512 filtreli olarak tasarlandı. İki boyutlu görüntüleri sınıflandırmak için kullanılan iki yaygın kriter, Dice (DSC) ve Birlikte Kesişim (IoU-Jaccard) metrikleridir. Çalışmada her iki metrik için de 0.3 eşik değeri varsayılmıştır. Bir eşik değeri tanımlayarak, değerlendirmeyi öngörülebilirliğe indirgeriz ve 0.3'ten düşük

tahmin deęerlerini sıfır olarak kabul ederiz. Eşikli Dice (Thresh-DSC) ve Eşikli IoU (Thresh-IoU), bu süreci uygulayacağınız metriklerdir. Bu veriler, Python aracı MedPy'den çıkarılmıştır.

4.2.1 Modelin uygulama ayrıntıları

Seçilen modellerin eğitimi ve validasyonu P100 grafik kartı seçilerek gerçekleştirildi. Hazırlanan modeller, veri seti üzerinde 100 dönem boyunca eğitilmesi planlanmıştır. Aşırı öğrenmeyi engellemek için erken durdurma değeri 8 olarak belirlendi. Modellerin algoritmaları Kaggle ekosisteminde Python programlama dili ve Tensorflow_gpu kütüphanesi ile eğitilmiştir.

İncelenen tüm mimariler U-Net tabanlı olduğu için ortak özellikler taşımaktadır. Tüm modeller kodlayıcı-çözücü tabanlı bir mimari üzerine kuruludur. Kodlayıcı kısmında görüntüden özellikler çıkarılmakta, çözücü kısmında ise bu özellikler yukarı örnekleme ile orijinal görüntü boyutuna geri getirilmektedir. Atlamalı bağlantı yapıları kullanılarak kodlayıcıdaki uzamsal bilginin çözücüye aktarılması sağlanmıştır.

Tüm mimarilerde girdi boyutu 256×256 olarak belirlenmiştir. Kodlayıcı boyunca 3×3 kernel boyutuna sahip 2B evrişim (Conv2D) katmanları kullanılmıştır. Kanal sayıları 32, 64, 128, 256 ve 512 olacak şekilde artmaktadır. Çıkış katmanında 1×1 konvolüsyon ve sigmoid aktivasyonu kullanılarak ikili (binary) segmentasyon gerçekleştirilmiştir.

Eğitim sürecinde tüm modeller de optimizör olarak Adam kullanılmıştır. Eğitim oranı (learning rate) $1e-4$ 'dür. Kayıp fonksiyonu olarak Binary Cross Entropy + Focal Tversky Loss tercih edilmiştir. Performans ölçümü için Dice skoru ve IoU metrięi kullanılmıştır. Aşırı öğrenmeyi engellemek için Early Stopping aktif edilmiştir. Ortak yapı sayesinde modellerin temel amacı aynıdır. Sınırlı veri ile en iyi segmentasyon maskesini üretmek.

Mimariler arasındaki farklar en dar katmanda (bottleneck) kullanılan bilgi işleme yöntemlerinden doğmaktadır. U-Net2B, evrişimsel katmanlara dayalı klasik bir mimaridir. Öğrenme süreci lokal özellikler üzerinden ilerler. Bu sayede küçük ve net yapıları segment etmekte başarılıdır. V-Net2B, residual bloklara sahiptir. Residual bağlantılar sayesinde

gradyan kaybı azaltılır ve daha derin ağların eğitimi kolaylaşır. Bu yapı, modelin daha hızlı öğrenmesine katkı sağlar. Dikkat tabanlı UNet2B, dikkat kapısı (attention gate) mekanizması kullanır. Bu mekanizma, atlamalı bağlantılar üzerinden gelen bilgilerin önemini ağırlıklandırır. Model ilgisiz arka plan bilgilerini baskılayarak hedef bölgelere daha fazla odaklanır. Mekanizma özellikle karmaşık arka planlara sahip görüntülerde avantaj sağlamaktadır. TransUNet2B, Transformer encoder blokları kullanır. Yapılan çalışmada 3 adet transformer katmanı, 16 dikkat başlığı (attention head), MLP (Multi-Layer Perceptron) boyutu 1024 kullanılmıştır. Transformer yapısı modele lokal özelliklerin yanında uzak (global) özellikleri öğrenmesini sağlamıştır. Taransformer yapısı daha fazla parametre ve hesaplama gerektirdiği için daha erken aşırı öğrenmeye uğrayabilmektedir. Swin-UNet2B, transformer tabanlı mimari olup pencere (window-based) öz-dikkat (self-attention) mekanizması kullanır. Genel (global) bilgi daha verimli şekilde öğrenilir. Pencereleme yaklaşımı, veri yapısına bağlı olarak öğrenme süresini uzatabilir. Focal-UNet2B, çalışmada kullanılan en güncel yaklaşımlardan biridir. En dar katmanda Focal Modulation blokları yer alır. Bloklar 3 farklı kernel boyutu kullanarak (3×3 , 5×5 , 7×7) çok ölçekli bağlam çıkarır. 2 adet odaklı modülasyon katmanı ile genişleme (Expansion) oranı 2 olarak tasarlanmıştır. Hem bölgesel hem de genel bağlamı öğrenmeyi amaçlar. Klasik dikkat mekanizmalarına göre daha hafif bir yapı sunar.

Yapılan eğitimler sonucu erken durdurma (early stopping) sonuçları modellerin öğrenme davranışı hakkında bazı bilgiler sunmaktadır:

- U-Net, eğitim çevrimi (Epoch) 92’de durdu ve en iyi ağırlıklar 84’te alındı. Öğrenme süresi uzundur, daha yavaş ama istikrarlı öğrenme göstermiştir.
- V-Net2B, eğitim çevrimi 67’de durdu ve en iyi ağırlıklar 59’da alındı. Residual yapı sayesinde daha hızlı yakınsama sağlamıştır.
- Dikkat Tabanlı UNet, eğitim çevrimi 68’de durdu ve en iyi ağırlıklar 60’da alındı. Dikkat mekanizması öğrenmeyi hızlandırmıştır.
- TransUNet2B, eğitim çevrimi 52’de durdu ve en iyi ağırlıklar 44’de alındı. Transformer yapısı nedeniyle model çok erken aşırı öğrenmeye (overfitting) ulaşmıştır.
- Swin-UNet2B, eğitim çevrimi 69’da durdu ve en iyi ağırlıklar 61’de alındı. Pencere tabanlı attention öğrenmeyi dengeli hale getirmiştir.

- Focal-UNet2B, eğitim çevrimi 73'de durdu ve en iyi ağırlıklar 65'de alındı. Çok ölçekli bağlam (focal modulation) kullanımı sayesinde stabil ve dengeli bir öğrenme süreci göstermiştir.

Bu veriler özellikli mimarilerin daha erken epoclarda en iyi ağırlıklara ulaştığını göstermektedir. Temel mimarilerin öğrenme sürelerinin daha uzun olduğunu göstermektedir.

4.2.2 Modelin uygulama sonuçları













Bu çalışmada farklı U-Net türevi mimarilerin segmentasyon görevindeki davranışlarını karşılaştırmalı olarak incelemiştir. Ortak yapı kullanan mimarilerin farklılıklarının esas olarak en dar (bottleneck) katmanında kullanılan yöntemlerden kaynaklandığı görülmüştür.

Transformatör ve odak modülü tabanlı yaklaşımlar, öğrenme süresini kısaltırken daha hızlı aşırı öğrenmeye ulaşmıştır. U-Net2B yapılarının öğrenme süreleri daha uzun sürmüş ancak daha kararlı bir eğitim süreci sergilemiştir.

Kullanılan mimarilerinin karşılaştırmalı analiz sonuçları tablo 4.2'de gösterilmektedir. Veri setinin küçük olması nedeniyle Unet diğer mimarilere göre daha iyi performans göstermiştir. Sonuç olarak kullanılacak mimarinin veri boyutu, hesaplama maliyeti ve hedef uygulamaya göre seçilmesi gerektiğini göstermektedir.

Tablo 4.2: Modellerin karşılaştırmalı performans sonuçları çalışma 2

Mimariler	Yöntemler	Parametre (M)	Thresh-DSC	Thresh-IoU	ACC	PREC	REC
U-Net2B		7.83	86.55	77.34	99.90	92.16	82.96
V-Net2B		7.18	82.09	71.76	99.88	90.41	78.07
Dikkat Tabanlı UNet2B		7.96	85.47	75.83	99.90	91.56	81.89
TransUNet2B	BT görüntüleri	14.17	85.28	75.41	99.89	90.12	82.46
Swin- UNet2B		12.07	85.63	76.00	99.90	91.50	82.07
Focal- UNet2B		10.58	84.55	74.65	99.89	90.98	80.75

BT	GT	Temel Unet	Temel Vnet	Attention U-Net	TransU-Net	SwinU-Net	FocalU-Net
Image (raw)	GT	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.33)	Pred (th=0.30)
							
Image (raw)	GT	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.33)	Pred (th=0.30)
							
Image (raw)	GT	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.30)	Pred (th=0.33)	Pred (th=0.30)
							

Şekil 4.3: Segmentasyon Sonuçları

5. SONUÇ VE ÖNERİLER

Bu tezde, pankreas segmentasyonunda iki aşamalı bir araştırma gerçekleştirilmiştir. İlk aşamada, Temel U-Net ve Temel V-Net mimarilerini 2B görüntülerle karşılaştırdık ve ardından ikinci aşama, U-Net, V-Net2B, Dikkat Tabanlı UNet2B, TransUNet2B, Swin-UNet2B ve Focal-UNet2B mimarilerinde 2B görüntüler kullanarak segmentasyon performansını elde etmek için modelleri çeşitli şekillerde tanıtmaya yönelikti. Her iki çalışmada da küçük bir tıbbi görüntü veri seti üzerinde yöntemler uygulandı, modelleri segmentasyon çıktıları ve farklı metrikler kullanılarak karşılaştırılmıştır.

5.1. Araştırma Sonuçları

U-Net, az veri ile tıbbi görüntüleme uygulanan daha kararlı bir prosedürdür, daha az parametreye ihtiyaç duyar ve küçük organ segmentasyonu görevinde daha iyidir. V-Net 3B verileri işlemek için tasarlanmış bir mimari olduğundan hacimsel verilerde daha iyi performans göstermektedir. V-Net'in derin ve parametre açısından karmaşık yapısı, küçük veri setlerinde aşırı öğrenmeye neden oldu, bu nedenle gerçek uygulamada U-Net'ten daha kötü performans gösterdi. Swin-UNet2B, büyük ölçekli bağlam öğrenmenin teorik avantajını kullanarak U-Net tabanlı modele yakın performans gösterdi. Dikkat Tabanlı (Attention) UNet2B, dikkat mekanizması sayesinde küçük yapıların tespit doğruluğunu artırdı ve geleneksel U-Net'e yakın başarı sağladı. TransUNet2B, küçük veri seti, düşük çözünürlük ve transformer yapısının yüksek parametre gereksinimi nedeniyle U-Net tabanlı modellere yakın performans gösterdi. Focal-UNet2B, zor ve belirsiz alanlara odaklanan odak modülü kullanmasına rağmen pankreas segmentasyonunda yeterli sonuçlar elde etti. Her iki çalışmanın sonuçlarını karşılaştırırken, U-Net ve türevlerinin sınırlı verilerde daha iyi bir klinik teknik kullandığı, ancak transformer tabanlı modelin uygulanabilir olduğu durumlarda daha büyük veri setlerinde de rol oynayabileceği sonucuna varılmalıdır.

5.2. Araştırma Bulgularına Dayalı Öneriler

Bilimsel araştırma için küçük veri kullanan tıbbi görüntüleme problemleri için, transformer

tabanlı modelleri kullanmadan önce veri artırma stratejileri geliştirmek önemlidir. TransUNet2B ve Swin-UNet2B gibi modellerin performansını artırmak için, bu tür modelleri oluşturmak için birkaç başka yöntem vardır ve önerilen yöntemlerden biri, yüksek çözünürlüklü görüntü setleri ve büyük örneklemlili veri tabanlarının kullanılmasıdır. İnce ve belirsiz sınırları olan pankreas gibi organlarda, bu yeni varyantlar dikkate alınmalıdır. Gelecekteki çalışmalarda hem ESA'nın güçlü yönlerini hem de daha yaygın transformer mekanizmalarını kullanan hibrit yapılar, yeni modeller oluşturmak için kullanılabilir.

Klinik kullanım için bazı yazarlar, U-Net tabanlı modellerin öncelikli kullanımını önermektedir, çünkü bunlar daha hızlı, daha ucuz ve daha karardır ve klinik görevlerde tercih edilmelidir, çünkü klinik uygulamalar hızlı, kararlı ve düşük hesaplama maliyetine odaklanır. U-Net varyantları, sınırlı güç kaynağına sahip donanımlara sahip sağlık merkezleri için daha hızlı işlem yapabilir. Modele eklenen dikkat mekanizmaları küçük, tanımlanması zor dokuların segmentasyonunu işleme konusunda klinik iş akışını ve verimliliğini artırabilir.

KAYNAKLAR

- Albawi, S. Mohammed, T. A. ve Al-Zawi, S. (2017). Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*, 1-6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Ali F. Khalifa ve Eman Badr. (2023). Deep Learning for Image Segmentation: A Focus on Medical Imaging. *Computers, Materials and Continua*, 75(1), 1995-2024. <https://doi.org/10.32604/cmc.2023.035888>
- Aljabri, M. ve AlGhamdi, M. (2022). A review on the use of deep learning for medical images segmentation. *Neurocomputing*, 506, 311-335. <https://doi.org/10.1016/j.neucom.2022.07.070>
- Asgari Taghanaki, S. Abhishek, K. Cohen, J. P. Cohen-Adad, J. ve Hamarneh, G. (2021). Deep semantic segmentation of natural and medical images: A review. *Artificial Intelligence Review*, 54(1), 137-178. <https://doi.org/10.1007/s10462-020-09854-1>
- Ayhan, M. S. K hlew in, L. Aliyeva, G. Inhoffen, W. Ziemssen, F. ve Berens, P. (2020). Expert-validated estimation of diagnostic uncertainty for deep neural networks in diabetic retinopathy detection. *Medical Image Analysis*, 64, 101724. <https://doi.org/10.1016/j.media.2020.101724>
- Bayram, A. F. Gurkan, C. Budak, A. ve Karata , H. (2022). Fully Automatic End-to-End Convolutional Neural Networks-Based Pancreatic Tumor Segmentation on CT Modality. *Turkish Journal of Forecasting*, 06(2), 67-72. <https://doi.org/10.34110/forecasting.1190299>
- Cai, Y. Long, Y. Han, Z. Liu, M. Zheng, Y. Yang, W. ve Chen, L. (2023). Swin Unet3D: A three-dimensional medical image segmentation network combining vision transformer and convolution. *BMC Medical Informatics and Decision Making*, 23(1), 33. <https://doi.org/10.1186/s12911-023-02129-z>
- Cao, H. Wang, Y. Chen, J. Jiang, D. Zhang, X. Tian, Q. ve Wang, M. (2021). Swin-Unet: Unet-like Pure Transformer for Medical Image Segmentation (No. arXiv:2105.05537). arXiv. <https://doi.org/10.48550/arXiv.2105.05537>
- Castro, R. Ramos, L. Rom n, S. Bermeo, M. Crespo, A. ve Cuenca, E. (2023). U-Net vs. TransUNet: Performance Comparison in Medical Image Segmentation.  inde M. Botto-Tobar, M. Zambrano Vizuite, S. Montes Le n, P. Torres-Carri n, ve B. Durakovic (Ed.), *Applied Technologies* (C. 1755, ss. 212-226). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-24985-3_16
- Chen, J. Lu, Y. Yu, Q. Luo, X. Adeli, E. Wang, Y. Lu, L. Yuille, A. L. ve Zhou, Y. (2021). TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation (No. arXiv:2102.04306). arXiv. <https://doi.org/10.48550/arXiv.2102.04306>

- Chhikara, J. Goel, N. ve Rathee, N. (2024). Deep Learning Techniques for Pancreatic Cancer Analysis: A Systematic Review and Implantation Prerequisites. *Procedia Computer Science*, 235, 3118-3130. <https://doi.org/10.1016/j.procs.2024.04.295>
- Derin, A. Gurkan, C. Budak, A. ve KARATAŞ, H. (2022). Pancreas Segmentation Using U-Net Based Segmentation Networks in CT Modality: A Comparative Analysis. *Avrupa Bilim ve Teknoloji Dergisi*, 40, 94-98.
- Dogan, R. Ö. (2021). *Pankreas kanser dokularının segmentasyonunda farklı derin öğrenme tekniklerinin performanslarının incelenmesi (Investigation of different deep learning techniques in pancreas cancer tissues segmentation)*. <https://openreview.net/forum?id=U8vFgt5TYV>
- Dorgham, O. Naser, M. A. Ryalat, M. H. Hyari, A. Al-Najdawi, N. ve Mirjalili, S. (2022). U-NetCTS: U-Net deep neural network for fully automatic segmentation of 3D CT DICOM volume. *Smart Health*, 26, 100304. <https://doi.org/10.1016/j.smhl.2022.100304>
- Facts About Pancreatic Cancer*. (t.y.). Geliş tarihi 15 Kasım 2025, gönderen <https://www.cancer.org/cancer/types/pancreatic-cancer/about/key-statistics.html>
- Farag, A. Lu, L. Roth, H. R. Liu, J. Turkbey, E. ve Summers, R. M. (2017). A Bottom-Up Approach for Pancreas Segmentation Using Cascaded Superpixels and (Deep) Image Patch Labeling. *IEEE Transactions on Image Processing*, 26(1), 386-399. *IEEE Transactions on Image Processing*. <https://doi.org/10.1109/TIP.2016.2624198>
- Gibson, E. Giganti, F. Hu, Y. Bonmati, E. Bandula, S. Gurusamy, K. Davidson, B. Pereira, S. P. Clarkson, M. J. ve Barratt, D. C. (2018). Automatic Multi-Organ Segmentation on Abdominal CT With Dense V-Networks. *IEEE Transactions on Medical Imaging*, 37(8), 1822-1834. *IEEE Transactions on Medical Imaging*. <https://doi.org/10.1109/TMI.2018.2806309>
- Goodfellow, I. (2016). *Deep Learning. I. Goodfellow, Y. Bengio, A. Courville*. Cambridge, MA, USA: MIT Press.
- Hendrycks, D. ve Gimpel, K. (2023). *Gaussian Error Linear Units (GELUs)* (No. arXiv:1606.08415). arXiv. <https://doi.org/10.48550/arXiv.1606.08415>
- Jurado-Rodríguez, D. Jurado, J. M. Pádua, L. Neto, A. Muñoz-Salinas, R. ve Sousa, J. J. (2022). Semantic segmentation of 3D car parts using UAV-based images. *Computers ve Graphics*, 107, 93-103. <https://doi.org/10.1016/j.cag.2022.07.008>
- Juwita, J. Hassan, G. M. Akhtar, N. ve Datta, A. (2024). *M3BUNet: Mobile Mean Max UNet for Pancreas Segmentation on CT-Scans*. <https://doi.org/10.48550/ARXIV.2401.10419>
- Kasban, H. El-Bendary, M. A. M. ve Salama, D. H. (2015). A Comparative Study of Medical Imaging Techniques. *International Journal of Information Science and Intelligent System*, 4(2), 37-58.

- Kingma, D. P. ve Ba, J. (2014). Adam: A Method for Stochastic Optimization. *CoRR*.
<https://www.semanticscholar.org/paper/a6cb366736791bcccc5c8639de5a8f9636bf87e8>
- Koç, A. B. ve Akgün, D. (2021). U-net mimarileri ile glioma tümör segmentasyonu üzerine bir literatür çalışması. *Avrupa Bilim ve Teknoloji Dergisi*, 26, 407-414.
- Kurnaz, E. (2021). *Abdomen BT görüntülerinde pankreas segmentasyonu için yeni bir derin öğrenme yaklaşımı: Pascal U-Net* [Master's Thesis, Konya Teknik Üniversitesi]. <https://gcris.ktun.edu.tr/handle/20.500.13091/958>
- Kurnaz, E. ve Ceylan, R. (2020). Pancreas Segmentation in Abdominal CT Images with U-Net Model. *2020 28th Signal Processing and Communications Applications Conference (SIU)*, 1-4. <https://doi.org/10.1109/SIU49456.2020.9302180>
- Lakshmipriya, B. Pottakkat, B. ve Ramkumar, G. (2023). Deep learning techniques in liver tumour diagnosis using CT and MR imaging—A systematic review. *Artificial Intelligence in Medicine*, 141, 102557.
<https://doi.org/10.1016/j.artmed.2023.102557>
- LeCun, Y. Bengio, Y. ve Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Li, B. Nelson, M. S. Savari, O. Loeffler, A. G. ve Eliceiri, K. W. (2022). Differentiation of pancreatic ductal adenocarcinoma and chronic pancreatitis using graph neural networks on histopathology and collagen fiber features. *Journal of Pathology Informatics*, 13, 100158. <https://doi.org/10.1016/j.jpi.2022.100158>
- Li, C. Mao, Y. Liang, S. Li, J. Wang, Y. ve Guo, Y. (2024). Deep causal learning for pancreatic cancer segmentation in CT sequences. *Neural Networks*, 175, 106294. <https://doi.org/10.1016/j.neunet.2024.106294>
- Lim, S.-H. Kim, Y. J. Park, Y.-H. Kim, D. Kim, K. G. ve Lee, D.-H. (2022). Automated pancreas segmentation and volumetry using deep neural network on computed tomography. *Scientific Reports*, 12(1), 4075. <https://doi.org/10.1038/s41598-022-07848-3>
- Loshchilov, I. ve Hutter, F. (2019). *Decoupled Weight Decay Regularization* (No. arXiv:1711.05101). arXiv. <https://doi.org/10.48550/arXiv.1711.05101>
- Milletari, F. Navab, N. ve Ahmadi, S.-A. (2016). V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. *2016 Fourth International Conference on 3D Vision (3DV)*, 565-571. <https://doi.org/10.1109/3DV.2016.79>
- Mukherjee, S. Korfiatis, P. Khasawneh, H. Rajamohan, N. Patra, A. Suman, G. Singh, A. Thakkar, J. Patnam, N. G. Trivedi, K. H. Karbhari, A. Chari, S. T. Truty, M. J. Halfdanarson, T. R. Bolan, C. W. Sandrasegaran, K. Majumder, S. ve Goenka, A. H. (2023). Bounding box-based 3D AI model for user-guided volumetric segmentation of pancreatic ductal adenocarcinoma on standard-of-care CTs. *Pancreatology*, 23(5), 522-529. <https://doi.org/10.1016/j.pan.2023.05.008>

- Naderi, M. Givkashi, M. Piri, F. Karimi, N. ve Samavi, S. (2022). *Focal-UNet: UNet-like Focal Modulation for Medical Image Segmentation* (No. arXiv:2212.09263). arXiv. <https://doi.org/10.48550/arXiv.2212.09263>
- Ni, H. Zhou, G. Chen, X. Ren, J. Yang, M. Zhang, Y. Zhang, Q. Zhang, L. Mao, C. ve Li, X. (2023). Predicting Recurrence in Pancreatic Ductal Adenocarcinoma after Radical Surgery Using an AX-Unet Pancreas Segmentation Model and Dynamic Nomogram. *Bioengineering*, 10(7), 828. <https://doi.org/10.3390/bioengineering10070828>
- Oktay, O. Schlemper, J. Folgoc, L. L. Lee, M. Heinrich, M. Misawa, K. Mori, K. McDonagh, S. Hammerla, N. Y. Kainz, B. Glocker, B. ve Rueckert, D. (2018). *Attention U-Net: Learning Where to Look for the Pancreas* (No. arXiv:1804.03999). arXiv. <http://arxiv.org/abs/1804.03999>
- Paithane, P. ve Kakarwal, S. (2023). LMNS-Net: Lightweight Multiscale Novel Semantic-Net deep learning approach used for automatic pancreas image segmentation in CT scan images. *Expert Systems with Applications*, 234, 121064. <https://doi.org/10.1016/j.eswa.2023.121064>
- Ronneberger, O. Fischer, P. ve Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. İçinde N. Navab, J. Hornegger, W. M. Wells, ve A. F. Frangi (Ed.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (C. 9351, ss. 234-241). Springer International Publishing. https://doi.org/10.1007/978-3-319-24574-4_28
- Roth, H. R. Farag, A. Lu, L. Turkbey, E. B. ve Summers, R. M. (2015). Deep convolutional networks for pancreas segmentation in CT imaging. *Medical Imaging 2015: Image Processing*, 9413, 378-385. <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/9413/94131G/Deep-convolutional-networks-for-pancreas-segmentation-in-CT-imaging/10.1117/12.2081420.short>
- Roth, H. R. Lu, L. Farag, A. Shin, H.-C. Liu, J. Turkbey, E. B. ve Summers, R. M. (2015). DeepOrgan: Multi-level Deep Convolutional Networks for Automated Pancreas Segmentation. İçinde N. Navab, J. Hornegger, W. M. Wells, ve A. Frangi (Ed.), *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015* (ss. 556-564). Springer International Publishing. https://doi.org/10.1007/978-3-319-24553-9_68
- Roth, H. R. Lu, L. Farag, A. Sohn, A. ve Summers, R. M. (2016). Spatial Aggregation of Holistically-Nested Networks for Automated Pancreas Segmentation. İçinde S. Ourselin, L. Joskowicz, M. R. Sabuncu, G. Unal, ve W. Wells (Ed.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016* (ss. 451-459). Springer International Publishing. https://doi.org/10.1007/978-3-319-46723-8_52
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.

- Şentürk, T. ve Latifoğlu, F. (2023). Biyomedikal Görüntülerin Bölütlenmesine Yönelik Derin Öğrenmeye Dayalı Yöntemler: Bir Gözden Geçirme. *Dicle Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 12(1), 161-187.
- URL-2. (2020). The Cancer Imaging Archive (TCIA).
<https://www.cancerimagingarchive.net/collection/pancreas-ct/>
- Vakalopoulou, M. Christodoulidis, S. Burgos, N. Colliot, O. ve Lepetit, V. (2023). Deep Learning: Basics and Convolutional Neural Networks (CNNs). İçinde O. Colliot (Ed.), *Machine Learning for Brain Disorders* (ss. 77-115). Springer US.
https://doi.org/10.1007/978-1-0716-3195-9_3
- Vaswani, A. Shazeer, N. Parmar, N. Uszkoreit, J. Jones, L. Gomez, A. N. Kaiser, Ł. ukasz, ve Polosukhin, I. (2017). Attention is All you Need. *Advances in Neural Information Processing Systems*, 30.
<https://proceedings.neurips.cc/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html>
- Wang, Y. Gong, G. Kong, D. Li, Q. Dai, J. Zhang, H. Qu, J. Liu, X. ve Xue, J. (2021). Pancreas segmentation using a dual-input v-mesh network. *Medical Image Analysis*, 69, 101958. <https://doi.org/10.1016/j.media.2021.101958>
- Wolz, R. Chu, C. Misawa, K. Fujiwara, M. Mori, K. ve Rueckert, D. (2013). Automated Abdominal Multi-Organ Segmentation With Subject-Specific Atlas Generation. *IEEE Transactions on Medical Imaging*, 32(9), 1723-1730. *IEEE Transactions on Medical Imaging*. <https://doi.org/10.1109/TMI.2013.2265805>
- Xuan, W. ve You, G. (2020). Detection and diagnosis of pancreatic tumor using deep learning-based hierarchical convolutional neural network on the internet of medical things platform. *Future Generation Computer Systems*, 111, 132-142.
<https://doi.org/10.1016/j.future.2020.04.037>
- Yin, M. Liu, L. Gao, J. Lin, J. Qu, S. Xu, W. Liu, X. Xu, C. ve Zhu, J. (2023). Deep learning for pancreatic diseases based on endoscopic ultrasound: A systematic review. *International Journal of Medical Informatics*, 174, 105044.
<https://doi.org/10.1016/j.ijmedinf.2023.105044>
- Yu, Q. Xie, L. Wang, Y. Zhou, Y. Fishman, E. K. ve Yuille, A. L. (2017). Saliency transformation network: Incorporating multi-stage visual cues for pancreas segmentation. *CoRR*.
<https://www.academia.edu/download/85374847/1709.04518v2.pdf>
- Yuan, F. Zhang, Z. ve Fang, Z. (2023). An effective CNN and Transformer complementary network for medical image segmentation. *Pattern Recognition*, 136, 109228.
<https://doi.org/10.1016/j.patcog.2022.109228>
- Zhang, D. Zhang, J. Zhang, Q. Han, J. Zhang, S. ve Han, J. (2021). Automatic pancreas segmentation based on lightweight DCNN modules and spatial prior propagation. *Pattern Recognition*, 114, 107762. <https://doi.org/10.1016/j.patcog.2020.107762>

- Zhou, Y. Xie, L. Fishman, E. K. ve Yuille, A. L. (2017). Deep Supervision for Pancreatic Cyst Segmentation in Abdominal CT Scans. İçinde M. Descoteaux, L. Maier-Hein, A. Franz, P. Jannin, D. L. Collins, ve S. Duchesne (Ed.), *Medical Image Computing and Computer Assisted Intervention – MICCAI 2017* (ss. 222-230). Springer International Publishing. https://doi.org/10.1007/978-3-319-66179-7_26
- Zhou, Y. Xie, L. Shen, W. Wang, Y. Fishman, E. K. ve Yuille, A. L. (2017). A Fixed-Point Model for Pancreas Segmentation in Abdominal CT Scans. İçinde M. Descoteaux, L. Maier-Hein, A. Franz, P. Jannin, D. L. Collins, ve S. Duchesne (Ed.), *Medical Image Computing and Computer Assisted Intervention – MICCAI 2017* (ss. 693-701). Springer International Publishing. https://doi.org/10.1007/978-3-319-66182-7_79
- Zhu, F. Lv, J. Lu, K. Wang, W. Cong, H. Zhang, J. Chen, P. Zhao, Y. ve Wu, Z. (2022). A 3D Medical Image Segmentation Framework Fusing Convolution and Transformer Features. İçinde D.-S. Huang, K.-H. Jo, J. Jing, P. Premaratne, V. Bevilacqua, ve A. Hussain (Ed.), *Intelligent Computing Theories and Application* (ss. 772-786). Springer International Publishing. https://doi.org/10.1007/978-3-031-13870-6_63
- Zografos, V. Valentinitich, A. Rempfler, M. Tombari, F. ve Menze, B. (2016). Hierarchical multi-organ segmentation without registration in 3D abdominal CT images. *Medical Computer Vision: Algorithms for Big Data: International Workshop, MCV 2015, Held in Conjunction with MICCAI 2015, Munich, Germany, October 9, 2015, Revised Selected Papers 18*, 37-46. https://link.springer.com/chapter/10.1007/978-3-319-42016-5_4

BİBLİYOGRAFYA



EKLER

Ek 1: Yapay zekâ kullanım tablosu

No	Yapay Zekâ Aracı	Kullanım Amacı	Kullanıldığı Bölüm	Kullanım Şekli
1	ChatGPT (OpenAI)	Yazım Dili Kontrolü	Tüm Tez	Yazım dilinden oluşacak hataların bulunması ve akademik dilde literatür tanımlamaları için
2				
3				
4				
5				

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Azim USLUCUK
Doğum Yeri ve Tarihi :

Eğitim Durumu

Lisans Öğrenimi : Mustafa Kemal Üniversitesi
Yüksek Lisans Öğrenimi : Bartın Üniversitesi
Bildiği Yabancı Diller : İngilizce
Bilimsel Faaliyet/Yayınlar : Uslucuk, A. ve Öcal, H. (2023). Comparative Analysis of Baseline Vnet and Unet Architectures on Pancreas Segmentation. *Orclever Proceedings of Research and Development*, 3(1), 146–157.
<https://doi.org/10.56038/oprd.v3i1.309>
Aldığı Ödüller :

İş Deneyimi

Stajlar : Türkiye Taş Kömürü Merkez Atölyesi 2004, 2005
Projeler ve Kurs Belgeleri : TÜBİTAK – 7100031, KOBİ-GEL 2017, KOBİ-GEL 2020, Solidworks Temel Eğitim 2013, ÇSGB İSG Uzmanlığı Yetki Belgesi 2014, Siemens PLC Programlama Eğitim Belgesi 2015, ISO 9001-2015 Yetki Sertifikası 2018, Solidworks Sac Levha Eğitim Sertifikası 2020, MMO Doğalgaz İç Tesisat Yetki Belgesi 2022, Bakım Mühendisliği Eğitim Sertifikası 2024
Çalıştığı Kurumlar : Hema Endüstri A.Ş., Çanakcılar Yapı A.Ş.

İletişim

E-Posta Adresi :

Tarih : .../.../20... (Tez Savunma Tarihi)



