



Investigating the impact of data fusion on the ResUNet model for liver tumor segmentation

Ümran Şeker Ertuğrul^{1*}, Halife Kodaz², Onur İnan³

¹Technology Transfer Office, Yozgat Bozok University, 66100, Yozgat, Türkiye

²Department of Computer Engineering, Faculty of Engineering and Natural Sciences, Konya Technical University, 42250, Konya, Türkiye

³Department of Computer Engineering, Faculty of Technology, Selçuk University, 42250, Konya, Türkiye

Highlights:

- Impact of data fusion on the ResUNet architecture
- PCA+ResUNet-based tumor detection
- DWT+ResUNet-based tumor detection

Keywords:

- Medical image segmentation,
- Discrete Wavelet Transform image fusion,
- Liver tumor segmentation,
- Principal Component Analysis image fusion,
- ResUNet model

Article Info:

Research Article

Received: 28.05.2025

Accepted: 16.01.2026

DOI:

10.17341/gazimmfd.1708157

Correspondence:

Author: Ümran Şeker Ertuğrul

e-mail:

umran.seker@bozok.edu.tr

phone: +90 354 217 8991

Graphical/Tabular Abstract

In medical diagnosis and treatment planning, performing liver tumor segmentation using artificial intelligence-based automatic methods offers significant support to physicians and radiologists. In this study, a model was developed that segments the location and volume of liver tumors, as shown in Figure A, using the ResUNet architecture and data fusion techniques.



Figure A. An example segmentation result obtained using the ResUNet + DWT method

Purpose:

The aim of this study is to develop an artificial intelligence-based automatic method for liver tumor segmentation. It demonstrates that the developed method performs well and can be used as an additional informational tool for doctors in diagnosis and treatment processes.

Theory and Methods:

In this study, two different datasets obtained from online databases were used. The research focused on the development of the model. ResNet and U-Net architectures were developed for medical image segmentation, and these two architectures were hybridized to achieve better performance. Additionally, image fusion was incorporated into the hybrid architecture to increase data diversity in the limited medical datasets.

Results:

In this study, PCA- and DWT-based data fusion methods were used to transform images into different spaces, thereby increasing the model's diversity. The proposed model achieved a notable dice similarity coefficient value compared to existing studies in the literature.

Conclusion:

With the proposed model, a system has been developed for liver tumor segmentation that can provide doctors and radiologists with information about the tumor's location and shape during diagnosis and treatment processes.



Karaciğer tümör segmentasyonu için veri füzyonunun ResUNet modeli üzerindeki etkisinin araştırılması

Ümran Şeker Ertuğrul^{1*}, Halife Kodaz², Onur İnan³

¹Yozgat Bozok Üniversitesi, Teknoloji Transfer Ofisi, 66100, Yozgat, Türkiye

²Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, 42250, Konya, Türkiye

³Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, 42250, Konya, Türkiye

Ö N E Ç İ K A N L A R

- ResUNet mimarisine veri füzyonunun etkisi
- PCA+ResUNet yöntemiyle tümör tespiti
- DWT+ResUNet yöntemiyle tümör tespiti

Makale Bilgileri

Araştırma Makalesi
Geliş: 28.05.2025
Kabul: 16.01.2026

DOI:

10.17341/gazimmfd.1708157

Anahtar Kelimeler:

Tıbbi görüntü segmentasyonu, ayrık dalgacık dönüşümü ile görüntü füzyonu, karaciğer tümörü segmentasyonu, temel bileşenler analizi ile görüntü füzyonu, ResUNet modeli

ÖZ

Tıbbi görüntü segmentasyonu, hastalığın teşhisi veya hastalıklı bölgenin konumlandırılması amacıyla, görüntüdeki renk ve şekil farklılıklarını kullanarak bölgeleri ayırma işlemidir. Bu işlem manuel veya otomatik olarak gerçekleştirilebilir. Günümüzde makine öğrenmesi ve derin öğrenme tekniklerini kullanan otomatik segmentasyon yöntemlerinde, performansı artırmak amacıyla alana özgü modeller geliştirilmekte olup, tıbbi veri setlerinde U-Net tabanlı segmentasyon mimarileri sınırlı ve dengesiz veri ile bile etkili sonuçlar verebilmektedir. Ancak U-Net mimarisinde, derin ağlarda gradyan sönmesi gibi eğitim zorlukları ortaya çıkabilmektedir; bu noktada ResNet mimarisinde, daha derin bir yapı sağlayarak derinlik gereksinimlerini karşılamaktadır. Bu mimarilerin birleştirilmesiyle oluşan hibrit ResUNet mimarisi U-Net'in segmentasyon gücünü ResNet'in artık bağlantıları ile birleştirerek, hem derin ağların avantajını kullanmakta hem de eğitim sürecindeki zorlukları hafifletmektedir. Bu çalışmada, otomatik karaciğer tümör segmentasyonu amacıyla, Temel Bileşenler Analizi (PCA) ve Ayrık Dalgacık Dönüşümü (DWT) ile kanal bazlı birleştirilen veriler üzerinde hibrit ResUNet modeli uygulanmıştır. Her kanalın özgün ve ayırt edici örüntülerini koruyarak özellik temsillerini zenginleştirmek amacıyla kanal bazlı veri füzyonu kullanılmıştır. PCA ve DWT tabanlı her iki füzyon yöntemi de, verileri farklı uzaylara taşıyarak modelin görüntüdeki farklı yapıları ayırt etme kapasitesini güçlendirmiştir. Sonuçlar, her iki yöntemin de iki farklı veri setinde birbirine yakın dice benzerlik katsayısı değerleri elde ederek karşılaştırılabilir performans sergilediğini ortaya koymaktadır.

Investigating the impact of data fusion on the ResUNet model for liver tumor segmentation

H I G H L I G H T S

- Impact of data fusion on the ResUNet architecture
- PCA+ResUNet-based tumor detection
- DWT+ResUNet-based tumor detection

Article Info

Research Article
Received: 28.05.2025
Accepted: 16.01.2026

DOI:

10.17341/gazimmfd.1708157

Keywords:

Medical image segmentation, discrete wavelet transform image fusion, liver tumor segmentation, principal component analysis image fusion, ResUNet model

ABSTRACT

Medical image segmentation is employed to separate regions in images based on color and shape differences for disease diagnosis or localization of pathological areas. It can be performed manually or automatically. Automatic segmentation methods leverage machine learning and deep learning techniques, with domain-specific models developed to enhance performance; U-Net-based architectures can achieve effective results even with limited and imbalanced medical datasets. However, U-Net models may face training challenges such as vanishing gradients in deep networks, which can be addressed by ResNet architectures providing deeper structures. The hybrid ResUNet combines the segmentation capabilities of U-Net with the residual connections of ResNet, thus exploiting the advantages of deep networks while mitigating training difficulties. In this study, for automatic liver tumor segmentation, the hybrid ResUNet was applied to channel-based fused data obtained using Principal Component Analysis (PCA) and Discrete Wavelet Transform (DWT). Channel-based data fusion preserves the unique and distinctive patterns of each channel, enriching feature representations, and both PCA- and DWT-based fusion methods transform the data into different spaces, enhancing the model's ability to differentiate various structures. The results demonstrate that both methods achieve comparable performance, yielding similar dice similarity coefficient values across two different datasets.

1. Giriş (Introduction)

Vücudun en büyük iç organlarından birisi olan karaciğer, sindirim sürecine katkı sağlamak ve metabolik faaliyetleri düzenlemek gibi hayati görevleri yerine getirir. Ancak, kanser benzeri anormal hücre oluşumları bu işlevleri bozarak fonksiyonel düzensizliklere ve ciddi komplikasyonlara yol açabilir. Karaciğer kanseri, dünya genelinde kansere bağlı ölümlerin en yaygın nedenlerinden birisidir [1]. Dolayısıyla, kanserli dokuların zamanında ve kapsamlı değerlendirilmesi, tedavi planlamasında büyük önem taşır. Karaciğer hastalıklarının teşhis ve tedavisinde manuel, yarı otomatik ve tam otomatik olmak üzere çeşitli segmentasyon yöntemleri kullanılmaktadır. Her yöntemin kendine özgü avantajları olsa dahi son teknolojik gelişmeler ve segmentasyon görevlerinde artan verimlilik ihtiyacı nedeniyle otomatik yöntemler daha ön plana çıkmaktadır. Otomatik yöntemler; manuel yöntemlere göre zaman tasarrufu sağlamakla birlikte zahmetli değildir. Bunun yanı sıra, karaciğer ve mide gibi bazı organların anatomik olarak birbirine yakın olması ve aralarındaki kontrastın düşük olması, manuel analizleri zorlaştırmakta ve hata yapma olasılığını artırmaktadır; bu nedenle, otomatik yöntemler bu tür zorlukların üstesinden gelmede uygun ve etkili bir çözüm sunmaktadır. [2, 3].

Otomatik görüntü segmentasyonu, görüntüyü bölgelere ayıran, özelliklerini çıkaran ve özelliklerine göre segmentasyon yapan dijital bir görüntü kümeleme yöntemidir. Segmentasyon, görüntü işleminin hem zor hem de önemli bir parçası olup daha anlamlı bilgiler elde edilmesini sağlar [4]. Segmentasyon, bir görüntünün piksellere ayrılması ve bu piksellerin benzerlik veya farklılıklara göre gruplandırılmasıdır. Özellikle tıbbi verilerde, enfekte bölgenin tüm alandan ayrılması için kullanılır [5]. Bu yöntem, tıbbi uygulamalarda patoloji karakterizasyonu açısından oldukça önemli olmasına rağmen, tıbbi görüntülerin Manyetik Rezonans (MR) ve Bilgisayarlı Tomografi (BT) gibi farklı cihazlardan elde edilmesi nedeniyle şekil, boyut ve doku yapılarında farklılıklar oluşabilir [6]. Bu farklılıklar, segmentasyon işleminin performansını olumsuz yönde etkileyebilir. Bu tür olumsuzlukları azaltmak veya önlemek amacıyla gürültü giderme, öznitelik seçimi ve görüntü füzyonu gibi ön işleme adımları uygulanabilir. Bu yöntemlerden görüntü füzyonu, birden fazla görüntünün birleştirilerek daha yüksek boyutta ve daha kapsamlı görüntülerin oluşturulmasını sağlar. Füzyon uygulanmış görüntülerde, segmentasyon daha verimli gerçekleştirilebilir. Bu bağlamda, görüntü füzyonu, daha ayrıntılı ve güvenilir görsel veriler üretmek için tıbbi görüntü işleme alanında önemli bir yöntem haline gelmiş olup otomatik görüntü segmentasyonunda yapay zeka temelli uygulamalar için nitelikli veri oluşturabilmektedir.

Yapay zeka tabanlı derin öğrenme yöntemleri, tıbbi görüntü segmentasyonu için güçlü araçlar sağlamaktadır. Derin öğrenme, görüntülerin belirgin özelliklerini ayırt etme konusunda oldukça etkili olup piksel tabanlı analiz oluşturmanın yanı sıra, segmentasyon işleminde, veri sayısını artırmak gibi önemli avantajlar da sunmaktadır. Derin öğrenme modellerinin performansı, eğitim verisindeki örnek sayısına bağlı olarak değişmekte olduğu için veri artırımı çok önemlidir. Veri artırma, genelleme yeteneğini geliştirmeye yardımcı olan popüler bir tekniktir. Yeterli sayıda veri kullanılması, ağız aşırı öğrenmesini önlemektedir. Bu bağlamda, yapay olarak kullanılan veri artırma teknikleri;

- Döndürme, yakınlaştırma, kırpma ve yansıtma gibi afin dönüşümleriyle artırılan görüntüler, orijinal görüntülerle yüksek düzeyde benzerlik gösterdiği için model performansında sınırlı bir iyileşme sağlamaktadır [7-9].
- Elastik tabanlı veri artırma algoritmaları, görüntüde yapısal bütünlüğü bozarak gerçek dışı deformasyonlara ve yapay gürültüye

yol açabilir. Bu nedenle, aşırı kullanımları model performansını olumsuz etkileyebilir. Özellikle bu yöntemler fazla uygulandığında, tamamen gerçek dışı ve anlamsız görüntülerin ortaya çıkmasına neden olur ve modelin öğrenme sürecini yanıltabilir. Görüntülerde oluşan bu tür bozulmalar, modelin hatalı genelleme yapmasına ve gerçek veriler üzerinde düşük performans göstermesine yol açar [10, 11].

- Piksel düzeyinde yapılan görüntü dönüşümlerinde, büyüme aşamasında geometrik özellikler değişmeden kalır, ancak piksel yoğunluk değerleri farklılık gösterir. Tıbbi verilerde, piksel tabanlı yaklaşımlar daha başarılı olabilir [12].
- Yapay veri üretim yöntemlerinde, eğitim verisinin artırılmış örneklerini oluşturmak için algoritmalar yardımıyla yeni veriler oluşturulabilir [13-15].

Bu yöntemler, eğitim verisinin sayısını artırmak için kullanılabilir; buna karşın, tıbbi görüntüler genellikle çok kanallı dilimlerden oluşmaktadır. Tek bir kanal görüntülerin yalnızca tek bir yönünü veya özelliğini temsil ederken tüm kanallar farklı açılardan tüm özelliklerini temsil etmektedir. Kanal bazlı füzyon uygulamaları farklı kanallardan gelen bilgileri birleştirdiği için daha zengin ve kapsamlı bir özellik haritası oluşturmaktadır. Kanal bazlı veri füzyonu amacıyla Temel Bileşenler Analizi (PCA); boyut indirgeme, gürültü azaltma ve öne çıkan özelliklerin seçilmesi için Ayrık Dalgacık Dönüşümü (DWT); hem düşük frekanslı yapısal bilgiyi hem de yüksek frekanslı detayları koruyarak segmentasyon için zengin bir özellik temsili sağlamak amacıyla kullanılabilir. Kanal bazlı füzyon uygulamalarında, her kanaldaki farklı görüntüler ayrı işlendiği için görüntünün ayırt edici özellikleri daha iyi öğrenilir. Kanal bazlı birleştirilen görüntüler, segmentasyon için hem düşük hem de yüksek seviyeli bilgiyi bütünleştirerek daha zengin özellik temsili ve artan doğruluk sağlar.

Derin öğrenme yöntemlerinde çeşitli segmentasyon uygulamaları, problemlere en uygun çözüm yöntemini belirlemek amacıyla Konvolüsyonel Sinir Ağı (CNN) mimarileri temel alınarak geliştirilmiştir. Bu amaçla, biyomedikal görüntü segmentasyonu için U-Net ve ResNet mimarileri önerilmiştir. U-Net mimarisi, aynı giriş ve çıkış verilerine sahip kodlayıcı ve kod çözücü bir yapıdan oluşur. Bu mimari, her bir piksel değeri üzerinde sınıflandırma ve maskeleme işlemi yapar. U-Net, düşük seviyeli özelliklerin bile etkili bir şekilde kullanılmasını sağlayarak segmentasyon performansını artırır. Bununla birlikte, derin öğrenme mimarilerine ekstra katmanlar eklemek, eğitim ve doğrulama hatalarının artmasına yol açabilir. Birçok katmandan oluşan derin ağları optimize etmek, zorlu bir süreçtir. Ancak, ResNet mimarisi, derin ağların eğitimi aşamasında yaşanabilecek bozulma sorunlarını aşabilir [16]. Bunun yanı sıra, U-Net mimarisinde kodlayıcı-kod çözücü yapısı ve atlama bağlantıları segmentasyon görevleri için oldukça uygun olsa da, katman sayısı arttığında geri yayılım sürecinde gradyanlar derin katmanlara ulaştıkça giderek küçülür. Gradyanların küçülmesi, alt seviyeli katmanlardaki filtrelerin yeterli şekilde öğrenememesine yol açarak ağız temsil kapasitesini sınırlar. Sonuç olarak, eğitim yavaşlarken, modelin karmaşık yapıları öğrenmesi zorlanır ve ağız derinleşse bile modelin başarısına etkisi olmaz. ResNet mimarisi ise daha çok sınıflandırma uygulamaları için geliştirilmiş bir mimari olduğu için piksel bazlı segmentasyon uygulamalarında tek başına iyi performans sağlayamaz. Fakat, ResNet ve U-Net mimarisi birleştirildiğinde aşırı öğrenme riskinin azaldığı, gradyan kaybının önlenildiği, derin ve güçlü bir segmentasyon mimarisi oluşmaktadır.

Tıp alanında kaliteli veri elde etmek zaman alıcı ve zorlu bir süreçtir. Bu tür zorluklar, segmentasyon ve veri füzyon yöntemleri ile aşılabılır. Bu çalışmada, karaciğer tümörü segmentasyonu için karaciğer ve maske görüntülerine PCA ve DWT veri füzyon

yöntemleri uygulanmış ve segmentasyon işlemi hibrit ResUNet modeli ile gerçekleştirilmiştir. Tıbbi veriler yüksek boyutlu olduğu için analiz süreçleri oldukça uzundur. Analiz süreçlerini etkin ve optimum biçimde yönetmek amacıyla görüntüler, 120x120 boyutunda yeniden boyutlandırılmıştır. Yeniden boyutlandırma işlemi, veri tutarlılığı ve özellik çıkarımında verimlilik gibi avantajlar sağlar. Sonuç olarak, çalışmada iki farklı veri kümesi ile analizler gerçekleştirilmiş olup PCA ve DWT tabanlı uzay dönüşümleri ile elde edilen görüntüler, genel olarak performanslı sonuçlar üretmiştir. Bu dönüşümler, verilerin daha verimli işlenmesini sağlayarak modelin başarısını artırmıştır. Ayrıca, hibrit ResUNet mimarisi, her iki mimarinin de güçlü yönlerini birleştirerek daha kapsamlı ve etkili bir model ortaya çıkarmıştır. Bu hibrit yaklaşım, her iki yöntemin avantajlarını bir araya getirerek görüntü işleme görevlerinde daha yüksek doğruluk ve verimlilik sağlamıştır.

Çalışmanın akışı şu şekildedir: çalışmanın ikinci bölümünde, veri füzyonu ve karaciğer segmentasyonu ile ilgili yapılan literatür çalışmaları incelenmiştir. Yöntem bölümünde; problem açıklanmış, çalışmada kullanılan yöntemler özetlenmiş ve bu yöntemlerin uygulaması yapılmıştır. Sonuçlar ve tartışmalar bölümünde; elde edilen sonuçlar değerlendirilmiş, literatürdeki mevcut çalışmalarla karşılaştırılmaları yapılmış, modelin güçlü ve zayıf yönleri yorumlanmıştır. Son olarak, sonuçlar bölümünde çalışmanın bulgularına ilişkin genel bir değerlendirme yapılmıştır.

2. İlgili Çalışmalar (Related works)

Teknolojik altyapıların iyileşmesi ve derin öğrenme modellerindeki performans artışı sayesinde, derin öğrenme mimarileri tıbbi görüntü segmentasyonunda yaygın olarak kullanılmaktadır; özellikle U-Net ve varyantları organ ve tümör yapılarının segmentasyonunda yüksek doğruluk sağlarken, ResNet tabanlı ve attention mekanizmaları içeren modeller daha karmaşık anatomik yapıları doğru şekilde segmente edebilmekte ve genelleme yeteneğini artırmaktadır. Ayrıca, çok modlu görüntü füzyonu ve kanal bazlı veri birleştirme gibi teknikler, sınırlı veri setlerinde bile segmentasyon performansını iyileştiren önemli stratejiler olarak ön plana çıkmaktadır. Bu bölümde, veri füzyonu ve karaciğer segmentasyonu için literatürde kullanılan yöntemler incelenmiştir.

Derin öğrenme tabanlı çok modlu tıbbi görüntü segmentasyonu, farklı görüntüleme modalitelerinden elde edilen bilgileri bütünleştirerek tanı doğruluğunu artırmayı amaçlamaktadır. Bu kapsamda yapılan bir çalışmada [17], giriş verisine yönelik iki temel birleştirme yaklaşımından bahsedilmiştir. Bu yaklaşımlar;

- Concatenation, çoklu veri kaynaklarından gelen özellikleri tek bir tensörde birleştirme amacıyla kullanılır. Özellik uzayını büyütür ve bilgi kaybını önler.
- Merge, belirli bir stratejiye göre verileri harmanlayarak birleştirir. Hesaplama maliyeti ve karmaşıklığı fazladır.

Çok modlu tıbbi görüntü füzyonu için yapılan bir çalışmada, bulanıklaştırma, gürültü giderme ve yeniden yapılandırma işlemleri için hibrit bir SADE-DTCWT-PCA yöntemi uygulanmıştır [18]. Birden fazla kaynağa dayalı füzyon yöntemlerinin, veri miktarını artırarak büyük çeşitlilik sağladığı belirtilmiştir. Çalışmada, verileri bantlara ayırmak için DT-CWT yöntemi kullanılmıştır. Özvektörleri ayırmak için SADE yöntemi uygulanmıştır. Son adımda ise PCA füzyon kuralı uygulanmıştır. Uygulama, karaciğer veri seti üzerinde gerçekleştirilmiştir. Geleneksel yöntemlere kıyasla daha başarılı bir füzyon sonucu elde edilmiştir. Füzyon yöntemlerinin, tedavi planlamasına yardımcı olduğu ifade edilmiştir.

Karaciğer damar yapısını incelemek amacıyla gerçekleştirilen bir segmentasyon çalışmasında [19], yapının doğru analizinin karaciğer 536

hastalıklarının tedavisinde büyük öneme sahip olduğu belirtilmiştir. U-Net ve türevlerini içeren derin öğrenme mimarilerinin karaciğer yapısını otomatik olarak analiz etmek için yaygın olarak kullanıldığı ifade edilmiştir. İrcad veri seti BT tıbbi görüntüleriyle yapılan analizde, en başarılı sonuçlar MultiResU-Net mimarisıyla elde edilmiştir. İrcad veri seti, 10 kadın ve 10 erkekten alınan toplam 20 BT görüntüsünü içermektedir. Veri seti 512x512x120 boyutlarında yeniden boyutlandırılmıştır. Model girişlerinin tutarlı biçimde işlenebilmesi için, dilim sayısı 120'nin altında olan hacimlere sıfır dolgusu uygulanmış ve böylece tüm örneklerin boyutsal olarak standardizasyonu sağlanmıştır. Tümörün bulunduğu segmentin belirlenmesini sağlamak, segmentasyonun doğruluğunu artırmak ve cerrahi planlamaya yönelik analizleri desteklemek amacıyla Couinaud zonlaması kullanılmıştır. Ayrıca, veri bölme ve model eğitimi için Slab tabanlı ve Box tabanlı yaklaşım yöntemleri kullanılmıştır. Slabs tabanlı MultiResU-Net mimarisıyla %88 dice benzerlik katsayısı değeri elde edilmiştir.

3DU-Net mimarisıyla gerçekleştirilen bütün bir karaciğer çıkarımı çalışmasında [20], eğitim örneklerinin sayısını artırmak amacıyla döndürme ve yansıtma veri artırma teknikleri uygulanmıştır. Çalışmada Sliver07 ve 3DIrcad veri setleri kullanılmıştır. Segmentasyon doğruluğunu ve hassasiyetini artırmak amacıyla, loss fonksiyonu için dice katsayısına dayalı bir benzerlik metriği önerilmiştir. 3DU-Net mimarisi kullanılarak 3DIrcad veri setindeki BT görüntülerinin segmentasyonunda, dice benzerlik katsayısı %75,3 duyarlılık (sensitivity) %76,7 ve doğruluk (accuracy) %97,6 olarak elde edilmiştir.

Karaciğer segmentasyonu için derin öğrenme tabanlı ağların karşılaştırıldığı bir çalışmada [21], segmentasyon amacıyla Tam Evrişimli Sinir Ağı (FCN) mimarisıyla oluşturulmuş düz sinir ağı varyasyonları ve ResNet mimarisıyla oluşturulmuş artık sinir ağı modelleri kullanılmıştır. Çalışmada FCN, U-Net, SegNet, ResNet ve DenseNet olmak üzere beş temel mimari değerlendirilmiştir. Çalışmada kullanılan veri seti, karaciğer segmentasyon yarışmasından alınmış olup 512x512 boyutlarında 131 BT görüntüsünden oluşmaktadır. FCN mimarisi çalışmada en düşük performansı gösterirken, DenseNet mimarisi %91,44 dice katsayısı ile en yüksek performansı elde etmiştir. U-Net ve ResNet mimarileri, DenseNet mimarisine en yakın sonuçları elde etmiştir.

Görüntü segmentasyonunun araştırma ve yeniliğe açık bir konu olduğu gözlemlenmiştir. Literatürde, U-Net ve ResNet mimarileri tıbbi görüntü segmentasyonunda yüksek performanslarıyla öne çıkmaktadır. Bu çalışmada ise karaciğer tümör segmentasyonu için ResUNet modeli kullanılmıştır. Bu mimariyle birlikte ağ derinliği artırılmış, ancak bu durum eğitim performansını olumsuz etkilememiştir. Öte yandan, literatürde eğitim performansındaki düşüşler genellikle yetersiz veri, aşırı veri artırma, modelin gereğinden fazla derinleşmesi ve uygun olmayan hiperparametre seçimleri gibi faktörlerle ilişkilendirilmektedir. Özellikle kanal bazlı füzyon yöntemleri gibi daha karmaşık veri yapılarının kullanıldığı durumlarda, bu tür etkenlerin dikkate alınması model başarısını açısından kritik öneme sahiptir. Bu bağlamda, karaciğer tümör verisi üzerinde kanal bazlı veri füzyonunun etkisini incelemek amacıyla PCA ve DWT tabanlı füzyon yöntemleri kullanılmış ve bu yöntemlerin performansları ResUNet modeli üzerinden değerlendirilmiştir.

3. Metodoloji (Methodology)

Bu çalışmada, U-Net ve ResNet mimarisinin artık bağlantılarının birleştirildiği ResUNet mimarisi kullanılmıştır. Bu sayede, daha derin ağların eğitilmesi mümkün olmuş ve segmentasyon doğruluğu artırılmıştır. Ayrıca, modelin performansını artırmak amacıyla birden

fazla görüntüleme modundan elde edilen verilerin füzyonu gerçekleştirilmiş ve karmaşık tıbbi görüntüleme görevleri için daha güvenilir ve etkili bir çözüm sunulmuştur. Modelin etkinliğini değerlendirmek için iki farklı veri seti kullanılmış ve böylece çeşitli görüntüleme koşulları altında kapsamlı bir performans analizi yapılmıştır. Tüm analizler, Intel® Core™ i7-8750H işlemci, 16 GB RAM, 2.20 GHz CPU frekansı ve NVIDIA GeForce GTX 1060 GPU'ya sahip bir sistem üzerinde gerçekleştirilmiştir.

3.1. Karaciğer tümör segmentasyonu (Liver tumor segmentation)

Karaciğer segmentasyonunun manuel olarak yapılması, tekrarlanabilirlik açısından zayıf, değerlendirme açısından kişiye bağlı ve zaman açısından maliyetlidir. Ayrıca, karaciğer ile kalp gibi bazı organlar arasındaki yoğunluk farkları oldukça küçüktür. Bu nedenle, karaciğer lezyonlarının segmentasyonu için tam otomatik segmentasyon yöntemlerine olan ilgi artmıştır [22]. Bu yöntemlerle, tümör taramasında en önemli adım, lezyonların konumunun doğru bir şekilde belirlenmesidir. Karaciğerin konumu itibarıyla komşu organlarla bağlantılı olması, segmentasyon uygulamaları için sınırlarının net bir şekilde belirlenmesini zorlaştırmaktadır. Bu organların birbirine bitişik olması ve yoğunluk farklarının oldukça az olması sebebiyle düşük seviyeli görüntü işleme algoritmaları, karaciğer segmentasyonu için yetersiz kalmaktadır. Segmentasyon sürecinde lezyonların boyutu, şekli ve sayısındaki değişikliklerin yanı sıra, tedavi süresince karaciğerde meydana gelen değişiklikler de bu süreci daha karmaşık hale getirmektedir. Bu nedenlerle, gelişmiş yapay zeka tabanlı ve derin öğrenme yöntemlerine ihtiyaç duyulmaktadır [23, 24].

3.2. Veri (Data)

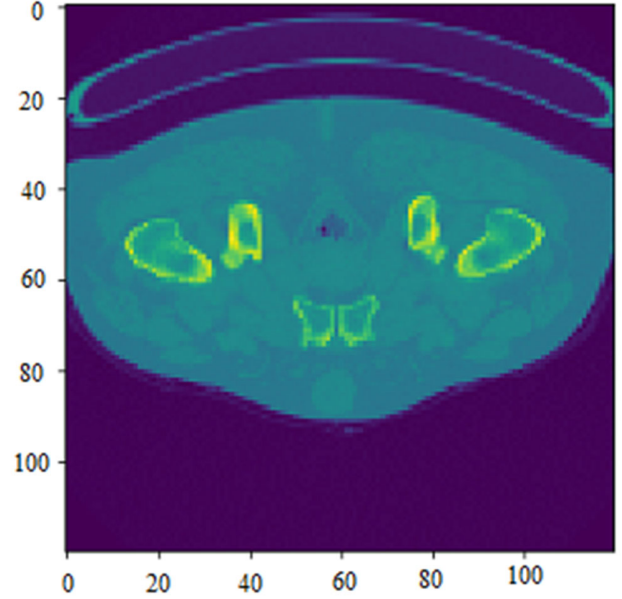
Çalışmada kullanılan tüm veriler Kaggle veri tabanından alınmıştır. İlk veri seti [25], "nii" formatında 123 adet karaciğer BT görüntüsü ve maske görüntüsü içermektedir. İlgili veri setinde taramalar enine (axial) düzlemde $143 \times 143 - 256 \times 256$ piksel boyutları aralığında olup, z kesit (z-slice) sayıları 25 ile 270 arasında değişmektedir. İkinci olarak kullanılan veri seti Liver Tumor Segmentation Challenge 2017 (LiTS17) kapsamında sağlanmış olup [26] "nii" formatında farklı BT cihazlarından elde edilen 131 adet karaciğer BT görüntüsü ve maske görüntüsü içermektedir. Taramalar enine düzlemde 512×512 piksel boyutunda olup, z kesit (z-slice) sayıları 74 ile 986 arasında değişmektedir. Kullanılan veri setleri, çeşitliliği ve yüksek anotasyon kalitesi ile segmentasyon modellerinin eğitimi ve performans değerlendirmesi için güvenilir bir kaynak oluşturmaktadır. Çalışmada kullanılan görüntülerin boyutları birbirinden farklı olduğu için 120×120 boyutlarında yeniden boyutlandırma işlemi yapılmıştır. Bu işlem, modelin performansını artırmaya ve eğitim sürecini optimize etmeye yönelik aşağıdaki avantajları sağlamıştır:

- **Bellek ve hesaplama kaynaklarının verimli kullanımı:** Görüntü boyutlarının küçülmesi, bellek kullanımını optimize ederken hesaplama maliyetini de düşürmektedir.
- **Genelleştirilmiş özellik çıkarımı:** Ayrıntı seviyesinin azaltılması, modelin daha soyut, genelleştirilmiş ve anlamlı özellik temsilleri öğrenmesine olanak tanır; bu durum, modelin farklı örnekler üzerinde daha tutarlı performans sergilemesine katkı sağlar.
- **Parametre sayısında azalma:** Görüntülerin girdi boyutunun küçültülmesi, tek başına modelin katmanlarındaki öğrenilebilir parametre sayısını doğrudan değiştirmez. Ancak, model mimarisinde (örneğin katman sayısı, genişlik veya derinlik) yapılan küçültmeler parametre sayısının azalmasına yol açar.
- **Girdi boyutu standardizasyonu:** Derin öğrenme modelleri, çoğunlukla sabit boyutlu veri girişleri ile çalışacak şekilde tasarlanmaktadır. Farklı boyutlara sahip görüntülerin doğrudan

modele verilmesi, giriş katmanında boyut uyumsuzluklarına neden olabileceğinden, bu tür uyumsuzlukları gidermek amacıyla eğitim öncesinde yeniden boyutlandırma veya padding gibi ön işleme adımları uygulanmaktadır.

- **Veri birleştirme uygulamalarında kullanım kolaylığı:** Tüm verilerin aynı boyutta olması, kanal bazlı veri birleştirme gibi uygulamalarda doğru ve tutarlı sonuçlar elde edilmesini sağlar.

Şekil 1'de, ilk veri setinden alınan bir görüntünün 120×120 piksel boyutlarında yeniden boyutlandırılmış hali örnek olarak gösterilmiştir.



Şekil 1. 120×120 piksel boyutlarında örnek bir karaciğer görüntüsü (A sample liver image with 120×120 pixels)

3.3. Görüntü füzyonu (Image fusion)

Veri füzyonu, veri analizinde veri katmanı füzyonu, özellik katmanı füzyonu ve karar katmanı füzyonu olarak uygulanır. Veri katmanı füzyonu, doğrudan giriş verilerine uygulanarak farklı kanalların birleştirilmesi amacıyla yaygın olarak kullanılır. Kanal bazlı füzyon, her görüntü kanalındaki bilgiyi ayrı bir perspektiften işleyip daha sonra birleştiren bir yaklaşımdır. Bu yöntem sayesinde model, tek bir kanal üzerinden elde edilemeyecek zengin ve detaylı özellikleri öğrenebilir. Sonuç olarak, model hem genel yapısal özellikleri hem de kritik küçük detayları aynı anda öğrenebilir; bu da segmentasyon doğruluğunu artırır ve modelin görüntüdeki farklı yapıları ayırtma kapasitesini güçlendirir [27].

Görüntü füzyonu işlemlerinde, özellikle kanal bazlı füzyon yöntemlerinde, filtreleme aşaması verideki önemsiz veya tekrarlayan özelliklerin elenmesini amaçlamaktadır. Bu aşamada, hangi özelliklerin önemsiz sayılacağı, genellikle varyans, korelasyon veya bilgi katkısı gibi ölçütlere göre belirlenir. Bununla birlikte, filtreleme işlemi yalnızca özellik azaltımı için değil, aynı zamanda uzay dönüşümü gerçekleştirmek ve farklı kanallardan elde edilen verilerin daha anlamlı temsillerini oluşturmak için de kullanılabilir. Kanal bazlı füzyon uygulamalarında, filtreleme süreci, kanallar arasındaki bilgi entegrasyonunu kolaylaştırmak ve bilgi kaybını minimize etmek adına kritik bir adım olarak kabul edilmektedir. Ancak bazı durumlarda, özelliklerin aşırı elenmesi model performansını olumsuz etkileyebileceğinden, filtreleme aşamasında dengeli bir yaklaşım benimsenmesi gerekmektedir. Bu çalışmada da kanal bazlı filtreleme,

temel olarak uzay dönüşümü amacıyla kullanılmış ve böylece sağlam ve yüksek seviyeli özelliklerin daha etkin bir şekilde temsil edilmesi sağlanmıştır. Buradaki “sağlam ve yüksek seviyeli özellikler” ifadesi, ham veriden elde edilen temel özneliklerin ötesinde, kanallardan gelen verinin daha soyut, ayırt edici ve genelleştirilebilir temsillerini ifade etmektedir. Bu tür özellikler, modelin öğrenme sürecinde veri içindeki gürültü ve rastgele varyasyonlardan daha az etkilenmesini sağlayarak, daha tutarlı performans göstermesine ve genelleme kapasitesinin artmasına katkıda bulunur [28]. Bu çalışmada, görüntüleri birleştirmek için PCA ve DWT yöntemleri kullanılmıştır.

3.3.1. Temel Bileşenler Analizi (PCA)

PCA, orijinal veri kümesini en iyi şekilde temsil eden bir alt küme oluşturmak için özelliklerin seçilmesiyle daha küçük bir veri kümesinin oluşturulduğu bir özellik çıkarma yöntemidir [29]. Bu yöntemde; kovaryans matrisi, özdeğerler ve özvektörler kullanılarak, ilişkisiz özvektörler bulunur. PCA, verilerin birbirine bağlı değişkenlerini küçük bir değere dönüştürerek verinin en az sayıda değişkenle ifade edilmesini sağlar [30].

3.3.2. Ayrık Dalgacık Dönüşümü (DWT)

Görüntü işleme alanında, DWT yöntemi, verileri farklı frekans bantlarına ayırarak çeşitli bileşenlere ayırmayı sağlar. Özellikle tıbbi görüntülerin füzyonunda, dalgacık (wavelet) teknikleri, görüntüdeki kararsızlık ve gürültü sorunlarını etkili biçimde azaltmada başarılıdır [31]. DWT, bilgi temelli bir yöntem olarak, hem uzaysal hem de frekans alanında lokalizasyon yeteneği sayesinde görüntünün hem ince detaylarını hem de genel yapısını eş zamanlı olarak koruyarak daha doğru ve etkili bilgi çıkarımı sağlar. Bu yöntem, görüntüdeki bilgi içeriğini entropi, standart sapma veya varyans gibi metriklerle değerlendirilerek, görüntü bileşenlerinin bilgi yoğunluğunu belirler ve füzyon işlemi sırasında en anlamlı ve ayırt edici bölümlerin seçilmesini mümkün kılar. Ayrıca, DWT'nin çok seviyeli ayrıştırma yaklaşımı, hesaplama yükünü önemli ölçüde azaltır; böylece diğer yüksek maliyetli yöntemlere kıyasla daha verimli bir işlem süreci sunar. Bu özellikleriyle DWT, tıbbi görüntü füzyonunda hem bilgi kalitesini artırır hem de işlem süresini optimize eden etkili bir teknik olarak kullanılmaktadır.

3.3.3. Veri füzyonunun uygulanması (Implementation of image fusion)

Çalışmada kanal bazında concatenation (veri birleştirme) yaklaşımı kullanılarak, aynı nesne veya bölgeden farklı açılardan ya da farklı görüntüleme yöntemleriyle elde edilen görüntüler, her biri bağımsız bir kanal olacak şekilde düzenlenmiştir. Her kanal, kendine özgü yapısal ve doku bilgilerini koruyarak model girişinde yan yana konumlandırılmıştır. Bu kanallar, tek bir çok-kanallı giriş formatı halinde birleştirilerek ResUNet modeline aktarılmıştır. Böylece modelin, her kanaldaki bilgiyi eş zamanlı işleyerek farklı görüntüler arasındaki ilişkileri öğrenmesi, veri çeşitliliğini artırarak daha zengin ve anlamlı öznelikler çıkarması sağlanmıştır. Kanal bazında veri birleştirme yöntemi, yalnızca farklı bilgi türlerinin eş zamanlı işlenmesini sağlamakla kalmayıp, aynı zamanda her kanalın orijinal bilgilerini koruyarak olası bilgi kayıplarını en aza indirmeyi amaçlamaktadır. Bu yöntem, modelin öğrenebileceği öznelik çeşitliliğini artırmakta ve bir kanalda oluşabilecek gürültü veya hataların diğer kanallardan gelen bilgilerle dengelenmesine olanak tanımaktadır. Ayrıca, farklı açılardan elde edilen görüntüler arasındaki mekânsal ve yapısal korelasyonların yakalanmasını kolaylaştırarak daha zengin ve anlamlı temsil öğrenimini desteklemektedir.

Bu çalışmada, concatenation yöntemi ile farklı veri kaynaklarından elde edilen özellikler kanallar boyunca birleştirilerek tek bir tensör

hâline getirilmiştir. Bu sayede her bir modaliteden gelen bilgi kaybolmadan korunmuş ve modelin çok modlu verilerden maksimum düzeyde faydalanması sağlanmıştır. Bununla birlikte, concatenation ile özelliklerin yan yana eklenmesi, tensör boyutunun artmasına ve dolayısıyla hesaplama maliyetinin de yükselmesine yol açmıştır. Uygulanan yöntem kapsamında, kanal bazında veri birleştirme ile sağlanan çeşitlilik ve örnek artışı ile mevcut veri yapısının işlem süresi göz önünde bulundurularak, ek veri artırma işlemi ek hesaplama yükü oluşturacağı için uygulanmamıştır.

Uygulamanın her adımında, ikili olarak görüntüler birleştirilerek, önceki görüntülere eklenmiştir. İkili olarak veri birleştirme yapıldığı için ilk veri setinde bulunan 123 adet veriden 122 tanesi ve LiTS veri setinde bulunan 131 adet veriden 130 tanesi kullanılmıştır. Görüntüler, matris tabanlı olup, her bir piksel değeri üzerinden ifade edildiği için, ilk sütun örnek sayısını, ikinci sütun yükseklik değerini ve üçüncü sütun genişlik değerini temsil etmektedir.

İlk görüntü verisi: (372, 120, 120) => 372 kanal, her biri 120x120 piksel

Sonraki görüntü verisi: (734, 120, 120) => 734 kanal, her biri 120x120 piksel

Birleştirilen görüntü verisi: (1106,120,120) => 1106 kanal, her biri 120x120 piksel

Son adımda,1106 kanal değerine sahip ve her biri 120x120 piksel boyutlarındaki görüntülere PCA ve DWT yöntemleri ayrı ayrı uygulanır. Daha sonra üçüncü ve dördüncü görüntü verisi üzerinde aynı işlemler uygulanır. Ve ilk birleştirilen görüntülere eklenir. Görüntüler sıralı bir biçimde alınır. İlk veri seti için veri füzyonundan sonra, (19457, 120, 120) boyutlarında farklı bir uzaya taşınmış yeni veri kümesi elde edilmiştir. Bu verilerin 16538'i eğitim için, 2919'u ise test için kullanılmıştır.

LiTS veri setinde ise veri füzyonu (604, 120, 120) değerinde 604 kanallı, 120x120 piksel boyutlarında başlamıştır.

$$a_1=(604, 120, 120)$$

$$a_2=(1564, 120, 120)$$

.

.


.

$$a_n=(44576, 120, 120) \text{ şeklinde devam etmiştir.}$$


LiTS veri seti için veri birleştirme işleminden sonra (44576, 120, 120) boyutlarında farklı bir uzaya taşınmış yeni veri kümesi elde edilmiştir. Yeni veri kümesinden 37889 adet görüntü eğitim, 6687 adet görüntü test için kullanılmıştır.

PCA ile veri birleştirmede eşik değeri belirlenirse, görüntü kalitesinin düştüğü fark edilmiştir. Bu sebeple, eşik değeri belirlenmemiştir. Çünkü her bir piksel değerinin anlamlı veriler içerdiği gözlenmiştir. Şekil 2'de PCA ve DWT tabanlı veri füzyon yöntemlerinin uygulanmasının ardından elde edilen karaciğer görüntüleri sunulmuştur; burada her iki yöntem ile farklı görüntü kanallarının birleştirilmesi sonucu, doku yapılarının daha belirgin ve ayrıntılı biçimde ortaya çıktığı gözlemlenmektedir.

Veri füzyonunda kullanılan farklı uzay dönüşümleri, orijinal görüntü verilerini yeni bir temsile dönüştürerek, ham verideki karmaşık ve yüksek boyutlu bilgiyi daha anlamlı ve yönetilebilir hale getirir. Bu dönüşümler, verideki temel yapıları, örüntüleri ve özellikleri ortaya çıkararak modelin öğrenme sürecini iyileştirir. Özellikle DWT gibi dönüşümler, görüntüyü frekans ve zaman bileşenlerine ayırarak hem detayları hem de genel yapıyı ayırıştırır. Bu sayede model, sadece ham pikselleri değil, verinin çok boyutlu yapısını da öğrenebilir.



Şekil 2. PCA ve DWT veri füzyonu sonrası örnek karaciğer görüntüleri (Sample liver images after PCA and DWT data fusion)



Şekil 3. U-Net mimarisi (U-Net architecture) [38]

3.4. Segmentasyonun uygulanması (Implementation of segmentation)

3.4.1. U-Net modeli (U-Net model)

Ronneberger ve arkadaşları tarafından 2015 yılında biyomedikal görüntü segmentasyonu için önerilen simetrik bir yapıya sahip olan CNN tabanlı sinir ağı mimarisidir [32]. Bu mimari, görüntü üzerindeki her piksel değeri için piksel tabanlı maskeleye yapar. Kodlayıcı, darboğaz ve kod çözücü olmak üzere daralan ve genişleyen yollardan oluşur [33]. Kodlayıcı, normal bir evrişimli sinir ağına benzer şekilde sınıflandırma yapılmasını sağlayan yol olarak ifade edilir. Bu yol, giriş görüntülerini daha düşük bir seviye de kodlamak için kullanılır [34]. Giriş verilerinden çok sayıda özellik haritası çıkarır. Kod çözücü, özellikleri alarak karmaşıklıkları inceler ve genişleme yoludur. Kaba özellik ile ince özellik arasında yeniden yapılandırma sağlar [35]. Giriş verileriyle aynı boyutta segmentasyon haritaları üretir. U-Net mimarisinde, kodlayıcı özelliklerinin bazıları

kod çözücü özelliklerle birleştirilir [36]. Düşük seviyeli özellikler için kullanılabilmesi ve az sayıda eğitim örneğiyle iyi performans göstermesi bu mimariyi segmentasyon tabanlı ağlardan daha avantajlı hale getirir. [37]. Şekil 3'te U-Net mimarisinin temel yapısı gösterilmiştir.

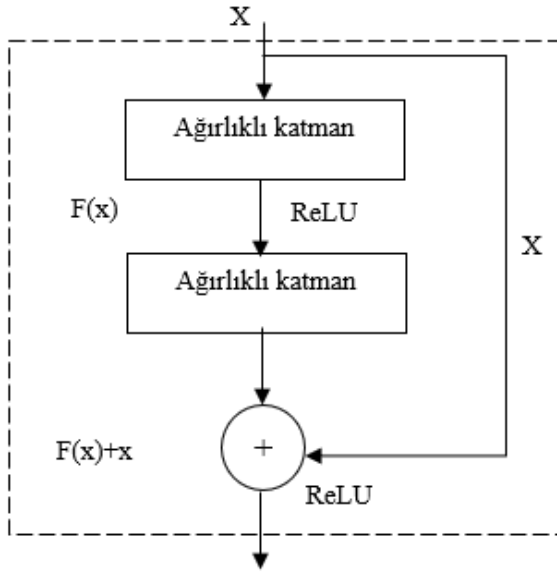
U-Net mimarisinde performans ölçümü için genellikle dice benzerlik katsayısı (DSC) metriği kullanılır; çünkü DSC, özellikle tıbbi görüntü segmentasyonunda sıkça karşılaşılan sınıf dengesizliği problemlerine karşı duyarlı bir ölçüt olup, tahmin edilen segmentasyon maskesi ile gerçek maske arasındaki örtüşmeyi hassas ve anlamlı bir şekilde değerlendirir [39].

3.4.2. ResNet blok (ResNet block)

Derin sinir ağları, karmaşık problemlerle başa çıkabilirken, bu ağlara çok fazla katman eklemek eğitim zorluklarına, geri yayılma ve

kaybolan gradyan problemlerine yol açabilir. Bu problemlerin üstesinden gelmek için 2015 yılında He ve arkadaşları tarafından önerilen ResNet mimarisi, ardaşık artık blokların kullanımıyla derin ağlarda yaşanan gradyan sorunlarını çözerek, ImageNet veri setinde görüntü sınıflandırma ve COCO veri setinde nesne tespiti ile segmentasyon görevlerinde literatürdeki diğer yöntemlere kıyasla daha üstün başarı ve yüksek doğruluk elde etmiştir. O dönem, ResNet mimarisi, en üst düzey (state-of-the-art) performansları ile derin öğrenme alanında öncü bir yöntem olarak kabul edilmektedir [40, 41].

Bu mimaride, ağa doğrudan bir bağlantı (skip connection) eklenerek önceki katmandan gelen giriş bilgisi tam olarak sonraki katmana aktarılır ve giriş verisi üzerinde müdahale edilmeden orijinal haliyle korunur. Artık bloklar, böylece ileri ve geri yayılım sırasında bilginin kesintisiz ve etkili bir şekilde iletilmesini sağlar [42]. Daha derin bir evrişimli sinir ağı ile daha güçlü haritalama yeteneği sunar [43]. Kaybolan gradyan sorununun üstesinden büyük oranda gelebilir [44, 45]. Derin sinir ağlarının eğitim zorluğunu azaltmak gibi avantajlar sağlar [46]. Artık bloklar ağ derinliğini daha da derinleştirerek ağın performansını artırmasını sağlar [47]. ResNet mimarisi, orijinal özellik eşlemesi yerine giriş ve çıkış değerleri arasında bir eşleme gerçekleştirir [48-51]. Diğer sinir ağlarına kıyasla daha hızlı eğitilebilir ve sinir ağlarının özellik çıkarma yeteneğini büyük ölçüde artırır [52]. Şekil 4'te ResNet mimarisinin artık blok yapısı gösterilmiştir.



Şekil 4. Artık blok yapısı (Residual block structure) [53]

Artık blok yapısı Eş. 1'deki gibi hesaplanmaktadır [54].

$$y = F(x, W) + x \quad (1)$$

3.4.3. Hibrit ResUNet modeli (Hybrid ResUNet model)

Tasarlanan hibrit mimari, ağı kolay eğitilmesini sağlayarak, bilgi kaybı olmadan düşük ve yüksek seviyeli özellikler arasında bilgi yayılımını kolaylaştırır. Böylece, ağ daha karmaşık özellikleri kolayca öğrenir [55]. Ağ, eğitim setindeki farklı girdilere karşı dayanıklıdır ve derinliği fazladır [56]. Bu durum, ağ özelliklerinin daha iyi çıkarılmasına olanak tanır [57]. Anlamsal segmentasyonda daha iyi performans sağlar ve az sayıda parametreyle önemli sonuçlar elde edilebilir. [58]. Hibrit ResUNet modeli, artık bloklar sayesinde öğrenme sürecini kolaylaştırarak aşırı öğrenme riskini azaltır. Ancak, aşırı öğrenmenin önlenmesi veri setinin büyüklüğü, model kapasitesi ve ağ derinliği gibi faktörlere de bağlıdır.

Çalışmada, kanal bazında veri birleştirme kullanılması özellik uzayında belirgin bir boyut artışına neden olmuş ve bu durum eğitim süresini kayda değer ölçüde uzatmıştır. Bu sebeple, hibrit model için $f = [16, 32, 64, 128]$ filtre kullanılarak ağ daha hızlı eğitilmiş ve daha az bellek kullanılmıştır. Yeniden boyutlandırma sonrası küçük boyutlu görüntülerde özellik karmaşıklığı azaldığı için yüksek filtre sayısı çoğu zaman gerekli olmayabilir. Bu nedenle, filtre sayısının azaltılması performansı belirgin biçimde düşürmez, hatta bazı durumlarda öğrenme sürecini daha verimli hale getirebilir. Bellek kullanımında aşırı yük oluşturmamak için yığın boyutu sabit olarak '32' alınmış olup model, eğitim süresini uzatmadan dengeli olarak çalışmıştır. Optimizasyon parametresi olarak 'Adam' kullanılmış ve bu parametre, eğitimi hızlandırarak her parametre için uygun öğrenme hızını hesaplamıştır. Öğrenme oranı '0.001' olarak alınmış ve hızlı yakınsama için yeterli olmuştur. Adam optimizasyon algoritmasıyla performanslı çalışması, küçük yığın değeri ve dengesiz veri setlerinde başarılı olması sebebiyle kayıp fonksiyonu için "Binary crossentropy" kullanılmıştır. Şekil 5'te tasarlanan hibrit ResUNet modeli görsel olarak sunulmuştur; burada modelin kodlayıcı-kod çözücü yapısı detaylı olarak gösterilmiştir.

3.5. Aktivasyon fonksiyonları (Activation function)

Aktivasyon fonksiyonu öğrenme oranını iyileştirir [59]. Bir sinir ağında, aktivasyon fonksiyonu kullanılmazsa, çıkış sinyali basitçe doğrusaldır. Doğrusal fonksiyonların çözümü kolaydır ve sınırlı karmaşıklığa sahiptir. Bu çalışmada, doğrusal olmayan sigmoid ve ReLU aktivasyon fonksiyonları kullanılmıştır.

Sigmoid: Doğrusal bir fonksiyon değildir. Lojistikte kullanılan en yaygın işlevlerden birisidir. Tüm gerçek girdi değerlerinin pozitif türevleri vardır. Girdi değerindeki büyük bir değişiklik, çıktı değerinde küçük bir değişikliğe yol açar ve bu da küçük bir eğim değeriyle sonuçlanır. Sigmoid fonksiyonu Eş. 2'deki gibi hesaplanmaktadır.

$$f(x) = \frac{1}{1+e^{-x}} \quad (2)$$

ReLU: Sürekli ve sınırsız bir fonksiyondur. Sıfır merkezli değildir. Üstel bir fonksiyon olmadığı için hesaplama maliyeti düşüktür. Performans ve genelleme açısından başarılıdır. [60]. ReLU fonksiyonu Eş. 3'teki gibi hesaplanmaktadır.

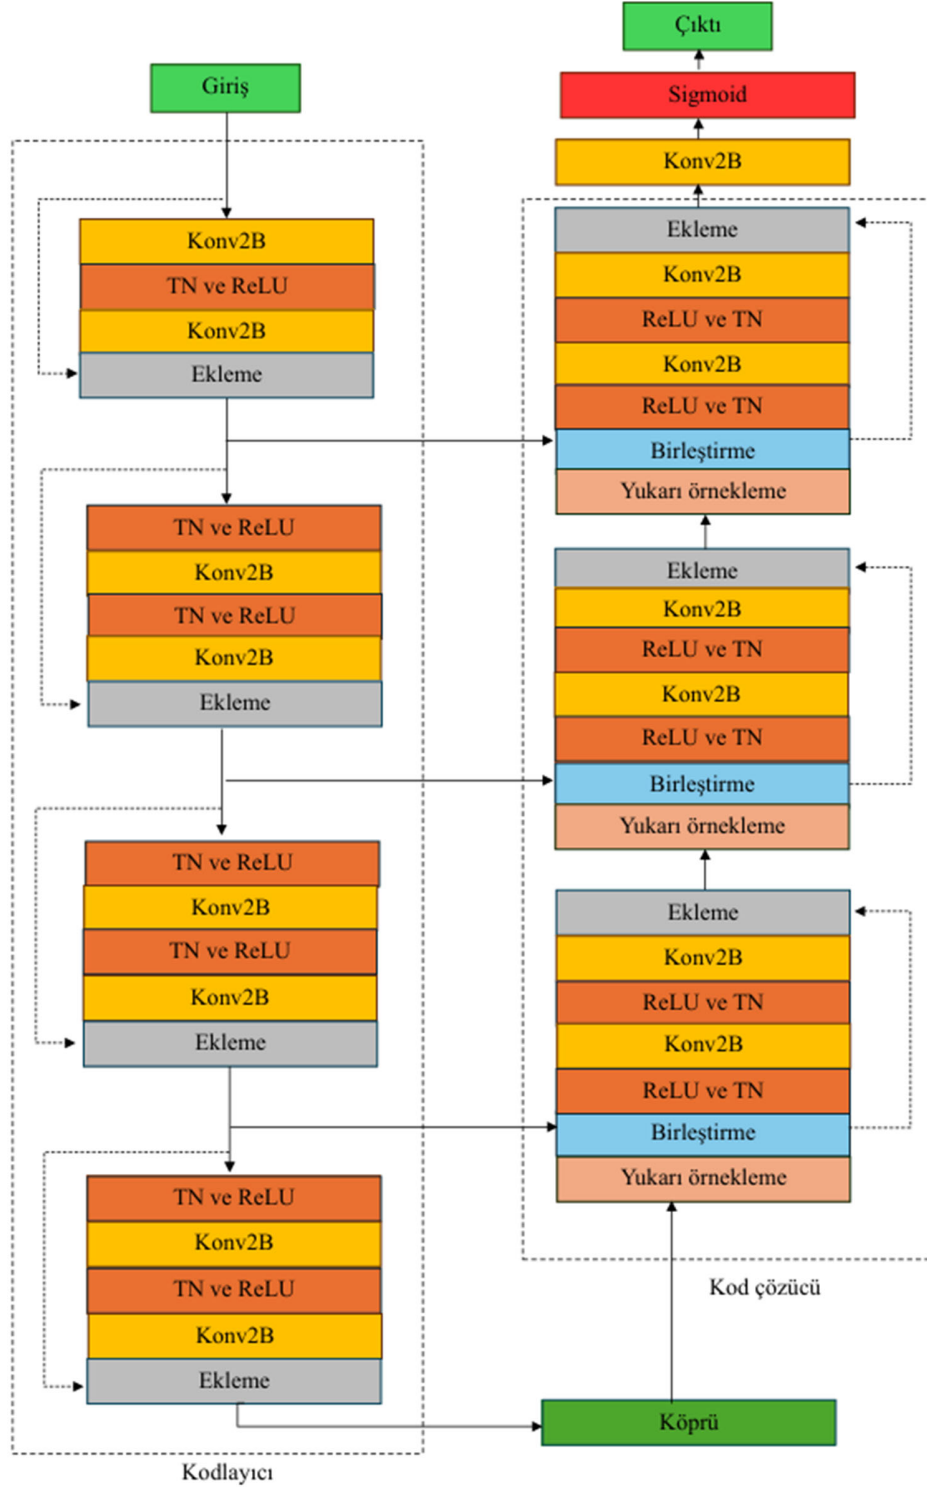
$$f(x) = \max(0, x) \quad (3)$$

ReLU aktivasyon fonksiyonu, görüntünün karmaşık özelliklerini çıkarmayı kolaylaştırması, hesaplama açısından verimli olması ve derin ağlarda diğer aktivasyon fonksiyonlarına göre gradyan kaybolma sorununu azaltması sebebiyle kodlayıcı, köprü ve kod çözücü aşamaların tamamında kullanılmıştır. Sigmoid fonksiyonu ise sonuçların ikili maskeye dönüştürülmesi, her piksel değeri için [0,1] aralığında ait olma olasılığını vermesi sebebiyle çıktı katmanında kullanılmıştır.

3.6. Performans değerlendirme metrikleri (Performance evaluation metrics)

Karışıklık matrisi, tahmin edilen ve gerçek sonuçları gösteren metriklerle ifade edilir. Karışıklık matrisinde kullanılan TP, TN, FP, FN, her sınıf için gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif değerler olarak ifade edilir. [61].

Keskinlik (Precision): Modelde doğru sınıflandırılan verilerin oranıdır. Keskinlik metriği Eş. 4'teki gibi hesaplanmaktadır.



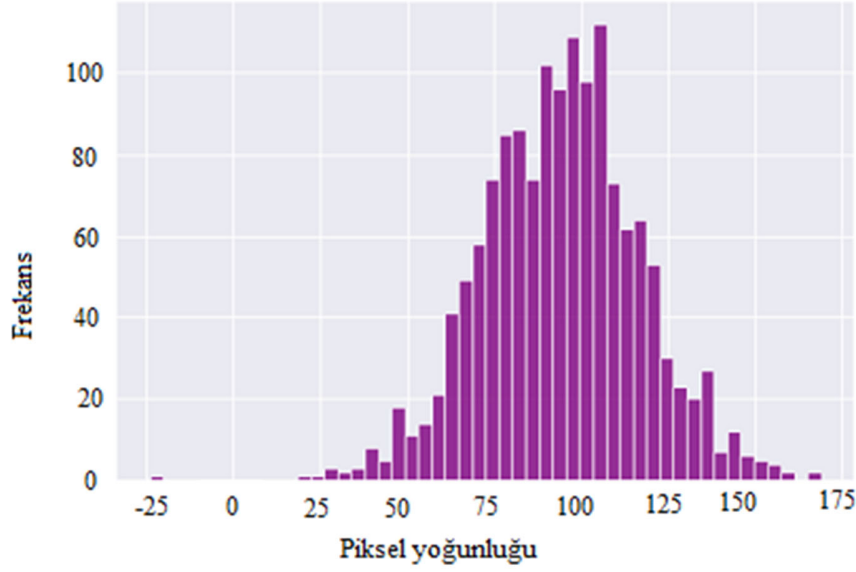
Şekil. 5. ResUNet modeli (ResUNet architecture)

$$Kesinlik = \frac{TP}{TP+FP} \quad (4)$$


Duyarlılık (Sensitivity): Modelde pozitif olarak sınıflandırılan verilerin gerçek pozitif verilere oranıdır. Duyarlılık metriği Eş. 5'teki gibi hesaplanmaktadır.

$$Duyarlılık = \frac{TP}{TP+FN} \quad (5)$$

F-skoru (F-score): Kesinlik ve duyarlılık değerlerinin harmonik ortalaması olarak ifade edilir. F-skoru metriği Eş. 6'daki gibi hesaplanmaktadır [62].



Şekil 6. LiTS veri seti için ResUNet + DWT veri birleştirme modeliyle bölümlendirilmiş bir örnek bölgenin yoğunluk histogramı (Density histogram of a sample region partitioned with the ResUNet + DWT data fusion model for the LiTS dataset)



Şekil 7. LiTS veri seti için ResUNet + DWT veri birleştirme modeliyle bölümlendirilmiş bir örnek bölgenin yoğunluk profili (Density profile of a sample region partitioned with the ResUNet + DWT data fusion model for the LiTS dataset)

$$F - \text{skoru} = \frac{2TP}{2TP+FP+FN} \quad (6)$$

Dice benzerlik katsayısı (Dice coefficient): Genellikle tıbbi görüntü segmentasyonu için kullanılır. İki verinin benzerliğini karşılaştırmak için kullanılan istatistiksel bir terimdir. [63]. [0,1] aralığında değer alır [64]. FP ve FN değerlerini içerdiği için veri dengesizliğine karşı dayanıklıdır. Dice benzerlik katsayısı metriği Eş. 7'deki gibi hesaplanmaktadır.

$$Dice = \frac{2TP}{FN+FP+2TP} \quad (7)$$

Birleştirilen veriler, %85 eğitim ve %15 test verisi olacak şekilde ilk aşamada ayrılmıştır. Daha sonra, veri seti boyutlarının oldukça büyük olması nedeniyle, eğitim verilerinin %20'si doğrulama (validation) amacıyla ayrılmış ve modelin performansının optimize edilmesinde kullanılmıştır.

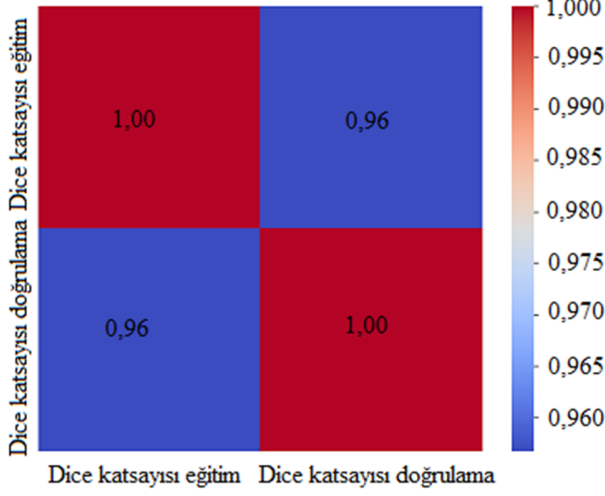
4. Sonuçlar ve Tartışmalar (Results and Discussions)

LiTS veri seti için ResUNet + DWT veri birleştirme modeliyle bölümlendirilmiş bir örnek bölgenin yoğunluk histogramı Şekil 6'da gösterilmiştir. LiTS veri seti için ResUNet + DWT veri birleştirme modeli ile segmentlere ayrılmış bir örnek bölgenin yoğunluk profili Şekil 7'de gösterilmiştir.

Şekil 8'de LiTS veri seti için ResUNet + DWT modeliyle segmente edilen bölgedeki yoğunluk değerlerinin korelasyon ısı haritası gösterilmiştir.

Tablo 1, ilk veri seti üzerinde PCA ve DWT veri birleştirme yöntemleri kullanılarak eğitilen ResUNet modellerinin karaciğer tümörü segmentasyonu için test sonuçlarını göstermektedir. Tablo 2, LiTS veri seti üzerinde PCA ve DWT veri birleştirme yöntemleri

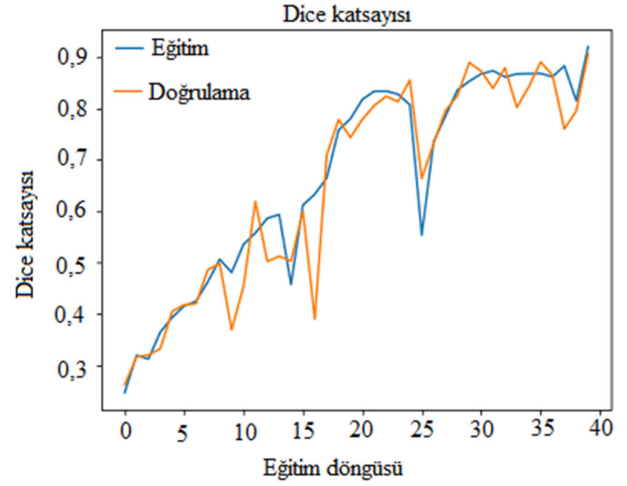
kullanılarak eğitilen ResUNet modellerinin karaciğer tümörü segmentasyon için test sonuçlarını göstermektedir.



Şekil 8. LiTS veri seti için ResUNet + DWT modeliyle segmente edilen bölgedeki yoğunluk değerlerinin korelasyon ısı haritası (Correlation heatmap of intensity values in the region segmented by the ResUNet + DWT model for the LiTS dataset)

Literatürdeki çalışmalara göre, LiTS veri setinin ResUNet+DWT veri füzyonu modeline göre analizinin sonuçları Tablo 3'te gösterilmiştir.

İlk veri kümesi ile karaciğer tümörü segmentasyonu için ResUNet + PCA veri füzyon modelinin dice benzerlik katsayısı değerinin eğitim ve doğrulama(validation) sonuçları Şekil 9'da gösterilmiştir.



Şekil 9. İlk veri kümesi için dice katsayısı metriğiyle ResUNet + PCA veri füzyon modelinin eğitim ve doğrulama sonuçları (Training and validation results of the ResUNet + PCA data fusion model with the dice coefficient metric for the first dataset)

LiTS veri kümesi ile karaciğer tümörü segmentasyonu için ResUNet + DWT veri füzyon modelinin dice benzerlik katsayısı değerinin eğitim ve doğrulama sonuçları Şekil 10'da gösterilmiştir.

Şekil 11, LiTS veri kümesi için ResUNet + PCA veri füzyon yöntemiyle elde edilen örnek bir segmentasyon sonucunu göstermektedir. Şekil 12, LiTS veri kümesi için ResUNet + DWT veri füzyon yöntemiyle elde edilen örnek bir segmentasyon sonucunu göstermektedir.

Tablo 1. İlk veri seti için ResUNet ve veri birleştirme ile elde edilen modelin test sonuçları (Test results of the model obtained using ResUNet and data fusion for the first dataset)

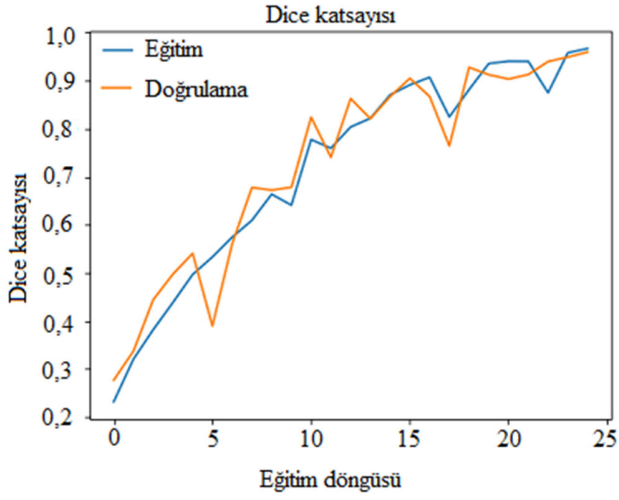
Yöntem	Kesinlik (%)	Duyarlılık (%)	F-skoru (%)	Dice benzerliği (%)
ResUNet + PCA veri füzyonu	96,97	97,68	97,32	91,65
ResUNet + DWT veri füzyonu	97,36	97,31	97,33	90,92

Tablo 2. LiTS veri seti için ResUNet ve veri birleştirme ile elde edilen modelin test sonuçları (Test results of the model obtained using ResUNet and data fusion for the LiTS dataset)

Yöntem	Kesinlik (%)	Duyarlılık (%)	F-skoru (%)	Dice benzerliği (%)
ResUNet + PCA veri füzyonu	97,79	98,62	98,20	95,33
ResUNet + DWT veri füzyonu	98,36	98,13	98,24	95,81

Tablo 3. Karaciğer tümör segmentasyonu için literatürdeki çalışmaların karşılaştırılması (Comparison of studies in the literature for liver tumor segmentation)

Yöntem	Veri seti	Kesinlik (%)	Duyarlılık (%)	F-skoru (%)	Dice benzerliği (%)
DefED-Net [65]	LiTS	-	-	-	87,52 ± 5,32
UV-Net-Multi-scale [66]	LiTS	91,65	87,02	89,28	88,92
MA-Net [6]	LiTS	-	-	-	74,9
FED-Net [67]	LiTS	-	-	-	65
Res-Unet [68]	LiTS	-	-	-	67
U-Net + level set [69]	IRCAD	-	-	-	76,1
MRDU-Net [70]	3D-IRCADb1	-	-	-	65,34
DWT tabanlı veri füzyonu ile geliştirilmiş ResUNet [72]	[71]	98,53	98,70	98,62	94,45
Önerilen model	LiTS	98,36	98,13	98,24	95,81




Şekil 10. LiTS veri kümesi için dice katsayısı metriğiyle ResUNet + DWT veri füzyonu modelinin eğitim ve doğrulama sonuçları (Training and validation results of the ResUNet + DWT data fusion model with the dice coefficient metric for the LiTS dataset)


Çalışmada kanal bazlı veri füzyonu, her bir modalitenin özgün uzaysal ve spektral özelliklerinin korunarak, çoklu modalite veriler arasında tamamlayıcı bilgi entegrasyonunu optimize etmiştir. Bu yaklaşım,

modelin temsil kapasitesini ve genelleme performansını artırmış, özellikle heterojen ve yüksek boyutlu veri setlerinde segmentasyon doğruluğunda anlamlı iyileşmeler sağlamıştır. Kanal bazlı füzyon uygulanmadığında, modaliteler arası korelasyonlar yeterince yakalanamadığı için bilgi kaybı yaşanmakta ve bu durum modelin öğrenme kapasitesini sınırlandırarak aşırı öğrenme riskini artırmaktadır. Buna karşın, kanal bazlı füzyonun getirdiği yüksek boyutlu veri işleme ve hesaplama yükü, kanal ağırlıklandırma optimizasyonu ve uzay dönüşümü teknikleri PCA veya DWT ile minimize edilerek, ek maliyetlerin performans üzerinde olumsuz etkisi engellenmiştir. Modelde PCA ve DWT yöntemleri, veri füzyonunda sıkça kullanılan ve birbirini tamamlayıcı özelliklere sahip iki yöntem olmaları nedeniyle tercih edilmiştir. PCA, yüksek boyutlu verilerde boyut indirgeme ve veri fazlalığını azaltmada; DWT ise frekans ve uzamsal bilgiyi koruyarak yapısal ayrıntıların birleştirilmesinde üstünlük sağlamaktadır. Bununla birlikte, bu çalışmada PCA'da belirli bir eşik değerine göre boyut indirgeme uygulanmamıştır. Çünkü yapılan ön denemelerde, eşik değerine dayalı boyut indirgeme modelin performansını olumsuz etkilemiş ve bilgi kaybına yol açmıştır. Bu nedenle PCA, yalnızca veri fazlalığını azaltma ve daha kompakt bir temsile ulaşma amacıyla kullanılmış; boyut indirgeme işlemi ise tercih edilmemiştir.

Çalışmada elde edilen sonuçlar, daha derin mimarilerin özellik çıkarma kapasitesini artırarak segmentasyon performansını iyileştirdiğini göstermektedir. Ancak derin yapılar, optimizasyon sürecinde gradyan sönümlenmesi gibi zorluklara yol açabilmektedir.



Şekil 11. LiTS veri kümesi için örnek bir segmentasyon sonucu (An example segmentation result for the LiTS dataset)



Şekil 12. LiTS veri kümesi için örnek bir segmentasyon sonucu (An example segmentation result for the LiTS dataset)

Bu sorun, ResNet mimarisinde kullanılan artık bloklar sayesinde büyük ölçüde giderilmiş ve eğitim süreci daha kararlı hale gelmiştir. Ayrıca, atlamalı bağlantıların düşük ve yüksek seviyeli özellikler arasındaki bilgi kaybını önlediği ve çok ölçekli bilgi aktarımını güçlendirdiği gözlemlenmiştir. Bu yapı sayesinde, model görece az parametreyle aşırı öğrenme riskini azaltmış ve genel doğruluk düzeyini artırmıştır. U-Net mimarisine eklenen artık bloklar ve kanal bazlı füzyon yöntemleri ile oluşturulan ResUNet yapısı, özellikle karmaşık dokuların segmentasyonunda dikkate değer bir başarı sağlamıştır. Bu durum, farklı kanallardan sağlanan bilgilerin birleşiminin modelin ayırt edici gücünü artırdığını göstermektedir. Ayrıca, görüntü segmentasyonunda doğruluk (accuracy) metriği anlamlı bir performans ölçütü sunmadığından, modelin başarısı daha duyarlı bir metrik olan dice katsayısı üzerinden değerlendirilmiştir.

Modelin ilk veri seti için 40 epoch ve LiTS veri seti için 25 epoch eğitim süresi yaklaşık iki gün sürmüştür. Kanal bazında veri birleştirme, giriş verisinin boyutunu artırarak modelin daha zengin bir özellik uzayına erişmesini sağlar; bu durum hesaplama yükünü, bellek kullanımını ve eğitim süresini artırır da, farklı veri kaynaklarından gelen bilgilerin entegrasyonu sayesinde segmentasyon doğruluğu ve genelleme yeteneği geliştirilir. Öte yandan, tıbbi görüntülerin yüksek boyutlu yapısı hâlen gerçek dünya uygulamalarını sınırlamakta; özellikle hesaplama maliyeti ve donanım gereksinimleri önemli bir kısıtlama oluşturmaktadır. Donanım teknolojilerindeki hızlı gelişmeler ise bu sınırlamaların aşılmasına ve modelin klinik uygulamalarda daha yaygın kullanılmasına olanak tanıyabilir.

5. Sonuçlar (Conclusions)

Karaciğer hastalıkları, karaciğer damar bozuklukları veya tümör gibi rahatsızlıklar nedeniyle karaciğer fonksiyonlarının bozulmasına yol açabilir. Tümörler, diğer organlara metastaz yapabilen kötü huylu hücrelerdir. Bu nedenle, karaciğerle ilgili hastalıkların hızlı bir şekilde tespit edilmesi ve tedavi planlamasının zamanında yapılması, canlıların yaşam koşullarının olumsuz etkilenmemesi açısından önemlidir. Karaciğerin anatomik konumu ve çevresindeki hayati organlar, hastalıklı veya tümörlü bölgelerin manuel olarak tespit edilmesini zorlaştırmaktadır. Bu nedenle, biyomedikal veriler üzerinde derin öğrenme tabanlı otomatik segmentasyon yöntemleri yaygın olarak tercih edilmektedir. Bu çalışmada, U-Net mimarisine artık ağ yapısı eklenmiş ve segmentasyon işlemi ResUNet modeliyle gerçekleştirilmiştir. Hibrit olarak oluşturulan bu mimari, az sayıda parametre ile karşılaştırılabilir sonuçlar sunmuş ve anlamsal segmentasyonda iyi bir performans sergilemiştir. Segmentasyon performansını etkileyen bir diğer adım ise görüntü füzyonudur. Çalışmada kullanılan PCA ve DWT füzyon yöntemleri, görüntüleri bir uzaydan başka bir uzaya dönüştürmüştür. DWT yöntemi ile veri frekans bileşenlerine ayrılarak daha anlamlı bilgilerin sunulması sağlanırken, PCA, verinin boyutunu küçülterek en fazla varyansı temsil eden bileşenlere odaklanarak önemli özelliklerin vurgulanmasına yardımcı olmaktadır. Bu çalışmada, karaciğer tümörü segmentasyonu için iki farklı veri seti kullanılmıştır. Füzyon yöntemlerinin yakın ve iyi sonuçlar elde ettiği ve ResUNet modelinin yüksek performans analizi sağlayabileceği gözlemlenmiştir. Sonuç olarak, sağlık verilerini analiz etmek için kullanılan makine öğrenimi ve derin öğrenme tabanlı otomatik yöntemler, yalnızca daha hızlı ve doğru hastalık tespiti sağlamakla kalmayacak, aynı zamanda tedavi planlarını kişiselleştirecek, sağlık hizmetlerinde zaman ve hata oranlarını azaltacak ve nihayetinde tedavi sonuçlarını iyileştirecektir.

Gelecekte, hızlı teşhis ve tedavi oluşturmak amacıyla otomatik segmentasyon yöntemlerinin manuel yöntemlerin yanı sıra yaygın bir şekilde kullanılacağı düşünülmektedir.

Kaynaklar (References)

1. Sayiner M., Golabi P., Younossi Z.M., Disease burden of hepatocellular carcinoma: a global perspective, *Digestive Diseases and Sciences*, 64, 910-917, 2019.
2. Li X., Huang Y., Tian J., H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes, *IEEE Transactions on Medical Imaging*, 37 (12), 2663-2674, 2018.
3. Sefti R., Sbibi D., Jennane R., An automatic B-snake model based on deep learning for medical image segmentation, *Expert Systems with Applications*, 2025.
4. Karakoyun M., Gülcü Ş., Kodaz H., D-MOSG: Discrete multi-objective shuffled gray wolf optimizer for multi-level image thresholding, *Engineering Science and Technology, an International Journal*, 24 (6), 1455-1466, 2021.
5. Mittal M., Garg A., Sofat S., Goyal L.M., Deep learning based enhanced tumor segmentation approach for MR brain images, *Applied Soft Computing*, 78, 346-354, 2019.
6. Fan T., Wang G., Li Y., Wang H., Ma-net: A multi-scale attention network for liver and tumor segmentation, *IEEE Access*, 8, 179656-179665, 2020.
7. Pereira S., Pinto A., Alves V., Silva C.A., Brain tumor segmentation using convolutional neural networks in MRI images, *IEEE Transactions on Medical Imaging*, 35 (5), 1240-1251, 2016.
8. Liu Y., Stojadinovic S., Hryciushko B., Wardak Z., Lau S., Lu W., Gu X., A deep convolutional neural network-based automatic delineation strategy for multiple brain metastases stereotactic radiosurgery, *PLoS One*, 12 (10), e0185844, 2017.
9. Shin H.C., Tenenholtz N.A., Rogers J.K., Schwarz C.G., Senjem M.L., Gunter J.L., Michalski M., Medical image synthesis for data augmentation and anonymization using generative adversarial networks, *Simulation and Synthesis in Medical Imaging: Third International Workshop, SASHIMI 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Proceedings 3*, 1-11, Springer International Publishing, 2018.
10. Mok T.C., Chung A.C., Learning data augmentation for brain tumor segmentation with coarse-to-fine generative adversarial networks, *Brain Lesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 4th International Workshop, BrainLes 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers, Part I 4*, Springer, 2019.
11. Dvornik N., Mairal J., Schmid C., On the importance of visual context for data augmentation in scene understanding, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43 (6), 2014-2028, 2019.
12. Agarwal M., Mahajan R., Medical images contrast enhancement using quad weighted histogram equalization with adaptive gamma correction and homomorphic filtering, *Procedia Computer Science*, 115, 509-517, 2017.
13. Goodfellow I.J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y., Generative adversarial nets, *Advances in Neural Information Processing Systems*, 27, 2014.
14. Nalepa J., Marcinkiewicz M., Kawulok M., Data augmentation for brain-tumor segmentation: a review, *Frontiers in Computational Neuroscience*, 13, 83, 2019.
15. Mouraviev A., Generative adversarial network for MRI super resolution.
16. Bi L., Kim J., Kumar A., Feng D., Automatic liver lesion detection using cascaded deep residual networks, *arXiv preprint arXiv:1704.02703*, 2017.
17. Li Y., Daho, M. E. H., Conze, P. H., Zeghlache, R., Le Boité, H., Tadayoni, R., Quellec, G., A review of deep learning-based information fusion techniques for multimodal medical image classification, *Computers in Biology and Medicine*, 177, 108635, 2024.
18. Aakaaram V., Bachu S., MRI and CT image fusion using synchronized anisotropic diffusion equation with DT-CWT decomposition, 2022 *Smart Technologies, Communication and Robotics (STCR)*, 1-5, 2022.
19. Affane A., Kucharski A., Chapuis P., Freyrier S., Lebre M.A., Vacavant A., Fabijańska A., Segmentation of liver anatomy by combining 3D U-net approaches, *Applied Sciences*, 11 (11), 4895, 2021.
20. Huang Q., Sun J., Ding H., Wang X., Wang G., Robust liver vessel extraction using 3D U-Net with variant dice loss function, *Computers in Biology and Medicine*, 101, 153-162, 2018.

21. Shen Y., Sheng V.S., Wang L., Duan J., Xi X., Zhang D., Cui Z., Empirical comparisons of deep learning networks on liver segmentation, *Computers, Materials & Continua*, 62 (3), 2020.
22. Bilic P., Christ P., Li H.B., Vorontsov E., Ben-Cohen A., Kaissis G., Menze B., The liver tumor segmentation benchmark (LiTS), *Medical Image Analysis*, 84, 102680–2023.
23. Moghbel M., Mashohor S., Mahmud R., Saripan M.I.B., Review of liver segmentation and computer assisted detection/diagnosis methods in computed tomography, *Artificial Intelligence Review*, 50, 497-537, 2018.
24. Çavga S.H., Performance of neural networks and heuristic models for disease prediction from liver enzymes: Application to biochemistry device output, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39 (4), 2263–2270, 2024.
25. Grover P., 3D Liver segmentation, Kaggle Dataset, Available from: <https://www.kaggle.com/datasets/prathamgrover/3d-liver-segmentation/data>, Accessed on 09.01.2025.
26. Tahir J., LiTS17, Kaggle Dataset, Available from: <https://www.kaggle.com/datasets/javariatahir/litstrain-val>, Accessed on 09.01.2025.
27. Aymaz S., A new hybrid approach for multi-focus image fusion using CNN and SVM methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39 (2), 1123–1136, 2024.
28. Salau A.O., Jain S., Eneh J.N., A review of various image fusion types and transform, *Indonesian Journal of Electrical Engineering and Computer Science*, 24 (3), 1515-1522, 2021.
29. Zou Y., Chen S., Che C., Zhang J., Zhang Q., Breast cancer histopathology image classification based on dual-stream high-order network, *Biomedical Signal Processing and Control*, 78, 104007, 2022.
30. Ünel F.B., Yalpir S., Reduction of mass appraisal criteria with principal component analysis and integration to GIS, *International Journal of Engineering and Geosciences*, 4 (3), 94-105, 2019.
31. Abdulkareem M.B., Design and development of multimodal medical image fusion using discrete wavelet transform, 2nd International Conference on Inventive Communication and Computational Technologies (ICICCT), IEEE, 2018.
32. Jaeger P.F., Kohl S.A., Bickelhaupt S., Isensee F., Kuder T.A., Schlemmer H.P., Maier-Hein K.H., Retina U-Net: Embarrassingly simple exploitation of segmentation supervision for medical object detection, *Machine Learning for Health Workshop*, PMLR, 171-183, Nisan 2020.
33. Ghosh S., Chaki A., Santosh K., Improved U-Net architecture with VGG-16 for brain tumor segmentation, *Physical and Engineering Sciences in Medicine*, 44 (3), 703-712, 2021.
34. Jin Q., Meng Z., Pham T.D., Chen Q., Wei L., Su R., DUNet: A deformable network for retinal vessel segmentation, *Knowledge-Based Systems*, 178, 149-162, 2019.
35. Jin Q., Meng Z., Sun C., Cui H., Su R., RA-UNet: A hybrid deep attention-aware network to extract liver and tumor in CT scans, *Frontiers in Bioengineering and Biotechnology*, 8, 605132, 2020.
36. Weng Y., Zhou T., Li Y., Qiu X., Nas-unet: Neural architecture search for medical image segmentation, *IEEE Access*, 7, 44247-44257, 2019.
37. Azad R., Asadi-Aghbolaghi M., Fathy M., Escalera S., Bi-directional ConvLSTM U-Net with densely connected convolutions, *IEEE/CVF International Conference on Computer Vision Workshops*, 0-0, 2019.
38. Ding Y., Chen F., Zhao Y., Wu Z., Zhang C., Wu D., A stacked multi-connection simple reducing net for brain tumor segmentation, *IEEE Access*, 7, 104011-104024, 2019.
39. Siddique N., Paheding S., Elkin C.P., Devabhaktuni V., U-net and its variants for medical image segmentation: A review of theory and applications, *IEEE Access*, 9, 82031-82057, 2021.
40. Wightman R., Touvron H., Jégou H., Resnet strikes back: An improved training procedure in timm, *arXiv preprint arXiv:2110.00476*, 2021.
41. Zhang C., Benz P., Argaw D.M., Lee S., Kim J., Rameau F., Kweon I.S., Resnet or densenet? Introducing dense shortcuts to resnet, *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 3550-3559, 2021.
42. Roy S.K., Manna S., Song T., Bruzzone L., Attention-based adaptive spectral-spatial kernel ResNet for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 59 (9), 7831-7843, 2020.
43. Yu H., Sun H., Tao J., Qin C., Xiao D., Jin Y., Liu C., A multi-stage data augmentation and AD-ResNet-based method for EPB utilization factor prediction, *Automation in Construction*, 147, 104734, 2023.
44. Keles A., Keles M.B., Keles A., COV19-CNNNet and COV19-ResNet: diagnostic inference engines for early detection of COVID-19, *Cognitive Computation*, 2021, 1-11.
45. McNeely-White D., Beveridge J.R., Draper B.A., Inception and ResNet features are (almost) equivalent, *Cognitive Systems Research*, 59, 312-318, 2020.
46. Zhang K., Tang B., Deng L., Liu X., A hybrid attention improved ResNet based fault diagnosis method of wind turbines gearbox, *Measurement*, 179, 109491, 2021.
47. Nguyen G.N., Le Viet N.H., Elhoseny M., Shankar K., Gupta B.B., Abd El-Latif A.A., Secure blockchain enabled Cyber-physical systems in healthcare using deep belief network with ResNet model, *Journal of Parallel and Distributed Computing*, 153, 150-160, 2021.
48. Lu Y., Qin X., Fan H., Lai T., Li Z., WBC-Net: A white blood cell segmentation network based on UNet++ and ResNet, *Applied Soft Computing*, 101, 107006, 2021.
49. Zhang K., Tang B., Deng L., Tan Q., Yu H., A fault diagnosis method for wind turbines gearbox based on adaptive loss weighted meta-ResNet under noisy labels, *Mechanical Systems and Signal Processing*, 161, 107963, 2021.
50. Mandal B., Okeukwu A., Theis Y., Masked face recognition using ResNet-50, *arXiv preprint arXiv:2104.08997*, 2021.
51. Gao M., Qi D., Mu H., Chen J., A transfer residual neural network based on ResNet-34 for detection of wood knot defects, *Forests*, 12(2), 212, 2021.
52. Ma L., Shuai R., Ran X., Liu W., Ye C., Combining DC-GAN with ResNet for blood cell image classification, *Medical & Biological Engineering & Computing*, 58, 1251-1264, 2020.
53. Chen X., Yao L., Zhang Y., Residual attention U-Net for automated multi-class segmentation of COVID-19 chest CT images, *arXiv preprint arXiv:2004.05645*, 2020.
54. Lu Z., Bai Y., Chen Y., Su C., Lu S., Zhan T., Wang S., The classification of gliomas based on a pyramid dilated convolution ResNet model, *Pattern Recognition Letters*, 133, 173-179, 2020.
55. Vuola A.O., Akram S.U., Kannala J., Mask-RCNN and U-net ensemble for nuclei segmentation, 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), IEEE, 2019.
56. Kerfoot E., Clough J., Oksuz I., Lee J., King A.P., Schnabel J.A., Left-ventricle quantification using residual U-Net, *Statistical Atlases and Computational Models of the Heart. Atrial Segmentation and LV Quantification Challenges: 9th International Workshop, STACOM 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers 9*, Springer International Publishing, 371-380, 2019.
57. Li D., Dharmawan D.A., Ng B.P., Rahardja S., Residual U-Net for retinal vessel segmentation, 2019 IEEE International Conference on Image Processing (ICIP), 1425-1429, 2019.
58. Zhang Z., Liu Q., Wang Y., Road extraction by deep residual U-Net, *IEEE Geoscience and Remote Sensing Letters*, 15 (5), 749-753, 2018.
59. Sharma S., Sharma S., Athaiya A., Activation functions in neural networks, *Towards Data Sci*, 6 (12), 310-316, 2017.
60. Gustineli M., A survey on recently proposed activation functions for deep learning, *arXiv preprint arXiv:2204.02921*, 2022.
61. Makris, A., Kontopoulos, I., Tserpes, K., COVID-19 detection from chest X-Ray images using Deep Learning and Convolutional Neural Networks, in 11th Hellenic Conference on Artificial Intelligence, 2020.
62. Sankaran, K. S., Thangapandian, M., Vasudevan, N., Brain tumor grade identification using deep Elman neural network with adaptive fuzzy clustering-based segmentation approach, *Multimedia Tools and Applications*, 80(16), 25139-25169, 2021.
63. Rahman, Z., Hussain, A., Shah, H., Arshad, M., Urdu news clustering using K-Mean algorithm on the basis of Jaccard coefficient and Dice coefficient similarity, 2022.
64. Wang, L., Wang, C., Sun, Z., Chen, S., An improved dice loss for pneumothorax segmentation by mining the information of negative areas, *IEEE Access*, 8, 167939-167949, 2020.
65. Lei, T., Wang, R., Zhang, Y., Wan, Y., Liu, C., Nandi, A. K., DefED-Net: Deformable encoder-decoder network for liver and liver tumor segmentation, *IEEE Transactions on Radiation and Plasma Medical Sciences*, 6 (1), 68-78, 2021.
66. Zhang, C., Hua, Q., Chu, Y., Wang, P., Liver tumor segmentation using 2.5D UV-Net with multi-scale convolution, *Computers in Biology and Medicine*, 133, 104424, 2021.

67. Chen, X., Zhang, R., Yan, P., Feature fusion encoder decoder network for automatic liver lesion segmentation, in 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), 2019, IEEE.
68. Han, X., Automatic liver lesion segmentation using a deep convolutional neural network method, arXiv preprint arXiv:1704.07239, 2017.
69. Alir, O.I., Deep learning and level set approach for liver and tumor segmentation from CT scans. Journal of Applied Clinical Medical Physics, 2020, 21 (10), 200-209.
70. Tummala, B.M. and S.S. Barpanda, Liver tumor segmentation from computed tomography images using multiscale residual dilated encoder-decoder network. International Journal of Imaging Systems and Technology, 32 (2), 600-613, 2022.
71. Sks-zod, Resized Liver Tumor, Kaggle Dataset, Available from: <https://www.kaggle.com/datasets/skszod/resized-liver-tumor>, Accessed on 10.12.2024.
72. Şeker Ertuğrul Ü., Kodaz H., Discrete Wavelet Transform-Based Data Fusion with ResUNet Model for Liver Tumor Segmentation, Electronics, 14 (13), 2589, 2025.

