



Göğüs X-ışını görüntülerinde akciğer segmentasyonu için U-Net tabanlı modellerin eğitim stratejileri ve hiperparametre analizi

Training strategies and hyperparameter analysis of U-Net based models for lung segmentation in chest X-ray images

Nihan Kazak Çerçevik^{1,*} , Sündüs Sena Uysal² 

^{1,2} Bilecik Şeyh Edebali Üniversitesi, Bilgisayar Mühendisliği Bölümü, 11100, Bilecik, Türkiye

Öz

Göğüs X-ışını görüntülerinde akciğer alanlarının doğru belirlenmesi, hastalıkların tespiti ve güvenilir klinik analizler için kritik öneme sahiptir. Bu çalışmada, U-Net tabanlı derin öğrenme modellerinde hiperparametrelerin ve mimari tercihlerinin akciğer segmentasyonu performansına etkileri sistematik olarak incelenmiştir. Deneysel süreçte optimizasyon algoritmaları, öğrenme katsayıları, yığın boyutları, omurga yapıları ve kayıp fonksiyonları karşılaştırmalı biçimde değerlendirilmiştir. Sonuçlar, Adam optimizasyon algoritmasının $1e-4$ öğrenme katsayısı ile en kararlı yakınsamayı sağladığını göstermiştir. Mimari analizlerde, ResNet34 omurgasının dikkat mekanizması ile entegrasyonu düşük kontrastlı sınır bölgelerinde ve karmaşık anatomik yapılarda segmentasyon başarısını artırmıştır. Kayıp fonksiyonu incelemelerinde, İkili Çapraz Entropi (Binary Cross Entropy – BCE) ve Dice Loss'un eşit oranlı hibrit kullanımı hem piksel bazlı detayların hem de global yapısal bütünlüğün korunmasında tekil fonksiyonlara göre üstün performans sergilemiştir. En iyi konfigürasyon (50 epok, 8 yığın boyutu) ile 0.9736 Dice, 0.9485 IoU ve 0.9845 piksel doğruluğu elde edilmiştir. Modelin güvenilirliği 5-katlı çapraz doğrulama ile doğrulanmış ve hibrit yapının yüksek genelleme yeteneği sunduğu kanıtlanmıştır. Bu bulgular, medikal görüntü segmentasyonunda bütüncül hiperparametre optimizasyonunun ve hibrit kayıp stratejilerinin klinik doğruluk açısından önemini vurgulamaktadır.

Anahtar kelimeler: Akciğer segmentasyonu, U-Net, Dikkat mekanizması, Hibrit kayıp fonksiyonu, Hiperparametre optimizasyonu

1 Giriş

Akciğer hastalıkları, dünya genelinde en yaygın görülen sağlık problemleri arasında yer almakta olup erken tanı ve tedavi süreçleri hastalığın seyrini doğrudan etkilemektedir. Tüberküloz, zatürre ve COVID-19 gibi solunum yolu hastalıklarının değerlendirilmesinde göğüs X-ışını (Chest X-ray – CXR) görüntüleri, düşük maliyetli, hızlı ve kolay erişilebilir olması nedeniyle klinik uygulamalarda yaygın olarak kullanılmaktadır. Ancak bu görüntüler üzerinden akciğer bölgelerinin doğru ve güvenilir biçimde

Abstract

Accurate identification of lung fields in chest X-ray images is critical for disease detection and reliable clinical analysis. This study systematically investigates the effects of hyperparameters and architectural preferences on lung segmentation performance in U-Net-based deep learning models. In the experimental process, optimization algorithms, learning rates, stack sizes, backbone structures, and loss functions were evaluated comparatively. The results showed that the Adam optimization algorithm achieved the most stable convergence with a learning rate of $1e-4$. In architectural analyses, the integration of the ResNet34 backbone with the attention mechanism improved segmentation success in low-contrast border regions and complex anatomical structures. In loss function analyses, the equally balanced hybrid use of Binary Cross Entropy (BCE) and Dice Loss demonstrated superior performance compared to individual functions in preserving both pixel-based details and global structural integrity. With the best configuration (50 epochs, 8 batch sizes), 0.9736 Dice, 0.9485 IoU, and 0.9845 pixel accuracy were obtained. The model's reliability was validated with 5-fold cross-validation, demonstrating that the hybrid structure offers high generalization capability. These findings highlight the importance of holistic hyperparameter optimization and hybrid loss strategies in medical image segmentation for clinical accuracy.

Keywords: Lung segmentation, U-Net, Attention mechanism, Hybrid loss function, Hyperparameter optimization.

belirlenmesi, bilgisayar destekli tanı sistemlerinin başarımı açısından kritik bir ön işlem adımdır.

Geleneksel yaklaşımlarda akciğer segmentasyonu çoğunlukla uzman hekimler tarafından manuel olarak gerçekleştirilmektedir. Bununla birlikte manuel segmentasyon süreci zaman alıcı olup uzman deneyimine bağlı olarak değişkenlik gösterebilmektedir. Uzmanlar arasında oluşabilecek değerlendirme farklılıkları, segmentasyon sonuçlarının tutarlılığını ve tekrarlanabilirliğini sınırlayabilmektedir. Bu nedenle son

* Sorumlu yazar / Corresponding author, e-posta / e-mail: nihan.kazak@bilecik.edu.tr (N. Kazak Çerçevik)

Geliş / Received: 01.03.2026 Kabul / Accepted: 22.06.2026 Yayınlanma / Published: 09.07.2026

doi: 10.28948/ngumuh.1900094

yıllarda akciğer bölgelerinin otomatik olarak belirlenmesine yönelik derin öğrenme tabanlı yöntemlere olan ilgi önemli ölçüde artmıştır.

Tıbbi görüntü segmentasyonu alanında yaygın olarak kullanılan mimarilerden biri U-Net yapısıdır. Encoder-decoder mimarisi ve atlama bağlantıları sayesinde U-Net, hem yüksek seviyeli anlamsal özellikleri hem de uzamsal detayları birlikte öğrenebilmektedir. Bu özellik, özellikle sınırları net olmayan anatomik yapıların segmentasyonunda U-Net mimarisini güçlü bir çözüm haline getirmiştir. Literatürde U-Net mimarisinin farklı omurga yapıları, dikkat mekanizmaları ve kayıp fonksiyonu kombinasyonları ile desteklenerek performansın artırılmasına yönelik çok sayıda çalışma bulunmaktadır.

Bununla birlikte mevcut çalışmalar incelendiğinde, çoğunlukla yeni model mimarilerinin önerildiği, ancak model performansını doğrudan etkileyen eğitim stratejilerinin ve hiperparametre seçimlerinin sistematik olarak ele alındığı çalışmaların sınırlı olduğu görülmektedir. Özellikle öğrenme oranı katsayısı, yığın boyutu, epok sayısı, kayıp fonksiyonu kombinasyonları ve veri bölme stratejileri gibi eğitimsel parametrelerin segmentasyon başarımı üzerindeki etkilerinin bütüncül bir yaklaşımla incelenmesi literatürde yeterince ele alınmamıştır. Bu durum, farklı çalışmalar arasında performans karşılaştırmalarını zorlaştırmakta ve model tasarım sürecinde belirsizliklere neden olabilmektedir.

Bu çalışmada, göğüs X-ışını görüntülerinden akciğer segmentasyonu problemi U-Net tabanlı derin öğrenme modelleri kullanılarak ele alınmıştır. Çalışma kapsamında farklı omurga yapıları, dikkat mekanizmasının dahil edilmesi, kayıp fonksiyonu kombinasyonları ve eğitim hiperparametreleri karşılaştırmalı olarak incelenmiştir. Ayrıca modelin genelleme yeteneğini değerlendirmek amacıyla çapraz doğrulama stratejileri analiz edilmiş ve segmentasyon çıktılarının doğruluğunu artırmak amacıyla eşik değeri optimizasyonu uygulanmıştır. Elde edilen bulgular, segmentasyon performansının yalnızca mimari yapıdan değil, aynı zamanda eğitim stratejilerinden de önemli ölçüde etkilendiğini göstermektedir. Bu çalışmanın, U-Net tabanlı segmentasyon modellerinin eğitim süreçlerinin daha iyi anlaşılmasına katkı sağlaması ve bilgisayar destekli tanı sistemlerinin geliştirilmesine yönelik gelecekteki çalışmalara yol göstermesi amaçlanmaktadır. Bu çalışmanın temel katkıları şu şekilde özetlenebilir:

(i) U-Net tabanlı akciğer segmentasyon modellerinde eğitim stratejileri ve hiperparametrelerin etkileri sistematik olarak analiz edilmiştir.

(ii) Dikkat mekanizmasının farklı eğitim konfigürasyonları ile etkileşimi kapsamlı biçimde değerlendirilmiştir.

(iii) Hibrit kayıp fonksiyonlarının segmentasyon başarımına etkisi karşılaştırmalı olarak incelenmiştir.

(iv) Önerilen modelin kararlılığı 5-katlı çapraz doğrulama yöntemi ile doğrulanmıştır.

(v) Elde edilen sonuçlar literatürdeki güncel çalışmalarla karşılaştırılarak önerilen yaklaşımın etkinliği gösterilmiştir.

2 İlgili çalışmalar

Göğüs X-ışını görüntülerinden akciğer segmentasyonu, bilgisayar destekli tanı sistemlerinin geliştirilmesinde önemli bir araştırma alanı olarak öne çıkmaktadır. Erken dönem çalışmalarda akciğer bölgelerinin belirlenmesi için atlas tabanlı yöntemler, eşikleme teknikleri ve morfolojik işlemler kullanılmıştır. Candemir ve arkadaşları [1], anatomik atlas tabanlı bir segmentasyon yaklaşımı önermiş ve yöntemlerini Montgomery ve JSRT veri setleri üzerinde değerlendirmiştir. Çalışma, geleneksel yöntemlerin belirli koşullarda başarılı sonuçlar üretebildiğini göstermiştir. Ancak anatomik varyasyonlar, patolojik değişimler ve görüntü kalitesindeki farklılıklar, bu tür yöntemlerin genelleme yeteneğini sınırlamaktadır.

Derin öğrenme tabanlı yaklaşımların gelişmesiyle birlikte tıbbi görüntü segmentasyonunda konvolüsyonel sinir ağları yaygın olarak kullanılmaya başlanmıştır. Ronneberger ve arkadaşları [2] tarafından önerilen U-Net mimarisi, encoder-decoder yapısı ve atlama bağlantıları sayesinde hem düşük seviyeli uzamsal bilgiyi hem de yüksek seviyeli anlamsal özellikleri birlikte öğrenebilmesi nedeniyle tıbbi görüntü segmentasyonu alanında yaygın biçimde kullanılmaktadır. U-Net mimarisi, özellikle sınırlı veri setleri ile çalışılabilmesi ve hassas sınır belirleme yeteneği sayesinde akciğer segmentasyonu çalışmalarında temel model olarak tercih edilmektedir.

U-Net mimarisinin performansını artırmaya yönelik olarak literatürde çok sayıda varyasyon önerilmiştir. Zhou ve arkadaşları [3] tarafından geliştirilen UNet++, iç içe geçmiş atlama bağlantıları ve yoğun özellik birleştirme yapıları ile segmentasyon doğruluğunu artırmayı hedeflemiştir. Çalışma, farklı tıbbi görüntü segmentasyon problemlerinde klasik U-Net mimarisine kıyasla daha yüksek Dice katsayısı elde edilebileceğini göstermiştir. Benzer şekilde Oktay ve arkadaşları [4] tarafından önerilen Attention U-Net mimarisi, modelin önemli anatomik bölgelere odaklanmasını sağlayan dikkat mekanizmaları içermektedir. Bu yaklaşım, özellikle sınırları belirsiz anatomik yapıların segmentasyonunda performans artışı sağlayabilmektedir. Das [5], COVID-19 tanısına yönelik olarak adaptif U-Net tabanlı bir akciğer segmentasyon yaklaşımı ve topluluk öğrenme stratejisi önermiştir. Çalışmada derin özellik çıkarımı ile desteklenen adaptif segmentasyon yapısının tanı performansını iyileştirebildiği gösterilmiştir.

Akciğer segmentasyonuna özel olarak gerçekleştirilen çalışmalar incelendiğinde, derin öğrenme tabanlı yöntemlerin yüksek doğruluk oranlarına ulaştığı görülmektedir. Hofmanninger ve arkadaşları [6], farklı veri setlerinden elde edilen CXR görüntülerini kullanarak model genelleme performansını incelemiş ve segmentasyon başarımının büyük ölçüde veri çeşitliliğine bağlı olduğunu göstermiştir. Gite ve arkadaşları [7], derin öğrenme tabanlı geliştirilmiş bir akciğer segmentasyon yaklaşımı önererek farklı ön işleme ve özellik öğrenme stratejilerinin segmentasyon başarımına etkilerini incelemiştir. Çalışma, özellikle model genelleme performansının artırılmasında eğitim sürecinin ve veri çeşitliliğinin önemli rol oynadığını göstermiştir.

COVID-19 pandemisi ile birlikte akciğer segmentasyonu çalışmalarına olan ilgi daha da artmıştır. Din ve arkadaşları [8], CXR-Seg adlı yeni bir derin öğrenme mimarisi önererek göğüs X-ışını görüntülerinden akciğer segmentasyonu görevini gerçekleştirmişlerdir. Çalışmada EfficientNet tabanlı önceden eğitilmiş bir kodlayıcı, uzamsal geliştirme modülü ve transformer tabanlı dikkat mekanizması ile çok ölçekli özellik birleştirme bloğu kullanılmıştır. Türk ve Kılıçaslan [9], tüberkülozun doğru teşhisini desteklemek amacıyla göğüs X-ışını görüntülerinden akciğer segmentasyonu için U-Net, V-Net ve Seg-Net tabanlı derin öğrenme modelleri önermişlerdir. Çalışmada Shenzhen ve Montgomery veri setleri kullanılmış ve yapılan deneyler sonucunda U-Net ve V-Net modelleri sırasıyla %96,43 ve %96,42 Dice katsayısı elde ederek Seg-Net ve geleneksel yöntemlere kıyasla daha başarılı sonuçlar vermiştir. Murugappan ve arkadaşları [10], göğüs bilgisayarlı tomografi (BT) görüntülerinde otomatik semantik akciğer segmentasyonu için derin sinir ağı tabanlı bir yöntem önermiştir. Çalışmada derin öğrenme mimarilerinin karmaşık anatomik yapıların ayrıştırılmasında yüksek başarı sağlayabildiği gösterilmiş ve otomatik segmentasyonun klinik karar destek sistemlerine katkısı vurgulanmıştır. Bu tür çalışmalar, doğru segmentasyonun sınıflandırma ve tanı performansını doğrudan etkilediğini ortaya koymaktadır.

Segmentasyon performansını artırmak amacıyla yalnızca mimari geliştirmeler değil, aynı zamanda kayıp fonksiyonlarının iyileştirilmesine yönelik çalışmalar da gerçekleştirilmiştir. Sudre ve arkadaşları [11], sınıf dengesizliği problemini azaltmak amacıyla genelleştirilmiş Dice kayıp fonksiyonunu önermiştir. Salehi ve arkadaşları [12] ise yanlış pozitif ve yanlış negatif sonuçların kontrol edilmesini sağlayan Tversky kayıp fonksiyonunu geliştirmiştir. Jadon tarafından gerçekleştirilen kapsamlı bir karşılaştırma çalışmasında [13], farklı kayıp fonksiyonlarının segmentasyon performansı üzerindeki etkileri analiz edilmiş ve hibrit kayıp fonksiyonlarının daha dengeli sonuçlar sağlayabildiği gösterilmiştir.

Son yıllarda model performansını etkileyen eğitim stratejilerinin incelenmesine yönelik çalışmalar da artış göstermiştir. Smith [14], öğrenme katsayısının eğitim sürecindeki rolünü incelemiş ve dögüsel öğrenme katsayısı stratejilerinin model yakınsamasını hızlandırabileceğini ortaya koymuştur. Keskar ve arkadaşları [15] ise yığın boyutunun model genelleme performansı üzerindeki etkisini analiz etmiş ve büyük yığın boyutlarının daha düşük genelleme başarımına yol açabileceğini göstermiştir. Bu çalışmalar, segmentasyon performansının yalnızca model mimarisine değil, aynı zamanda eğitim hiperparametrelerine de bağlı olduğunu ortaya koymaktadır.

Tıbbi görüntü segmentasyonu alanındaki genel eğilimler incelendiğinde, Litjens ve arkadaşları tarafından gerçekleştirilen kapsamlı derleme çalışması [16], derin öğrenme tabanlı yöntemlerin geleneksel yaklaşımlara kıyasla önemli performans artışı sağladığını ortaya koymuştur. Hesamian ve arkadaşları [17] ise U-Net tabanlı mimarilerin tıbbi segmentasyon problemlerinde en yaygın kullanılan yapılar arasında yer aldığını belirtmiştir. Bununla birlikte mevcut çalışmaların büyük bölümünün yeni mimari

tasarımlar geliştirmeye odaklandığı görülmektedir. Örneğin Zhang [18], NasNet-Large tabanlı kodlayıcı-çözücü yapısı kullanarak akciğer segmentasyonu için derin öğrenme tabanlı bir mimari önermiştir. Benzer şekilde birçok güncel çalışma, mimari iyileştirmeler ve dikkat mekanizmaları üzerine yoğunlaşmaktadır. Buna karşın eğitim stratejilerinin ve hiperparametre seçimlerinin segmentasyon performansı üzerindeki etkilerini sistematik biçimde inceleyen çalışmaların sınırlı olduğu görülmektedir.

Bu çalışmada, literatürdeki bu boşluk dikkate alınarak U-Net tabanlı akciğer segmentasyon modellerinde mimari bileşenler ile eğitim stratejilerinin segmentasyon performansı üzerindeki etkileri bütüncül bir yaklaşımla analiz edilmiştir. Farklı omurga yapıları, dikkat mekanizmasının varlığı, kayıp fonksiyonu kombinasyonları ve eğitim hiperparametreleri karşılaştırmalı olarak değerlendirilmiş ve model genelleme yeteneği çapraz doğrulama yöntemleri ile analiz edilmiştir.

3 Materyal ve yöntem

3.1 Veriseti

Bu çalışmada, Kaggle platformunda yer alan ve Karmakar [19] tarafından derlenen “Chest X-ray Dataset for Tuberculosis Segmentation” veri seti kullanılmıştır. Veri seti, toplam 704 adet göğüs X-ışını görüntüsünden oluşmaktadır. Bu veriler, iki temel kaynaktan derlenmiştir: Amerika Birleşik Devletleri’ne ait Montgomery County Chest X-ray Database [20] (141 görüntü, %20) ve Çin’e ait Shenzhen Chest X-ray Database [1] (563 görüntü, %80). Veri setinde 345 adet tüberküloz pozitif ve 359 adet normal CXR görüntüsü bulunmaktadır. Her bir görüntüye karşılık gelen uzman onaylı akciğer segmentasyon maskeleri ve hastaların cinsiyet, yaş, tüberküloz durumu gibi meta verileri veri seti içerisinde mevcuttur. Bu çalışmada meta veriler modele girdi olarak verilmemiş, yalnızca veri seti popülasyonunun tanımlanması amacıyla kullanılmıştır.

3.2 Veri önileme ve veri artırma

Bu bölümde veri setine uygulanan önileme yöntemleri ve veri artırma teknikleri sunulmuştur. Deney sürecinin diğer tüm adımlarında önileme ve veri artırma teknikleri sabit tutulmuştur. Böylece performans karşılaştırmaları yapılırken veri setinden kaynaklanan bir değişimin önüne geçilmiştir.

3.2.1 Veri önileme

Model eğitiminden önce, veri setinde yer alan tüm göğüs X-ışını görüntüleri ve bunlara karşılık gelen akciğer segmentasyon maskeleri çeşitli ön işleme adımlarından geçirilmiştir. Öncelikle tüm görüntüler ve segmentasyon maskeleri 256×256 piksel boyutuna yeniden ölçeklendirilmiştir. Bu işlem, farklı çözünürlükteki görüntülerin standart bir giriş boyutuna dönüştürülmesini ve hesaplama maliyetinin azaltılmasını amaçlamaktadır.

Orijinal gri seviye görüntüler, transfer öğrenme tabanlı omurga yapılarla uyum sağlanması amacıyla üç kanallı RGB formatına dönüştürülmüştür. Ardından piksel değerleri [0,1] aralığına ölçeklendirilmiş ve her bir renk kanalı için ImageNet [21] veri setine ait ortalama ve standart sapma değerleri kullanılarak normalizasyon işlemi

gerçekleştirilmiştir. Bu ön işleme adımları, tüm veri seti üzerinde tutarlı bir şekilde uygulanmıştır.

3.2.2 Veri artırma

Veri setinin sınırlı sayıda örnek içermesi nedeniyle, modelin genelleme yeteneğini artırmak ve aşırı öğrenmenin önüne geçmek amacıyla veri artırma teknikleri kullanılmıştır. Eğitim sırasında görüntülere rastgele yatay çevirme işlemi uygulanmıştır. Buna ek olarak, hasta pozisyonundaki küçük farklılıkları ve görüntüleme koşullarındaki değişimleri simüle etmek amacıyla $\pm 5^\circ$ öteleme, $\pm 5^\circ$ ölçekleme ve $\pm 10^\circ$ döndürme işlemleri gerçekleştirilmiştir. Ayrıca çekim ayarlarından kaynaklanabilecek parlaklık farklılıklarını modelin öğrenebilmesi için $[-0.1, +0.1]$ aralığında rastgele parlaklık ve kontrast ayarlamaları uygulanmıştır. Sensör kaynaklı gürültü etkilerini simüle etmek amacıyla varyans değeri [5, 20] aralığında rastgele seçilen Gauss gürültüsü eklenmiştir. Bu sayede modelin, gürültülü ve düşük kaliteli görüntüler karşısında da kararlı ve güvenilir tahminler üretebilmesi hedeflenmiştir.

Uygulanan tüm veri artırma işlemleri, görüntüler ve bunlara karşılık gelen segmentasyon maskeleri üzerinde eş zamanlı olarak gerçekleştirilmiştir. Böylece geometrik dönüşümler sonrasında görüntü ile maske arasındaki uzamsal uyum korunmuştur. Veri artırma teknikleri yalnızca eğitim veri kümesi üzerinde uygulanmış, doğrulama ve test veri kümeleri ise herhangi bir artırma işlemi yapılmadan kullanılmıştır.

3.3 Kullanılan model mimarisi


Bu çalışmada, göğüs X-ışını görüntülerinden akciğer segmentasyonu problemi için U-Net tabanlı derin öğrenme mimarileri kullanılmıştır. U-Net mimarisi, encoder-decoder yapısı ve bu yapılar arasında yer alan atlama bağlantıları (skip connections) sayesinde, hem yüksek seviyeli anlamsal özelliklerin hem de düşük seviyeli uzamsal bilgilerin birlikte öğrenilmesine olanak tanımaktadır. Bu özellik, sınırları belirsiz anatomik yapıların segmentasyonunda U-Net mimarisini etkili bir çözüm haline getirmektedir. Mimarinin encoder bölümünde, giriş görüntüsünden hiyerarşik özellik çıkarımı gerçekleştirilirken, ardışık konvolüsyon ve havuzlama katmanları kullanılarak uzamsal çözünürlük kademeli olarak azaltılmaktadır. Decoder bölümünde ise, encoder aşamasında elde edilen özellik haritaları, yukarı örnekleme işlemleri ile yeniden yüksek çözünürlüğe taşınmakta ve karşılık gelen encoder katmanlarından aktarılan özelliklerle birleştirilmektedir. Bu yapı, segmentasyon maskelerinin daha hassas sınırlar ile oluşturulmasını sağlamaktadır.

Çalışma kapsamında, temel U-Net mimarisine ek olarak farklı omurga yapılarına sahip U-Net varyasyonları değerlendirilmiştir. Bu amaçla, önceden ImageNet veri seti üzerinde eğitilmiş derin konvolüsyonel ağlar omurga olarak kullanılmıştır. Transfer öğrenme yaklaşımı sayesinde, sınırlı veri setleri ile çalışırken modelin daha hızlı yakınsaması ve daha kararlı öğrenme süreci hedeflenmiştir. Önerilen çalışmada model performansını artırmak amacıyla, dikkat kapıları içeren U-Net tabanlı mimari de kullanılmıştır. Önerilen Attention U-Net mimarisinde, encoder

katmanlarından gelen özellik haritaları doğrudan decoder'a aktarılacak yerine bir dikkat kapıları biriminden geçirilmiştir. Burada, alt katmandan gelen kaba özellikler (gating signal), üst katmandaki uzamsal detayları filtrelemek için kullanılır. Bu işlem sonucunda, akciğer sınırları dışındaki bölgelerin ağırlığı düşürülerek segmentasyon keskinliği artırılmıştır. Tüm modeller, ikili segmentasyon problemi kapsamında yapılandırılmış olup, çıktı katmanında sigmoid aktivasyon fonksiyonu kullanılarak piksel tabanlı akciğer olasılık haritaları elde edilmiştir. Elde edilen olasılık haritaları, belirlenen eşik değeri üzerinden ikili segmentasyon maskelerine dönüştürülmüştür.

3.4 Eğitim ayarları ve deneysel tasarım

Bu çalışmada deneysel tasarım, U-Net tabanlı akciğer segmentasyon modellerinde mimari konfigürasyonlar ile eğitim hiperparametrelerinin performans üzerindeki etkilerini sistematik bir yaklaşımla incelemek üzere kurgulanmış ve Şekil 1'de sunulmuştur.



Şekil 1. Deneysel tasarım ve hiperparametre optimizasyonu akış diyagramı

Çalışmanın temel motivasyonu, statik bir model sunmanın ötesinde, modelin başarısını belirleyen kritik

bileşenlerin etkileşimlerini kademeli bir optimizasyon stratejisi ve ablasyon analizi çerçevesinde ortaya koymaktır. Deneysel süreçte model performansının tarafsız bir şekilde ölçülmesi amacıyla, veri setindeki görüntüler %80 eğitim, %10 doğrulama ve %10 test olacak şekilde rastgele bölünmüştür. Bu doğrultuda deneysel süreç, birbirini takip eden ve ardışık bir mantıkla ilerleyen beş temel aşamadan oluşturulmuştur. Hiperparametre optimizasyon sürecinde her bir parametre kontrollü biçimde analiz edilmiştir. Deneyler sırasında ilgili hiperparametre değiştirilirken diğer tüm eğitim ayarları sabit tutulmuştur. Böylece performans değişimlerinin doğrudan analiz edilen hiperparametreden kaynaklanması sağlanmıştır. Deneysel süreç boyunca test edilen hiperparametre konfigürasyonları **Tablo 1**'de sunulmuştur.

Tablo 1. Hiperparametre Konfigürasyonları

Parametre	Test Edilen Değerler
Optimizasyon algoritması	Adam, AdamW, RMSprop, RAdam
Öğrenme katsayısı	1e-3, 1e-4, 1e-5
Yığın boyutu	2, 4, 8
Epok sayısı	10, 30, 40, 50
Kayıp fonksiyonu	BCE, Dice, 0.5 BCE + 0.5 Dice, 0.3 BCE + 0.7 Dice
Omurga yapısı	Temel U-Net, VGG16, EfficientNetB4, ResNet34

Sürecin ilk aşamasında, modelin genel yakınsama davranışını belirlemek amacıyla temel bir ResNet34 omurgası ve BCE kayıp fonksiyonu referans alınmıştır. Bu aşamada; Adam, AdamW, RMSprop ve RAdam optimizasyon algoritmaları, farklı yığın boyutları ve çeşitli öğrenme katsayıları altında test edilmiştir. Buradaki temel amaç, modelin eğitim stabilitesini sağlayan en dirençli çekirdek parametre setini belirleyerek sonraki aşamalar için güvenilir bir temel oluşturmaktır.

Belirlenen bu en iyi hiperparametre seti kullanarak geçilen ikinci aşamada ise modelin öğrenme hedefi optimize edilmiştir. Akciğer segmentasyonunda karşılaşılan sınıf dengesizliği ve sınır belirsizliklerini aşmak için BCE ve Dice kayıp fonksiyonları tekil olarak ve farklı ağırlıklı kombinasyonlar halinde değerlendirilmiş; böylece piksel bazlı doğruluk ile hacimsel örtüşme arasındaki optimum denge analiz edilmiştir.

Üçüncü aşamada, belirlenen optimum hiperparametre ve kayıp fonksiyonu seti üzerine, modelin anatomik odaklanma yeteneğini artırmak amacıyla dikkat kapıları entegre edilmiştir. Mimari karmaşıklığın artmasıyla birlikte eğitim dinamikleri yeniden şekillenmiş; bu bağlamda modelin doyumluğa ulaştığı en iyi epok sayısı ve gradyan kararlılığı için yığın boyutu değerleri yeniden optimize edilmiştir. Bu adım, mimari yeniliğin eğitim parametreleriyle uyumlandırılmasını sağlayarak modelin odaklanma kapasitesini maksimize etmiştir.

Dördüncü aşamada elde edilen bu gelişmiş eğitim konfigürasyonu altında, mimarinin öznetelik çıkarımı kapasitesi test edilmiştir. Bu kapsamda, ImageNet [21] üzerinde ön eğitilmiş EfficientNetB4 [22], VGG16 [23] ve

ResNet34 [24] omurga yapıları ile omurgasız temel model karşılaştırılarak, transfer öğrenme kapasitesinin segmentasyon hassasiyetine katkısı analiz edilmiş ve nihai mimari tasarım sabitlenmiştir.

Deneysel sürecin son aşamasında ise seçilen en iyi konfigürasyonun genelleme yeteneğini ve veri setindeki anatomik varyasyonlara karşı direncini ölçmek amacıyla 5-katlı çapraz doğrulama yöntemi uygulanmıştır. Bu yöntemle, modelin başarısının veri setinin belirli bir bölümüne özgü olmadığı ve farklı veri alt kümelerinde tutarlı performans sergilediği istatistiksel olarak raporlanmıştır. Tüm bu süreç boyunca veri seti, ön işleme ve veri artırma stratejileri sabit tutularak, performans değişimlerinin doğrudan test edilen parametrelerden kaynaklanması sağlanmıştır.

3.5 Önerilen yöntemin algoritmik akışı

Şekil 1'de sunulan deneysel tasarım ve hiperparametre optimizasyon sürecinin daha açık ve tekrarlanabilir biçimde ifade edilmesi amacıyla önerilen yöntemin temel işlem adımları Algoritma 1'de sunulmuştur.

Algoritma 1. Önerilen deneysel süreç ve hiperparametre optimizasyonu

Girdi:
Göğüs X-ışını görüntüleri (I)
Yer doğruluk (ground truth) maskeleri (M)
Çıktı:
Nihai akciğer segmentasyon modeli
1: Tüm görüntüleri ve maskeleri 256×256 boyutuna yeniden ölçeklendir
2: Gri seviye görüntüleri RGB formatına dönüştür
3: Görüntülere ImageNet normalizasyonu uygula
4: Eğitim veri kümesine veri artırma işlemleri uygula
5: Veri setini eğitim, doğrulama ve test kümelerine ayır
6: Her optimizasyon algoritması için:
7: Temel U-Net modelini eğit
8: Doğrulama performansını değerlendir
9: Son
10: En uygun optimizasyon algoritmasını ve öğrenme katsayısını seç
11: Her kayıp fonksiyonu konfigürasyonu için:
12: Modeli seçilen hiperparametreler ile eğit
13: Dice ve IoU performanslarını değerlendir
14: Son
15: U-Net mimarisine dikkat mekanizmasını entegre et
16: Her epok ve yığın boyutu konfigürasyonu için:
17: Attention tabanlı modeli eğit
18: Doğrulama performansını değerlendir
19: Son
20: Farklı omurga mimarilerini karşılaştır
21: Nihai model konfigürasyonunu belirle
22: 5-katlı çapraz doğrulama uygula
23: Dice, IoU ve Piksel Doğruluğu (PA) metriklerini hesapla
24: Nihai segmentasyon modelini döndür

3.6 Performans değerlendirme metrikleri

Bu çalışmada, akciğer segmentasyon modellerinin başarısını değerlendirmek amacıyla tıbbi görüntü işleme literatüründe yaygın olarak kabul görmüş örtüşme tabanlı metriklerden yararlanılmıştır. Modellerin performansı, tahmin edilen ikili segmentasyon maskeleri (A) ile yer doğruluk (ground truth) maskeleri (B) arasındaki benzerlik üzerinden ölçülmüştür. Değerlendirme sürecinde temel performans ölçütü olarak Dice benzerlik katsayısı (Dice Similarity Coefficient – DSC) kullanılmıştır. Dice katsayısı, tahmin edilen bölge ile gerçek bölge arasındaki kesişimin,

iki bölgenin toplam alanına oranının iki katı olarak tanımlanmakta ve Eşitlik (1) ile hesaplanmaktadır.

$$DSC = \frac{2|A \cap B|}{|A| + |B|} \quad (1)$$

Özellikle tıbbi görüntü segmentasyonunda, sınıf dengesizliğine karşı (akciğer alanının toplam görüntüye oranı gibi) dirençli olması nedeniyle DSC, modelin segmentasyon hassasiyetini ölçmede en güvenilir metrik olarak kabul edilmektedir. Buna ek olarak, segmentasyon başarısını desteklemek ve literatürdeki diğer çalışmalarla adil bir karşılaştırma yapabilmek amacıyla Intersection over Union (IoU) metriği, bir diğer adıyla Jaccard İndeksi raporlanmıştır. IoU Eşitlik (2)'de gösterildiği gibi, tahmin edilen ve gerçek maske arasındaki kesişimin birleşime oranını ifade eder.

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (2)$$

Çalışma kapsamında ayrıca modellerin genel sınıflandırma başarısını gözlemlemek adına Pksel Doğruluğu (Pixel Accuracy - PA) değerleri de hesaplanmıştır. PA, doğru tahmin edilen piksellerin toplam piksel sayısına oranını temsil etmektedir. 5-katlı çapraz doğrulama yönteminin uygulandığı deneylerde, her bir kat için elde edilen metriklerin aritmetik ortalaması ve standart sapması hesaplanarak nihai performans sonuçları raporlanmıştır. Çapraz doğrulama uygulanmayan hiperparametre optimizasyonu deneylerinde ise değerlendirme, bağımsız test veri seti üzerinde gerçekleştirilmiştir.

4 Deneyel sonuçlar


Bu bölümde, göğüs X-ışını görüntülerinden akciğer segmentasyonu performansı üzerinde belirleyici rol oynayan mimari bileşenler ve eğitim parametreleri, metodolojide sunulan kademeli optimizasyon stratejisi çerçevesinde analiz edilmiştir. Gerçekleştirilen deneyler, modelin sadece nihai başarısını raporlamakla kalmayıp, hiperparametre seçiminden kayıp fonksiyonuna kadar her bir adımın segmentasyon kalitesine olan katkısını ablasyon analizi yaklaşımıyla ortaya koymaktadır.

Deney süreci boyunca izlenen ardışık yapı, modelin en zayıf konfigürasyonundan başlayarak en gelişmiş haline evrilmesini sağlayan tasarım kararlarını doğrulamaktadır. Bu bağlamda sonuçlar; eğitim kararlılığı, sınır hassasiyeti ve mimari verimlilik gibi üç temel boyut üzerinden değerlendirilmiştir. Analizlerin ilk kısmında modelin eğitim stratejisini belirleyen hiperparametrelerin etkisi incelenmiş, ardından bu temel üzerine inşa edilen mimari iyileştirmelerin ve istatistiksel doğrulama süreçlerinin çıktıları sunulmuştur. Son olarak önerilen konfigürasyonun başarımı literatürdeki benzer çalışmalarla karşılaştırılarak, performansı değerlendirilmiştir.

4.1 Başlangıç konfigürasyonu


Deneyel sürecin ilk aşaması, modelin öğrenme kapasitesini ve yakınsama hızını belirleyen başlangıç konfigürasyonunun optimizasyonuna odaklanmıştır. Bu kapsamda yürütülen deneyler, özellikle optimizasyon algoritmalarının, yığın boyutlarının ve öğrenme katsayılarının akciğer segmentasyonundaki kritik rolünü ortaya koymuştur. Tüm ön testler, ResNet34 omurgası ve BCE kayıp fonksiyonu temelinde gerçekleştirilmiştir.

Hiperparametre optimizasyonunun ilk basamağında Adam, AdamW, RMSprop ve RAdam algoritmaları kıyaslanmıştır. Şekil 2'deki veriler, Adam algoritmasının en hızlı yakınsamayı sergilediğini göstermiştir. Ayrıca bu algoritma, validasyon kaybını en düşük varyansla minimize etmiştir. AdamW ve RAdam algoritmaları benzer yakınsama eğilimleri sunmuştur. Ancak RMSprop algoritması 14. epok civarında ani bir kayıp sıçraması yaşamıştır. Bu durum, algoritmanın gradyan güncellemelerindeki kararsızlığını ve yerel minimumlardan kaçarken yaşadığı kontrolsüz dalgalanmaları belgelemektedir. Bu nedenle Adam optimizasyon algoritması, çalışmanın çekirdek algoritması olarak belirlenmiştir.



Şekil 2. Optimizasyon algoritmalarının analizi


Eğitim stratejisinin bir diğer kritik bileşeni olan yığın boyutu analizleri, modelin genelleme yeteneği ile gradyan kararlılığı arasındaki dengeyi netleştirmiştir. Şekil 3'te görüldüğü üzere yığın boyutu 2, 4 ve 8 seçilerek değerlendirilmiştir. Başlangıç konfigürasyonunda küçük yığın boyutlarının (BS=2) modelin veri setindeki ince anatomik varyasyonları öğrenmesinde en etkili seçenek olduğu saptanmıştır. Yüksek yığın boyutları (BS=8) kaybı düşürmede daha yavaş bir ivme sergilemiştir. BS = 2 konfigürasyonu ise 16. epok itibarıyla en düşük validasyon kaybına ulaşmıştır. Bu bulgu, akciğer sınırları gibi detayların öğrenilmesinde düşük yığın boyutlarının sağladığı yüksek çözünürlüklü gradyan tahminlerinin üstünlüğünü kanıtlamaktadır.



Şekil 3. Yığın boyutu seçiminin etkisi

Optimizasyon sürecinin son basamağında, öğrenme katsayılarının modelin yakınsama karakteristiği üzerindeki etkisi Şekil 4'te gösterilmiştir. Yapılan testlerde $1e-3$ gibi yüksek öğrenme katsayılarının gradyan patlamalarına veya aşırı salınımlara neden olduğu görülmüştür. Bu durum validasyon eğrisinde kararsızlık yaratmıştır. Öte yandan $1e-5$ gibi daha düşük değerlerin eğitim sürecini gereksiz yere uzattığı ve 20 epokluk süreçte modelin doygunluğa ulaşmasını zorlaştırdığı saptanmıştır. En kararlı öğrenme eğrisi, yakınsama hızı ile eğitim stabilitesi arasında optimum bir köprü kuran $1e-4$ konfigürasyonu ile elde edilmiştir.

Yüksek öğrenme katsayısı ile gerçekleştirilen eğitimlerde, büyük gradyan güncellemeleri nedeniyle validasyon kaybında dalgalanmalar gözlenmiş ve modelin kararlı yakınsaması zorlaşmıştır. Düşük öğrenme katsayılarında ise daha stabil bir öğrenme süreci elde edilmesine rağmen, sınırlı epok sayısı içerisinde modelin optimum performansa ulaşması gecikmiştir. Buna karşılık $1e-4$ öğrenme katsayısı, yakınsama hızı ile eğitim kararlılığı arasında daha dengeli bir optimizasyon süreci sağlayarak en yüksek segmentasyon performansını üretmiştir.



Şekil 4. Farklı öğrenme katsayılarının performans karşılaştırması

Özellikle 20 epok süresince, ilk denemeler sonucunda belirlenen Adam optimizasyon algoritması, 2 yığın boyutu ve $1e-4$ öğrenme katsayısı kombinasyonu, modelin karmaşık göğüs yapısı içerisindeki akciğer sınırlarını ayırt etmeye başlaması için en uygun temel konfigürasyonu sunmuştur. Eğitim rejiminin bu şekilde sağlam bir zemine oturtulması kritik bir adımdır. Bu durum, sonraki aşamalarda yapılacak dikkat mekanizması ve hibrit kayıp fonksiyonu çalışmalarının güvenilirliği için önemli bir ön koşuldur.

4.2 Kayıp fonksiyonu analizi

Eğitim stratejisi sabitlendikten sonra kayıp fonksiyonlarının etkisi analiz edilmiştir. Bu aşamada modelin öğrenme hedefi optimize edilmiştir. Deneylerde öncelikle temel kayıp fonksiyonları olan BCE ve Dice bağımsız olarak test edilmiştir. Ardından bu iki fonksiyonun farklı ağırlıklardaki hibrit kombinasyonları değerlendirilmiştir. Elde edilen sonuçlar Tablo 2'de verilmiştir.

Tablo 2. Kayıp fonksiyonu analizi

Kayıp Fonksiyonu	Dice	IoU	PA
BCE	0.9450	0.8973	0.9818
Dice	0.9441	0.8991	0.9739
0.5 BCE + 0.5 Dice	0.9603	0.9249	0.9822
0.3 BCE + 0.7 Dice	0.9592	0.9227	0.9811

Akciğer segmentasyonunda en önemli zorluklardan biri sınıf dengesizliği ve düşük kontrastlı sınırların doğru belirlenmesidir. Yapılan deneyler, tek başına kullanılan kayıp fonksiyonlarının bu sorunları tam olarak çözemediğini göstermiştir. BCE kaybı pikselleri doğru tahmin etmede başarılı olsa da akciğerin bütünlüğünü korumakta yetersiz kalmıştır. Dice kaybı ise genel şekli daha iyi yakalamış, ancak sınırların keskinliğini sağlayamamıştır. Bu nedenle hibrit kayıp fonksiyonu denenmiş ve 0.5 BCE + 0.5 Dice kombinasyonu en dengeli sonucu vermiştir. Bu yapı, BCE'nin küçük detayları yakalama gücü ile Dice'in genel şekli koruma avantajını birleştirerek akciğer sınırlarını daha gerçekçi ve keskin şekilde üretmiştir. Diğer ağırlıklandırma senaryolarında performans düşmüş, bu yüzden eşit oranlı hibrit yapı en uygun seçenek olarak belirlenmiştir.

4.3 Dikkat (Attention) mekanizması ve eğitim stratejisinin yeniden yapılandırılması

En iyi parametre seti ve kayıp fonksiyonu belirlendikten sonra modele dikkat mekanizması dahil edilmiştir. Bu aşamada $1e-4$ öğrenme katsayısı, hibrit kayıp fonksiyonu 0.5 BCE + 0.5 Dice ve Adam optimizasyon algoritması sabit tutulmuştur. Yeni mimari ile birlikte eğitim süresini optimize etmek amacıyla kademeli deneyler yürütülmüştür. İlk adımda yığın boyutu 4 olarak sabitlenmiş ve ResNet34 omurgası üzerinde 10, 30, 40 ve 50 epok değerleri test edilmiştir. Elde edilen sonuçla Tablo 3'te verilmiştir. Düşük epok sayılarında modelin karmaşık anatomik yapıları yeterince öğrenemediği gözlemlenmiştir. Epok sayısının artırılmasıyla birlikte modelin özellik temsil kapasitesi gelişmiş ve validasyon performansı daha kararlı hale gelmiştir. 50 epok sonrasında ise performans artışının doygunluğa ulaştığı görülmüştür.

Tablo 3. Epok sayısının yeni oluşturulan model ile performans analizi

Epok sayısı	Dice	IoU	PA
10	0.9589	0.9226	0.9795
30	0.9668	0.9367	0.9837
40	0.9680	0.9387	0.9845
50	0.9716	0.9453	0.9858

İkinci adımda, belirlenen 50 epok sayısı üzerinden yığın boyutu optimizasyonu yapılmıştır. Epok sayısı, optimizasyon algoritması ve öğrenme katsayısı sabit tutularak 2, 4 ve 8 değerleri ile test edilmiştir. Elde edilen sonuçlar **Tablo 4**'te sunulmuştur. Yapılan analizlerde, yığın boyutu 8 olduğunda modelin en yüksek başarıya ulaştığı saptanmıştır. Küçük yığın boyutları, gradyan güncellemelerinde daha yüksek varyasyon oluşturarak modelin ince anatomik detayları öğrenmesine katkı sağlamıştır. Bununla birlikte dikkat mekanizmasının eklendiği daha karmaşık mimaride, daha büyük yığın boyutlarının gradyan kararlılığını artırdığı ve modelin daha dengeli yakınsamasına yardımcı olduğu gözlemlenmiştir.

Tablo 4. Yığın boyutunun performans karşılaştırması

Yığın Boyutu	Dice	IoU	PA
2	0.9672	0.9374	0.9836
4	0.9716	0.9453	0.9858
8	0.9736	0.9489	0.9865

4.4 Omurga (Backbone) analizi


Eğitim stratejisi 50 epok ve 8 yığın boyutu olarak sabitlendikten sonra farklı omurga yapılarının etkisi incelenmiştir. Bu aşamada; herhangi bir omurga kullanılmayan temel model, EfficientNetB4, VGG16 ve ResNet34 mimarileri kıyaslanmıştır. Tüm deneylerde diğer parametreler sabit tutulmuştur. **Tablo 5**'te görüldüğü üzere, yapılan karşılaştırmalı analizler sonucunda, ResNet34 omurgasının diğer mimarilere göre en yüksek segmentasyon başarısını sergilediği görülmüştür. VGG16 ve EfficientNetB4 modellerinin de yüksek performans göstermesine rağmen, ResNet34 yapısının dikkat mekanizmasıyla daha uyumlu bir özellik çıkarımı sağladığı saptanmıştır. Sonuç olarak; ResNet34 + Attention + 50 Epok + 8 Yığın Boyutu + Adam + $1e-4$ Öğrenme Katsayısı + 0.5 BCE + 0.5 Dice kombinasyonu, bu çalışma kapsamındaki en iyi segmentasyon sonucunu vermiştir. Bu konfigürasyon, hem sayısal metriklerde en yüksek skorlara ulaşmış hem de anatomik sınırları en doğru şekilde belirleyen yapı olarak kaydedilmiştir.

Tablo-5. Omurga kullanımının model başarımına etkisi

Model Mimarisi (Omurga)	Dice	IoU	PA
Omurgasız (Temel U-Net)	0.9215	0.8544	0.9650
VGG16	0.9610	0.9250	0.9815
EfficientNetB4	0.9685	0.9390	0.9830
ResNet34	0.9736	0.9485	0.9845

Bu sayısal bulgular, önerilen modelin üstünlüğünü ortaya koyarken, görsel karşılaştırmalar da bu sonucu niteliksel olarak desteklemektedir. **Şekil 5**'te sunulan görsel karşılaştırma, standart U-Net'in akciğer dışındaki bazı bölgeleri yanlışlıkla akciğer olarak sınıflandırdığını göstermektedir. Bu durum, modelin düşük kontrastlı anatomik bölgelerde sınırlı ayırt edicilik kapasitesine sahip olduğunu ve yanlış pozitif segmentasyon ürettiğini ortaya koymaktadır. Özellikle kalp çevresi ve üst lob sınırlarında

gözlenen bu hatalar, standart U-Net'in akciğer dokusu ile çevre anatomik yapıları ayırt etmede yetersiz kaldığını ve maskeye gereksiz alanlar eklediğini göstermektedir. Bu tür yanlış pozitifler, klinik uygulamalarda segmentasyonun güvenilirliğini azaltarak tanısal süreçlerde hatalı yorumlara yol açma potansiyeline sahiptir. Buna karşın, ResNet34 omurgası ile dikkat mekanizmasının entegre edildiği önerilen model, akciğer sınırlarını daha doğru biçimde belirlemiş ve anatomik olarak gerçekçi bir maske üretmiştir. Önerilen model, sınır bütünlüğünü daha etkin biçimde korumuş ve segmentasyon çıktılarında daha yüksek yapısal tutarlılık sağlamıştır. Özellikle düşük kontrastlı ve karmaşık anatomik bölgelerde, dikkat mekanizmasının odaklanma yeteneği sayesinde modelin hem piksel bazlı doğruluğu hem de global yapısal bütünlüğü artmıştır. Bu iyileştirme, modelin yanlış pozitifleri azaltarak seçiciliğini yükselttiğini ve klinik açıdan daha güvenilir çıktılar ürettiğini kanıtlamaktadır. Dolayısıyla, **Şekil 5**'te sunulan görsel kanıtlar, **Tablo 4**'te raporlanan metriklerle uyumlu olarak, önerilen modelin hem sayısal hem de görsel değerlendirmelerde üstün performans sergilediğini ortaya koymaktadır.



Şekil 5. Göğüs X-ışını görüntüsünde akciğer segmentasyonu: (a) Orijinal görüntü, (b) Uzman anotasyonlu maske, (c) Standart U-Net çıktısı, (d) Önerilen model çıktısı.

4.5 5-katlı çapraz doğrulama analizi

Önerilen modelin kararlılığını ölçmek amacıyla 5-katlı çapraz doğrulama yöntemi uygulanmıştır. Tüm deneylerde dikkat mekanizması ve ResNet34 omurgası sabit tutulmuştur. Bu sayede kayıp fonksiyonu ve yığın boyutu değişimlerinin istatistiksel etkisi gözlemlenmiştir. İlk aşamada (K_1), sadece Dice kayıp fonksiyonu ve 4 yığın boyutu kullanılmıştır. Bu konfigürasyon 5-kat sonucunda 0.9495 ortalama Dice skoru elde etmiştir. İkinci aşamada (K_2), hibrit kayıp fonksiyonuna (0.5 BCE + 0.5 Dice) geçiş yapılmıştır. Hibrit yapının, ortalama Dice skorunu 0.9625 seviyesine yükselttiği görülmüştür. Son aşamada ise çalışmanın en iyi konfigürasyonu (Hibrit kayıp fonksiyonu + BS: 8) çapraz doğrulamaya tabi tutulmuştur. Yığın boyutunun 8'e çıkarılmasıyla birlikte model, 0.9638 ortalama Dice skoru ile en yüksek ve en kararlı performansına ulaşmıştır. Tüm sonuçlar **Tablo 6**'da özetlenmiştir.


Bu bulgular, önerilen modelin farklı veri bölüntülerinde tutarlı bir başarı sergilediğini ve düşük standart sapma değerleriyle yüksek uyum yeteneğine sahip olduğunu göstermektedir. Hibrit kayıp fonksiyonunun, BCE'nin küçük detayları yakalama gücü ile Dice'nin genel şekli koruma avantajını birleştirerek segmentasyon başarısını artırdığı

görülmüştür. Yığın boyutunun artırılması ise modelin gradyan kararlılığını güçlendirmiş ve performansın daha dengeli bir şekilde dağılmasını sağlamıştır. Bu sonuçlar, önerilen sistemin istatistiksel olarak sağlam bir temele dayandığını ve klinik ortamlarda uygulanabilirliğini desteklediğini ortaya koymaktadır.

Tablo 6. Farklı konfigürasyonların 5-katlı çapraz doğrulama analizi

Konfigürasyon	Kayıp Fonksiyonu	Yığın Boyutu	Ortalama Dice Skoru
K_1	Dice Loss	4	0.9495 ± 0.0009
K_2	0.5 BCE + 0.5 Dice	4	0.9625 ± 0.005
Nihai Model	0.5 BCE + 0.5 Dice	8	0.9638 ± 0.003

Çapraz doğrulama sonuçlarının daha ayrıntılı değerlendirilmesi amacıyla Dice ve IoU metrikleri için boxplot gösterimleri Şekil 6'da verilmiştir. Dice skorlarının ortalama 0.964 civarında ve oldukça düşük varyansla dağıldığı görülmektedir. Bu durum, modelin farklı katlarda tutarlı segmentasyon başarısı sergilediğini ve küçük varyasyonlara karşı dirençli olduğunu göstermektedir. IoU skorları ise ortalama 0.9325 seviyesinde olup yine düşük varyans ile dağılmıştır. Bu bulgu, modelin segmentasyon maskelerinin alan örtüşmesinde istikrarlı olduğunu ve anatomik varyasyonlara karşı uyum yeteneğinin yüksek olduğunu kanıtlamaktadır.



Şekil 6. Dice ve IoU metriklerinin 5-katlı çapraz doğrulama sonuçlarındaki dağılımı

Boxplot analizleri, Tablo 6'daki nihai modelin sayısal sonuçlarını görsel olarak desteklemekte ve modelin hem piksel bazlı doğruluk (Dice) hem de alan örtüşmesi (IoU) açısından güvenilir performans sergilediğini ortaya koymaktadır. Bu bütüncül değerlendirme, önerilen sistemin klinik uygulamalarda kullanılabilirliğini destekleyen güçlü bir istatistiksel doğrulama sağlamaktadır.

4.6 Literatür karşılaştırması

Önerilen modelin başarısını değerlendirmek amacıyla literatürdeki benzer çalışmalarla karşılaştırma yapılmıştır. Tablo 7, literatürdeki benzer akciğer segmentasyonu çalışmalarını, kullanılan modelleri, veri setlerini, veri bölme protokollerini ve elde edilen Dice skorlarını özetlemektedir. Souza ve arkadaşlarının 2019 yılında CNN tabanlı modeli Montgomery veri seti üzerinde test ettikleri çalışmada [25], yaklaşık %56 eğitim, %14 doğrulama ve %30 test bölme protokolü kullanılmış ve 93.56 Dice skoru elde edilmiştir.

Daha yakın tarihli çalışmalarda performansın belirgin şekilde arttığı görülmektedir. Örneğin, Salkade ve Rathi'nin 2025 yılında Res-UNet modeli ile Montgomery ve Shenzhen veri setlerini 5-katlı çapraz doğrulama yöntemiyle değerlendirdikleri çalışmada 96.33 Dice skoru raporlanmıştır [26]. Din ve arkadaşlarının 2025 yılında geliştirdikleri CXR-Seg modeli [8] ise Montgomery veri setinde %80 eğitim, %10 doğrulama ve %10 test protokolü ile 97.76 Dice, Shenzhen veri setinde ise 96.32 Dice skoruna ulaşmıştır.

Bu çalışmada önerilen model, U-Net tabanlı mimari üzerine dikkat mekanizması entegrasyonu ile geliştirilmiş ve hem 5-katlı çapraz doğrulama hem de klasik %80-%10-%10 bölme protokolü altında test edilmiştir. Çapraz doğrulama sonuçlarında 96.38 Dice skoru elde edilmiş, klasik bölme protokolünde ise 97.36 Dice skoruna ulaşılmıştır. Bu bulgular, önerilen modelin literatürdeki güncel çalışmalarla rekabet edebilir düzeyde olduğunu ve özellikle farklı veri bölme stratejilerinde tutarlı performans sergilediğini göstermektedir.

Tablo 7. Literatürdeki akciğer segmentasyonu çalışmaları ile önerilen modelin karşılaştırılması

Çalışma	Model	Veri Seti	Veri Bölme Protokolü	Dice (%)
Souza vd. [25]	CNN	Montgomery	~ %56 Eğitim ~ %14 Doğrulama ~ %30 Test	93.56
Salkade ve Rathi [26]	Res-UNet	Montgomery + Shenzhen	5-katlı çapraz doğrulama	96.33
Din vd. [8]	CXR-Seg	Montgomery	%80 Eğitim %10 Doğrulama %10 Test	97.76
Din vd. [8]	CXR-Seg	Shenzhen	%80 Eğitim %10 Doğrulama %10 Test	96.32
Bu Çalışma	Resnet34-Attention U-Net	Montgomery + Shenzhen	5-katlı çapraz doğrulama	96.38
Bu Çalışma	Resnet34-Attention U-Net	Montgomery + Shenzhen	%80 Eğitim %10 Doğrulama %10 Test	97.36

5 Sonuç

Bu çalışmada, göğüs X-ışını görüntülerinde akciğer segmentasyonu performansı kapsamlı bir şekilde incelenmiş ve U-Net tabanlı derin öğrenme modellerinde hiperparametrelerin ve mimari tercihlerinin etkileri sistematik olarak analiz edilmiştir. Çalışmanın temel amacı, en yüksek segmentasyon başarısını sağlayan bileşenleri ve bu bileşenlerin göreceli katkılarını ortaya koymaktır. Deneysel bulgular, yığın boyutu, epok sayısı, öğrenme katsayısı ve optimizasyon algoritmasının model başarısını üzerinde belirgin etkiler yarattığını göstermiştir. Özellikle 1e-4 öğrenme katsayısı ve Adam optimizasyon algoritması en kararlı yakınsamayı sağlamış, küçük yığın boyutları başlangıç aşamasında detayların öğrenilmesine katkı sunarken, dikkat mekanizmalı nihai modelde 50 epok ve 8 yığın boyutu kombinasyonu en yüksek Dice skoruna (0.9736) ulaşılmasını mümkün kılmıştır.

Mimari düzeyde yapılan karşılaştırmalar, omurga seçiminin kritik rolünü ortaya koymuş; ResNet34 omurgası,

VGG16 ve EfficientNetB4 gibi alternatiflere göre daha üstün özellik çıkarımı sergilemiştir. Dikkat mekanizmasının entegrasyonu, modelin odaklanma yeteneğini artırarak özellikle akciğer sınır bölgelerinde daha tutarlı segmentasyon çıktıları elde edilmesini sağlamıştır. Kayıp fonksiyonu analizlerinde hibrit yapıların sınıf dengesizliğiyle başa çıkmada daha etkili olduğu belirlenmiş; 0.5 BCE + 0.5 Dice kombinasyonu hem genel örtüşme oranını hem de sınır keskinliğini artırarak en dengeli sonuçları vermiştir. 5-katlı çapraz doğrulama sonuçları, bu hibrit yapının yalnızca tekil deneylerde değil, tüm veri setinde daha yüksek ortalama başarı (0.9638) ve istatistiksel kararlılık sunduğunu göstermiştir.

Sonuç olarak bu çalışma, akciğer segmentasyonunda performansı belirleyen faktörlerin bütüncül bir bakış açısıyla ele alınmasının önemini vurgulamaktadır. Elde edilen bulgular, medikal görüntü segmentasyonu problemlerinde model tasarımı ve eğitim stratejileri için yol gösterici niteliktedir. Gelecek çalışmalarda, daha büyük ve farklı kaynaklardan derlenmiş veri setleri kullanılarak modelin genelleme yeteneği geliştirilebilir. Ayrıca BT ve MR gibi farklı görüntüleme yöntemlerinin entegre edildiği çoklu-modal yaklaşımlar incelenebilir. Daha gelişmiş dikkat mekanizmaları ve otomatik hiperparametre optimizasyon yöntemlerinin kullanımı ise segmentasyon doğruluğunu daha ileri seviyelere taşıma potansiyeli sunmaktadır.

CRedit yazarlık katkı beyanı

Nihan Kazak Çerçevik: Kavramsallaştırma, Formal analiz, Araştırma, Yöntem, Danışmanlık, Doğrulama, Görselleştirme, Yazma-inceleme ve düzenleme; **Sündüs Sena Uysal:** Veri düzenleme, Formal analiz, Yöntem, Yazılım, Doğrulama, Görselleştirme, Yazma-ilk taslak, Yazma-inceleme ve düzeltme.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %17

Yazım sürecinde üretken yapay zekâ (YZ) ve YZ destekli teknolojilerin kullanımına ilişkin beyan

Yazarlar, bu çalışmanın hazırlanmasında herhangi bir yapay zekâ aracı kullanmamıştır.

Kaynaklar

- [1] S. Candemir, S. Jaeger, K. Palaniappan, J. P. Musco, R. K. Singh, Z. Xue, A. Karargyris, S. Antani, g. Thoma ve C.J. McDonald, "Lung segmentation in chest radiographs using anatomical atlases with nonrigid registration," *IEEE Transactions on Medical Imaging*, 33(2), 577-590, 2013. <https://doi.org/10.1109/TMI.2013.2290491>
- [2] O. Ronneberger, P. Fischer ve T. Brox, "U-Net: Convolutional networks for biomedical image segmentation," *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, 9351, sayfa 234-241, 2015. *MICCAI 2015. Lecture Notes in Computer Science*, vol. 9351. Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_28.
- [3] Z. Zhou, M.M. Rahman Siddiquee, N. Tajbakhsh ve J. Liang, "UNet++: A nested U-Net architecture for medical image segmentation," *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, 11045, sayfa 3-11, 2018. *DLMIA ML-CDS 2018 2018. Lecture Notes in Computer Science*, vol 11045. Springer, Cham. https://doi.org/10.1007/978-3-030-00889-5_1
- [4] O. Oktay, J. Schlemper, L.L. Folgoc, M. Lee, M. Heinrich, K. Misawa, K. Mori, S. McDonagh, N. Y. Hammerla, B. Kainz, B. Glocker ve D. Rueckert, "Attention U-Net: learning where to look for the pancreas," *arXiv preprint arXiv:1804.03999*, 2018. <https://doi.org/10.48550/arXiv.1804.03999>
- [5] A. Das, "Adaptive UNet-based Lung Segmentation and Ensemble Learning with CNN-based deep features for automated COVID-19 diagnosis," *Multimed Tools Appl*, 81, 5407-5441, 2022. <https://doi.org/10.1007/s11042-021-11787-y>
- [6] J. Hofmanninger, F. Prayer, J. Pan, S. Röhrich, H. Prosch ve G. Langs, "Automatic lung segmentation in routine imaging is primarily a data diversity problem, not a methodology problem," *European Radiology Experimental*, 4(1), 1-13, 2020. <https://doi.org/10.1186/s41747-020-00173-2>
- [7] S. Gite, A. Mishra ve K. Kotecha, "Enhanced lung image segmentation using deep learning," *Neural Comput & Applic*, 35, 22839-22853, 2023. <https://doi.org/10.1007/s00521-021-06719-8>
- [8] S. Din, M. Shoaib ve E. Serpedin, "CXR-seg: A novel deep learning network for lung segmentation from chest X-ray images," *Bioengineering*, 12(2), 167, 2025. <https://doi.org/10.3390/bioengineering12020167>
- [9] F. Turk ve M. Kılıçaslan, "Lung image segmentation with improved U-Net, V-Net and Seg-Net techniques," *PeerJ Computer Science*, 11, e2700, 2025. <https://doi.org/10.7717/peerj-cs.2700>
- [10] M. Murugappan, A.K. Bourisly, N.B. Prakash, M. G. Smithra ve U. R. Acharya, "Automated semantic lung segmentation in chest CT images using deep neural network," *Neural Comput & Applic*, 35, 15343-15364, 2023. <https://doi.org/10.1007/s00521-023-08407-1>
- [11] C.H. Sudre, W. Li, T. Vercauteren, S. Ourselin ve M.J. Cardoso, "Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations," *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, 10553, 240-248, 2017. https://doi.org/10.1007/978-3-319-67558-9_28
- [12] S.S.M. Salehi, D. Erdogmus ve A. Gholipour, "Tversky loss function for image segmentation using 3D fully convolutional deep networks," *Machine Learning in Medical Imaging*, 10541, 379-387, 2017. https://doi.org/10.1007/978-3-319-67389-9_44
- [13] S. Jadon, "A survey of loss functions for semantic segmentation," 2020 *IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)*, sayfa 1-7, Via del

- Mar, Chile, 2020. <https://doi.org/10.1109/CIBCB48159.2020.9277638>
- [14] L.N. Smith, "Cyclical learning rates for training neural networks," 2017 IEEE Winter Conference on Applications of Computer Vision (WACV), sayfa 464-472, Santa Rosa, CA, USA, 2017. <https://doi.org/10.1109/WACV.2017.58>
- [15] N.S. Keskar, D. Mudigere, J. Nocedal, M. Smelyanskiy ve P.T.P. Tang, "On large-batch training for deep learning: Generalization gap and sharp minima," arXiv preprint arXiv:1609.04836, 2016. <https://doi.org/10.48550/arXiv.1609.04836>
- [16] G. Litjens, T. Kooi, B.E. Bejnordi, A.A.A. Setio, F. Ciompi, M. Ghafoorian, J.A.W.M. van der Laak, B. Van Ginneken ve C.I. Sánchez, "A survey on deep learning in medical image analysis," *Medical Image Analysis*, 42, 60-88, 2017. <https://doi.org/10.1016/j.media.2017.07.005>
- [17] M.H. Hesamian, W. Jia, X. He ve P. Kennedy, "Deep learning techniques for medical image segmentation: achievements and challenges," *Journal of Digital Imaging*, 32(4), 582-596, 2019. <https://doi.org/10.1007/s10278-019-00227-x>
- [18] Y. Zhang, "Lung segmentation with nasnet-large-decoder net," arXiv preprint, arXiv:2303.10315, 2023. <https://doi.org/10.48550/arXiv.2303.10315>
- [19] T. Karmakar, "Chest X-ray lungs segmentation," Kaggle, 2020. Available: <https://www.kaggle.com/datasets/iamtapendu/chest-x-ray-lungs-segmentation>, [Accessed Nov. 9, 2025].
- [20] S. Jaeger, S. Candemir, S. Antani, Y.X.J. Wang, P.X. Lu ve G. Thoma, "Two public chest X-ray datasets for computer-aided screening of pulmonary diseases," *Quantitative Imaging in Medicine and Surgery*, 4(6), 475-477, 2014. <https://doi.org/10.3978/j.issn.2223-4292.2014.11.20>
- [21] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. C. Berg ve L. Fei-Fei, "ImageNet large scale visual recognition challenge," *International Journal of Computer Vision*, 115(3), 211-252, 2015. <https://doi.org/10.1007/s11263-015-0816-y>
- [22] M. Tan ve Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *Proceedings of the 36th International Conference on Machine Learning (ICML)*, 97, sayfa 6105-6114, 2019. <https://doi.org/10.48550/arXiv.1905.11946>
- [23] K. Simonyan ve A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv preprint, arXiv:1409.1556, 2015. <https://doi.org/10.48550/arXiv.1409.1556>
- [24] K. He, X. Zhang, S. Ren ve J. Sun, "Deep residual learning for image recognition," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, sayfa 770-778, 2016. <https://doi.org/10.1109/CVPR.2016.90>
- [25] J.C. Souza, J.O.B. Diniz, J.L. Ferreira, G.L.F. Da Silva, A.C. Silva ve A.C. De Paiva, "An automatic method for lung segmentation and reconstruction in chest X-ray using deep neural networks," *Computer Methods and Programs in Biomedicine*, 177, 285-296, 2019. <https://doi.org/10.1016/j.cmpb.2019.06.005>
- [26] S.A. Salkade ve S.V. Rathi, "An adaptive convolution neural network model for tuberculosis detection and diagnosis using semantic segmentation," *Polish Journal of Radiology*, 90, e124-e135, 2025. <https://doi.org/10.5114/pjr/200628>

