

# Az Örnekli Öğrenme Yöntemiyle Ağaçlık Alan Bölütlemesi<sup>1</sup>

## Woodland Segmentation Using Few-Shot Learning

Zehra Merve Gül<sup>1</sup>, Murat Gezer<sup>2</sup>

 0009-0003-5137-3632  0000-0002-7111-4975

<sup>1</sup>Fen Bilimleri Enstitüsü  
İstanbul Üniversitesi  
zehramervegul@ogr.iu.edu.tr

<sup>2</sup>Fen Fakültesi  
İstanbul Üniversitesi  
murat.gezer@istanbul.edu.tr

### Özet

Ağaçlık alanların bölütlenmesi, çevresel sürdürülebilirlik takibi ve haberleşme altyapı planlaması gibi alanlarda kritik bir role sahiptir; ancak tam denetimli derin öğrenme modellerinin piksel tabanlı yoğun veri etiketleme gereksinimi, maliyet, zaman ve uygulanabilirlik açısından önemli kısıtlar oluşturmaktadır. Bu çalışma söz konusu kısıtlamaları aşmak amacıyla yüksek çözünürlüklü hava görüntüleri üzerinde ağaçlık alan bölütlemesi için prototip ağırları tabanlı bir az örnekli öğrenme yaklaşımı sunmaktadır. LandCover.ai veri kümesi üzerinde gerçekleştirilen sistematik deneylerde, evrişimli ve dönüştürücü tabanlı sekiz farklı öznelik omurgası, dondurulmuş ağırlıklar koşulunda karşılaştırılmış ve ardından en başarılı evrişimli mimariler üzerinde katman bazlı ince ayar stratejileri değerlendirilmiştir. Deneysel sonuçlar, önerilen yöntemin en yüksek başarıyı dondurulmuş koşuldaki dönüştürücü tabanlı mimari ile elde ettiğini, evrişimli mimarilerde ise kontrollü katman açmanın başarıyı daha da artırdığını göstermektedir. Önerilen yöntem, yoğun piksel düzeyinde etiketleme gerektirmeden yalnızca beş etiketli destek örneğiyle anlamlı düzeyde bölütleme başarımlarını sergilemiştir.

**Anahtar kelimeler:** Az Örnekli Öğrenme, Anlamsal Bölütleme, Prototip Ağları, Hava Görüntüleri, Veri Verimliliği

### Abstract

Woodland segmentation plays a critical role in environmental sustainability monitoring and telecommunications infrastructure planning; however, fully supervised deep learning models impose significant constraints due to their intensive pixel-level annotation requirements. This study proposes a Prototypical Networks-based few-shot learning approach for woodland segmentation in high-resolution aerial imagery. Systematic experiments on the LandCover.ai dataset compared eight convolutional and transformer-based backbone architectures using

frozen weights, followed by an evaluation of layer-wise fine-tuning strategies on the best-performing convolutional backbones. Experimental results demonstrate that the transformer-based architecture achieves the highest performance under frozen conditions, while controlled layer unfreezing on convolutional architectures further improves segmentation accuracy. The proposed method achieves meaningful segmentation performance using only five labeled support examples without requiring dense pixel-level annotation.

**Keywords:** Few-Shot Learning, Semantic Segmentation, Prototypical Networks, Aerial Imagery, Data Efficiency

### 1. Giriş

Yüksek çözünürlüklü hava görüntüleri üzerinden arazi örtüsünün hassas bir şekilde haritalandırılması, karar vericilere çevresel izleme, doğal kaynak yönetimi ve kentsel planlama süreçlerinde stratejik bilgiler sunmaktadır [1, 2]. Günümüzde bilgisayarlı görü teknikleri ve derin öğrenme algoritmaları, bu tür yüksek çözünürlüklü görsel verilerin yorumlanmasında ve piksel düzeyinde bölütlenmesinde önemli ilerlemeler sağlamaktadır [3]. Bu bağlamda, ağaçlık alanların hassas bir şekilde bölütlenmesi, yalnızca tarım ve ormancılık faaliyetleri için değil; aynı zamanda haberleşme altyapı yönetimi ve baz istasyonlarının optimum konumlandırılması süreçlerinde de belirleyici bir rol oynamaktadır [4]. Geleneksel haritalama yöntemlerinin aylar süren zaman maliyeti ve hataya açık yapısı göz önüne alındığında, derin öğrenme tabanlı bölütleme sistemleri bu süreçleri hızlandırmak ve doğruluğu artırmak için vazgeçilmez bir araç haline gelmiştir [1].

Görüntülerin anlamsal bölütlenmesi görevlerinde, evrişimli sinir ağırları tabanlı tam denetimli mimariler, sağladıkları yüksek ayırt etme gücü ile baskın bir yaklaşım haline gelmiştir [5]; ancak söz konusu modellerin bu yüksek başarımları, veri açlığı olarak nitelendirir.

<sup>1</sup>Bu makale, İstanbul Üniversitesi Fen Bilimleri Enstitüsü Enformatik Anabilim Dalı'nda tamamlanan "Yüksek Çözünürlüklü Hava Görüntülerinde Az Örnekli Öğrenme Yöntemiyle Ağaçlık Alan Bölütlemesi" başlıklı yüksek lisans tezinden üretilmiştir.

len ve eğitim aşamasında geniş ölçekli ve piksel düzeyinde etiketlenmiş veri kümelerine erişim koşuluna dayanmaktadır [3]. Hava görüntüleri özelinde bu verilerin uzmanlar tarafından piksel düzeyinde etiketlenmesi, en büyük maliyet kalemi ve uygulama gücü olarak karşımıza çıkmaktadır [1, 2]. Yeterli etiketli verinin bulunmadığı veya acil analiz gerektiren yeni coğrafi bölgelerde, bu denli yoğun veri gereksinimi duyan mimarilerin uygulanabilirliği ve ölçeklenebilirliği önemli ölçüde kısıtlanmaktadır. Buna ek olarak, modellerin eğitim verisinden farklı karakteristiklere sahip heterojen coğrafi bölgelere doğrudan uygulanması, alan kayması nedeniyle ciddi başarımları kayıplarına yol açmaktadır [2, 6]. Mevcut tam denetimli yöntemler, her yeni bölge veya değişen koşullar için modelin yeniden eğitilmesini gerektirmekte; bu da sistemlerin ölçeklenebilirliğini kısıtlamaktadır [2].

Bu bağlamda, yüksek etiketleme maliyetlerini ortadan kaldıran ve veri kıtlığı durumlarında dahi hedef bölgelere hızla uyarlanabilen esnek bir öğrenme çerçevesine duyulan ihtiyaç, az örnekle öğrenme yaklaşımını öne çıkarmıştır [7, 8]. Her ne kadar genel bilgisayarlı görü alanında az örnekle anlamsal bölütleme yöntemleri başarılı sonuçlar verse de; uzaktan algılama görüntülerinin içerdiği aşırı ölçek farklılıkları ve karmaşık uzamsal yerleşimler, bu algoritmaların doğrudan uygulanmasını zorlaştırmaktadır [9]. Bu çalışma, yüksek çözünürlüklü hava görüntülerinden ağaçlık alanların bölütlenmesi için az sayıda etiketli örnekle çalışabilen, metrik tabanlı bir az örnekle öğrenme yaklaşımını önermektedir. LandCover.ai veri kümesi [1] temel alınarak kurgulanan bu yöntemde, prototip ağları mimarisi yoğun piksel tahmini görevine uyarlanmış olup sorgu piksellerini en yakın sınıf prototipine atayarak bölütleme haritaları üretmektedir [8]. Bu yöntem, tam denetimli derin öğrenme modellerinin ihtiyaç duyduğu yoğun etiketleme maliyetlerini en aza indirirken, sınırlı sayıda etiketli örnekle yeni sınıflara uyum sağlama kapasitesini değerlendirmeyi hedeflemektedir [1, 4, 8].

### 1.1. Çalışmanın Temel Katkıları

Çalışmanın literatüre sunduğu temel katkılar aşağıda özetlenmiştir:

- Prototip ağları tabanlı az örnekle bölütleme yaklaşımı, LandCover.ai veri kümesi üzerinde ağaçlık alanların bölütlenmesi amacıyla ilk kez uygulanmıştır. Bu yaklaşım, yalnızca beş etiketli destek örneğiyle bölütleme gerçekleştirerek yoğun piksel düzeyinde etiketleme gereksinimini önemli ölçüde azaltmaktadır.
- Evrişimli ve dönüştürücü tabanlı sekiz farklı öznelik omurgası, dondurulmuş koşulda sistematik olarak karşılaştırılmıştır. Bu karşılaştırma, uzaktan algılamada az örnekle bölütleme için mimari seçimine ilişkin somut deneysel kanıtlar sunmaktadır.
- Katman açma stratejilerinin başarıma etkisi, en başarılı

evrişimli mimariler üzerinde kontrollü deneylerle incelenmiştir. Bu deneyler, dondurulmuş ve ince ayarlı yapılandırılmalar arasındaki ödünleşimi nicel olarak ortaya koymaktadır.

### 1.2. Çalışmanın Teşkili (Organizasyonu)

Çalışmanın geri kalanı şu şekilde kurgulanmıştır: Bölüm 2 hava görüntüleri üzerinde anlamsal bölütleme ve az örnekle öğrenme yaklaşımlarına dair literatürdeki ilgili çalışmaları incelemektedir. Bölüm 3 ele alınan az örnekle bölütleme problemini tanımlamakta ve epizodik öğrenme yapısını formüle etmektedir. Bölüm 4 prototip ağları mimarisi temelinde geliştirilen yöntemin teknik bileşenlerini sunmaktadır. Bölüm 5 veri kümesi, eğitim yapılandırması ve deneysel sonuçları değerlendirmektedir. Son olarak Bölüm 6 çalışmayı özetlemekte ve gelecekteki araştırma yönlerine dair önerilerde bulunmaktadır.

## 2. İlgili Çalışmalar

Derin öğrenme tabanlı bölütleme, tam bağlı katmanları evrişimli katmanlarla değiştirerek piksel düzeyinde yoğun tahminler üreten tam evrişimli ağlar ile başlamıştır [10]; ancak tam evrişimli ağlardaki ardışık havuzlama işlemleri uzamsal bilgi kaybına yol açmıştır. Bu sorunu aşmak için kodlayıcıdan gelen yüksek çözünürlüklü öznelikler kod çözücüyle birleştiren ve böylece hassas konumlandırma sağlayan U-Net mimarisi geliştirilmiştir [11]. Daha derin ağların eğitimi için sunulan ResNet (*Residual Network*), artık öğrenme blokları sayesinde kaybolan gradyan problemini çözmüş ve modern bölütleme ağlarının standart öznelik omurgası haline gelmiştir [12]. Nesne ölçeklerindeki farklılıkları yönetmek için PSPNet (*Pyramid Scene Parsing Network*) ile küresel bağlam bilgisi kullanılırken [13], FPN (*Feature Pyramid Network*) ile hiyerarşik özellik piramitleri önerilmiştir [14]. DeepLabv3+ ise nesnelere farklı ölçeklerde yakalayabilen özel filtreleme yapıları sayesinde günümüzün en başarılı modellerinden biri olmuştur [15]; ancak bu tam denetimli modellerin başarısı, literatürde veri açlığı olarak bilinen, geniş ölçekli etiketli veri kümelerine duyulan mutlak bağımlılık ve yüksek etiketleme maliyeti ile sınırlıdır [10, 11, 15]. Uzaktan algılama alanında bu veri açlığı sorunu; nesnelere santimetre düzeyinde çözünürlükten çok hektarlık alanlara kadar gösterdiği aşırı ölçek farklılıkları ve çevresel faktörlerin neden olduğu aynı sınıfa ait nesnelere kendi içindeki yüksek çeşitliliğiyle birleştğinde ciddi bir kısıt oluşturmaktadır.

Az örnekle öğrenme, eğitim aşamasında görülmemiş yeni sınıfları yalnızca birkaç etiketli örnekle tanımayı hedefleyen bir meta öğrenme yaklaşımıdır. Bu alandaki etkili metrik tabanlı yöntemlerden olan prototip ağları, sınıfların gömme uzayındaki merkezlerini birer proto-

tip olarak temsil ederek sınıflandırmayı en yakın prototipe olan mesafeye dayandırır [7, 8, 16]. Eşleştirme ağları, ağırlıklı en yakın komşu mantığıyla, MAML (*Model-Agnostic Meta-Learning*) ise ağ ağırlıklarının yeni görevlere kısıtlı veriyle ve yalnızca birkaç gradyan adımıyla hızla uyarlanmasını hedefleyen optimizasyon tabanlı yapısıyla öne çıkmaktadır [17, 18]; ancak prototip ağları, mesafe tabanlı basit tümevarımsal yanlılığı sayesinde düşük veri koşullarında daha sağlam ve daha az parametrelili bir yapı sunmaktadır [7, 8]. Görüntü düzeyinde sınıflandırma görevlerinde tasarlanan bu yöntemlerin, pikseller arası uzamsal ve geometrik ilişkilerin korunmasını gerektiren yoğun piksel düzeyinde bölütleme görevlerine uyarlanması, [7, 19] çalışmalarda daha karmaşık bir problem olarak incelenir.

Az örnekli bölütleme, genel az örnekli öğrenme teorisini yoğun piksel tahmini görevine uyarlayarak kısıtlı destek örnekleri yardımıyla eğitimde görülmemiş sınıflar için maskeler üretmeyi amaçlar [7, 16]. OSLSM (*One-Shot Learning for Semantic Segmentation*), bir meta öğrencinin bölütleme dalı için parametre ürettiği ilk iki dallı mimariyi sunmuştur [19]. Ardından geliştirilen PANet (*Prototype Alignment Network*), parametrik olmayan metrik öğrenme prensibi ve prototip hizalama düzenlemesi tekniğiyle destek ve sorgu prototipleri arasındaki anlamsal tutarlılığı artırmıştır [20]. CANet (*Class-Agnostic Segmentation Network*) ise uzamsal özellikleri yoğun bir şekilde karşılaştırıp tahminleri yinelemeli bir iyileştirme modülüyle optimize ederek başarımları daha ileri taşımıştır [21]. PFENet (*Prior Guided Feature Enrichment Network*), eğitimden bağımsız ön bilgi maskeleriyle öznitelik zenginleştirme sunarken [16], HS-Net (*Hypercorrelation Squeeze Network*) çok seviyeli hiper-korelasyon sıkıştırma yöntemiyle yüksek başarımlar elde etmiştir [22]. Güncel yaklaşımlarda ise, destek ve sorgu görüntüleri arasındaki görünüm uyumsuzluğunu aşmak amacıyla sorgu görüntüsünün yüksek güvenilirliğe sahip bölgelerinden yararlanarak sınıf prototiplerini dinamik olarak zenginleştiren öz destekli mekanizmalar önerilmiştir [23]. Bu çalışmaların büyük bir kısmı PASCAL-5i veya COCO-20i gibi standart bilgisayarlı görü veri kümelerine odaklanmış olup nesnelere tek bir küresel prototip ile temsil etme eğilimindedir. Bu yaklaşım, uzaktan algılama görüntülerindeki karmaşık uzamsal yerleşimleri ve yüksek sınıf içi çeşitliliği yakalamada yetersiz kalmaktadır.

Uzaktan algılama özelinde ise TAFD (*Task Augmentation and Feature Disentanglement*), görev artırma mekanizması ve öznitelik ayrıştırma modülü ile kaynak-hedef alanlar arasındaki alan kaymasını çözmeyi hedeflemiş ve piksel sınıflandırmasını grafik tabanlı etiket yayılımı ile gerçekleştirmiştir [6]. GlocalDualNet, tek küresel prototipin uzamsal bilgi kaybına yol açtığı varsayımından hareketle nesnelere küresel ve yerel

prototip kümeleriyle temsil eden çok ölçekli bir yapı sunmuştur [9]. Broni-Bediako vd. ise OpenEarthMap veri kümesi üzerinde Swin-T (*Swin Transformer-Tiny*) omurgasıyla genelleştirilmiş az örnekli bölütleme değerlendirmesi gerçekleştirmiştir [24]. Ancak bu çalışmaların tamamı tek bir öznitelik omurgasıyla sınırlı kalmış olup farklı mimari ailelerinin başarıma etkisini sistematik olarak karşılaştırmamaktadır. LandCover.ai üzerinde ağaçlık alanların bölütlenmesinde tam denetimli modeller başarılı sonuçlar elde etmiş [4] olsa da metrik tabanlı az örnekli bir yaklaşım henüz uygulanmamıştır. Bu çalışma, söz konusu boşluğu ele almaktadır.

Literatürdeki mevcut çalışmaların karşılaştırmalı analizi ve araştırma boşlukları Tablo 1’te özetlenmiştir.

Önerilen yöntemin yöntemsel yaklaşım, öğrenme biçimi ve uygulama alanı açısından mevcut çalışmalarla karşılaştırması Tablo 2’de sunulmuştur.

### 3. Sistem Modeli ve Problem Tanımı

Bu bölümde, yüksek çözünürlüklü hava görüntülerinden ağaçlık alanların bölütlenmesi için önerilen sistemin teorik çerçevesi ve problem tanımı sunulmaktadır. Öncelikle problemin teknik kısıtları ve matematiksel tanımı yapılmakta, ardından modelin temelini oluşturan epizodik öğrenme yapısı ile farklı öznitelik omurgası mimarilerinin sistem üzerindeki işlevi detaylandırılmaktadır.

#### 3.1. Az Örnekli Bölütleme Problemi

Yüksek çözünürlüklü hava görüntülerinden ağaçlık alanların bölütlenmesi, üç temel teknik zorluk barındırmaktadır. Birincisi, ağaçlık alan sınıfına ait bölgeler yüksek sınıf içi çeşitlilik sergilemektedir. Ağaç türlerinin farklılığı, büyüme evreleri ve yoğunluk değişimleri, aynı sınıfa ait piksellerin öznitelik uzayında geniş bir dağılım göstermesine yol açmaktadır [1]. İkincisi, mevsimsel değişimler ve atmosferik koşullar nedeniyle güneş açısı, aydınlatma farklılıkları ve gölge boyları gibi faktörler nesne sınırlarının belirsizleşmesine yol açmakta; bu durum aynı anlamsal sınıf içindeki spektral heterojenliği artırarak öznitelik çıkarımını zorlaştırmaktadır [2, 9]. Üçüncüsü, eğitim verisinden farklı coğrafi karakteristiklere veya sensör özelliklerine sahip bölgelere geçildiğinde, literatürde alan kayması olarak bilinen durum nedeniyle ciddi başarımlar düşüşleri gözlemlenmektedir [2].

Bu zorluklar, mevcut tam denetimli bölütleme modellerinin geniş ölçekli, piksel düzeyinde etiketlenmiş veriye olan yoğun bağımlılığıyla birleştiğinde, pratik uygulanabilirliği önemli ölçüde kısıtlamaktadır. Bu çalışma söz konusu kısıtlamaları aşmak amacıyla az örnekli bölütleme yaklaşımını benimsemektedir. Az örnekli bölütleme, modelin eğitim aşamasında hiç görmediği yeni sınıfları ( $C_{\text{novel}}$ ), test aşamasında yalnızca birkaç

Tablo 1: Mevcut Yöntemlerin ve Önerilen Yöntemin Teknik ve Alansal Karşılaştırması

Çalışma	Yoğun Tahmin	Az Örnekli	Metrik Tabanlı	Hava Görüntüsü	Yüksek Çözünürlük
<i>Tam Denetimli Bölütleme</i>					
U-Net [11]	Evet	Hayır	Hayır	Evet	Evet
DeepLabv3+ [15]	Evet	Hayır	Hayır	Evet	Evet
Berka vd. [25]	Evet	Hayır	Hayır	Evet	Evet
FPN (Darici) [4]	Evet	Hayır	Hayır	Evet	Hayır
<i>Az Örnekli Bölütleme (Doğal Sahneler)</i>					
OSLSM [19]	Evet	Evet	Hayır	Hayır	Hayır
PANet [20]	Evet	Evet	Evet	Hayır	Hayır
CANet [21]	Evet	Evet	Hayır	Hayır	Hayır
PFENet [16]	Evet	Evet	Hayır	Hayır	Hayır
HSNet [22]	Evet	Evet	Evet	Hayır	Hayır
SSP [23]	Evet	Evet	Evet	Hayır	Hayır
<i>Az Örnekli Bölütleme (Uzaktan Algılama)</i>					
TAFD [6]	Evet	Evet	Evet	Evet	Hayır
GlocalDualNet [9]	Evet	Evet	Evet	Evet	Hayır
Broni-Bediako vd. [24]	Evet	Evet	Evet	Evet	Evet
<b>Bu Çalışma</b>	<b>Evet</b>	<b>Evet</b>	<b>Evet</b>	<b>Evet</b>	<b>Evet</b>

Yoğun tahmin: Piksel düzeyinde sınıflandırma (bölütleme). Metrik tabanlı: Prototip veya korelasyon tabanlı eşleştirme.  
Yüksek çözünürlük:  $\leq 50$  cm/piksel.

Tablo 2: Önerilen Yöntemin En Yakın İlgili Çalışmalarla Karşılaştırılması

Çalışma	Yaklaşım	Öznitelik Omurgası	Veri Kümesi	Alan	Temel Sınırlılık
<i>Tam Denetimli Bölütleme</i>					
U-Net [11]	Kodlayıcı-kod çözücü	Özel kodlayıcı	Çeşitli	Biyomedikal/UA	Yoğun etiketli veri gerektirir
DeepLabv3+ [15]	Genişletilmiş evrişim + ASPP	Xception, ResNet	PASCAL, Cityscapes	Genel	Yeni sınıflar için baştan eğitim gerektirir
Berka vd. [25]	DeepLabv3+ füzyon	Xception	LandCover.ai	Hava	Yoğun etiketli veri gerektirir
Darici vd. [4]	FPN tabanlı bölütleme	ResNet	Özel (0,6m)	Hava/Uydu	Az örnekli koşullara uyulanamaz
<i>Az Örnekli Bölütleme (Doğal Sahneler)</i>					
ProtoNet [8]	Prototip tabanlı sınıflandırma	CNN	Omniglot, miniImageNet	Genel	Görüntü düzeyinde; uzamsal bilgi kullanamaz
PANet [20]	Prototip hizalama	ResNet-50	PASCAL, COCO	Doğal	Tek prototip karmaşık sahnelerde yetersiz
PFENet [16]	Ön bilgi destekli zenginleştirme	ResNet-50/101	PASCAL, COCO	Doğal	Ön maske eğitim sınıflarına bağımlı
HSNet [22]	Çok seviyeli hiper-korelasyon	ResNet-50/101	PASCAL, COCO	Doğal	4B evrişimler yüksek hesaplama maliyeti getirir
SSP [23]	Öz destekli prototip zenginleştirme	ResNet-50/101	PASCAL, COCO, FSS-1000	Doğal	UA ölçek farklılıklarına odaklanmaz
<i>Az Örnekli Bölütleme (Uzaktan Algılama)</i>					
TAFD [6]	Çapraz alan az örnekli bölütleme	ResNet-50	WHDL, GID5	Uydu	Alan uyarlamasına odaklanır; omurga analizi yok
GlocalDualNet [9]	Küresel-yerel ikili prototip	ResNet-50	iSAID	Uydu	Tek omurga; ön eğitim analizi yok
Broni-Bediako vd. [24]	Genelleştirilmiş FSS	Swin-T	OpenEarthMap	Hava/Uydu	Tek omurga; sınırlı ön eğitim analizi
<b>Bu çalışma</b>	<b>Prototip tabanlı az örnekli bölütleme</b>	<b>8 omurga (CNN + dönüştürücü)</b>	<b>LandCover.ai</b>	<b>Hava</b>	<b>Tek ölçekli prototip; tek veri kümesi</b>

UA: Uzaktan algılama. FSS: Az örnekli anlamsal bölütleme.

etiketli destek örneği kullanarak sorgu görüntüleri üzerinde piksel düzeyinde tahmin etmeyi hedefler. Modelin genelleme başarısını güvence altına almak amacıyla eğitim ve test aşamalarında kullanılan sınıflar kesin bir biçimde ayrık tutulur. Böylece model, eğitim sırasında temel sınıflar ( $\mathcal{C}_{\text{base}}$ ) üzerinden meta öğrenme yoluyla *az örnekten nesne karakteristiği çıkarma ve bölütleme yapma* becerisini edinir ve bu beceriyi test aşamasında  $\mathcal{C}_{\text{novel}}$  sınıfına aktarır.

### 3.2. Epizodik Öğrenme Yapısı

Az örneklî bölütlemede model, standart yığın tabanlı eğitimden farklı olarak, her yinelemede veri kümesinden rastgele örneklenen epizotlar üzerinden eğitilir; böylece test aşamasında karşılaşacağı az örneklî görevleri eğitim sırasında sistematik olarak deneyimler. Her epizot, bir destek kümesi ( $\mathcal{S}$ ) ve bir sorgu kümesi ( $\mathcal{Q}$ ) olmak üzere iki temel bileşenden oluşur.

Bu çalışmada 1-way 5-shot ikili bölütleme yapılandırması benimsenmiştir. Her epizotta yalnızca bir hedef sınıf ele alınmakta ( $W = 1$ ) ve destek kümesi bu sınıfa ait beş etiketli karo-maske çiftinden ( $K = 5$ ) meydana gelmektedir:

$$\mathcal{S} = \{(x_i, m_i)\}_{i=1}^K, \quad m_i = \mathbb{1}[\text{maske}(x_i) = c_{\text{hedef}}] \quad (1)$$

burada,

$$\begin{aligned} x_i \in \mathbb{R}^{3 \times H \times W} & : \text{RGB görüntü karesi,} \\ m_i \in \{0, 1\}^{H \times W} & : \text{Hedef sınıfa ilişkin ikili maske,} \\ H, W & : \text{Karonun uzamsal boyutları} \end{aligned}$$

olarak tanımlanmıştır. Sorgu kümesi ise, modelin destek kümesindeki bilgilerle bölütleme tahmini üretmesi beklenen tek bir karodan oluşmaktadır:

$$\mathcal{Q} = \{(x_q, m_q)\} \quad (2)$$

Deneylerin bilimsel geçerliliğini korumak ve epizotların coğrafi bilgi sızıntısından arınmış olmasını sağlamak amacıyla üç kural uygulanmaktadır. Birincisi, bir epizot içindeki beş destek karesi ve bir sorgu karesi kesinlikle farklı kaynak görüntülerden seçilmektedir. İkincisi, bir karonun destek kümesine dahil edilebilmesi için içerdiği hedef sınıf piksel oranının, istatistiksel geçerliliği garanti eden ve sınıf bazında önceden belirlenmiş asgari ön plan eşliğini aşması zorunlu tutulmuştur. Üçüncüsü, eğitim epizotları yalnızca  $\mathcal{C}_{\text{base}}$  sınıflarından, test epizotları ise modelin eğitim sürecinde hiç karşılaşmadığı  $\mathcal{C}_{\text{novel}}$  sınıfından oluşturulmaktadır. Bir epizotun genel yapısı Şekil 1'de gösterilmektedir.

### 4. Önerilen Yöntem

Bu bölümde, yüksek çözünürlüklü hava görüntülerinde ağaçlık alanların az örnekle bölütlenmesi amacıyla pro-

totip ağları [8] temel alınarak geliştirilen ve piksel düzeyinde yoğun tahmin yapacak şekilde özelleştirilen mimari bileşenler sırasıyla açıklanmaktadır.

#### 4.1. Genel Sistem Mimarisi

Önerilen mimari, epizodik eğitim stratejisine uygun olarak destek ve sorgu dalı olmak üzere iki dallı bir yapı üzerine kurgulanmıştır. Her iki dalda da ağırlıkları paylaşılan özdeş bir öznitelik çıkarıcı kullanılmaktadır. Modelin temel işleyişi, giriş görüntüsünden yoğun öznitelik haritalarının çıkarılması, bu haritalar üzerinden sınıf düzeyinde prototiplerin oluşturulması ve sorgu piksellerinin prototiplere olan benzerliğine göre sınıflandırılması aşamalarından oluşmaktadır. Mimarinin uçtan uca akışı Şekil 2'de gösterilmektedir.

#### 4.2. Öznitelik Omurgası

Modelin öznitelik çıkarım kapasitesinin başarımlar üzerindeki etkisini incelemek amacıyla sekiz farklı öznitelik omurgası mimarisi değerlendirilmiştir. Evrişimli sinir ağlarından ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152 [12] ve Xception [26]; dönüştürücü tabanlı mimarilerden Swin-T [27] ve ViT-B/16 (*Vision Transformer - Base, patch size 16*) [28]. Tüm mimariler ImageNet-1K V1 [29] ön eğitilmiş ağırlıklarla başlatılmış ve öznitelik omurgası katmanları dondurulmuştur; böylece gözlemlenen başarımlar farklılıkları doğrudan öznitelik çıkarma kapasitesine atfedilebilmektedir.

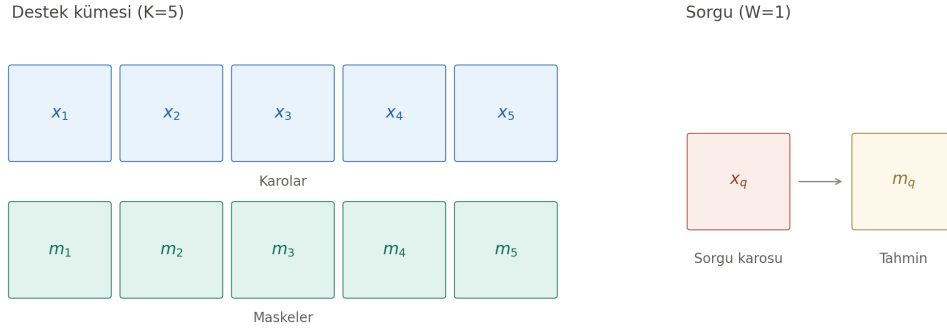
Evrişimli öznitelik omurgalarında bölütleme görevinin gerektirdiği uzamsal çözünürlüğün korunması amacıyla, son iki aşamadaki adım işlemleri genişletilmiş evrişimlerle değiştirilmiştir. Katman 3 için genişleme oranı  $d = 2$ , katman 4 için  $d = 4$  olarak atanmıştır. Bu yapılandırma çıkış adımını 32'den 8'e düşürerek,  $473 \times 473$  boyutundaki giriş görüntüsünden  $60 \times 60$  boyutunda öznitelik haritaları elde edilmesini sağlamaktadır.

Farklı öznitelik omurgaların çıkış kanal derinlikleri mimariye göre değişmektedir; örneğin ResNet-50 ailesinde 2048, Swin-T mimarisinde ise 768 kanallı öznitelik haritaları üretilmektedir. Bu çıktılar ortak bir metrik uzayda karşılaştırılabilir kılmak amacıyla,  $1 \times 1$  evrişim, yığın normalizasyonu ve ReLU etkinleştirme fonksiyonundan oluşan bir boyut indirgeme bloğu tüm öznitelik omurgalarına uygulanarak çıkış 256 kanala düşürülmektedir:

$$\mathbf{F} = \text{ReLU}(\text{BN}(\text{Conv}_{1 \times 1}(\mathbf{F}_{\text{backbone}}))) \in \mathbb{R}^{256 \times H' \times W'} \quad (3)$$

#### 4.3. Maskelenmiş Ortalama Havuzlama ile Prototip Oluşturma

Her epizot için biri ön plan (hedef sınıf) diğeri arka plan olmak üzere iki prototip hesaplanmaktadır. Ön plan pro-



Şekil 1. 1-way 5-shot epizot yapısı. Destek kümesi  $\mathcal{S}$  beş karo–maske çiftinden  $(x_i, m_i)$ , sorgu kümesi  $\mathcal{Q}$  tek bir karodan  $(x_q)$  oluşmaktadır.

totipi, destek maskesinde hedef sınıfa ait ( $m = 1$ ) konumların öznitelik vektörlerinin ortalaması alınarak elde edilir:

$$\mathbf{p}_{fg} = \frac{\sum_{i=1}^K \sum_{(h,w)} m_i(h,w) \cdot \mathbf{F}_i(h,w)}{\sum_{i=1}^K \sum_{(h,w)} m_i(h,w)} \quad (4)$$

Arka plan prototipi ise maskenin tümleyeni ( $1 - m_i$ ) kullanılarak aynı yöntemle hesaplanır:

$$\mathbf{p}_{bg} = \frac{\sum_{i=1}^K \sum_{(h,w)} (1 - m_i(h,w)) \cdot \mathbf{F}_i(h,w)}{\sum_{i=1}^K \sum_{(h,w)} (1 - m_i(h,w))} \quad (5)$$

İki prototipin birlikte kullanılması, modelin karar sınırını yalnızca ön plana olan benzerlik yerine ön plan ve arka plan arasındaki göreceli benzerlik üzerinden oluşturmasını sağlamaktadır. Maskelenmiş ortalama havuzlamanın güvenilir bir prototip üretebilmesi, maskelenmiş bölgedeki geçerli piksel sayısına doğrudan bağlıdır; bu nedenle destek karosu seçiminde sınıf bazında asgari ön plan eşikleri uygulanmaktadır (bkz. Bölüm 5.1, Tablo 5).

#### 4.4. Kosinüs Benzerliği ve Sıcaklık Ölçeklemesi

Sorgu öznitelik haritası  $\mathbf{F}_q \in \mathbb{R}^{256 \times H' \times W'}$  üzerindeki her  $(h, w)$  konumu için ön plan ve arka plan prototipleriyle kosinüs benzerliği hesaplanır:

$$\text{sim}(\mathbf{F}_q(h, w), \mathbf{p}_c) = \frac{\mathbf{F}_q(h, w) \cdot \mathbf{p}_c}{\|\mathbf{F}_q(h, w)\| \|\mathbf{p}_c\|} \quad (6)$$

Burada  $c \in \{\text{fg}, \text{bg}\}$  olmak üzere her uzamsal konum için iki ayrı benzerlik değeri elde edilir. Kosinüs benzerliğinin  $[-1, +1]$  aralığında sınırlı değerler üretmesi gradyan akışının kararlılığını desteklemekte, vektör büyüklüğünden bağımsız olması ise farklı destek görüntülerinden hesaplanan prototiplerin norm farklılıklarına karşı dayanıklılık sağlamaktadır [8]. Ancak bu sınırlı değer aralığı, doğrudan eşikleme yapıldığında yetersiz sınıf ayırımına yol açabilir. Bu sorunu gidermek amacıyla öğrenilebilir bir sıcaklık parametresi  $\tau$  kullanılmaktadır. Parametre, log uzayında tanımlanarak pozitiflik kısıtı sağlanmakta ve başlangıç değeri  $\tau_0 = 10,0$  olarak belirlenmektedir. Son çıkış, ön plan ve arka plan benzerlik değerleri arasındaki fark olarak hesaplanır ve sıcaklık parametresiyle ölçeklenir:

$$\text{logit}(h, w) = \tau \cdot (\text{sim}(\mathbf{F}_q(h, w), \mathbf{p}_{fg}) - \text{sim}(\mathbf{F}_q(h, w), \mathbf{p}_{bg})) \quad (7)$$

Sıcaklık parametresinin eğitim sürecinde öğrenilebilir olması, modelin veri kümesine ve görev zorluğuna uygun bir ayırım keskinliğini kendiliğinden belirlemesine olanak tanımaktadır. Bölütleme maskesi,  $\sigma(\text{logit}(h, w)) > 0,5$  eşikine göre ikili olarak üretilir; burada  $\sigma$  sigmoid fonksiyonudur.

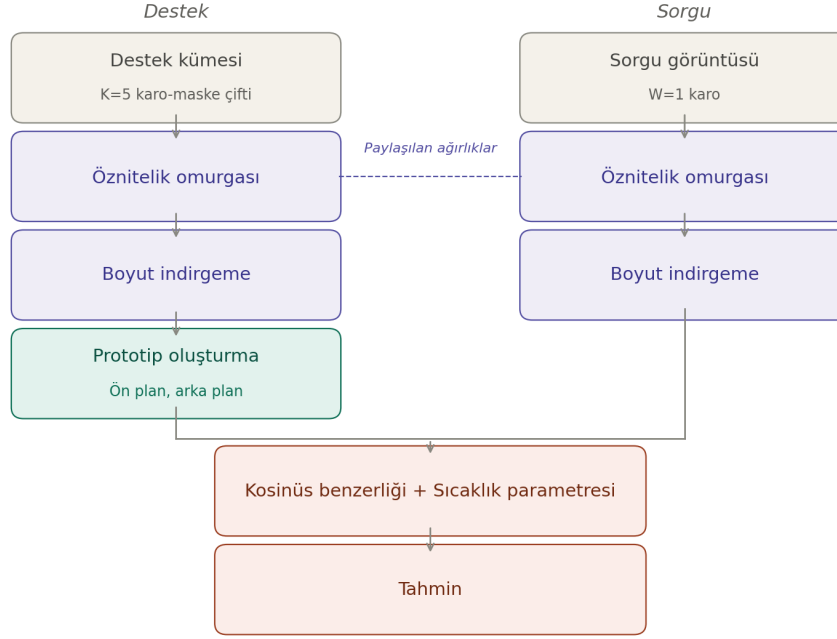
#### 4.5. Bileşik Kayıp Fonksiyonu

İkili bölütleme görevindeki sınıf dengesizliğini ele almak amacıyla, birbirini tamamlayan iki kayıp fonksiyonunun ağırlıklı toplamı kullanılmaktadır:

$$\mathcal{L} = \mathcal{L}_{\text{focal}} + \lambda \mathcal{L}_{\text{dice}}, \quad \lambda = 0,5 \quad (8)$$

Focal Loss [30], kolay sınıflandırılan örneklerin kayba katkısını  $(1 - p_t)^\gamma$  terimi ile azaltarak modelin zor piksellerden öğrenmesini teşvik eder ( $\alpha = 0,25$ ,  $\gamma = 2,0$ ):

$$\mathcal{L}_{\text{focal}} = -\alpha (1 - p_t)^\gamma \log(p_t) \quad (9)$$



Şekil 2. Önerilen Prototip Ağları Tabanlı Az Örnekli Bölütleme Mimarisinin Genel Yapısı

Dice Loss ise bölge örtüşmesini doğrudan optimize ederek piksel sayısından bağımsız bir denge sağlar:

$$\mathcal{L}_{\text{dice}} = 1 - \frac{2 \sum_{h,w} \hat{y}(h,w) \cdot y(h,w) + \epsilon}{\sum_{h,w} \hat{y}(h,w) + \sum_{h,w} y(h,w) + \epsilon} \quad (10)$$

Focal Loss piksel düzeyinde sınıflandırma doğruluğunu, Dice Loss ise bölge düzeyinde örtüşme oranını optimize etmektedir. İki kaybın birlikte kullanılması, piksel düzeyinde hassasiyet ile bölge düzeyinde tutarlılık arasında denge kurarak daha güvenilir bölütleme maskeleri üretilmesini sağlamaktadır.

## 5. Deneysel Çalışmalar ve Bulgular

Bu bölümde, önerilen az örnekli bölütleme yaklaşımının başarımını LandCover.ai veri kümesi üzerinde gerçekleştirilen kapsamlı deneylerle değerlendirilmektedir. Bölüm kapsamında veri kümesi özellikleri, veri ön işleme adımları, eğitim parametreleri, değerlendirme metrikleri ve elde edilen nicel ve nitel bulgular ile tartışma sunulmaktadır.

### 5.1. Veri Kümesi ve Ön İşleme

Bu çalışmada açık erişimli LandCover.ai [1] veri kümesi kullanılmıştır. Veri kümesi, Polonya'daki kırsal bölgelerden alınmış yüksek çözünürlüklü hava görüntülerini ve bunlara ait piksel düzeyinde etiketli bölütleme maskelerini içermektedir. Toplam 216,27 km<sup>2</sup>'lik alanı kapsa-

yan veri kümesi üç spektral kanal (RGB) barındırmakta olup iki farklı uzamsal çözünürlüğe sahip 41 görüntüden oluşmaktadır (Tablo 3).

Tablo 3: Veri Kümesinin Çözünürlük Gruplarına Göre Dağılımı

Çözünürlük	Görüntü	Uzamsal Çöz.	Piksel Boyutu
Yüksek	33	25 cm/piksel	~9 000 × 9 500
Düşük	8	50 cm/piksel	~4 200 × 4 700
<b>Toplam</b>	<b>41</b>		


Az örnekli öğrenme protokolüne uygun olarak bina, su ve yol sınıfları  $C_{\text{base}}$ , ağaçlık alan sınıfı ise  $C_{\text{novel}}$  olarak belirlenmiştir. Dört temel arazi örtüsü sınıfının alansal dağılımı Tablo 4'de sunulmuştur.

Tablo 4: Veri Kümesindeki Sınıf Dağılımları

Sınıf	Alan (km <sup>2</sup> )	Oran (%)
Ağaçlık alan	72,02	33,3
Su kaynakları	13,15	6,1
Yollar	3,50	1,6
Binalar	1,85	0,9
Arka plan	125,75	58,1
<b>Toplam</b>	<b>216,27</b>	<b>100,0</b>

Sınıfların uzamsal dağılımı ve görünüm çeşitliliği yalnızca piksel oranlarıyla değil, görsel örneklerle de değerlendirilmelidir. Şekil 3'te veri kümesinden seçilen görüntü kesitleri ve bunlara karşılık gelen referans maskeleri sunulmaktadır. Ağaçlık alanların geniş ve belirsiz

sınırlara sahip olduğu, binaların küçük ve ayırık yapılar biçiminde dağıldığı, su kütlelerinin az sayıda ancak büyük alanlar kapladığı ve yolların dar doğrusal yapılar olarak görüntüye yayıldığı gözlemlenmektedir.



Şekil 3. LandCover.ai veri kümesinden örnek görüntüler ve referans maskeleri. Ağaçlık alanların heterojen sınır yapısı ve sınıflar arası ölçek farklılıkları gözlemlenmektedir. [1].

Eğitim süresince ağaçlık alana ait pikseller ikili maskelerde sıfır olarak işaretlenmekte ve model bu sınıfa ilişkin herhangi bir etiket bilgisi almamaktadır.

Her bir görüntü, orijinal çalışmayla [1] uyumlu biçimde  $512 \times 512$  piksellik örtüşmeyen karolarla bölünmüş ve toplamda 10.674 karo elde edilmiştir. Veri bölme işlemleri coğrafi sınıntıyı önlemek amacıyla görüntü seviyesinde gerçekleştirilmiş olup aynı görüntüden elde edilen tüm karolar her zaman aynı alt kümede yer almaktadır. 5 katlı çapraz doğrulama uygulanmış; her katta farklı görüntüler test kümesini oluşturmuştur.

Maskelenmiş ortalama havuzlamanın güvenilir prototip üretebilmesi için destek karolarında yeterli ön plan pikseli bulunması gerekmektedir.  $60 \times 60$  konumluk öznitelik haritasında merkezi limit teoremine göre güvenilir bir ortalama için en az 36 ön plan konumu gerekmekte olup bu değer toplam öznitelik uzayının %1'ine karşılık gelmektedir. Bu teorik alt sınır temel alınarak sınıf bazında asgari ön plan eşikleri belirlenmiştir (Tablo 5). Belirlenen eşiklerin altında kalan karolar ilgili sınıfın epizot kümesinden çıkarılmış ve bu karolarda yalnızca arka plan rolüyle kullanılmaya devam edilmiştir.

Tablo 5: Sınıf Bazında Asgari Ön Plan Eşikleri ve Geçerli Karo Sayıları

Sınıf	Eşik (%)	Karo	Görüntü
Bina	0,5	1 040	24
Ağaçlık alan	5,0	4 530	28
Su	1,0	1 109	27
Yol	1,0	2 457	28

Bina eşiği düşük yaygınlık (%0,9) nedeniyle %0,5, ağaçlık alan yüksek yaygınlık (%33) nedeniyle %5 olarak belirlenmiştir.

Her  $512 \times 512$  karo, öznitelik omurgasının çıkış adımı yapılandırmasıyla uyumlu olması amacıyla  $473 \times 473$  piksele yeniden boyutlandırılmış ve ImageNet-1K V1 [29] eğitim kümesinin kanal bazlı istatistikle-

riyle normalize edilmiştir. Eğitim aşamasında  $p = 0,5$  olasılıkla rastgele yatay ve dikey çevirme,  $90^\circ$  katlarında rastgele döndürme ile parlaklık, karışıklık ve doygunculukta  $\pm\%10$  rastgele renk bozulması uygulanmış; doğrulama ve test süreçlerinde yalnızca yeniden boyutlandırma ve normalizasyon korunmuştur. Çapraz doğrulama bölümünde her iki çözünürlük grubundan orantılı temsil sağlanması amacıyla tabakalı örnekleme uygulanmıştır.

## 5.2. Eğitim Yapılandırması ve Değerlendirme Metrikleri

Eğitim süreci sabit 50 000 epizot üzerinden yürütülmüştür. Ağırlık güncellemesi için AdamW [31] algoritması kullanılmış olup kafa katmanları  $\eta_{\text{head}} = 1 \times 10^{-4}$ , öznitelik omurgası katmanları açıldığında ise  $\eta_{\text{bb}} = 1 \times 10^{-5}$  öğrenme oranıyla güncellenmiştir. Öğrenme oranı, kosinüs tavlama (*cosine annealing*) [32] çizelgesiyle  $\eta_{\text{min}} = 1 \times 10^{-6}$  değerine kadar kademeli olarak düşürülmüştür. Doğrulama işlemi her 1 000 epizotta bir, 2 000 doğrulama epizodu üzerinden gerçekleştirilmiş ve en yüksek mIoU değerini veren ağırlıklar son model olarak kaydedilmiştir. mIoU, yalnızca hedef sınıfı değil arka plan ayrımını da hesaba katarak dengeli bir model seçimi sağlamaktadır. Bellek verimliliğini artırmak amacıyla otomatik karma hassasiyet (AMP) kullanılmıştır. Tüm deneyler Ulusal Yüksek Başarımlı Hesaplama Merkezi (UHeM) bünyesindeki Altay kümesinde, 80 GB HBM2e belleğe sahip NVIDIA A100 PCIe GPU üzerinde, PyTorch 2.1.0 (CUDA 11.8) ortamında ve sabit rastgele başlangıç değeri ( $\text{seed}=42$ ) ile yürütülmüştür.

Hiperparametre değerlerinin belirlenmesinde literatürdeki yaygın uygulamalar ve görev yapısı temel alınmıştır. Focal Loss parametreleri ( $\alpha = 0,25$ ,  $\gamma = 2,0$ ) Lin vd. [30] tarafından önerilen ve sınıf dengesizliği bulunan görevlerde standart kabul edilen değerlerdir. Dice Loss ağırlık katsayısı  $\lambda = 0,5$ , iki kayıp bileşenine dengeli katkı sağlayan yaygın bir başlangıç tercihidir. Sıcaklık parametresinin başlangıç değeri  $\tau_0 = 10,0$  olarak belirlenmiş olup eğitim sürecinde uçtan uca öğrenilerek veri kümesine uygun ayırım keskinliğine ulaşmaktadır. Öğrenme hızları ( $\eta_{\text{head}} = 10^{-4}$ ,  $\eta_{\text{bb}} = 10^{-5}$ ) arasındaki on katlık fark, ön eğitim aşamasında kazanılmış temsillerin ani bozulmasını engellerken hedefe yönelik ince ayarın gerçekleştirilmesine olanak tanımaktadır.

Sınıf dengesizliği barındıran uzaktan algılama veri kümelerinde genel piksel doğruluğu yanıltıcı olabildiğinden, model başarımının değerlendirilmesinde üç temel metrik kullanılmıştır.

Formüllerde *TP doğru pozitif*, *FP yanlış pozitif*, *FN yanlış negatif* ve *TN doğru negatif piksel sayısını ifade etmektedir*.

**Hedef Sınıf IoU (fgIoU):** Yalnızca ilgili hedef sınıfın

Tablo 6: Öznitelik Omurgası Karşılaştırma Sonuçları (ImageNet-1K V1, dondurulmuş, 5 katlı çapraz doğrulama, 50 000 epizot)

Öznitelik Omurgası	Omurga Param.	fgIoU	mIoU	F1
ResNet-18	11,7M	.498 ± .047	.488 ± .039	.649 ± .042
ResNet-34	21,8M	.479 ± .071	.484 ± .049	.630 ± .066
ResNet-50	25,6M	.502 ± .059	.479 ± .047	.652 ± .053
ResNet-101	44,5M	.502 ± .069	.479 ± .042	.652 ± .063
ResNet-152	60,2M	.497 ± .068	.482 ± .042	.646 ± .063
Xception	22,9M	.466 ± .057	.434 ± .028	.617 ± .054
Swin-T	28,3M	<b>.514 ± .050</b>	.471 ± .031	<b>.664 ± .044</b>
ViT-B/16	86,6M	.470 ± .054	.460 ± .035	.618 ± .051

Parametre sayıları yalnızca öznitelik omurgası mimarisine aittir. Tüm öznitelik omurgaları dondurulmuş olup eğitilebilir parametreler boyut indirgeme bloğu ve sıcaklık parametresinden oluşmaktadır (Öznitelik omurgasının çıkış kanal sayısına bağlı olarak ~132K–525K).

(ağaçlık alan) bölütleme başarımlarını ölçer:

$$fgIoU = \frac{TP}{TP + FP + FN} \quad (11)$$

**Ortalama IoU (mIoU):** Hem hedef ön plan (fg) hem de arka plan (bg) için hesaplanan IoU değerlerinin aritmetik ortalamasıdır:

$$mIoU = \frac{1}{2} (fgIoU + bgIoU) \quad (12)$$

**F1:** Kesinlik ve duyarlılığın harmonik ortalaması olup [33], dengesiz sınıf dağılımlarında dayanıklı bir başarımlar göstergesi sağlar:

$$F_1 = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (13)$$

Modelin genelleme kapasitesini istatistiksel olarak güvenilir biçimde raporlayabilmek adına, tüm nicel sonuçlar 5 katlı çapraz doğrulama üzerinden ortalama ± standart sapma biçiminde sunulmuştur.

### 5.3. Öznitelik Omurgası Karşılaştırma Sonuçları

Önerilen yöntemin başarımlarını iki aşamalı olarak değerlendirilmiştir. Birinci aşamada sekiz farklı öznitelik omurgası mimarisi tüm katmanları dondurulmuş biçimde karşılaştırılarak en uygun öznitelik çıkarıcılar belirlenmiştir. Tablo 6’de elde edilen sonuçlar sunulmaktadır.

Hedef IoU ölçütüne göre en yüksek başarımlar Swin-T (0,514) tarafından elde edilmiştir. Kaydırılmış pencere dikkat mekanizması [27], yerel doku bilgisini küresel bağlamla birleştirerek belirsiz sınırlara sahip ağaçlık alanların bölütlenmesinde belirgin üstünlük sağlamıştır. ResNet-50 ve ResNet-101 (0,502) ikinci sırada yer almakta olup Bottleneck mimarisinin 2048 kanallı öznitelik haritaları daha yüksek duyarlılık üretmiştir.

ResNet ailesi içinde derinlik artışının belirgin bir etkisi gözlemlenmemiştir. Parametre sayısını 11,7M’den

60,2M’ye çıkarmak fgIoU’yu 0,479–0,502 aralığında tutmuştur. Bu durum, dondurulmuş öznitelik omurgası koşulunda yalnızca boyut indirgeme bloğunun öğrenilmesiyle derin katmanların sunduğu ek kapasitenin kullanılmamasıyla açıklanabilir.

BasicBlock temsilcisi ResNet-18 (0,498) ile Bottleneck temsilcisi ResNet-50 (0,502) kendi alt gruplarında en yüksek başarımlar göstermiştir. Bu iki öznitelik omurgası, parametre verimliliği ve öznitelik zenginliği açısından farklı tasarım noktalarını temsil ettiğinden, ikinci aşamada katman açma stratejileri bu iki mimari üzerinde test edilmiştir.


En düşük başarımlar Xception (0,466) ve ViT-B/16 (0,470) sergilemiştir. Her iki öznitelik omurgasında da genişletilmiş evrişim uygulanmadığından düşük çözünürlüklü öznitelik haritaları üretilmekte ve uzamsal ayrıntılar kaybolmaktadır. ViT-B/16’nın en yüksek parametre sayısına (86,6M) rağmen düşük başarımlar göstermesi, dondurulmuş genel amaçlı dönüştürücü özniteliklerinin az örneklî bölütleme görevine doğrudan aktarımda yetersiz kaldığını ortaya koymaktadır. Genel olarak, öznitelik haritasının uzamsal çözünürlüğü ve yerel doku özniteliklerini yakalama kapasitesi, parametre sayısından daha belirleyici olmuştur.

Öznitelik omurgası karşılaştırma sonuçları Şekil 4’te gösterilmiştir.

### 5.4. Katman Açma Sonuçları

Birinci aşamada en yüksek başarımlar gösteren BasicBlock temsilcisi ResNet-18 ve Bottleneck temsilcisi ResNet-50 üzerinde üç farklı dondurma stratejisi karşılaştırılmıştır (Tablo 7). Dondurulmuş stratejisinde tüm öznitelik omurgası katmanları dondurulmuş, katman 4 stratejisinde son katman bloğu, katman 3 stratejisinde ise son iki katman bloğu açılarak ince ayar yapılmıştır.

**ResNet-18** BasicBlock mimarisinde katman açma tutarlı biçimde başarımlar düşüşüne yol açmıştır. Katman 4 açıldığında fgIoU 0,498’den 0,484’e, katman 3 ile 0,477’ye gerilemiştir. BasicBlock yapısında katman 4



Şekil 4. Öznitelik Omurgası Karşılaştırması: fgIoU ve mIoU değerleri (Hata çubukları  $\pm$  standart sapmayı göstermektedir.)

Tablo 7: Katman açma sonuçları (ImageNet-1K V1, 5 katlı çapraz doğrulama, 50 000 epizot)

Öznitelik Omurgası	Strateji	Eğitilebilir Param.	fgIoU	mIoU	F1
ResNet-18	dondurulmuş	132K	.498 $\pm$ .047	.488 $\pm$ .039	.649 $\pm$ .042
ResNet-18	katman 4	8,5M	.484 $\pm$ .050	.454 $\pm$ .032	.637 $\pm$ .045
ResNet-18	katman 3	10,6M	.477 $\pm$ .061	.444 $\pm$ .052	.630 $\pm$ .057
ResNet-50	dondurulmuş	525K	.502 $\pm$ .059	.479 $\pm$ .047	.652 $\pm$ .053
ResNet-50	katman 4	15,5M	.489 $\pm$ .066	.436 $\pm$ .054	.640 $\pm$ .060
ResNet-50	katman 3	22,6M	<b>.515 <math>\pm</math> .066</b>	.453 $\pm$ .045	<b>.663 <math>\pm</math> .059</b>

Not: dondurulmuş satırları birinci aşamadan alınmıştır. Açılan katmanlar  $\eta_{bb} = 1 \times 10^{-5}$ , kafa katmanları  $\eta_{head} = 1 \times 10^{-4}$  ile güncellenmiştir.

yalnızca iki evrişim bloğu içerdiğinden, açılan parametre kapasitesi ImageNet özniteliklerini hedef alana uyarlamak için yeterli olmamış ve önceden öğrenilmiş temsillerin bozulmasına yol açmıştır. Eğitilebilir parametre sayısının 132K'dan 8,5M'ye sıçraması, 41 görüntülük küçük bir veri kümesinde aşırı öğrenme riskini artırmıştır.

**ResNet-50** Bottleneck mimarisinde katman 3 stratejisi tüm deneylerdeki en yüksek fgIoU değerine (0,515) ulaşmıştır. Bu sonuç, dondurulmuş duruma göre +0,013 iyileşme sağlamaktadır. Bottleneck yapısının  $1 \times 1$  daraltma evrişimleri sayesinde daha fazla katman açıldığında bile parametre artışı kontrollü kalmakta ve ince ayar ImageNet özniteliklerini hava görüntüsü alanına uyarlayabilmektedir. Öte yandan, katman 4 stratejisi (0,489) dondurulmuş durumun altında kalmıştır; bu durum, yalnızca son bloğun açılmasının yeterli temsil kapasitesi sağlayamadığını göstermektedir.

Her iki öznitelik omurgasında da mIoU değerleri katman açmayla düşmüştür. Bu sonuç, ince ayarın ön plan başarımını artırırken arka plan sınıflandırmasını kısmen


bozduğunu göstermektedir. fgIoU ile mIoU arasındaki bu dönüşüm, katman açma stratejisinin tek bir metriğe göre değil birden fazla ölçütle değerlendirilmesi gerektiğini göstermektedir.

Katman açma stratejilerinin fgIoU ve mIoU üzerindeki etkisi Şekil 5'te gösterilmiştir.

### 5.5. Görsel Sonuçlar

Nitel değerlendirmede tüm modellerin aynı test görüntüleri üzerinde karşılaştırılabilmesi amacıyla, her modelin medyan başarımına en yakın sonucu veren ortak kat seçilmiştir (fold 0). Tahmin haritalarında doğru pozitif (TP) pikseller yeşil, yanlış pozitif (FP) pikseller kırmızı, yanlış negatif (FN) pikseller ise mavi ile gösterilmektedir. Örnekler, dondurulmuş ResNet-50 modelinin fgIoU değerine göre kolay (fgIoU > 0,80), orta (0,40–0,60) ve zor (0,15–0,35) olmak üzere üç zorluk düzeyinde seçilmiştir.

Öznitelik omurgası karşılaştırması için BasicBlock



Şekil 5. Katman Açma Stratejilerinin fgIoU ve mIoU Üzerindeki Etkisi (Düz çizgi: fgIoU, Kesikli çizgi: mIoU)

temsilcisi ResNet-18, Bottleneck temsilcisi ResNet-50 ve en yüksek fgIoU değerini elde eden Swin-T seçilmiştir. Şekil 6'da sunulan sonuçlara göre kolay örnekte ResNet-50 neredeyse hatasız bir bölütleme üretirken (fgIoU = 0,90), ResNet-18 ve Swin-T'nin tahmin haritalarında belirgin FP bölgeleri gözlemlenmektedir (sırasıyla 0,71 ve 0,73). Orta zorlukta üç omurga da benzer hata örüntüsü sergilemekte, ancak Swin-T ön plan sınırlarını görece daha iyi yakalamaktadır (0,47'ye karşı 0,43 ve 0,40). Zor örnekte ise tüm modeller yüksek FN oranı üretmekte, buna karşın Swin-T en az kaçırma hatasıyla en yüksek fgIoU değerine ulaşmaktadır (0,20). Bu gözlemler, Tablo 6'daki fgIoU sıralamasını (Swin-T > ResNet-50 > ResNet-18) destekler niteliktedir. Öte yandan kolay örnekte ResNet-50'nin belirgin üstünlüğü, bu omurganın mIoU metriğindeki üstünlüğüyle tutarlıdır. ResNet-50 arka plan piksellerini daha az FP ile sınıflandırarak genel doğruluğu yükseltmektedir.

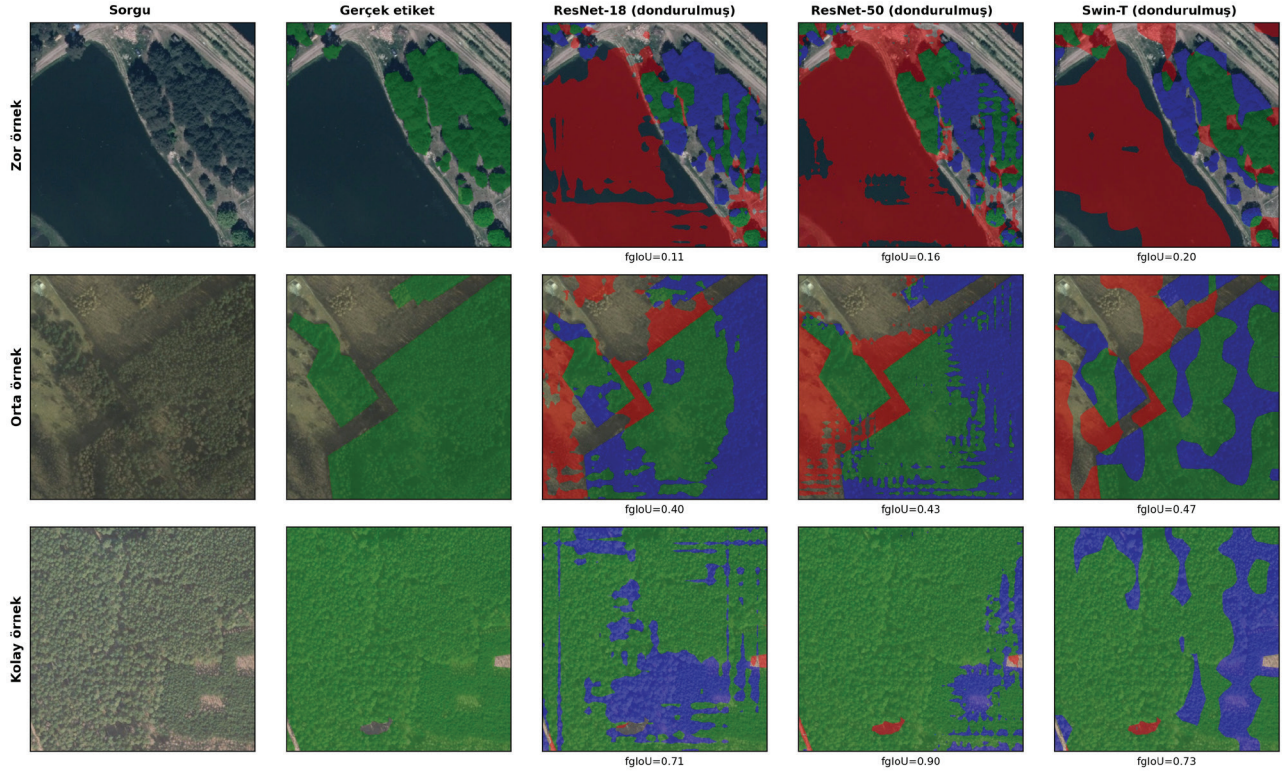
Katman açma etkisi için ise ResNet-50 üzerindeki üç strateji (dondurulmuş, katman 4, katman 3) aynı test örnekleri üzerinde değerlendirilmiştir. Şekil 7'de sunulan sonuçlara göre zor örnekte dondurulmuş model büyük ölçüde FN üretirken fgIoU = 0,16 ile sınırlı kalmakta; katman 4 açıldığında bu değer 0,21'e, katman 3 açıldığında ise 0,24'e yükselmektedir. Tahmin haritalarında soldan sağa mavi alanların azaldığı ve ön plan bölgelerinin giderek daha doğru yakalandığı gözlemlenmektedir. Benzer bir eğilim orta zorlukta da geçerlidir. Dondurulmuş modelin 0,43 olan fgIoU değeri katman 3 açıldığında 0,52'ye yükselmekte, özellikle tarla sınırlarındaki FN hataları belirgin biçimde azalmaktadır. Kolay örnekte ise dondurulmuş model zaten

yüksek bir başarımla göstermekte (fgIoU = 0,90); katman açma ile bu değer 0,96'ya ulaşarak kalan FN hatalarının büyük ölçüde giderildiği görülmektedir. Bu gözlemler, Tablo 7'deki nicel bulguları doğrular niteliktedir. Katman açma stratejisi özellikle zor örneklerde dondurulmuş özneliklerin yetersiz kaldığı durumlarda modelin alana özgü bilgi edinmesini sağlayarak FN oranını düşürmektedir.

## 5.6. Tartışma

Görsel sonuçlar, ön plan için kullanılan tek prototip sınırlılığını ortaya koymaktadır. Yoğun ağaçlık alanlarda (Şekil 6, kolay örnek) prototip hedef sınıfı yeterli düzeyde temsil ederken, tarım arazileri arasına dağılmış küçük ağaç kümelerinde (Şekil 7, zor örnek) fgIoU belirgin biçimde düşmektedir. Tek bir ön plan prototipi, farklı ölçek ve yoğunluktaki ağaçlık görünümlemlerini aynı anda yakalayamamaktadır. Literatürde PFE-Net [16] çok seviyeli öznelik birleştirme, HSNet [22] ise hiper-korelasyon sıkıştırma yoluyla bu soruna çözüm üretmiştir; ancak bu yöntemler doğal sahne veri kümeleri üzerinde tasarlanmış olup uzaktan algılamaya özgü aşırı ölçek farklılıklarına uyarlanmaları henüz incelenmemiştir. Bu uyarılama gelecek çalışmalarda ele alınacaktır.

LandCover.ai üzerinde tam denetimli yöntemler önemli ölçüde yüksek başarımla elde etmektedir. Boguszewski vd. [1] DeepLabv3+ ile ağaçlık alan IoU değerini %91,75, Berka vd. [25] ise çift girdili DeepLabv3+ füzyon modeli ile %90,90 olarak raporlamıştır. Bu çalışmalardaki ağaçlık alan IoU değeri, bu çalışmada kullanılan fgIoU metriğiyle eşdeğerdir; ancak bu mo-



Şekil 6. Öznitelik omurgası karşılaştırması: ResNet-18, ResNet-50 ve Swin-T (dondurulmuş). Renk kodlaması: yeşil = TP (Doğru Pozitif), kırmızı = FP (Yanlış Pozitif), mavi = FN (Yanlış Negatif)

deller sırasıyla 74700 ve 7470 adet piksel düzeyinde etiketlenmiş karo ile eğitilmiştir. Önerilen yöntem ise eğitim aşamasında hedef sınıfı hiç görmemekte ve test aşamasında yalnızca 5 etiketli destek karosuyla  $fgIoU = 0,515$  değerine ulaşmaktadır. Farklı eğitim/test bölmesi ve değerlendirme protokolü nedeniyle doğrudan karşılaştırma sınırlı olmakla birlikte, etiketleme maliyetindeki fark iki yaklaşımın farklı uygulama koşullarını hedeflediğini göstermektedir.

Modellerin hesaplama maliyeti NVIDIA A100 GPU üzerinde, tek epizot için ( $K = 5$ ,  $473 \times 473$  girdi) otomatik karma hassasiyet açıkken 100 ileri yayılım ortalaması alınarak ölçülmüştür. Dondurulmuş öznitelik omurgası deneyinde Swin-T, en yüksek  $fgIoU$  değerine (0,514) ulaşırken 18,99 ms çıkarım (*inference*) süresi ve 490 MB bellek tüketimiyle ViT-B/16'ya kıyasla 3,4 kat daha hızlı çalışmış ve %42 daha az bellek kullanmıştır. ResNet ailesinde derinlik artışı (11,3 M – 58,7 M parametre) çıkarım süresini 5,95 ms'den 39,39 ms'ye yükseltirken  $fgIoU$ 'da belirgin bir iyileşme sağlamamıştır (0,498  $\rightarrow$  0,497). Katman açma stratejileri çıkarım süresini değiştirmemiş (16,93  $\rightarrow$  16,79 ms), ancak eğitim sırasında geri yayılım için ara katman çıktılarının bellekte tutulması nedeniyle GPU bellek kullanımını %39 artırmıştır (520  $\rightarrow$  722 MB).

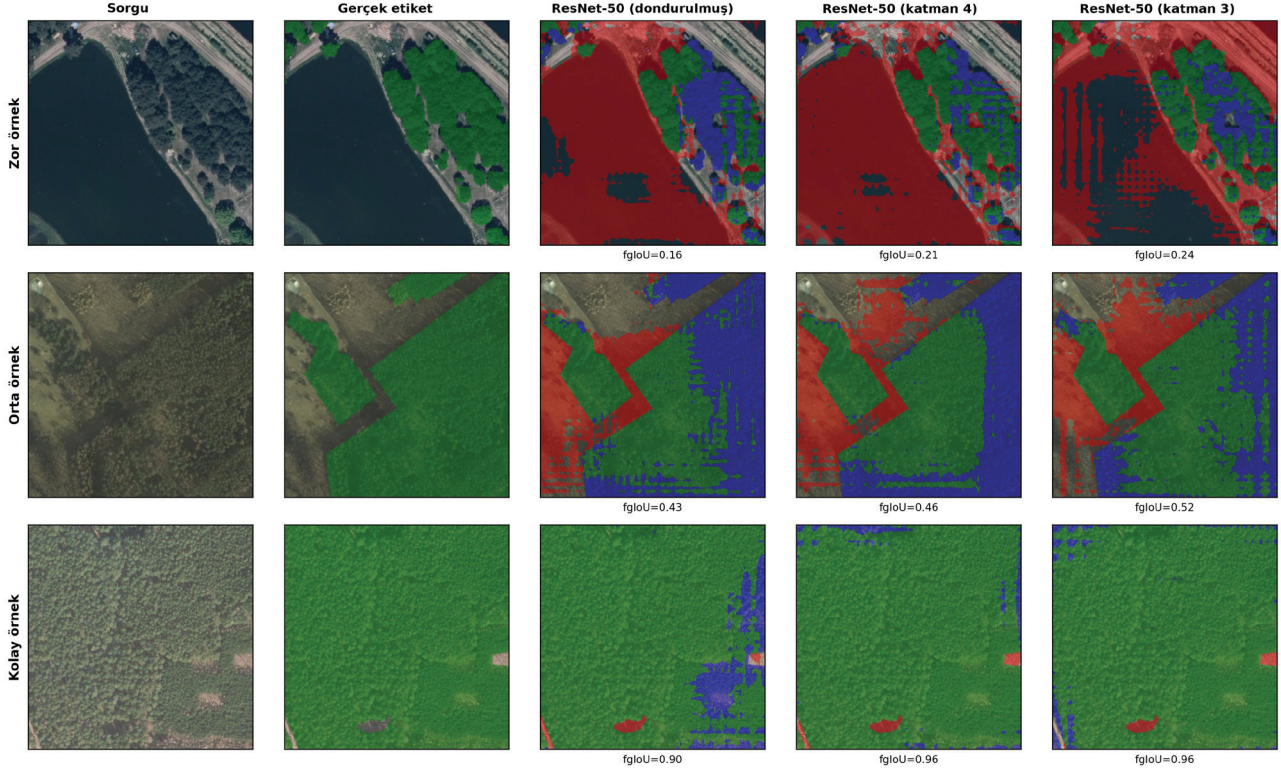
## 6. Sonuç ve Gelecekteki Çalışmalar

Bu bölümde, gerçekleştirilen deneysel çalışmalar sonucunda ulaşılan temel çıkarımlar sentezlenerek çalışmanın sunduğu katkılar özetlenmektedir. Bunun yanında, önerilen az örnekli bölütleme yaklaşımının kapsamını ve başarımını artırmaya yönelik gelecekteki araştırma yönleri sunulmaktadır.

### 6.1. Sonuç

Bu çalışmada, yüksek çözünürlüklü hava görüntülerinden ağaçlık alanların bölütlenmesi için prototip ağı tabanlı bir az örnekli öğrenme yaklaşımı sunulmuş ve LandCover.ai veri kümesi üzerinde sistematik olarak değerlendirilmiştir.

Elde edilen bulgular, az örnekli bölütlemeye öznitelik omurgası seçimi ve dondurma stratejisinin birbirine bağımlı kararlar olduğunu ortaya koymaktadır. Dondurulmuş öznitelik omurgası, ImageNet üzerinde milyonlarca doğal görüntüyle kazanılmış genel temsilleri koruyarak aşırı öğrenme riskini azaltır; ancak bu temsiller hava görüntülerinin kendine özgü doku, renk ve ölçek yapısına uyarlanamaz. Derin ağlarda ilk katmanlar kenar, köşe ve basit doku gibi genel öznitelikler kodlarken, üst katmanlar eğitim verisine özgü soyut temsiller üretmektedir. Katman açma bu üst katmanların



Şekil 7. Katman açma etkisi: ResNet-50 (dondurulmuş), ResNet-50 (katman 4) ve ResNet-50 (katman 3).  
Renk kodlaması: yeşil = TP (Doğru Pozitif), kırmızı = FP (Yanlış Pozitif), mavi = FN (Yanlış Negatif)

hedef alana uyarlanmasını sağlar; ancak sınırlı veriyle güncellenen parametre sayısı arttıkça aşırı öğrenme riski de yükselir. Bu ödünleşim deneylerde doğrulanmıştır: küçük kapasiteli ResNet-18’de katman açma temsilleri bozarken, ResNet-50’de katman 3’ün açılması başarıyı artırmıştır. Dönüştürücü tabanlı Swin-T ise dondurulmuş koşulda en yüksek başarıyı elde etmiştir. Ayrıca ön plan başarıyı ile genel bölütleme kalitesi arasında gözlemlenen ödünleşim, ince ayar stratejilerinin çoklu ölçütlerle değerlendirilmesi gerektiğini göstermektedir.

Bölüm 5.6’te tartışıldığı üzere, ulaşılan en yüksek fgIoU değeri tam denetimli yöntemlerin başarımının altında kalmakla birlikte, önerilen yöntem eğitim aşamasında hedef sınıfı hiç görmemekte ve yalnızca beş etiketli destek örneğiyle çalışmaktadır. Bu koşullar altında elde edilen başarı, yoğun etiketlemenin mümkün olmadığı uygulamalar için pratik değer taşımaktadır.

Sonuç olarak bu çalışma, az örnekli öğrenmenin yüksek çözünürlüklü hava görüntülerinde ağaçlık alan bölütlemesi için uygulanabilir bir alternatif olduğunu göstermiştir. Sekiz farklı öznelik omurgasının sistematik karşılaştırması ve kontrollü ince ayar deneyleri, mimari seçimi ile dondurma stratejisinin birlikte optimize edilmesi gerektiğini ortaya koymuştur. Elde edilen bulgular, etiketli verinin kısıtlı olduğu uygulamalarda prototip

tabanlı az örnekli yaklaşımların değerlendirilmeye değer bir çözüm yolu sunduğunu göstermektedir.

## 6.2. Gelecekteki Çalışmalar

Mevcut çalışma birkaç yönde genişletilebilir. Birincisi, öznelik omurgası özneliklerinin hedef alana uyumunu artırmak amacıyla farklı ön-egitimli ağırlık kaynaklarının (Million-AID, BigEarthNet, SeCo gibi uzaktan algılamaya özgü kontrol noktaları) karşılaştırılması planlanmaktadır. İkincisi, Swin-T’nin birinci aşamada gösterdiği yüksek başarı göz önüne alındığında, dönüştürücü öznelik omurgalarında aşama açma (stage unfreezing) stratejilerinin az örnekli bölütlemeye etkisinin araştırılması hedeflenmektedir. Üçüncüsü, modelin tek ölçekli prototip yapısı, ağaçlık alanların farklı ölçeklerdeki görünümünü yakalamada sınırlı kalmaktadır; çoklu ölçek öznelik birleştirme ve çoklu prototip stratejileri bu sınırlılığı giderebilir. Son olarak, model çıktılarının sınır kalitesini artırmak amacıyla koşullu rastgele alan tabanlı maske iyileştirme yöntemlerinin uyarlanması hedeflenmektedir.

## Kaynaklar

- [1] Boguszewski, A., Batorski, D., Ziemia-Jankowska, N., Dziedzic, T., & Zambrzycka, A. (2021). Land-

- Cover.ai: Dataset for automatic mapping of buildings, woodlands, water and roads from aerial imagery. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 1102–1110).
- [2] Petrov, M., Pandilova, E., Dimitrovski, I., Trajanov, D., Spasev, V., & Kitanovski, I. (2026). Few-shot semantic segmentation in remote sensing: A review on definitions, methods, datasets, advances and future trends. *Remote Sensing*, 18(4), 637.
- [3] Sun, X., Wang, B., Wang, Z., Li, H., Li, H., & Fu, K. (2021). Research progress on few-shot learning for remote sensing image interpretation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 2387–2402.
- [4] Darici, M. B., Gumuslu, E., & Serifoglu, M. O. (2025, June). Woodland Segmentation: A Comprehensive Analysis on China Region. In 2025 33rd Signal Processing and Communications Applications Conference (SIU) (pp. 1–4). IEEE.
- [5] Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2017). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4), 834–848.
- [6] Chen, J., Wang, X., Hong, L., & Liu, M. (2024). Cross-domain few-shot segmentation for remote sensing image based on task augmentation and feature disentanglement. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 9360–9375.
- [7] Dong, N., & Xing, E. P. (2018, September). Few-shot semantic segmentation with prototype learning. In *BMVC* (Vol. 3, No. 4, p. 4).
- [8] Snell, J., Swersky, K., & Zemel, R. (2017). Prototypical networks for few-shot learning. *Advances in Neural Information Processing Systems*, 30.
- [9] Tang, H., Jia, Y., Cheng, J., Mu, Y., Wu, Y., & Yao, X. (2026). GlocalDualNet: Disentangling Scale and Representation for Few-Shot Remote Sensing Segmentation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
- [10] Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 3431–3440).
- [11] Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-Net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 234–241). Springer.
- [12] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 770–778).
- [13] Zhao, H., Shi, J., Qi, X., Wang, X., & Jia, J. (2017). Pyramid scene parsing network. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 2881–2890).
- [14] Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 2117–2125).
- [15] Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In Proceedings of the European Conference on Computer Vision (ECCV) (pp. 801–818).
- [16] Tian, Z., Zhao, H., Shu, M., Yang, Z., Li, R., & Jia, J. (2020). Prior guided feature enrichment network for few-shot segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(2), 1050–1065.
- [17] Vinyals, O., Blundell, C., Lillicrap, T., & Wierstra, D. (2016). Matching networks for one shot learning. *Advances in Neural Information Processing Systems*, 29.
- [18] Finn, C., Abbeel, P., & Levine, S. (2017, July). Model-agnostic meta-learning for fast adaptation of deep networks. In *International Conference on Machine Learning* (pp. 1126–1135). PMLR.
- [19] Shaban, A., Bansal, S., Liu, Z., Essa, I., & Boots, B. (2017). One-shot learning for semantic segmentation. *arXiv preprint arXiv:1709.03410*.
- [20] Wang, K., Liew, J. H., Zou, Y., Zhou, D., & Feng, J. (2019). PANet: Few-shot image semantic segmentation with prototype alignment. In Proceedings of the IEEE/CVF International Conference on Computer Vision (pp. 9197–9206).
- [21] Zhang, C., Lin, G., Liu, F., Yao, R., & Shen, C. (2019). CANet: Class-agnostic segmentation networks with iterative refinement and attentive few-shot learning. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 5217–5226).
- [22] Min, J., Kang, D., & Cho, M. (2021). Hypercorrelation squeeze for few-shot segmentation. In Proceedings of the IEEE/CVF International Conference on Computer Vision (pp. 6941–6952).
- [23] Fan, Q., Pei, W., Tai, Y. W., & Tang, C. K. (2022, October). Self-support few-shot semantic segmentation. In *European Conference on Computer Vision* (pp. 701–719). Springer.
- [24] Broni-Bediako, C., Xia, J., Song, J., Chen, H., Siam, M., & Yokoya, N. (2024). Generalized few-shot se-

- mantic segmentation in remote sensing: Challenge and benchmark. *IEEE Geoscience and Remote Sensing Letters*, 21, 1-5.
- [25] Berka, A., Hajji, M. E., Canals, R., Es-saady, Y., & Hafiane, A. (2025). Enhancing DeepLabV3+ to fuse aerial and satellite images for semantic segmentation. *arXiv preprint arXiv:2503.22909*.
- [26] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1251–1258).
- [27] Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., ... & Guo, B. (2021). Swin Transformer: Hierarchical vision transformer using shifted windows. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 10012–10022).
- [28] Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Houlsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.
- [29] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009, June). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition* (pp. 248-255). Ieee.
- [30] Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017). Focal loss for dense object detection. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 2980–2988).
- [31] Loshchilov, I., & Hutter, F. (2017). Decoupled weight decay regularization. *arXiv preprint arXiv:1711.05101*.
- [32] Loshchilov, I., & Hutter, F. (2016). SGDR: Stochastic gradient descent with warm restarts. *arXiv preprint arXiv:1608.03983*.
- [33] Powers, D. M. (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *arXiv preprint arXiv:2010.16061*.

## Özgeçmişler



**Zehra Merve Gül**, yüksek lisans derecesini İstanbul Üniversitesi Enformatik bölümünden, lisans derecesini Sakarya Üniversitesi Bilgisayar Mühendisliği bölümünden almıştır. Yüksek lisans tez çalışmasında yüksek çözünürlüklü hava görüntülerinde az örnekli öğrenme yöntemiyle ağaçlık alan bölütlemesi üzerine araştırma yapmıştır. Yazılım sektöründe üç yılı aşkın profesyonel yazılım geliştirme deneyimine sahiptir. Araştırma alanları arasında derin öğrenme, bilgisayarlı görü, uzaktan algılama görüntü analizi ve az örnekli öğrenme yer almaktadır.



**Murat Gezer**, 2007 yılında enformatik alanında yüksek lisansını, 2014 yılında ise sinyal işleme ve görüntü işleme konularında uzmanlaşarak elektrik-elektronik mühendisliği doktora derecesini almıştır. Hâlen İstanbul Üniversitesi Fen Fakültesi Bilgisayar Bilimleri Bölümünde Doçent Doktor olarak görev yapmaktadır. 2003-2024 yılları arasında İstanbul Üniversitesi Enformatik Bölümünde Öğretim Görevlisi olarak çalışmış, akademik kariyerine Bilgisayar Bilimleri Bölümünde Doçent olarak devam etmiştir. Bunun yanı sıra Türk-Alman Üniversitesi ve Kadir Has Üniversitesi gibi farklı kurumlarda misafir öğretim üyesi olarak dersler vermiştir. Ulusal ve uluslararası düzeyde yürütülen çeşitli araştırma projelerinde aktif görev almış; sektörel iş birlikleri kapsamında geliştirilen projelerde yürütücü ve araştırmacı olarak katkı sunmuştur. Akademik çalışmalarının yanı sıra bilişim sektöründeki projelere danışmanlık desteği sağlamaktadır. Çeşitli bilimsel dergilerde ve konferanslarda yayımlanmış çok sayıda yayını bulunan Gezer'in çalışmaları, uluslararası literatürde atıf almaya devam etmektedir. Araştırma alanları; bilgisayarlı görü, makine öğrenmesi, derin öğrenme, sinyal işleme, yapay zekâ uygulamaları ve veri bilimi konularını kapsamaktadır.