




## Türkiye Uzaktan Algılama Dergisi

<https://dergipark.org.tr/tr/pub/tuzal>

e-ISSN 2687-4997



# Çok Yüksek Çözünürlüklü Uydu Görüntülerinden Bina Çıkarımında Derin Öğrenme ve Çoklu-Çözünürlüklü Bölütleme Kullanılarak Nesne-Tabanlı Entegrasyon

Şaziye Özge Atik\*<sup>1</sup>

<sup>1</sup>Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kocaeli, Türkiye

### Anahtar Kelimeler:

Derin Öğrenme  
Nesne-tabanlı Görüntü Analizi  
Çoklu-çözünürlüklü Bölütleme  
Entegrasyon

### ÖZ

Son yıllarda, kentsel alanlarda yapılan analizler ve değişimlerin tespitinin hızlı ve güvenilir şekilde gerçekleştirilmesi konusundaki çalışmalarda artış olmuştur. Bu doğrultuda, binaların sınıflandırılması bilgisayarlı görünümün ön plana çıkan güncel konularından biridir. Birçok alanda olduğu gibi bu konuda da derin öğrenme mimarilerinin kullanımı trend uygulamalar arasındadır. Bina ayak izinin belirlenmesi amacıyla evrimsel sinir ağları (ESA) kullanılarak semantik segmentasyon uygulamaları yaygınlaşmıştır. Ancak derin öğrenme ile segmentasyon işlemleri sonrası elde edilen tahmin görüntülerinde karşılaşılan problemlerin başında tuz-biber etkisiyle oluşmuş gürültüler gelmektedir. Bu çalışmada güncel ESA mimarilerinden olan U-Net ve SegNet algoritmalarının kullanımının, Nesne-Tabanlı Görüntü Analizinin (NTGA), Çoklu-Çözünürlüklü Bölütleme (ÇÇB) algoritmasıyla entegrasyonu kullanılmıştır. Deneyler çok yüksek çözünürlüklü uydu görüntülerinden (Gaofen-2, Worldview-2 ve Ikonos) oluşan açık paylaşımlı Wuhan Üniversitesi Bina Çıkarımı Veri seti (WHUBED) üzerinde gerçekleştirilmiştir. ESA+ÇÇB modeli genel doğruluk, F1 skor, Dice skoru ve Intersection over Union (IoU) metriklerinde, sadece ESA kullanımıyla elde edilen tahmin sonuçlarına göre iyileştirmeler sağlamıştır. Bina sınıflandırılması ile elde edilen haritalar karşılaştırılmalı görseller olarak son kısımda sunulmuştur.

## Object-Based Integration Using Deep Learning and Multi-Resolution Segmentation in Building Extraction from Very High Resolution Satellite Imagery

### Keywords:

Deep Learning  
Object-based Image Analysis  
Multi-resolution Segmentation  
Integration

### ABSTRACT

In recent years, there has been an increase in studies on the analysis of urban areas and the detection of changes in a fast and reliable way. In this respect, the classification of buildings is one of the prominent current issues of computer vision. As in many areas, the use of deep learning architectures is among the trending applications. Semantic segmentation applications have become widespread by using convolutional neural networks (CNN) to determine the building footprint. However, at the beginning of the problems encountered in the prediction images obtained after segmentation processes with deep learning, the noise formed by the effect of salt and pepper comes. In this study, the integration of the use of U-Net and SegNet algorithms, which are among the state-of-the-art CNN architectures, with the Object-Based Image Analysis (OBIA) and Multi-Resolution Segmentation (MRS) algorithm is used. Experiments were performed on the open shared Wuhan University Building Inference Dataset (WHUBED) consisting of very high-resolution satellite images (Gaofen-2, Worldview-2 and Ikonos). The model in the study, provides improvements in overall accuracy, F1 score, Dice score and Intersection over Union (IoU) metrics over the prediction results obtained using CNN alone. Building footprint maps obtained by building extraction are presented in the last section as comparative images.

### Makale Bilgileri/Article Info

Geliş /Received: 04/08/2023  
Kabul/Accepted: 25/09/2023  
Yayınlanma/Published: 30/12/2023

### Alıntı/Citation:

Atik, Ş.Ö. (2023). Çok Yüksek Çözünürlüklü Uydu Görüntülerinden Bina Çıkarımında Derin Öğrenme ve Çoklu-Çözünürlüklü Bölütleme Kullanılarak Nesne-Tabanlı Entegrasyon. Türkiye Uzaktan Algılama Dergisi, 5 (2), 67-77.

## 1. GİRİŞ

Uzaktan algılama verilerinin ulaşılabilirliği ve yaygın kullanım alanları gelişen teknolojiyle beraber her geçen gün artmaktadır. Yeryüzünde olan doğal kaynaklı ve insan yapımı birçok alan sürekli olarak değişip, dönüşmekte ve bu değişimler uydu görüntüleriyle periyodik olarak izlenmektedir. Yer gözlem uyduları yardımıyla, yer yüzeyindeki arazi kullanım ve arazi örtüsü (AKAÖ) sınıfları derin öğrenme yaklaşımlarıyla otomatik olarak sınıflandırılmaktadır (Xu vd., 2021; Ali ve Johnsonn, 2022; Balarabe ve Jordonav, 2022). Dünyanın %0,1'inden azı kentleşmiş alanlardan oluşmasına rağmen, dünya nüfusunun %50'den fazlası bu alanlarda yaşamaktadır (Lee ve Baik, 2011). Arazi örtüsü ve kullanımı sınıflarının en büyük değişimi yerleşim sınıfında olduğundan, binaların hızlı ve etkili şekilde otomatik olarak sınıflandırılması oldukça önemli bir konudur. Bu nedenle, semantik segmentasyon olarak bilinen uygulamalar bina çıkarımında son yılların öne çıkan araştırma konularından biri olmuştur. Ancak derin öğrenme yaklaşımlarıyla piksel tabanlı semantik segmentasyon uygulamalarının tuz-biber etkisi gibi bazı gürültüleri mevcuttur. Nesne-tabanlı görüntü analizinin sağladığı imkanlar farklı şekillerde kullanılarak evrimsel sinir ağlarıyla (ESA) sınıflandırılmış görüntüleri iyileştirmede bir teknik olarak kullanılmaktadır (Ghorbanzadeh vd., 2021; Dewali vd., 2023; Tang vd. 2020; Li vd., 2022; Merchant, 2021).

Son on yılda, derin öğrenme yaklaşımı, uydu görüntülerini kullanarak segmentasyon oluşturmak için sağlam bir yöntem olarak etkili olmuştur. Pan vd. (2020) karmaşık bir kentsel köydeki bireysel binaları karakterize etmek için bir yaklaşım önermiştir. Çalışmada, 0,5 m mekansal çözünürlüğe ve bina sınır vektör dosyalarına sahip sekiz bantlı Worldview uydu görüntüleri kullanılmıştır. Arıkan ve Yıldız (2023) Göktürk-1 uydu görüntüleri ile bina çıkarımında U-net modelini kullanarak semantik segmentasyon yapmışlardır. Kaiser vd. (2017), binaları ve yolları çıkarmak için VGG-16 mimarisine dayalı bir derin öğrenme ağı önermiştir. Bu çalışmada, otomatik harita üretimi için, yüksek çözünürlüklü hava görüntülerinin kontrollü sınıflandırma yoluyla semantik segmentasyonu amaçlanmaktadır. Yi vd. (2019), çok yüksek çözünürlüklü (VHR) görüntülerin semantik segmentasyonu için U-Net ve ResNet mimarilerine dayalı DeepResUnet yöntemini önermişlerdir. DeepResUnet, özellikle düzensiz şekilli ve küçük boyutlu binaları yüksek doğruluk ve bütünlükle tespit edebilmektedir. Ji vd. (2019) binaları hava ve uydu görüntülerinden çıkarmak için ölçekli güçlü bir derin öğrenme mimarisi önermişlerdir. Qin vd. (2019) kentsel alanlardaki binaların özellikle çatılarını doğru bir şekilde haritalamak için uçtan uca evrimsel bir ağ tasarlamışlardır. Abdollahi vd. (2022) yüksek çözünürlüklü hava görüntülerine

semantik segmentasyon uygulamak için iki popüler ESA mimarisini, SegNet ve U-Net'i birleştirerek yeni bir model oluşturmuşlardır. Liu vd. (2021), bina ayak izi oluşturmak için iki temel modül içeren bir metodoloji önermişlerdir. Liu vd. (2021), doğal afetlerdeki değişim analizinde VHR havadan uzaktan algılama görüntüleri semantik segmentasyonu için Nesne-Tabanlı Görüntü Analizi (NTGA) ve derin öğrenmeyi birleştirmeyi önermişlerdir. Marcu ve Leordeanu (2016) tarafından yayınlanan çalışmada, bina ve yol çıkarımı için çift akışlı derin sinir ağı modeli geliştirilmiştir. Atik ve İpbüker gerçekleştirdiği çalışmada ESA mimarilerine girdi veri olarak 3 bant: Kırmızı (R), Yeşil (G), Mavi (B) yerine; yakın kızılötesi (NIR), ve/veya spektral indislerin de eklendiği veri setlerini kullanarak arazi kullanım ve arazi örtüsü sınıflandırması gerçekleştirmişlerdir. Söz konusu çalışmada önerilen ESA+ÇÇB (2021) yaklaşımı bu çalışmada farklı özellikte verilere uygulanmış (RGB) ve hedefi bina çıkarımı olarak özelleştirilmiştir.

Bu çalışma, bina çıkarımı sürecinin doğruluğunu ve otomasyonunu iyileştirmek için çoklu çözünürlüklü bölütleme (ÇÇB) uygulamasını birleştiren ESA tabanlı modeller ile birleştiren bina segmentasyonu amaçlanmaktadır. ESA+ÇÇB modeli bu çalışmada ESA tabanlı bina sınıflandırması ve ÇÇB ile sınıflandırma performansının iyileştirilmesi olmak üzere iki adımdan oluşmaktadır. Bu çalışmada,

- Üç farklı uydunun görüntülerinden oluşan açık paylaşımlı Wuhan University Building Extraction Dataset (WHUBED) veri seti kullanılarak U-net ve SegNet derin öğrenme mimarileriyle bina sınıfı için semantik segmentasyon yapılması hedeflenmiştir. Yaygın kullanımı olan ESA mimarilerinin kullanımıyla elde edilen bina sınıfı tahminlerinin içerdiği gürültüler, ÇÇB algoritmasının entegrasyonu ile önemli ölçüde azaltılmıştır.


- ESA ve ÇÇB yöntemlerinin entegrasyonu, sadece ESA mimarilerinin kullanımıyla elde edilen sınıflandırmayla karşılaştırıldığında genel doğruluk, F1 skor, Dice skoru ve Intersection Over Union (IoU) metriklerinde iyileştirmeler sağlamıştır.

- WHUBED veri setinin kullanıldığı literatürdeki diğer çalışmalarla karşılaştırma yapıldığında, bu çalışmada ortaya konan yaklaşım ile daha yüksek F1-skorları elde edilmiştir.

## 2. VERİ VE YÖNTEM

Çalışmada izlenen akış diyagramı Şekil 1'de gösterilmiştir. Kullanılan veri ilk aşamada eğitim, validasyon ve test olarak ayrılmıştır. İşlem aşamasında, veri seti üzerinde U-Net ve SegNet ESA ağları kullanılarak derin öğrenme ile bina sınıfı tahmin görüntüleri oluşturulmuştur. Aynı zamanda test görüntülerine ÇÇB algoritması uygulanmış ve görüntülerde algoritmaya göre oluşturulan

nesnelerin bölütleri elde edilmiştir. Sınıflandırma kısmında, bölütler ve tahmin görüntüleri bir arada kullanılarak entegre bir işlem gerçekleştirilmiştir. Burada çoğunluk oylaması ile bölütler rafine edilerek bina sınıflarını içeren sonuç görüntüleri oluşturulmuştur. Analiz kısmında bu alanda yaygın kullanılan metrikler ile doğruluk analizi gerçekleştirilmiş ve analize dair sayısal değerler tablolarda gösterilmiştir.



Şekil 1. Çalışmanın iş akışı.

## 2.1. Veri


Çalışmada, uydu görüntülerinden binaların çıkarılması için Wuhan Üniversitesi Bina Çıkarımı Veri seti (Wuhan University Building Extraction Dataset -WHUBED) kullanılmıştır (Bi vd., 2019). Veri seti, 31 tanesi pan-keskinleştirilmiş olmak üzere, toplam 57 görüntü içermektedir. Veri setindeki uydu görüntüleri, 0,6, 0,8 ve 0,5 m mekânsal çözünürlüğe sahip QuickBird, Gaofen-2 ve WorldView2 uydularına ait görüntülerden oluşmaktadır. Veri setinde referans veri olarak, bina ve bina olmayan

sınıflar etiketli halde açık kaynak olarak paylaşılmıştır (Şekil 2). Veri setinin görüntüleri NIR, RGB bantlarından oluşmaktadır. NIR bant kullanımının, bina sınıfını, bina olmayan bölgeden ayırmaya yardımcı olduğu bilinmektedir. Bu bağlamda oluşturulan veri seti örneklerinin kullanıldığı çalışmalar mevcuttur (Thenkabail vd., 2005, Attri vd., 2015, Atik vd., 2022). Bu çalışmada ESA mimarilerinde veri olarak NIR-R-G bant kombinasyonu kullanılmıştır.



Şekil 2. Veri setine ait örnek görüntü ve referans görüntüsü.

Eğitim aşamasında 54 görüntü (%93) kullanılmış olup, doğrulama için 2 görüntü (3.5) ve test aşamasında 2 görüntü (%3.5) kullanılmıştır. WHUBED veri setine ait görüntüler ESA mimarilerinde kullanılmak üzere alt görüntü oluşturma (görüntü kırpma işlemi) ile 32 x 32 görüntü boyutlarına getirilmiştir. Veri setine ait görüntülere rastgele alt görüntü (görüntü parçacığı) oluşturma uygulanarak veri artırımı yapılmıştır. Veri artırımının şematik çizimi Şekil 3'te temsil edilmiştir.



Şekil 3. Veri artırımı ile alt görüntü üretimi gösterimi.


## 2.2. ESA Mimarileri

Kontrollü sınıflandırma uygulamalarında son dönemlerde popüler olarak tercih edilen ESA mimarileri, evrişim aşamasında Kernel filtreleri yardımıyla girdi verisini kullanarak özellik haritaları üretir. Orijinal görüntüler yerine bu özellik haritalarını ESA ağlarında işlemek daha kolay ve hızlıdır. Bu aşamada üretilen linear çıktıların yerine

gerçek hayattaki örneklerde lineer olmayan örneklere daha çok rastlanır. Bu nedenle bir aktivasyon fonksiyonu yardımıyla tensörlerin ürettiği lineer değerler lineer olmayan değerlere dönüştürülür. Sigmoid ve tanh aktivasyon katmanları basit ama etkili olduklarından ötürü Rectified Linear Unit (ReLU) olarak en çok tercih edilen türleri arasındadır. Havuzlama katmanında özellikleri koruyarak, olası mekansal, dokusal veya diğer türdeki bozulmaların önüne geçmek için piksellerin maksimum değerleri işleme alınmaktadır. Havuzlamanın bir başka faydası da parametre sayısını azaltarak aşırı uyumun önlenmesidir. Hassas-ayarlı ise, kullanılan algoritma için mümkün olan en iyi hiperparametrelerin bulunmaya çalışıldığı aşamadır. ESA mimarisinin son katmanı olan Softmax aşamasında piksellerin segmentasyon sonucunda tahmin sınıflarının ataması yapılır. Pikseller için en yüksek olasılığa sahip sınıf hangisiyse, atama o sınıfa gerçekleştirilir. ESA mimarisinde Softmax Fonksiyonundan sonra, Çapraz Entropi Fonksiyonu kullanılarak modelin güvenilirliği test edilir ve Kayıp Fonksiyon izlenerek modelin yüksek performans göstermesi hedeflenir.

### 2.3. U-Net Mimarisi

U-Net derin öğrenme mimarisi (Ronneberger vd, 2015) 23 evrişim katmanına sahiptir. U-Net mimarisi çok kanallı özellik haritalarına sahiptir. Mimaride her özellik haritasının ardından bir ReLU katmanı,  $2 \times 2$  çekirdek boyutunda maks-havuzlama katmanı ve iki adet  $3 \times 3$  evrişim katmanı vardır. U-Net mimarisinin diğer ESA mimarileri arasındaki önemi, örnekleme aşamasında birçok özellik kanalı bulundurması ve bu sayede ağıın bilgilerini daha yüksek çözünürlüklü katmanlara yaymasını sağlamasıdır. Mimaride, ağıın sahip olduğu geniş yol, darboğaza simetiktir ve bu sayede mimarinin yapısı U şeklini alır. U-Net mimarisi, ilk olarak biyomedikal görüntülerin segmentasyon uygulamalarında iyi performans sağlamasıyla ortaya çıkmıştır. Çalışmada kullanılan U-Net mimarisi çizimi Şekil 4'te gösterilmektedir. Az veri boyutunda gerçekleştirilen eğitimlerde dahi iyi performans göstermesi özelliğiyle sık tercih edilen bir ESA mimarisidir.



Şekil 4. U-Net mimarisinin şeması (Ronneberger vd., 2015).


U-Net mimarisi, segmentasyon haritasındaki hücrelerin her birinin kolayca tanımlanması için görüntünün her pikseli için bir kayıp fonksiyonu kullanır. Aynı zamanda her piksele softmax katmanı ve ardından bir kayıp fonksiyonu uygulanır. Bu sayede, her pikselin sınıflardan birine atanmasını gerektiren bir sınıflandırma işlemi uygulanır. Ancak bu işlemler piksel bazında olduğundan, sonuç ürünlerde her piksel bir sınıfa atanmış olacaktır. Bu çalışmanın kullanılan yaklaşımı sayesinde piksel arasındaki komşuluk ve ilgililik piksel gruplarının bir arada kullanılarak sınıflandırılmasını içerir. Bu sayede ESA mimarilerinin ürettiği sonuç çıktılarındaki gürültüler iyileştirilmiş olur.

Yüksek doğrulukta sonuç veren basit U-Net mimarisinin medikal çalışmalarda (Koç ve Akgün, 2021) kullanımının yanı sıra, esnek ve eklenebilir yapısı sayesinde bir çok farklı uygulamada da tercih edildiği bilinmektedir. U-Net mimarisinde sınırlı sayıda örnekleme ile de iyi sonuçlar üretmesinin yanı sıra veri artırımı ile rastgele şekilde örnekleme alt-görüntülerinin çoğaltılarak oluşturulması yardımıyla aşırı uyumu azaltabileceğinden doğruluğu artırdığı görülmüştür (Kurnaz ve Ceylan, 2020). Bu çalışmada da rastgele alt görüntü oluşturma yöntemi ile veri artırımı gerçekleştirilmiş ve bu işlemler her iki ESA mimarisinde de uygulanmıştır.

### 2.4. SegNet Mimarisi

SegNet (Badrinarayanan vd., 2017), girdi görüntüsüyle aynı boyutta tahmin çıktısı veren tamamen evrişimli bir sinir ağı mimarisidir. Piksel bazında sınıflandırma için kullanılan bu ağda, evrişim katmanlarını, kodlayıcı-kod çözücü (encoder-decoder) katmanlarını, evrişim ve yığın toplu normalleştirme, havuzlama katmanı ve ReLU aktivasyon aşamalarını içerir. Mimaride altörnekleme ve üstörnekleme aşamaları simetrik yapıdadır (Şekil 5). ESA ağının son kısmında, softmax katmanında semantik segmentasyon sonucu üretilir.

Ağda kodlayıcılar ve kod çözücü ağı, özellik haritalarını oluşturmak ve toplu olarak normalleştirmek için bir filtre bankası oluşturur. Bu aşamadan sonra, ReLU katmanı bir aktivasyon işlemini gerçekleştirir. Mimaride daha sonra  $2 \times 2$  çekirdek boyutunda maks-havuzlama katmanı yer alır. Son kod çözücü kısmında, görüntüdeki her piksel için çok sınıflı bir sınıflandırıcı olan softmax katmanı ile semantik segmentasyon işlemi tamamlanır.



Şekil 5. SegNet mimarisi. Görüntü Badrinarayanan vd. nin çalışmasından uyarlanmıştır (2017).

## 2.5. Nesne-Tabanlı Görüntü Analizi

NTGA piksel tabanlı görüntü analizine alternatif olarak ortaya çıkmıştır. Görüntü işlemenin bu çeşidinde, pikseller yerine nesnelere (bölütler) üzerinde işlem yapılır. NTGA çoğunlukla yüksek ve çok yüksek çözünürlüklü görüntülerin sınıflandırılmasında tercih edilmektedir. Çünkü, kullanılan görüntülerdeki mekânsal çözünürlük arttıkça sınıflandırmada karşılaşılan tuz-biber etkisi kaynaklı gürültüler de önemli bir sorun haline gelmektedir. Görüntü segmentasyonu, NTGA'nın kritik ve önemli bir aşamasıdır. NTGA'da elde edilecek kalite, büyük oranda görüntü bölütleme aşamasındaki kaliteye bağlıdır (Hossain ve Chen, 2019). Birçok farklı açık-kaynak yazılımı (Spring ve Monteverdi-Orfeo Toolbox) imkanıyla NTGA işlemleri gerçekleştirilebilirken; eCognition, ENVI, ERDAS Imagine gibi ticari yazılımlarla da bu işlemler sürdürülebilmektedir. NTGA'nın literatürde yaygın kullanımlı çeşitleri arasında ÇÇB algoritması (Torunlar vd., 2021, Ghorbanzadeh vd., 2022, de Pinho vd. 2012) ve Yalın Doğrusal Yinelemeli Kümeleme (SLIC-Simple Linear Iterative Clustering) uygulamalarına (Manaf vd., 2018; Kawamura, 2021) sık rastlanmaktadır. Bu çalışmada, en yaygın ve etkili NTGA yöntemlerinden biri olan ÇÇB algoritması kullanılmıştır.

### 2.5.1. Çoklu-Çözünürlüklü Bölütleme

Baatz vd. (2000) piksel tabanlı görüntü işleme algoritmasına alternatif bir algoritma önermişlerdir. ÇÇB algoritması olarak bilinen bu algoritma literatürde yaygın olarak kullanımını sürdürmektedir (Hossain ve Chen, 2019). ÇÇB tekniği görüntünün sahip olduğu spektral özelliklere göre gruplandırma yapmaktadır. Bölütleme yani nesne tabanlı segmentasyon, görüntüleri birbiriyle ilgili olan piksellerden oluşan parçalara ayırma yöntemidir. Bir görüntüyü nesnelere ayırmak, bu ayırmadan öznitelikler çıkarmak ve sonrasında öznitelikleri sınıflandırarak görüntüyü anlamlandırmak bu yaklaşımın temelini oluşturur (Wang, 2008). Bu sayede, piksel tabanlı algoritmalara alternatif olarak görüntünün anlamlı nesnelere bölünüp; doku ve bağlamsal ayrıntılar gibi daha tanımlayıcı yeni nitelikler elde edilebilir (Tian ve Chen, 2007). Daha ileri sınıflandırmanın amaçlandığı nesne tabanlı görüntü analizinde bölütleme önemli bir aşamadır (Ghorbanzadeh vd, 2021). Bu bölütleme esnasında, görüntüdeki nesnelere belirlenirken, şekil ve renk parametrelerinin ağırlık değerlerinin toplamı 1 olacak şekilde uygun değerler seçilir. Aynı şekilde, kompaktlık ve düzgünlük değerleri toplamı 1'e eşit olacak şekilde en uygun haliyle belirlenir. Algoritmanın birleştirme maliyet fonksiyonunun, spektral ve şekil heterojenliği arasındaki bağlantısı Eşitlik 1'de (Wang, 2008) gösterilmiştir.

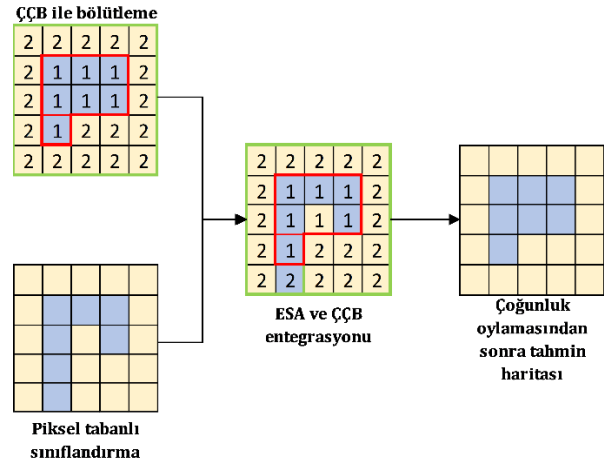
$$f = w \times h_{renk} + (1 - w) \times h_{biçim} \quad (1)$$

Eşitlikte 0-1 değer aralığında olan  $w$  değeri, spektral heterojenlik ağırlığına;  $h_{biçim}$  ve  $h_{renk}$  ise şekil ve renk parametrelerine karşılık gelir.

Bölütleme aşamasından sonra, görüntü artık birbiriyle ilgili piksellerin bir arada olduğu gruplara ayrılmıştır. Bu bölütlerin ESA+ÇÇB entegrasyonundaki görevi, daha önceden ESA mimarisi kullanılarak görüntüde tahmin değerlerine ait aynı grubun (segment) içinde kalan pikseller için yeniden oylama gerçekleştirmektir. Bu sayede bu grubun içinde kalan başka sınıflara ait olduğu tahmin edilmiş gürültüler de ağırlık oylamasında belirlenen eşik değerin uygun şekilde seçilmesiyle azaltılır. Bu işlem Şekil 6'da gösterilmiştir.

### 2.6. Çoğunluk Oylaması

ESA+ÇÇB yaklaşımında, ESA mimarilerinin tahmin sonucu belirlenen sınıf kategorisi, ÇÇB yardımıyla rafine edilir. Çoğunluk oylaması (majority voting) ÇÇB algoritması tarafından bölümlere ayrılan her nesne (bölütte), pikseller yardımıyla gerçekleştirilir.



**Şekil 6.** Segmentasyon aşamasında çoğunluk oylamasının şematik açıklaması (Atik ve İpbüker, 2021'den uyarlanmıştır)

İlk aşama olarak, çalışmada kullanılan uydu görüntüleri, ÇÇB algoritması ile nesnelere ayrılır. ÇÇB algoritması sonucu elde edilen bir bölüt,  $n$  sayıda piksel içerir. ESA kullanılarak semantik segmentasyon ile sınıf etiketlemesinden (tahmin) sonra bir sınıf kategorisi elde edilir. ÇÇB yardımıyla üretilen bir nesne, kendi içinde sınıf kategorisinde çoğunluğu sağlayamazsa, o nesnedeki tüm piksellerin sınıfları, ESA tahmini haliyle aynı kalacaktır. Eğer oylamada çoğunluk sağlanırsa, daha önce ESA ile farklı sınıfa atanmış pikseller de çoğunluğun sınıfına atanır (Şekil 6). Yani bu durumda, nesnedeki her piksel, modelin uygulanması sonucunda içerdiği nesnenin yeni kategori değerini alır. Bu nedenle, ESA+ÇÇB modeli her nesne için yeniden bir kategori (sınıf) hesaplamasını temsil eder. Böylece, ESA tabanlı

sınıflandırma, ÇÇB algoritması kullanılarak çoğunluk oylamasıyla rafine edilmiş olur.

$$Kesinlik = \frac{GP}{GP + YP} \quad (2)$$

$$Duyarluluk = \frac{GP}{GP + YN} \quad (3)$$

$$F1 \text{ skor} = 2 \frac{Kesinlik \times Duyarluluk}{Kesinlik + Duyarluluk} \quad (4)$$

$$IoU = \frac{GP}{GP + YP + YN} \quad (5)$$

$$Dice = \frac{2 \times GP}{2 \times GP + YP + YN} \quad (6)$$

$$Genel \text{ Doğruluk} = \sum_{i=1}^k \frac{N_{ii}}{N} \quad (7)$$

Çalışmada, bina çıkarımının doğruluk analizi için kullanılan performans ölçütleri Eşitlik 2-7'de gösterilmiştir. Eşitliklerde, tahmin edilen etiket ile referans etiketinin aynı olduğu piksel sayısı gerçek pozitif (GP) değerine karşılık gelmektedir. Yanlış pozitif (YP) değeri ise, referans etiketi negatifken tahmin edilen etiketin pozitif olduğu piksel sayısına karşılık gelir. Tahmin edilen etiket negatif iken, referans etiketinin pozitif olduğu piksel sayısı yanlış-negatif (YN) ile ifade edilir. IoU, başka bir deyişle Jaccard indeksi, iki bölgenin üst üste örtüşmesini ölçen ve 0-1 aralığında değerler alan bir metriktir. Dice katsayısı, iki görüntünün benzerliğini ölçmeye yarayan semantik segmentasyon uygulamalarında sıkça tercih edilen bir istatistiktir.

## 2.7. Uygulama

Bu çalışmada uydu görüntülerinin ESA tabanlı piksel sınıflandırma sonuçlarının çok-çözünürlüklü bölütleme ile elde edilen nesnelere kullanılarak iyileştirilmesi amaçlanmaktadır. ESA modeli olarak U-Net ve SegNet mimarileri kullanılmıştır. ESA mimarisinde kullanılan girdi görüntüler 512 × 512 piksel boyutundadır. Eğitim parametreleri momentum 0.9, küme boyutu 128 ve öğrenme hızı 0.001 olarak belirlenmiştir. Eğitim sırasında ince ayar ve optimizasyonlar (erken, durdurma vb.) için validasyon doğrulukları ve kayıp fonksiyonları dikkate alınmıştır.

NTGA kısmında, görüntüler nesnelere ayrılırken kullanılan ÇÇB algoritmasında test görüntüleri için, ölçek parametresi 60 ve 0.25 biçim ve 0.5 kompaktlık parametreleri seçilerek işlemler gerçekleştirilmiştir.

Aynı zamanda sınıflandırılan görüntüler üzerinde 5x5 çekirdek boyutunda medyan filtre uygulanarak yumuşatma işlemi (smoothing) uygulanmıştır.

Tüm deneyler, GPU destekli RTX 3070 ekran kartı, 32 GB RAM ve i7-11800H 2.3 GHz işlemciye sahip bir bilgisayar kullanılarak gerçekleştirilmiştir. ESA uygulamaları MATLAB ortamında geliştirilmiştir. ÇÇB algoritması eCognition yazılımı kullanılarak uygulanmıştır.

## 3. BULGULAR

Uygulanan yaklaşımın, WHUBED veri seti üzerinde derin öğrenme tabanlı görüntü sınıflandırması ve ESA+ÇÇB modelini kullanılarak yapılan deneylerde elde edilen sonuçlar Tablo 1-3'te gösterilmiştir. U-Net algoritması ile sadece ESA kullanıldığı durumda %87.13 Genel Doğruluk (GD), %78.87 F1-skor ve %65.01 IoU elde edilmiştir. ESA sonuçlarına ÇÇB ile elde edilen görüntü bölütleri rafine işlemi için uygulandığında ise genel doğrulukta %2.83, F1-skor'da %3.07 ve IoU'da %4.84 artış olduğu görülmektedir. SegNet modelinde ise U-Net'e göre daha az miktarda artış görülmüştür. GD'de %0.7 ve IoU'da %1.34 artış görülürken, F1-skor'da %1.42 düşüş gerçekleşmiştir.


Elde edilen sonuçlara göre U-Net mimarisinin kullanılan deneylerde, U-Net+ÇÇB modelinin ölçütlerin tamamında sadece U-Net kullanımından daha başarılı olmuştur. SegNet mimarisinin kullanıldığı deneylerde de sadece bir test görüntüsündeki F1 skorda artış sağlayamamıştır. Bu deneylerde diğer tüm ölçütlerde yine SegNet+ÇÇB modeli en yüksek doğrulukları elde etmiş, sadece SegNet kullanılan tahmin değerlerindeki gürültüleri azaltmada etkin rol oynamıştır. Algoritmaların test verisi üzerindeki ortalama sonuçları Tablo 1'de sunulmuştur. Ayrıca her bir test görüntüsüne ait sınıflandırma haritaları Şekil 7-8'de gösterilmiştir.

**Tablo 1.** Algoritmaların test verisi üzerindeki sonuçları. Değerler % olarak verilmiştir.

ESA	Model	G.D	F1-skor	IoU	Dice
U-Net	ESA	85.06	84.17	65.35	66.47
	ESA+ÇÇB	88.98	89.32	72.19	73.93
SegNet	ESA	86.79	84.68	68.53	70.87
	ESA+ÇÇB	88.01	83.93	70.85	73.46

Sınıf bazlı sonuçlar incelendiğinde, U-Net algoritmasının kullanıldığı ESA+ÇÇB yaklaşımının hem bina hem de bina olmayan sınıfın metriklerini önemli ölçüde iyileştirdiği görülmüştür. Özellikle IoU metriğinde bina sınıfı için %8.88 performans artışı gözlemlenmiştir. Yine bina sınıfında ESA+ÇÇB modeli ile GD metriğinde %1.68 ve F1-skor metriğinde %3.56 artış sağlanmıştır. Bina olmayan sınıfının ESA modeli ile GD, F1-skor ve IoU değerleri sırasıyla %90,21, %84.03 ve %80.88 iken, ESA+ÇÇB modeli ile GD %95.48, F1-skor %90.78 ve IoU değeri %85.70'tir. U-Net modeline ait piksel tabanlı semantik segmentasyonda tahmin görüntülerinde yoğun

şekile tuz-biber etkisi bulunmaktadır. ÇÇB ile elde edilen görüntü nesnelere sayesinde bu gürültüler önemli oranda giderilmektedir. Böylece, özellikle referans veri ve tahmin verisi arasında sınıfların kesişim oranını ölçen IoU metriğinde yüksek oranda iyileşme sağlandığı gözlenmiştir. U-Net modelini içeren ESA ve ESA+ÇÇB'ye ait metrik sonuçları Tablo 2'de sunulmuştur. Tahmin görüntüleri ise Şekil 7'da sunulmuştur.




Şekil 7. U-Net ile ESA ve ESA+ÇÇB yaklaşımlarının test sonuçları ve referans görüntüsü.

Tablo 2. U-Net algoritmasının test görüntüleri üzerinde sınıf bazlı sonuçları. Değerler % olarak verilmiştir.

Model	Sınıf	Genel Doğruluk	F1-score	IoU
ESA	Bina olmayan	90.21	84.03	80.88
	Bina	64.66	84.31	49.80
ESA+ÇÇB	Bina olmayan	95.48	90.78	85.70
	Bina	66.34	87.87	58.68

U-Net modeline benzer şekilde, SegNet kullanılan ESA+ÇÇB yaklaşımı sayesinde semantik segmentasyonun doğruluğu GD ve IoU metriklerinin değerlerinde iyileştirilmektedir. Sadece bir test görüntüsünde F-1 skor metriğinde, az oranda bir düşüş görülmektedir. Bunun en önemli sebeplerinden birisi de ESA tarafından tam olarak tespit edilemeyen bina yapısının ESA+ÇÇB tarafından tamamen bina dışı sınıfa atanmasıdır.

Çünkü ESA modeli ile yüksek oranda tahmin edilemeyen bir piksel grubunun ESA+ÇÇB tarafından tahmin edilemediği görülmektedir. Dolayısıyla, ESA+ÇÇB modelinin performansının, kullanılan ESA modelinin tahmin kalitesine direkt bağlı olduğu da gözlenmiştir. SegNet ve ÇÇB beraber kullanıldığında bina sınıfının GD değeri %1.12 ve IoU değeri %3.17 oranlarında geliştirilmiştir. Bina olmayan sınıfta ESA+ÇÇB ile GD %90.68, F1-skor %86.46 ve IoU %83.65 olarak elde edilmiştir. SegNet modelini içeren ESA ve ESA+ÇÇB'ye ait metrik sonuçları Tablo 3'te sunulmuştur. Tahmin görüntüleri ise Şekil 8'dedir.



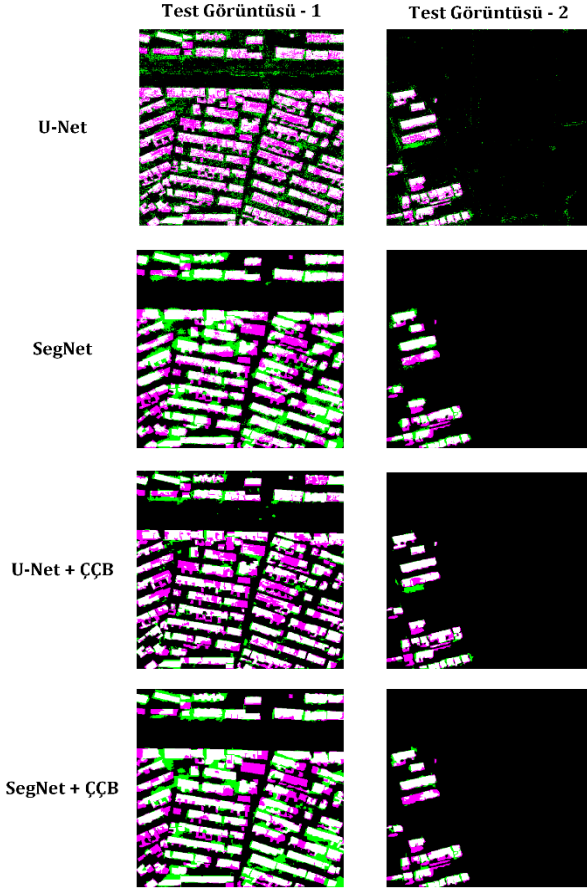
Şekil 8. SegNet ile ESA ve ESA+ÇÇB yaklaşımlarının test sonuçları ve referans görüntüsü.

Tablo 3. SegNet algoritmasının test görüntüleri üzerinde sınıf bazlı sonuçları. Değerler % olarak verilmiştir.

Model	Sınıf	Genel Doğruluk	F1-score	IoU
ESA	Bina olmayan	89.41	86.64	82.17
	Bina	68.94	82.72	54.88
ESA+ÇÇB	Bina olmayan	90.68	86.46	83.65
	Bina	70.06	81.41	58.05

ESA+ÇÇB yaklaşımının tuz-biber etkisini gidermenin yanı sıra bina kenarlarını belirginleştirmede de başarılı katkılar sağladığı görülmektedir. Ancak, ESA tarafından tahmin edilemeyen bir sınıf ESA+ÇÇB modeli tarafından da tahmin edilememektedir. ESA+ÇÇB yaklaşımı ESA modellerinin tahmin sonuçlarının ÇÇB ile üretilen

görüntü nesnelere sayesinde iyileştirilmesini amaçlamaktadır. Derin öğrenme mimarisinin tahmin görüntüsünde olmayan bir sınıfı ortaya çıkarması geliştirilen yöntemin amacının dışında kalmaktadır. Dice benzerliğinin görüntü bazlı gösterimi Şekil 9’da sunulmuştur.



**Şekil 9.** Referans görüntüler ile tahmin görüntüleri arasında hesaplanan Dice benzerliğinin gösterimi. Beyaz doğru tahminleri, mor yanlış negatif ve yeşil yanlış pozitif ifade etmektedir.

**Tablo 4.** WHUBED veri setinin kullanıldığı diğer çalışmalarla karşılaştırma.

Model	F1-skor (%)
MFBI (Bi et al., 2019)	77.31
Bi et al. (2019)	78.70
DeepLabV3+Xception (Atik ve Ipbuker, 2021)	82.64
DeepLabV3+ResNet18 (Atik ve Ipbuker, 2022)	84.96
U-Net + ÇÇB*	89.32
SegNet + ÇÇB*	83.93

\*Bu çalışma Tablo 4’te WHUBED veri seti kullanılan diğer çalışmaların sonuçlarıyla karşılaştırma yapılmıştır. Buna göre, bu çalışmada U-Net+ÇÇB yaklaşımı ile elde edilen F1-skor karşılaştırılan diğer çalışmalara göre iyileştirilmiştir.

#### 4. SONUÇLAR

Bu çalışmada VHR uydu görüntüleri üzerinden bina çıkarımında ESA modellerinin segmentasyon performansını iyileştirmek amacıyla ESA+ÇÇB modelinin kullanımına yönelik deneyler sunulmuştur. Deneylerde derin öğrenme mimarisi olarak U-Net ve SegNet modelleri kullanılmıştır. Her iki ESA modelinin ayrı ayrı kullanıldığı bina çıkarımı için, bir nesne tabanlı görüntü analizi yaklaşımı olan Çoklu-Çözünürlüklü Bölütleme (ÇÇB) algoritmasının modele entegrasyonu ile genel doğruluk, F1-skor ve IoU metriklerinde iyileştirmeler sağlanmıştır. Çalışmada ortaya konan yaklaşım ESA ve ÇÇB yaklaşımının entegrasyonunu belirtmek üzere ESA+ÇÇB olarak adlandırılmıştır. U-Net veya SegNet’in yanı sıra farklı derin öğrenme mimarilerinde de ESA+ÇÇB modelinin uygulanması mümkündür. Çalışmada farklı mekansal çözünürlüğe sahip uydu görüntülerini içeren WHUBED veri seti kullanılmıştır. Derin öğrenme uygulamalarında genelde, eğitim verisine çok benzer test verilerinde başarı sağlanırken, test verisi eğitimden farklılaştıkça performansta azalmalar gözlenir. Ancak bu çalışmada kullanılan veri seti birbirinden farklı 3 sensöre sahip ve farklı mekansal çözünürlükteki uydu görüntülerinden oluşmaktadır. Bu durumda, çalışmanın derin öğrenmenin dezavantajlarından olan bir konuda da çözüme katkı sağlayan yönde sonuçlar ortaya konduğu düşünülmektedir.

ESA+ÇÇB yaklaşımı IoU, Dice katsayısı ve F1-skor ölçütlerinde tek başına ESA kullanımının elde ettiği değerleri iyileştirmiştir. Bunun önemli bir nedeni, ESA tahmin sonucundaki tuz-biber görüntülerinin ESA+ÇÇB modeli ile önemli ölçüde giderilmesinden kaynaklanır. Ancak SegNet mimarisinin kullanıldığı yaklaşımda F1-skorda az da olsa düşüşün nedeni, bazı binaların alanlarını SegNet mimarisi U-Net kadar bütün çıkaramadığından; ESA+ÇÇB modelinin filtreleme etkisi ile küçük bina alanlarının daha da küçülmesinden kaynaklanmaktadır. Ancak bu dezavantaj U-Net’in kullanıldığı ESA+ÇÇB modelinin uygulanmasında geçerli değildir. Bu çalışmada ESA+ÇÇB modeli ile, F1-Skor da dahil olmak üzere tüm metriklerde iyileştirme sağlanmıştır.

Derin öğrenme algoritmalarının kullanımının birçok alanda olduğu gibi sahip olduğu avantaj ve dezavantajların kullanım alanı ve kapsamına göre ele alınması önem arz etmektedir. Örneğin bina sınıflandırması uygulamalarında, derin öğrenme mimarilerinin tercihi otomatik sınıflandırma yaklaşımına imkân tanırken aynı zamanda işlem yükü (özellikle kullanılan teknolojik cihazların GPU kapasitesindeki kısıtlar) dezavantajları arasında sayılabilir. Sunduğu hızlı çözüm elde etme imkanı rağmen, ESA mimarilerinin piksel bazlı tahminlerindeki tuz biber etkisiyle oluşan görüntüler de yine dezavantajlardan biri olarak sayılabilir. Ancak bu çalışmada ESA ve NTGA algoritmalarından olan ÇÇB algoritmasının entegrasyonu sayesinde,



sınıflandırmada karşımıza çıkan gürültü miktarlarını azaltma imkânı ortaya konmuştur. Bu sayede bina çıkarımında elde edilen bina sınıfının daha bütün ve sınırları daha düzgün şekilde elde edilme imkânı oluşmuştur. Bina sınır problemleri, pafta üzerindeki sınır koordinatlar gibi daha birçok meselenin uygulamalarında ESA+ÇÇB modeli ile hem derin öğrenme sınıflandırmasının avantajlarından yararlanılırken hem de elde edilen nesne-tabanlı yaklaşımın sınıflandırmada pikseller yerine görüntüdeki nesnelere ile daha bütünsel ürün şeklinde üretilmesi söz konusudur. Gelecek çalışmalarda çoklu-sınıf içeren arazi örtüsü haritalarının hızla ve güvenilir güncellenmesinde ESA+ÇÇB modeli kullanılabilir. AKAÖ veri tabanlarının (CORINE, AfriCover vb.) otomatik oluşturulmasında çok bantlı veri setleri ile ESA+ÇÇB modelinin kullanım alanları daha çok genişletilebilir.

#### Araştırmacıların katkı oranı beyan özeti

Yazar çalışmaya %100 oranında katkı sağlamıştır.

#### Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

#### Araştırma ve yayın etiği beyanı

Yapılan çalışmada yazar, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

#### KAYNAKÇA

- Abdollahi, A., Pradhan, B., & Alamri, A. M. (2022). An ensemble architecture of deep convolutional Segnet and U-net networks for building semantic segmentation from high-resolution aerial images. *Geocarto International*, 37(12), 3355-3370.
- Ali, K., & Johnson, B. A. (2022). Land-Use and Land-Cover Classification in Semi-Arid Areas from Medium-Resolution Remote-Sensing Imagery: A Deep Learning Approach. *Sensors*, 22(22), 8750.
- Arıkan, D. & Yıldız, F. (2023). Göktürk-1 Uydu Görüntülerinden U-Net Modeli Kullanılarak Binaların Segmentasyonu . *Türkiye Uzaktan Algılama Dergisi*, 5 (1) , 50-58 . DOI: 10.51489/tuzal.1300939
- Atik, S. O., & Ipbuker, C. (2021). Integrating convolutional neural network and multiresolution segmentation for land cover and land use mapping using satellite imagery. *Applied Sciences*, 11(12), 5551.
- Atik, S. O., Atik, M. E., & Ipbuker, C. (2022). Comparative research on different backbone architectures of DeepLabV3+ for building segmentation. *Journal of Applied Remote Sensing*, 16(2), 024510-024510.
- Atik, S. O., & Ipbuker, C. (2022). Building Extraction in VHR Remote Sensing Imagery Through Deep Learning. *Fresenius Environ. Bull*, 31, 8468-8473.
- Attri, P., Chaudhry, S., & Sharma, S. (2015). Remote sensing & GIS based approaches for LULC change detection—A review. *Int. J. Curr. Eng. Technol*, 5, 3126-3137.4e
- Baatz, M. (2000). Multi resolution segmentation: an optimum approach for high quality multi scale image segmentation. In *Beutrage zum AGIT-Symposium*. Salzburg, Heidelberg, 2000 (pp. 12-23).
- Badrinarayanan V., Kendall A. and Cipolla R., (2017) SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 12, pp. 2481-2495, 1 Dec., doi: 10.1109/TPAMI.2016.2644615.
- Balarabe, A. T., & Jordanov, I. (2021). LULC image classification with convolutional neural network. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS* (pp. 5985-5988). IEEE.
- Baştuğ Koç, A., Akgün, D. (2021). U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 407-414.
- Bi, Q., Qin, K., Zhang, H., Zhang, Y., Li, Z., & Xu, K. (2019). A multi-scale filtering building index for building extraction in very high-resolution satellite imagery. *Remote Sensing*, 11(5), 482.
- de Pinho, C. M. D., Fonseca, L. M. G., Korting, T. S., De Almeida, C. M., & Kux, H. J. H. (2012). Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. *International Journal of Remote Sensing*, 33(19), 5973-5995.
- Dewali, S. K., Jain, K., Varshney, D., Dhamija, S., & Pundir, E. (2023). Combining OBIA, CNN, and UAV Photogrammetry for Automated Avalanche Deposit Detection and Characterization. *Advances in Space Research*. 72(8), 3109-3132.
- Ghorbanzadeh, O., Gholamnia, K., & Ghamisi, P. (2022). The application of ResU-net and OBIA for landslide detection from multi-temporal sentinel-2 images. *Big Earth Data*, 1-26.

- Ghorbanzadeh, O., Tiede, D., Wendt, L., Sudmanns, M., & Lang, S. (2021). Transferable instance segmentation of dwellings in a refugee camp-integrating CNN and OBIA. *European Journal of Remote Sensing*, 54(sup1), 127-140.
- Hossain, M. D., & Chen, D. (2019). Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, 115-134.
- Ji, S., Wei, S., & Lu, M. (2019). A scale robust convolutional neural network for automatic building extraction from aerial and satellite imagery. *International journal of remote sensing*, 40(9), 3308-3322.
- Kaiser, P., Wegner, J. D., Lucchi, A., Jaggi, M., Hofmann, T., & Schindler, K. (2017). Learning aerial image segmentation from online maps. *IEEE Transactions on Geoscience and Remote Sensing*, 55(11), 6054-6068.
- Kawamura, K., Asai, H., Yasuda, T., Soisouvanh, P., & Phongchanmixay, S. (2021). Discriminating crops/weeds in an upland rice field from UAV images with the SLIC-RF algorithm. *Plant Production Science*, 24(2), 198-215.
- Kurnaz, E., & Ceylan, R. (2020, October). Pancreas segmentation in abdominal CT images with U-Net model. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Li, H., Tian, Y., Zhang, C., Zhang, S., & Atkinson, P. M. (2022). Temporal sequence Object-based CNN (TS-OCNN) for crop classification from fine resolution remote sensing image time-series. *The Crop Journal*, 10(5), 1507-1516.
- Liu, T., Yang, L., & Lunga, D. (2021). Change detection using deep learning approach with object-based image analysis. *Remote Sensing of Environment*, 256, 112308.
- Manaf, S. A., Mustapha, N., Sulaiman, M. N., Husin, N. A., Shafri, H. Z. M., & Razali, M. N. (2018). Hybridization of SLIC and Extra Tree for Object Based Image Analysis in Extracting Shoreline from Medium Resolution Satellite Images. *International Journal of Intelligent Engineering & Systems*, 11(1).
- Marcu, A., & Leordeanu, M. (2016). Dual local-global contextual pathways for recognition in aerial imagery. *arXiv preprint arXiv:1605.05462*.
- Merchant, M. A. (2021). Classification of open water features using OBIA and deep learning. In *2021 IEEE international geoscience and remote sensing symposium IGARSS* (pp. 104-107). IEEE.
- Pan, Z., Xu, J., Guo, Y., Hu, Y., & Wang, G. (2020). Deep learning segmentation and classification for urban village using a worldview satellite image based on U-Net. *Remote Sensing*, 12(10), 1574.
- Qin, Y., Wu, Y., Li, B., Gao, S., Liu, M., & Zhan, Y. (2019). Semantic segmentation of building roof in dense urban environment with deep convolutional neural network: A case study using GF2 VHR imagery in China. *Sensors*, 19(5), 1164.
- Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science, vol 9351. Springer, Cham. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Lee, S. H., & Baik, J. J. (2011). Evaluation of the vegetated urban canopy model (VUCM) and its impacts on urban boundary layer simulation. *Asia-Pacific Journal of Atmospheric Sciences*, 47, 151-165.
- Tang, Z., Li, M., & Wang, X. (2020). Mapping tea plantations from VHR images using OBIA and convolutional neural networks. *Remote Sensing*, 12(18), 2935.
- Thenkabail, P. S., Schull, M., & Turrall, H. (2005). Ganges and Indus river basin land use/land cover (LULC) and irrigated area mapping using continuous streams of MODIS data. *Remote Sensing of Environment*, 95(3), 317-341.
- Tian, J., & Chen, D. M. (2007). Optimization in multi-scale segmentation of high-resolution satellite images for artificial feature recognition. *International Journal of Remote Sensing*, 28(20), 4625-4644.
- Torunlar, H., Tuğaç, M. G. & Duyan, K. (2021). Nesne Tabanlı Sınıflandırma Yönteminde Sentinel-2A Uydu Görüntüleri Kullanılarak Tarımsal Ürün Desenlerinin Belirlenmesi; Konya - Karapınar Örneği . *Türkiye Uzaktan Algılama Dergisi*, 3 (2) , 36-46 . DOI: 10.51489/tuzal.932912
- Wang, M. (2008). A multiresolution remotely sensed image segmentation method combining rainfalling watershed algorithm and fast region merging. *Int. Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37, 1213-1217.

Xu, Z., Su, C., & Zhang, X. (2021). A semantic segmentation method with category boundary for Land Use and Land Cover (LULC) mapping of Very-High Resolution (VHR) remote sensing image. *International Journal of Remote Sensing*, 42(8), 3146-3165.

Yi, Y., Zhang, Z., Zhang, W., Zhang, C., Li, W., & Zhao, T. (2019). Semantic segmentation of urban buildings from VHR remote sensing imagery using a deep convolutional neural network. *Remote sensing*, 11(15), 1774.



© Author(s) 2023.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>