

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

TARİHİ HAVA FOTOĞRAFLARININ DERİN ÖĞRENME İLE SEMANTİK
SEGMENTASYONU

YÜKSEK LİSANS TEZİ

Gülsena YILANCI

EKİM 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**TARİHİ HAVA FOTOĞRAFLARININ DERİN ÖĞRENME İLE SEMANTİK
SEGMENTASYONU**

Gülsena YILANCI

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"HARİTA YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 19 / 09 / 2024

Tezin Savunma Tarihi : 21 / 10 / 2024

Tez Danışmanı : Doç. Dr. Mustafa DİHKAN

Trabzon 2024

ÖNSÖZ

“Tarihi Hava Fotoğraflarının Derin Öğrenme ile Semantik Segmentasyonu” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Yüksek lisans eğitimim boyunca hiçbir desteğini esirgemeyen, daima yol gösteren, bilgisi, tecrübesi ve birikimlerinden faydalandığım danışman hocam Sayın Doç. Dr. Mustafa DİHKAN’a sonsuz teşekkürlerimi sunarım.

Lisans ve lisansüstü hayatım boyunca fotogrametri ve uzaktan algılama alanlarına ilgi duymamı sağlayan, vizyonunu örnek aldığım, deneyimlerinden yararlandığım Sayın Prof. Dr. Fevzi KARSLI’ya teşekkürlerimi sunarım.

Engin bilgileri ile ufkumu genişleten, önerileri ile yol gösteren Sayın Prof. Dr. Abdulaziz GÜNEROĞLU’na teşekkürü bir borç bilirim.

Tez çalışmam boyunca desteğini esirgemeyen, tezimin her aşamasında yardım aldığım, bilgilerinden yararlandığım sevgili hocam Sayın Dr. Öğr. Üyesi Zeynep AKBULUT’a teşekkür ederim.

Tez çalışması süresince yardımlarını esirgemeyen, her türlü destek veren meslektaşım ve okul arkadaşım sevgili Zeliha İskender’e çok teşekkür ederim.

Doğduğum andan bugüne kadar daima yanımda olan, bana her zaman güvenen, koşullar ne olursa olsun desteklerini hiç esirgemeyen sevgili annem Reyhan YILANCI, sevgili babam Mustafa YILANCI, kardeşlerim Elif Rana YILANCI ve Selahattin Taha YILANCI’ya sonsuz teşekkür ederim.

Hayatımın her anında tecrübelerinden faydalandığım, abla bildiğim sevgili kuzenim Zeynep Nur YILANCI’ya teşekkür ederim.

Hayata bakışımı değiştiren, doğruları bulmamı sağlayan, koşullar ne olursa olsun yalnız bırakmayan ve tüm hayatım boyunca yanımda olacağını bildiğim sevgili eşim Mert GÜLER’e tüm kalbimle teşekkür ederim.

Gülsena YILANCI

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Tarihi Hava Fotoğraflarının Derin Öğrenme ile Semantik Segmentasyonu” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Mustafa DİHKAN’ın sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 21/10/2024

Gülsena YILANCI

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VII
SUMMARY.....	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	X
SEMBOLLER VE KISALTMALAR DİZİNİ	XI
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.2. Tezin Amacı	3
1.3. Tezin Kapsam ve Organizasyonu	4
1.4. Literatür Araştırması	4
1.5. Temel Kavramlar	13
1.5.1. Fotogrametri	13
1.5.2. Fotogrametrinin Matematiksel Modeli.....	16
1.5.3. Hava Fotogrametrisi ve Uzaktan Algılama Kameraları	18
1.5.4. Görüntü Sınıflandırma.....	20
1.5.5. Nesne Tabanlı Sınıflandırma ve Segmentasyon.....	22
1.5.6. Yapay Zeka ve Derin Öğrenme.....	24
1.5.7. CNN (Evrışimli Sinir Ağı)	27
1.5.8. Doğruluk Metrikleri	30
2. YAPILAN ÇALIŞMALAR.....	33
2.1. Çalışma Alanı ve Veri Seti	33
2.1.1. Veri Setinin Hazırlanması	34
2.1.2. SYM Üretimi.....	36
2.2. Yöntem.....	37
2.2.1. MMSegmentation Kütüphanesi.....	37
2.2.2. DeepLabV3	38
2.2.3. U-Net Mimarisi	39

3. BULGULAR.....	43
3.1. 5 Sınıf ile Gerçekleştirilen Sınıflandırma İşlemi	43
3.2. 3 Sınıf ile Gerçekleştirilen Sınıflandırma İşlemi	46
3.3. SYM Eklenerek 5 Sınıf ile Gerçekleştirilen Sınıflandırma İşlemi	48
3.4. SYM Eklenerek 3 Sınıf ile Gerçekleştirilen Sınıflandırma İşlemi	51
4. TARTIŞMA	56
5. SONUÇLAR VE ÖNERİLER.....	60
6. KAYNAKLAR	61
ÖZGEÇMİŞ	



ÖZET

TARİHİ HAVA FOTOĞRAFLARININ DERİN ÖĞRENME İLE SEMANTİK SEGMENTASYONU

Gülsena YILANCI

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Mustafa DİHKAN
2024, 74 Sayfa

Tarihi görüntü arşivleri, uydu çağından önceki dünya bölgeleri hakkında değerli bilgiler sağlar. Arazi örtüsü ve kullanımı hakkında bilgi edinmek ve zamansal değişimlerin gözlemlenebilmesi açısından bu arşivler vazgeçilmez bir kaynak olmuştur. Bu durum, tarihi hava fotoğraflarının yüksek doğrulukta semantik olarak anlamlandırılmasını gerektirmiştir. Çalışmada, semantik segmentasyon işlemi için U-Net omurgalı DeepLabV3 modeli uyarlanarak kullanılmış ve bu mimarinin tarihi hava fotoğrafları üzerindeki başarımı zemin ve zemin üstü objeleri kapsayacak şekilde 5 sınıflı ve 3 sınıflı olarak değerlendirilmiştir. Veri etiketleme süreci, LabelMe yazılımı ile manuel olarak gerçekleştirilmiştir. Tarihi hava fotoğrafları, toplamda 120 adet 256×256 piksel boyutu ile alt parçalara bölündükten sonra eğitim, validasyon ve test kümelerine ayrılmıştır. Ayrıca mimariye, söz konusu tarihi hava fotoğraflarının 3 boyutlu değerlendirilmesiyle üretilmiş Sayısal Yükseklik Modeli (SYM) ilave edilerek sonuçlar karşılaştırılmıştır. Performans değerlendirme aşamasında, kesişim birleşim oranı (Intersection over Union - IoU) ve F1 Skor doğruluk metrikleri kullanılmıştır. 5 sınıflı veri için F1 Skor %60.94 ve IoU %46.90, 3 sınıflı veri için F1 Skor %76.19 ve IoU %66.85, SYM eklenerek oluşturulmuş 5 sınıflı veri için F1 Skor %61.48 ve IoU %47.53, 3 sınıflı veri için F1 Skor %77.59 ve IoU %68.24 düzeyinde hesaplanmıştır.

Anahtar Kelimeler: Derin öğrenme, Tarihi hava fotoğrafı, Semantik segmentasyon

Master Thesis

SUMMARY

SEMANTIC SEGMENTATION OF HISTORICAL AERIAL PHOTOGRAPHS USING DEEP LEARNING

Gülsena YILANCI

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Geomatics Engineering Graduate Programme
Supervisor: Assoc. Prof. Mustafa DİHKAN
2024, 74 Pages

Historical image archives provide valuable information about the regions of the world before the satellite era. These archives have been an indispensable source for obtaining information about land cover and use and observing temporal changes. This situation necessitated the semantic interpretation of historical aerial photographs with high accuracy. In the study, U-Net backbone DeepLabV3 model was adapted and used for semantic segmentation and the performance of this architecture on historical aerial photographs was evaluated as 5-class and 3-class to cover ground and above-ground objects. The data labeling process was performed manually with LabelMe software. Historical aerial photographs were divided into training, validation and test sets after being divided into 120 sub-segments with a total size of 256×256 pixels. In addition, Digital Elevation Model (DEM) produced by evaluating the historical aerial photographs in 3D was added to the architecture and the results were compared. Intersection over Union (IoU) and F1 score accuracy metrics were used in the performance evaluation phase. For 5-class data, F1 Score was calculated as 60.94% and IoU as 46.90%, for 3-class data, F1 Score was calculated as 76.19% and IoU as 66.85%, for 5-class data created by adding SYM, F1 Score was calculated as 61.48% and IoU as 47.53%, for 3-class data, F1 Score was calculated as 77.59% and IoU as 68.24%.

Key Words: Deep learning, Historical aerial photography, Semantic segmentation

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Fotogrametrinin alt sınıfları (Toprak, 2014)	15
Şekil 2. Fotogrametrinin matematiksel modeli (Marangoz, 2002)	16
Şekil 3. Segmentasyon ile görüntünün piksel seviyesinden görüntü nesnesi seviyesine dönüşümü	23
Şekil 4. Yapay zeka ve derin öğrenme arasındaki ilişki (Bingöl vd., 2020)	24
Şekil 5. (a) Makine öğrenmesi ve (b) derin öğrenme arasındaki fark (Wani vd., 2020).....	25
Şekil 6. CNN ağ mimarisi örneği (Alom vd., 2019).....	27
Şekil 7. Hata matrisi	31
Şekil 8. Farklı arazi örtüsü karakterinde çalışma bölgelerini kapsayan ortofoto verileri.....	33
Şekil 9. LabelMe yazılımı ile etiketlenmiş tarihi hava fotoğrafları	35
Şekil 10. SfM algoritması genel iş akışı (Altuntaş, 2019)	36
Şekil 11. SYM üretim aşamaları.....	37
Şekil 12. MMSegmentation kütüphanesi bileşenleri (URL-4, 2024).....	38
Şekil 13. U-Net mimarisi (Ronneberger vd., 2015).....	40
Şekil 14. 5 sınıflı sınıflandırma sonuçlarına dair örnek test görüntüleri (a) gerçek harita, (b) referans harita, (c) tahmin haritası, (d) fark haritası	44
Şekil 15. 3 sınıflı sınıflandırma sonuçlarına dair örnek test görüntüleri (a) gerçek harita, (b) referans harita, (c) tahmin haritası, (d) fark haritası	47
Şekil 16. Yükseklik özellikleri eklenmesi sonrası 5 sınıf ile gerçekleştirilen sınıflandırma sonuçlarına dair örnek test görüntüleri (a) gerçek harita, (b) referans harita, (c) tahmin haritası, (d) fark haritası	49
Şekil 17. Yükseklik özellikleri eklenmesi sonrası 3 sınıf ile gerçekleştirilen sınıflandırma sonuçlarına dair örnek test görüntüleri (a) gerçek harita, (b) referans harita, (c) tahmin haritası, (d) fark haritası	52
Şekil 18. (a) bina ağırlıklı, (b) bitki ağırlıklı, (c) tarım alanı ağırlıklı tarihi hava fotoğrafları	56
Şekil 19. Modelin arka plan olarak atadığı eksik pikseller.....	57

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Hata matrisinin yapısı.....	31
Tablo 2. U-Net omurgalı DeepLabV3 modelinin mimari yapılandırması ve hiper parametreleri	42
Tablo 3. 5 sınıflı segmentasyon sonuçlarına ilişkin hata matrisi	45
Tablo 4. 5 sınıflı segmentasyon sonucu elde edilen sınıf bazlı doğruluklar (%).....	46
Tablo 5. 3 sınıflı segmentasyon sonuçlarına ilişkin hata matrisi	48
Tablo 6. 3 sınıflı segmentasyon sonucu elde edilen sınıf bazlı doğruluklar (%).....	48
Tablo 7. Yükseklik özellikleri eklenmiş 5 sınıflı segmentasyon sonuçlarına ilişkin hata matrisi.....	50
Tablo 8. Yükseklik özellikleri ile 5 sınıflı segmentasyon sonucu elde edilen sınıf bazlı doğruluklar (%).....	51
Tablo 9. Yükseklik özellikleri eklenmiş 3 sınıflı segmentasyon sonuçlarına ilişkin hata matrisi.....	53
Tablo 10. Yükseklik özellikleri ile 3 sınıflı segmentasyon sonucu elde edilen sınıf bazlı doğruluklar (%).....	53
Tablo 11. Elde edilen doğruluk metrikleri (%).....	54
Tablo 12. Literatürdeki benzer çalışmalar ve tez çalışması karşılaştırılması	58

SEMBOLLER VE KISALTMALAR DİZİNİ

CNN	: Convolutional Neural Network
FCN	: Fully Convolutional Network
HGM	: Harita Genel Müdürlüğü
IoU	: Intersection over Union
İHA	: İnsansız Hava Aracı
RGB	: Red Green Blue
3B	: 3 Boyutlu
2B	: 2 Boyutlu
SfM	: Structure From Motion
SYM	: Sayısal Yükseklik Modeli
ASPP	: Atrous Spatial Pyramid Pooling

1. GENEL BİLGİLER

1.1. Giriş

Hava fotoğrafları, dünya yüzeyiyle ilgili anlık görsel veriler sağlayabilmenin yanı sıra arazi yüzeyindeki zamansal değişimi haritalamak için kullanılan önemli araçlardan biridir (Morgan vd., 2010; Heisig & Simmen, 2021). Mekansal anlamda kentsel gelişmenin hızla artması, sadece tematik envanterler yapmak ve değişiklikleri izlemek için değil, aynı zamanda karmaşık manzaraların bütünsel yönlerini tanımlamak için de değerli olduğu kanıtlanan hava fotoğrafları sayesinde incelenebilir (Antrop & Eetvelde, 2000). Uzaktan algılamanın en eski veri biçimlerinden olan tarihi hava fotoğrafları ise arazi örtüsü ve arazinin kullanım durumu ile ilgili bilgi sağlarken bunların zaman içindeki değişimiyle ilgili de tarihsel veri akışı sunmaktadır (Pinto vd., 2019). Ayrıca tarihi hava fotoğraflarının kentsel gelişim süreçlerini analiz ederken de önemli bir kaynak olduğu kanıtlanmıştır. Taranan tarihi hava fotoğraf arşivleri, zamanda geriye dönük değerlendirmeye imkan sağlaması ile iklim adaptasyonu, şehir planlaması ve arazi yönetimi dahil olmak üzere birçok uygulamada arazi örtüsü değişiminin uzun vadeli ölçümleri için yararlı bir veri kaynağı sağlamaktadır (Knuth vd., 2023). Uydu çağından önceki dünya bölgeleri hakkında değerli bilgiler barındıran tarihi görüntü arşivlerinin son yıllarda, dijitalleştirilmesi ve jeo-bilimlerde veri kaynağı olarak kullanılma eğilimi artmaktadır (Cowley & Stichelbaut, 2012; Heisig & Simmen, 2021; Dahle vd., 2024). Bununla birlikte tarihi hava fotoğraflarının ve türevlerinin kullanımına yönelik hızla artan bir ilgi gözlemlenmiştir. İlgi, arkeoloji (Cowley & Stichelbaut, 2012; Verhoeven vd., 2013), orman bilimleri (Nurminen vd., 2015; Božek vd., 2019; Whiteside vd., 2020; Riccardi vd., 2024), tarihi peyzaj ve yerleşim analizi (Nebiker vd., 2014; Gomez vd., 2015; Mertes vd., 2017; Sevara vd., 2018), buzul bilimi (Schiefer & Gilbert, 2007; Fischer vd., 2011; Mölg & Bolch 2017; Vargo vd., 2017) veya jeomorfoloji (Ford, 2013; Strozzi vd., 2013; Micheletti vd., 2015; Spiekermann vd., 2017) gibi bir çok uygulama alanına dayanmaktadır. Ayrıca görüntü eşleştirme alanında yaşanan son gelişmeler nedeniyle (Remondino vd., 2014; Natale vd., 2024), tarihi hava fotoğraflarından türetilen SYM çok zamanlı analizine özel ilgi gösterilmeye başlanmıştır.

Tarihi fotoğrafları doğası gereği, genellikle birçok emek ve zaman gerektirmesi büyük veri kümelerinin işlenmesini engellemektedir. Bunun yanı sıra bu veri setlerinin kullanımını

etkileyen temel sorunlardan biri, mevcut olan dijital formatların kolayca kullanılabilir olmasıdır. Çoğu tarihi hava fotoğrafı pankromatik filmlerde çekilmiş olmasından ötürü, çevre, arazi örtüsü ve zamansal değişiklikler hakkında çalışma yapıp değerlendirme sağlamak ancak bu verilerin işleme aşamasındaki zorlukların aşılabilmesi durumunda yapılabilir (Mboga vd., 2020). Buna ek olarak zamanla, tarihi hava fotoğraflarının analog kopyalarında eskimeden dolayı küçülme ve parlaklıkta bozulmalar yaşanabilmektedir. Analog fotoğrafların dijital kopyalarını oluşturma sürecinde gerçekleştirilen yeniden üretim ve tarama işlemleri sırasında oluşan parlaklıktaki pozlama farklılıkları görüntü boyunca tutarsız parlaklık dağılımına yol açmaktadır (Donald vd., 1997). Ayrıca tarama sırasında iç geometrinin korunamaması, metadata eksikliği, stereo örtüşme yetersizliği gibi sorunlar tarihi görüntü arşivlerinin modern dijital görüntü işleme karşısındaki eksikliğini göstermektedir (Girod vd., 2018). Potansiyellerine rağmen, çoğu görüntülerin yalnızca tarama olarak mevcut olduğu, metadata içermediği ve zayıf coğrafi konum doğruluğa sahip olduğu için yeterince kullanılmadığını belirten Dahle vd. (2024) metadata eksikliğinin, bilgilerin bilimsel araştırmalara dahil edilebilmesi için önemli miktarda manuel çalışma gerektirdiğini vurgulamaktadır. Manuel süreç zaman alıcıyken, gri tonlamalı bu görüntülerden otomatik bir segmentasyon yöntemi kullanılarak semantik anlamlar çıkarmak da oldukça zor bir işlemdir. Bu nedenle, arazi örtüsü sınıflandırması için kullanılacak olan görüntülerin akıllı ve otomatik yöntemlerle yorumlanması gerekmektedir (Cheng vd., 2016; Liu vd., 2020).

Son yıllarda uzaktan algılamada görüntü analizi konusunda popülerlik kazanan derin öğrenmenin en yaygın araştırma konularından biri olan görüntü segmentasyonu, desen tanıma ve görüntü anlamlandırmanın temelini sağlamaktadır (Ma vd., 2019). Görüntü segmentasyon alanındaki teknolojik yenilikler hem teori hem de uygulamada önemli ölçüde ilerlemeler sağlamıştır. Semantik segmentasyon, bir görüntüyü aynı sınıf veya anlamdaki ayrık bölgelere yani bazı eşdeğer özellikler içeren çeşitli parçalara ayırma ve bu bölgeleri piksel düzeyinde etiketleme işlemidir (Cheng vd., 2024a). Segmentasyon süreci, karmaşık arka plan ve görüntüdeki parlaklık dengesizliği sebebiyle zorlaşmaktadır (Brar vd., 2024). Segmente edilen görüntülerin kalitesinin düşük olması ise hatalı ve etkisiz sonuçlara neden olabilir. Geleneksel görüntü özellik çıkarma algoritmaları, genellikle profesyonel uzmanlık ve insan aracılığı ile tek bir görüntüde bulunan belirli görüntü özelliklerini manuel olarak ayarlamaya odaklanır bu yüzden de zayıf genelleme yeteneğine ve uyumluluğa sahiptirler (Chen vd., 2021). Ancak görüntülerden yüksek düzeyde anlamsal bilgi elde etmek ve yüksek

doğruluk gereksinimlerini karşılamak kritik öneme sahiptir. Bu sebeple derin sinir ağlarından türetilen görüntü segmentasyon yaklaşımları giderek yaygın bir alan haline gelmiştir (Brar vd., 2024). Derin öğrenme modelleri, makine öğrenimi yöntemlerinden biri olarak kabul edilmelerine rağmen, giriş verilerinden özellikleri otomatik olarak çıkarabildikleri ve kullanıcı etkisini azaltabildikleri için geleneksel makine öğrenimi algoritmalarından farklıdır (Mboga vd., 2020). Görüntü sınıflandırma tekniklerindeki son gelişmelerle birlikte, Evrişimli Sinir Ağı'nı (Convolutional Neural Network - CNN) kullanan derin öğrenme tabanlı yöntemler, nesne tanıma, hassas haritalama, tarımsal ve kentsel bölgelerinin izlenmesi gibi çeşitli uygulama alanlarında yüksek çözünürlüklü görüntülerin verimli, otomatik ve yüksek doğrulukla sınıflandırılması için tercih edilen bir yöntem haline gelmiştir (Dewali vd., 2023). CNN, birden fazla özellik çıkarma aşamasından oluşan ve giriş verilerinden düşük seviyeli, orta seviyeli ve yüksek seviyeli özellikleri öğrenmek/çıkartmak için doğrusal olmayan çok katmanlı bir ağ kullanan eğitilebilir bir derin öğrenme mimarisidir (Zhang vd., 2016). CNN mimarisinin bilgisayarla görme alanında başarılı bir şekilde uygulanmasıyla birlikte, araştırmacılar anlamsal görüntü segmentasyonunda CNN kullanmanın doğru sonuçlar vereceğini düşünmüşlerdir (He vd., 2020).

Uydu teknolojilerinin henüz gelişim aşamasında olduğu dönemlerde (1960 – 2000 yılları arası), arazi örtüsü ve kullanımı hakkında hem bilgi edinmek hem de zaman içindeki değişimlerin daha net bir şekilde gözlemlenebilmesi açısından tarihi hava fotoğrafları, yüksek çözünürlüklü görsel verilerin elde edilmesi ve coğrafi analizlerin yapılabilmesi için vazgeçilmez bir kaynak olmuştur. Bu durum, tarihi hava fotoğraflarının yüksek doğrulukta semantik olarak anlamlandırılmasını gerektirmiştir.

1.2. Tezin Amacı

Bu tez çalışması kapsamında, tarihi hava fotoğraflarının derin öğrenme mimarisi ile otomatik olarak sınıflandırılması amaçlanmıştır. Çalışmada, semantik segmentasyon işlemi için U-Net omurgalı DeepLabV3 mimarisi uyarlanarak kullanılmış ve bu mimarinin sonuçlarının değerlendirilmesi amaçlanmıştır. Veri etiketleme süreci, LabelMe yazılımı ile manuel olarak bina, zemin, bitki, yol ve tarım alanı olmak üzere beş farklı sınıfa ayrılacak şekilde etiketlenmiştir (URL-1, 2024). Ardından tarım alanı ve yol sınıfları zemin sınıfı altında birleştirilerek 3 sınıflı değerlendirme yapılmıştır. 1960 yılına ait etiketlenmiş gri tonlamalı tarihi hava fotoğrafları toplamda 120 adet 256×256 piksel şeklinde alt parçalara

bölündükten sonra %70 eğitim, %15 validasyon ve %15 test kümelerine dağıtılmıştır. Ayrıca mimariye, SYM kaynaklı yükseklik bilgisi entegre edilerek sonuçlar karşılaştırılmıştır. Performans değerlendirme aşamasında, IoU ve F1 Skor metrikleri kullanılmıştır.

1.3. Tezin Kapsam ve Organizasyonu

Genel Bilgiler başlığı altındaki giriş kısmında hava fotoğrafları ve tarihi hava fotoğrafları hakkında bilgi, tarihi hava fotoğraflarının zamansal değişim, kentsel gelişim süreci ve bunun gibi birçok alanda geniş veri kütüphanesi oluşturduğundan bahsedilmiştir. Metadata içermeyen tarama görüntülerin manuel işlem sürecinden geçmesinin zor bir işlem olduğu ve ayrıca otomatik segmentasyon ile sonuç çıkarmanın da bir o kadar zor olduğundan bahsedilmiştir. Semantik segmentasyonun tanımı verilmiş ve CNN'in semantik segmentasyon işlemlerinde kullanıldığından söz edilmiştir. Son olarak tarihi hava fotoğraflarının, uydu teknolojilerinin gelişmediği geçmiş dönemler hakkında bilgi almak için vazgeçilmez bir kaynak olduğu belirtilmiştir. Literatür araştırması bölümünde hava fotoğrafları ve tarihi hava fotoğrafları, görüntü segmentasyonu ve derin öğrenme ile ilgili yapılan çalışmalar, bu çalışmaların amacı, kullandığı veriler ve kullanılan yöntemler bir özet şekilde sunulmuştur. Temel Kavramlar kısmında tezin amacı ile ilgili kullanılan sistemler ve algoritmalar açıklanmıştır. Yapılan çalışmalar bölümünde çalışma alanları hakkında bilgi verilmiş, kullanılan veriler ve yazılımlar anlatılmış, son olarak uygulama aşaması detaylıca açıklanmıştır. Bulgular bölümünde, uygulama sonucu elde edilen sonuçlar ve bulgulara yer verilmiştir. Tartışma kısmında ise U-Net mimarisi ile segmentasyon sonrası elde edilen sonuçlara ilişkin doğruluk değerleri irdelenmiştir. Sonuçlar ve öneriler bölümünde ise yapılan çalışmanın avantajları ve literatüre katkısından bahsedilmiştir.

1.4. Literatür Araştırması

Bu bölümde; hava fotoğraflarının kullanım alanları ve kullanım yöntemleri, tarihi hava fotoğraflarının önemi, görüntü segmentasyonu, derin öğrenme ve CNN algoritmaları ile ilgili literatürde yapılan çalışmalar incelenmiş, bu çalışmalarda izlenen yöntem ve sonuçları aşağıda paylaşılmıştır. İncelenen 30 makale tarihi hava fotoğraflarının kullanıldığı ve kullanılmadığı çalışmalar şeklinde 2 başlık altında toplanmıştır.

Tarihi hava fotoğraflarının kullanıldığı çalışmalar;

Schiefer & Gilbert (2007), buzul öncesi çağlarda morfometrik arazi değişimlerini yeniden yapılandırmak için tarihi hava fotoğrafları ve dijital fotogrametrik uygulamaların kullanılabilirliğini araştırmışlardır. Morfometrik değişimin incelenmesi için, farklı tarihteki fotoğraflar üzerinden elde edilen dijital yükseklik modeli (Digital Elevation Model - DEM) yüzeylerinin farkı alınarak değerlendirilmiştir. Elde edilen sonuçlar buzul gerilemesi, moren oluşu erozyonu ve buzul alanındaki orman büyümesiyle ilişkili arazi yüzey değişimlerini tanımlamak için kullanmışlardır. Taranan arşivlenmiş fotoğraflara uygulanan dijital fotogrametrinin, tarihsel DEM yüzeylerini oluşturmada kullanılabileceğini ve buzul öncesi çağlardaki çevresel değişimin uzun vadeli izlenebileceğini tespit etmişlerdir.

Muñiz & García (2017), Gijón'daki banliyö alanındaki yeni kentsel gelişmelerin sürdürülebilirlik derecesini ele almayı amaçlamışlar ve bu kapsamda bilgi edinmek amacıyla tarihi hava fotoğrafçılığının kullanımını önermişlerdir. Oviedo Üniversitesi Coğrafya Bölümü tarafından tutulan tarihi hava fotoğrafçılığının dijital koleksiyonunun, kentsel gelişim süreçlerini analiz ederken önemli bir kaynak olduğunu ve görüntülerin, kentsel dokunun farklı parçalarının tanımlanmasına ve değişim sürecinin nasıl ortaya çıktığının anlaşılmasına yardımcı olduğunu belirtmişlerdir. Yeni kentsel gelişmelerin mekansal örüntüsünü tespit etmek için fotoğraf yorumlama teknikleri kullanmışlardır. Zaman içinde hava fotoğrafçılığının kullanımı, birden fazla uzay-zaman yapılandırması içindeki özelliklerin belirlenmesine olanak tanıdığı sonucuna varmışlardır.

Le Bris vd. (2020), tarihi hava fotoğraflarından arazi örtülerini tespit etmek için derin öğrenme semantik segmentasyonunu kullanmayı amaçlamışlardır. Ortofoto ve sayısal yükseklik modeli verilerini kullanarak U-Net-Deconv-Net'ten esinlenen derin öğrenme mimarisinin iki çeşidini geliştirmişlerdir. Bu bağlamda U-Net ve Fuse-Net için önerilen yöntemleri denemişlerdir. Ardından arşiv veri kümelerini işlemek için yakın tarihli bir veri tabanından türetilen bir temel gerçek üzerinden eğitmişlerdir. Buradaki asıl amaçları, temel topografik sınıfları almak için derin öğrenme yönteminin gürültülü ve kısmen yanlış eğitim verilerine karşı sağlamlığını değerlendirmek ve sayısal yükseklik modeli bilgilerinin görüntü bilgileriyle en iyi şekilde nasıl birleşebileceğini belirlemektir. Su, mahsuller, yollar, bitki örtüsü ve binalar olmak üzere toplam 5 ana sınıfları olsa da çalışmanın kapsamı gereği yol ve bina sınıfları çıkarımına odaklanmışlardır. Önerdikleri yöntemin, temel gerçeklikteki hatalara karşı oldukça dayanıklı olduğunu tespit etmişlerdir.

Mboga vd. (2020), tarihi hava pankromatik fotoğraflarından arazi örtüsünün çıkarılması için derin öğrenmenin ilk uygulamasını sunmuşlardır. Farklı iki ağ mimarisi düşünülerek tam evrişimli bir yaklaşım araştırmışlardır. İlk yaklaşımda, aşağı örnekleme olmadan atrous evrişim katmanlarını kullanırken, ikinci yaklaşım hem aşağı örnekleme hem de öğrenilmiş üst örnekleme evrişim katmanlarına (U-Net) sahip olduğunu belirtmişlerdir. Önerilen bu mimarileri; binalar, yüksek bitki örtüsü ve çıplak arazi ile düşük bitki örtüsü olmak üzere üç ana sınıfı tespit etmek üzere eğitmişlerdir. Çalışma bölgeleri olan Goma-Gisenyi ve Bukavu'da %90'dan fazla ve Bujumbura'da %85'ten fazla genel doğruluklar elde edilmiştir. Sonuç olarak tarihsel hava fotoğrafı arşivlerinin kullanımı için standart makine öğrenimi sınıflandırıcılarından daha iyi performans gösteren yeni bir metodoloji sunmuşlardır.

Whiteside vd. (2020), dünya mirası listesinde yer alan Kakadu Milli Parkı'ndaki tarihsel değişimi inceleme doğrultusunda odunsu örtü çıkarmak için tarihi hava fotoğrafları ve uydu görüntüleri şeklindeki iki çeşit uzaktan algılama verisine uygulanan yarı otomatik bir teknik geliştirmişlerdir. Geliştirdikleri nesne tabanlı görüntü analiz tekniğini, dört farklı tarihten dört veri kümesine uygulamışlardır. Kullanılan 4 farklı veri seti; gri tonlamalı, renkli ve kızılötesi hava fotoğrafı mozaikleri ve yüksek mekansal çözünürlüklü uydu görüntüsü olduğunu belirtmişlerdir. Doğrulama sonuçları ile yöntemin ürettiği yüksek doğruluğu ve çalışma bölgesindeki zamansal ve mekansal analiz için uygunluğunu göstermişlerdir. Her bir veri kümesinden elde edilen odunsu örtünün genel doğruluklarının %94'ü aştığını tespit etmişlerdir. Kullandıkları tekniğin başarısı nedeniyle, maden kapatılması için ekosistem restorasyon kriterlerini bilgilendirmek amacıyla odunsu örtünün zaman içindeki değişikliğini değerlendirmek için çalışma alanı üzerindeki farklı tarihli daha fazla veri kümesine uygulanacağını belirtmişlerdir.

Dorozynski vd. (2024), arazi örtüsü sınıflandırması için tarihi ortofotoları ve topografik haritaları kullanarak çok modlu bir UPerNet sınıflandırıcısı önermişlerdir. Sınıflandırıcıyı, sırasıyla segmentasyon ve bitki örtüsü segmentasyonu oluşturmak için eğitmişlerdir. Her iki sınıflandırıcıyı da bağımsız test setlerinde değerlendirip ve muadiliyle yani bir hava görüntüsü sınıflandırıcısı ve bir harita sınıflandırıcısıyla karşılaştırmışlardır. Çok-modlu bina segmentasyonu için ortalama %62,2'lik bir F1 puanı ve çok-modlu bitki örtüsü segmentasyonu için ortalama %83,7'lik bir F1 puanı elde etmişlerdir.

Riccardi vd. (2024), Kruger Milli Parkı'nın tarihi odunsu bitki örtüsü haritasını üretmek için 1939-1944 yılları arasında çekilmiş hava fotoğraflarından oluşan bir kompozit

oluşturmuşlardır. Google Earth Engine kullanarak, rastgele orman sınıflandırıcısı ile nesne tabanlı görüntü analizi gerçekleştirmeyi amaçlamışlardır. Doku, şekil, komşu özellikler ve spektral değişkenleri eğitim veri setine entegre ederek, siyah beyaz hava fotoğraflarından odunsu bitki örtüsünün tanımlanmasını sağlamışlardır. Başlangıçta, önerilen yöntemi küçük bir görüntü kümesinde test etmişler ve ardından tüm tarihi hava fotoğraflarına uygulamışlardır. Sonuçlarda, 1939-1944 yılları arasında parkın %26'sının odunsu bitki örtüsüyle kaplı olduğunu belirtmişler ve %89 genel doğruluk elde etmişlerdir. Bu çalışma ile önerilen yöntemlerin yüksek çözünürlüklü hava fotoğraflarını verimli bir şekilde analiz ettiğini ve arazi yönetimi için büyük ölçekli tarihi arazi örtüsü temel çizgileri oluşturmaının önemini belirtmişlerdir.

Tarihi hava fotoğraflarının kullanılmadığı çalışmalar;

Gupta vd. (2021), afet sonrası müdahale yapabilmek, etkilenen alanları ve erişilebilir yolları belirlemek için segmentasyon sinir ağlarını kullanan bir çerçeve önermişlerdir. ImageNet ile hava görüntü segmentasyonu için popüler segmentasyon modellerinin performansları karşılaştırılmışlardır. ImageNet üzerinde, ön işlem adımının genellikle segmentasyon performansını iyileştirdiğini gösterdiğini tespit etmişlerdir. Eğitim verisi olarak OpenStreetMap'ten (OSM) elde edilebilen açık veriler kullanılmışlardır. ENetSeparable, ENet'e kıyasla %30 daha az parametre kullanarak, son teknoloji ağlarla karşılaştırılabilir segmentasyon sonuçlarına ulaşmışlardır.

Liu vd. (2021), H-KFCM tabanlı bir hava görüntüsü değişim algılama algoritması önermişler ve algoritmanın performansını doğrulamak için çalışmalar yapmışlardır. Hava görüntüsü işlemede derin öğrenmenin gradyan kümeleme algoritması doğrultusunda çalışma yürütmüşlerdir. Hava verilerinin büyük ölçekli işlenmesi için CUDA'yı (Compute Unified Device Architecture) kullanmışlardır. Kullanılan yöntemin daha hızlı bir hesaplama hızına sahip olduğu ve yüksek çözünürlüklü görüntülerde daha az zaman kullandığı sonucuna varmışlardır. Ayrıca CPU'ya kıyasla iyi bir hızlanma oranına sahip olduğunu tespit etmişlerdir.

Toorani vd. (2021), 1955-2018 yılları için Landsat uydularından aldıkları TM, ETM ve OLI görüntüleri ile Google Earth görüntülerinin eklendiği hava fotoğrafları kullanarak Hazar Denizi'nin güney kıyılarındaki Tajan ve Sefidrud bölgelerindeki değişimini araştırmışlardır. Kıyı şeridi değişim analizi için, kullanılan yüksek çözünürlüklü hava fotoğrafları ve Google Earth görüntüleri üzerinden su hattı algoritmasından yararlanarak analiz etmişlerdir. ArcGIS 10.3'teki DSAS uzantısını kullanarak kıyı şeridi değişiklikleriyle

ilgili hesaplamaları 1955-1977, 1977-1995, 1995-2002 ve 2002-2018 olmak üzere 4 zaman diliminde gerçekleştirmişlerdir. Tajan kıyı şeridinde kıyı birikmesinin birinci, üçüncü ve dördüncü zaman dilimlerinde belirgin olduğunu ve ikinci zaman diliminde kıyı erozyonu olduğunu tespit etmişlerdir. Ancak Sefidrud kıyıları için değişim oranının tutarsız olduğunu tespit etmişlerdir. Bu bölgedeki deniz seviyesi ve kıyı şeridi değişiklikleri arasındaki uyumsuzluğun, deniz seviyesinden farklı olarak kıyı şeritlerinin durumunu etkileyen çeşitli faktörlerin var olduğunu tespit etmişlerdir.

Gevaert & Belgiu (2022), tam evrişimli ağını (Fully Convolutional Network - FCN) eğitmek için kullanılan görüntüler ile farklı bir alandaki bir test görüntüsü arasındaki benzerliği tanımlamak için manzara ölçümlerini kullanmışlardır. Manzara ölçümleri ile eğitim kümesinin aynı ölçümleri arasındaki benzerliği analiz etmişler ve bu benzerliğin FCN'nin performansı ile ilişkisini incelemişlerdir. Sonuçların, referans veriden hesaplanan manzara ölçümlerinin ve denetimsiz kümeleme/segmentasyon yöntemlerinden elde edilen sonuçların, F1 puanına güçlü ve orta düzeyde korelasyonlar gösterdiğini tespit etmişlerdir. Bunun sonucunda manzara ölçümleri gibi göstergelerin, eğitilmiş bir modelin yeni bir alana uygulanmaya uygun olup olmadığına karar verilmesinde kullanılan eğitim veri kümesinin oluşturulmasında iyi bir yaklaşım olduğunu belirtmişlerdir.

Petti & Li (2022), İnsansız Hava Aracı'ndan (İHA) toplanan görüntüleri kullanarak pamuk çiçeklerini otomatik sayan CNN'e dayalı bir mimari kullanmışlardır. Ayrıca modeli, Çoklu Örnek Öğrenme (Multiple Instance Learning - MIL) kullanarak eğitmişlerdir. MIL ile en az bir çiçeğe sahip herhangi bir görüntüyü pozitif sınıf, diğerlerini ise negatif sınıf olacak şekilde ikili bir sınıflandırma yapmışlardır. MIL kullanan görüntü işleme modellerinin performansını iyileştirecek yeni bir model geliştirmişlerdir. Modeli, bir pamuk bitkisi görüntü veri kümesi üzerinde eğitmişlerdir. Ek olarak, veri kümesi için açıklamaları oluştururken insan müdahalesini en aza indirmek için aktif öğrenme tabanlı bir yaklaşım kullanmışlardır. Birden fazla modeli farklı sayıda parametreyle test etmişler ve 2,43'lük minimum ortalama mutlak sayım hatası elde etmişlerdir. Sonuç olarak, bu çalışma ile modeli etiketlerken insan müdahalesini en aza indirip çiçek sayma problemini çözmek için umut verici bir yöntem olduğunu göstermişlerdir.

Behera vd. (2023), segmentasyon işlemi için LW-AerialSegNet olarak da bilinen CNN mimarisi önermişlerdir. Önerilen mimariyi değerlendirmek için İHA tabanlı bir görüntü segmentasyonu veri kümesi NITRDrone veri kümesi ve UDD (Urban Drone Dataset) kullanmışlardır. NITRDrone ve UDD veri kümeleri ile sırasıyla %82 ve %71'lik bir

IoU elde etmiş ve bu sayede en son teknolojik yöntemler arasında üstünlüğünü gösterdiğini belirtmişlerdir.

Wang vd. (2023), palmiye yaprağı el yazması (Palm-Leaf Manuscript - PLM) segmentasyonu için U-Net mimarisine dayalı PLM-SegNet adlı bir yöntem önermişlerdir. Elde ettikleri görüntüleri Labelme yazılımında etiketlemişlerdir. Daha sonra veriyi, PLM-SegNet modelini eğitmek, doğrulamak ve test etmek için belirli bir boyutlar halinde kırpılmışlardır. Ardından PLM görüntülerini segmentlere ayırmışlardır. İki bağımsız test setinden sırasıyla; %99,73 ve %98,36 piksel doğruluğu, %99,42 ve %98,31 IoU, %99,68 ve %99,95 geri çağırma ve %99,70 ve %99,15 F1 puanı sonuçlarını elde etmişlerdir. Sonuçların, etiketli eğitim verilerinin az olduğu durumlarda PLM-SegNet'in palmiye yaprağı el yazması segmentasyonu için hassas ve otomatik bir yöntem olduğunu belirtmişlerdir.

Abd Elaziz vd. (2024), değiştirilmiş bir SAO (Snow Ablation Optimizer) algoritmasına dayalı alternatif çok seviyeli eşik görüntü segmentasyonunu tanıtmışlardır. Farklı eşik seviyelerinde 16 adet hava fotoğrafını segmentlerken SAO'nun DCSAO adlı değiştirilmiş versiyonu kullanmış ve kalitesini doğrulamak için CEC2022 kullanmışlardır. Sonuçların performans ölçütlerine göre DCSAO'nun diğer algoritmalara kıyasla üstün performansını gösterdiğini belirtmişlerdir.

Cheng vd. (2024b), hava görüntüleri ve fotogrametri yoluyla gerçeklik yakalamayı kullanan bir hasar ve enkaz analizi çerçevesi önermişlerdir. Bu çerçevede, bölge tabanlı bir sinir ağını, hava fotoğraflarından enkaz yerlerini tespit etmek için kullanmışlardır. Çalışma bölgesi içerisindeki test alanında, 3B (3 Boyutlu) çevre modelini oluşturmuşlardır. 3B modelleme doğruluğu, afet müdahalesinde önemli olduğundan afet etki analizi ve enkaz hacmi tahmininin doğru tespiti ve 3B modeli oluştururken gereken optimum doğruluğu sağlamak için 2B (2 Boyutlu) hava fotoğraflarında bindirme oranını araştırmışlardır. Sonuç olarak enkaz analizi için en az %60 örtüşme, düz yeşil alanlar için en az %50 örtüşmenin yeterli olacağını belirtmişlerdir. Genel olarak, afet müdahale uygulamaları için %60 ile %70 arasındaki bir örtüşme oranının optimum olduğunu tespit etmişlerdir.

Chudasama vd. (2024), İHA tarafından çekilen 0,55 cm'lik mekansal çözünürlüklü hava fotoğraflarından temel kaya kırığı izlerinin otomatik haritalanması için yeni bir U-Net CNN tabanlı iş akışı sunmuşlardır. Sonrasında çıkıntı algılama algoritmasını U-Net tahmin sonuçlarına uygulamışlar ve ardından kırık izi piksellerini vektörleştirmişlerdir. Vektörleştirme sürecinde hem piksellerin yoğunluk değerlerini hem de topolojik bağlantıyı kullanmışlardır. Sonuçlarda, modelin sınıf dengeli doğruluk puanının 0,945 olduğunu ve

kırık-iz piksellerinin %88,79'unu tahmin ettiğini tespit etmişlerdir. Bu çalışma ile temel kaya-kırık izlerinin hızlı ve etkili bir şekilde otomatik haritalanması için İHA görüntülerinin başarılı şekilde kullanılabileceğini tespit etmişlerdir.

Ferreira vd. (2024), LiDAR ve dijital hava görüntüleri kullanılarak tropikal bir kentsel alanda ağaç türü sınıflandırmasını iyileştirmek için bir yöntem sunmuşlardır. Ağaç yapraklarının yüzey normalleri, yoğunluk, ağaç yüksekliği ve yaprak alanı indeksi dahil olmak üzere dört LiDAR özelliği çıkarmışlardır. İki farklı deneysel yaklaşım yürütmüşlerdir. İlkinde, LiDAR kullanarak kodlayıcı-kod çözücü CNN'leri eğitmişlerdir. İkincisinde, iki kodlayıcı-kod çözücü açısından özellik haritalarını birleştiren bir optik-LiDAR füzyon stratejisi geliştirmişlerdir. Bir ağı sadece optik bantlarla eğitirken, diğer ağı ilk deneyde sınıflandırma doğruluğunu iyileştiren LiDAR ile eğitmişlerdir. Deney sonuçlarında, ağaç türleri arasında ayırımında yüzey normallerinin ve yoğunluğun yararlılığını göstermişlerdir. Optik-LiDAR füzyon stratejisinin, yalnızca optik bant eğitimine kıyasla ortalama F1 puanını 12,6 yüzde puanı artırdığını tespit etmişlerdir. Bu çalışma ile tropikal bölgelerdeki kentsel ağaç türlerinin haritalanmasına ve izlenmesine katkı sağlamışlardır.

García vd. (2024), çok çözünürlüklü uydu ve hava görüntüleri veri setinden güneş panellerini segmentlere ayırmak için Mask2Former modelinin uygulamasını gerçekleştirmişlerdir. Güneş panellerinin hassas segmentasyonunu elde etmek için Mask2Former'ın derin öğrenme yeteneklerinden yararlanmayı amaçlamışlardır. Önceden var olan Mask2Former modelini düzenleyerek U-Net ve DeepLabV3+ gibi diğer derin öğrenme modellerine göre üstünlüğünü araştırmışlardır. Mask2Former'ın, %95'in üzerinde IoU puanları elde ederek semantik segmentasyonda yeni bir son teknoloji oluşturduğunu tespit etmişlerdir.

Gong vd. (2024), karmaşık görüntülerde karides tespiti için bir transformatör tabanlı karides dedektörü (Transformer-based Shrimp Detector - TSD) önermişlerdir. Sonrasında görüntü özelliklerini çıkarmak için CNN kullanmışlardır. Deneysel sonuçlar ile önerilen yöntemin, geleneksel nesne algılama modellerini geride bırakarak %82,7 ortalama hassasiyette algılama doğruluğuna ulaştığını tespit etmişlerdir.

Hou & Li (2024), geleneksel yöntemlerde karşılaşılan, özellik çıkarma işleminin düşük doğruluk ile yapabilmeyi ve 3B modellemeye yetersiz ayrıntı zorluklarını ele almayı amaçlamışlardır. Bu sorunları ele almak için, Maske Bölgesi-Evrişimli Sinir Ağı (Mask R-CNN) tabanlı bir özellik çıkarma işlemi yöntemi önermişlerdir. Hava fotoğrafları ile otomatik algılama ve özellik çıkarma işlemini gerçekleştirmek için derin öğrenme

tekniklerini önermişlerdir. Mask R-CNN tabanlı yöntem ile veri kümesinin işlenmesi ve sınıflandırılmasını gerçekleştirmiş ayrıca daha fazla analiz için aday bölgeler üretmişlerdir. CNN, Bölge Tabanlı Konvolüsyonel Sinir Ağı (Region-based Convolutional Neural Network - R-CNN), Hızlı Bölge Tabanlı Konvolüsyonel Sinir Ağı (Fast Region-based Convolutional Neural Network - Fast R-CNN), Daha Hızlı Bölge Tabanlı Konvolüsyonel Sinir Ağı (Faster Region-based Convolutional Neural Network - Faster R-CNN) ve Üretken Çatışmacı Ağ (Generative Adversarial Network - GAN) gibi modellerle karşılaştırılmalı analiz yapmışlardır. Mask R-CNN tabanlı yaklaşımın özellik çıkarmada, yaklaşık %95 sınıflandırma doğruluk elde ettiğini aynı zamanda güçlü kararlılık ve genelleme yetenekleri de sergilediğini tespit etmişlerdir.

K. Alkhalifa vd. (2024), İHA görüntüleri üzerinde derin öğrenme destekli hava görüntüsü sınıflandırma yaklaşımı ile bir Prairie Dog Optimizasyon Algoritması (Prairie Dog Optimization Algorithm with a Deep learning-assisted Aerial Image Classification Approach - PDODL-AICA) sunmuşlardır. PDODL-AICA tekniği ile hava fotoğraflarını çok sayıda sınıfa sınıflandırmak için en uygun derin öğrenme modelini kullanmışlardır. Özellik çıkarma prosedürünü EfficientNetB7 modelini kullanılarak yürütmüşlerdir. PDODL-AICA tekniği ile hava fotoğraflarını sınıflandırmak için bir evrişimli varyasyonel otokoder modeli kullanmışlardır. PDODL-AICA modelinin performans değerlendirmesini İHA görüntü veri kümesi üzerinde uygulanmışlardır. Sonuç olarak PDODL-AICA yaklaşımının güncel modeller üzerindeki etkisini tespit etmişlerdir.

Khan vd. (2024), bitkiler, tahıllar, meyveler ve sebzeler dahil olmak üzere çeşitli tarım alanlarındaki sınıflandırma zorlukları için multispektral ve hiperspektral görüntüleri kapsayan kapsamlı bir araştırma sunmuşlardır. Tarımsal alanda hiperspektral görüntüleri sınıflandırmak için makine öğrenimi tekniklerinden yararlanmaya amaçlamışlardır. Derin öğrenme ve destek vektör makinelerinin tarımda hiperspektral görüntü sınıflandırması için yaygın olarak kullanıldığını tespit etmişlerdir. Ayrıca spektral görüntülerle çalışmanın zorluklarına değinmişlerdir. Tarımda spektral görüntülemenin mevcut durumu ve gelecekteki potansiyeli hakkında bilgi edinmeyi amaçlamışlardır. Spektral görüntü veri kümelerinin kullanılabilirliği ve kalitesi arttıkça, tarım sektöründe daha doğru uygulama ve sonuç elde edilebileceğini tespit etmişlerdir.

Masoumi vd. (2024), gelişmekte olan kentsel alanlarda saha etkisini incelemek için hızlı ve uygun maliyetli bir yaklaşım önermişlerdir. Toprak birimlerinin jeomorfik ortamı ile temel frekansları arasındaki mekansal korelasyonu kullanarak geliştirdikleri bu yöntem

ile çalışma alanına ait eski hava fotoğraflarını kullanarak birleşik bir ortofoto-mozaiğini yeniden üretmişlerdir. Oluşturulan ortofoto-mozaik sayesinde şehrin mevcut kentsel kapsamından önceki bozulmamış jeomorfik arazi şekilleri ve özellikleri tespit edebilmişlerdir.

Scala vd.(2024), anlamsal segmentasyonla desteklenen yeni bir CNN tabanlı yaklaşım önermişlerdir. Daha çok bölgesel ölçekli çalışmalarda kullanılan bu yaklaşımda U-Net mimarisine dayanan bir CNN modeli kullanıldığını belirtmişlerdir. Uydu görüntülerindeki farklı piksel sınıflarını tanımlamak ve daha sonra kıyı şeridini otomatik olarak tespit etmeyi amaçlamışlardır. Coast Train veri kümesini CNN modelini eğitmek için kullanmışlar ve kullanılan yaklaşım sayesinde hassas bir kıyı şeridi çıkarımı sağlamışlardır. Segmentasyon sürecinde %85 doğruluk ve %80 IoU elde eden etmişlerdir. Doğruluğun yanı sıra modelin, gelişmiş kıyı analizi için yeterli sonuçlar ortaya çıkardığını belirtmişlerdir.

Sylvain vd. (2024), 10.000 km²'lik bir alanda orman türlerini ve arazi örtüsü tiplerini haritalamak için bir CNN topluluğu kullanmışlardır. Üç eğitim veri kümesinin ve üç yaygın CNN mimarisinin (VGG16, ResNet50v2, Densenet121) birleşiminden elde edilen dokuz modeli eğitmek ve test etmek için coğrafi olarak referanslandırılmış bir etiket veri tabanı oluşturmuşlardır. Modelleri, çok bantlı hava fotoğrafları ve LiDAR nokta bulutu verilerinden türetilen bir yükseklik modeli üzerinde eğitmişler ve ağaç türlerinin ve arazi örtüsü tiplerinin dağılımını haritalamak için kullanmışlardır. %90 küresel doğruluk elde etmişlerdir. Sonuçlarda önerilen yöntemin tüm bireysel mimarilerin performansını aştığını belirtmişlerdir.

Yang vd. (2024), hava fotoğrafları yardımıyla flamingoları saymak için yarı denetimli bir makine öğrenme yöntemi geliştirmişlerdir. Ayrıca uydu görüntüleri kullanarak yağış ve su baskını sıklığını analiz ederek flamingoların olası sıklığını tahmin etmişlerdir. Son olarak ise çalışma alanının flamingo üreme alanı olarak önemini incelemişlerdir. %97'nin üzerinde test doğruluğu elde etmişlerdir. Bu yöntemlerin, diğer büyük flamingo ve diğer hayvan konsantrasyonlarına uygulanabileceğini belirtmişlerdir.

Yıldırım vd. (2024), bina çıkarımı için FwSVM-Net adı verilen yeni bir CNN mimarisi tasarlamayı amaçlamışlardır. Hava görüntülerinden otomatik bina çıkarımı için Massachusetts Bina veri seti kullanmışlardır. FwSVM-Net'in test verileri üzerindeki performansı genel doğruluk, kesinlik, geri çağırma, F1 puanı ve IoU için sırasıyla %97, %91, %87, %89 ve %86 olarak hesaplamışlardır. FwSVM-Net'in U-Net mimarisiyle doğruluk açısından yaklaşık $\pm$ %2 benzerlik gösterdiğini tespit etmişlerdir. Ayrıca FwSVM-Net'in

eğitim sürecini U-Net mimarisine göre yaklaşık iki kat daha hızlı tamamladığını gözlemlemişlerdir.

Xu vd. (2024), hava ve uydu görüntülerinden hayvan tespiti için derin öğrenme yöntemlerinin uygulamalarıyla ilgili literatür incelemesi yapmışlardır. İncelenen yayınlarda yöntemleri; görüntü düzeyi, nokta düzeyi, sınırlayıcı kutu düzeyi, örnek segmentasyon düzeyi ve belirli bilgi düzeyi olarak kategorize etmişlerdir. İstatistiksel sonuçlarda, YOLO, Faster R-CNN, U-Net ve ResNet'in en çok kullanılan sinir ağı yapıları olduğunu tespit etmişlerdir. Derin öğrenme yöntemlerinin kullanım zorluklarını; dengesiz veri kümeleri, küçük örnekler, küçük nesneler, görüntü açıklama yöntemleri, görüntü arka planı, hayvan sayımı, model doğruluk değerlendirmesi ve belirsizlik tahmini olarak belirtmişlerdir. Bu zorluklar karşısında olası çözümleri araştırmışlardır. Son olarak gelecekteki araştırma eğilimlerinin; video tabanlı tespit, çok yüksek çözünürlüklü uydu görüntüsü ile tespit, çoklu tür tespiti, uzmanlaşmış ağ yapıları ve büyük temel modellerinin geliştirilmesi olduğunu gözlemlemişlerdir.

Brar vd. (2024), mevcut görüntü segmentasyonu yaklaşımları üzerine kapsamlı bir araştırma yapmışlar ve algoritmaların kategorilendirilmesini gerçekleştirmişlerdir. Ayrıca farklı segmentasyon tekniklerinin sonuçlarını karşılaştırarak çok sayıda değerlendirme ölçütü elde etmişler ve görüntü segmentasyonundaki farklı uygulama alanları hakkında ayrıntılı bir araştırma yapmışlardır. Analiz edilen örneklerin büyük veri kümelerini görüntü iyileştirmede bir araya getirmenin zor bir işlem olduğunu belirtmişler ve yeni görüntülerde açıklama yapmanın zor olacağını tespit etmişlerdir. Bu sorunu çözmek için ise çok sayıda metodoloji uygulamışlardır. Sonuç olarak, görüntü segmentasyonu için çeşitli metrikleri açıklamış, değerlendirmiş ve uygulamasını gerçekleştirmişlerdiler.

1.5. Temel Kavramlar

1.5.1. Fotogrametri

Uzaktan algılama; çeşitli sensör ve ölçme cihazları yardımıyla fiziksel temasta bulunmadan cisimler hakkında mekansal ve niteliksel olarak bilgi elde edilmesi, bu bilgilerin analiz edilmesi ve yorumlanması süreci olarak tanımlanabilir (Kayman, 2015; Şen, 2021). Fotogrametri ise, nesnelere temas etmeksizin perspektif görünümülerinden elde edilen fotoğraflar ile yüzeylerin ve objelerin konumsal ve konumsal olmayan özellikleri hakkında

bilgi veren, bu bilgileri ölçerek ve yorumlayarak çeşitli analizler yapılmasını sağlayan bir bilim dalıdır (Donnadieu vd., 2003; Çetin, 2019; Sayar, 2021; Kutlu, 2023). 2 boyutlu görüntüler ile 3 boyutlu modelleme yapılabilmesini sağlayan fotogrametri, fotoğraflar yardımıyla nesnelerin radyometrik ve geometrik özelliklerinin belirlenmesi, yorumlanması ve analizinin yapılmasını sağlamaktadır (Egels & Kasser, 2001; Erdoğan & Mutluoğlu, 2020). Fotogrametri, kelime anlamı olarak ışık yardımıyla ölçme ve çizim yapma anlamına gelmektedir. Latince ışık anlamına gelen (photo), çizim anlamına gelen (gramma) ve ölçme anlamına gelen (metron) sözcüklerinden türetilmiştir (Moğulkoç, 2023).


Fotogrametri biliminin tarihsel süreci, 1839 yılında Niépce ve Daguerre tarafından fotoğrafın icat edilmesiyle başlamıştır (Acar, 2012). Bu gelişmenin ardından 1859 yılında fotogrametrinin kurucusu olarak bilinen ve fotoğraflar üzerinden ölçüm yapılmasını sağlayan ilk kamerayı icat eden Laussedat, Paris Bilim akademisinde uzaysal önden kestirme ile cisim koordinatlarının hesaplanmasını anlatmıştır (Acar, 2018). Fotogrametrinin geometrik ve analitik esasları ise 1800'lü yıllarda S. Finsterwalder tarafından oluşturulmuştur (Toprak, 2014).

Fotoğrafın çekildiği konuma bağlı olarak fotogrametri; yersel fotogrametri ve hava fotogrametrisi olarak ikiye ayrılmıştır. Yersel fotogrametri, nesne fotoğraflarının yer üzerinde çekilerek değerlendirildiği fotogrametri tekniğidir. Yersel fotogrametri tekniği, nesnelere yaklaşmanın mümkün olmadığı fakat görüntüsünün alınabildiği durumlarda kullanılmaktadır. Ayrıca hareket halindeki objelerin ve fiziksel boyutları farklı olan objelerin ölçümlerinde kullanılan bir tekniktir (Pulat, 2022). Yersel fotogrametride topografik yönden alım yapılmasının imkansız olduğu durumlarda çekim noktası değiştirilerek hava düzeyine çıkartıldığında yeryüzünün ve nesnelerin daha detaylı çekilebildiği tespit edilmiştir. Bu durum hava fotogrametrisinde büyük bir gelişme sağlamıştır. 1897'de Scheimpflug, hava fotoğraflarını düşeye yönde ve ölçeğe uygun olarak çevirip arazinin plana geçirilmesini sağlamıştır (Kılınçoğlu, 2016). 1. Dünya Savaşı'nda motorlu uçakların kullanılması hava fotoğraflarının kullanılmasını arttırmıştır (Nikolakopoulos vd., 2017; Imam, 2018).

Fotogrametrinin tarihsel gelişimine bakıldığında 4 temel dönem gözlemlenebilmektedir. Bunlar;

- Fotoğraftan önceki gelişme dönemi
- Fotoğraf ve ilk gelişmeler dönemi
- Klasik fotogrametri dönemi
- Çağdaş fotogrametri dönemi

şeklinde sıralanabilir (Hasdemir, 2023). Zaman içerisinde bilim ve teknolojinin hızla ilerlemesi, bunun sonucunda üretilen cihaz ve araçların gelişimiyle birlikte fotogrametri alt bölümlere ayrılmıştır (Şekil 1). Özellikle fotoğraf, uçak, bilgisayar ve elektronik cihazlar fotogrametrinin gelişmesi ve şekillenmesinde büyük rol oynamışlardır.




Şekil 1. Fotogrametrinin alt sınıfları (Toprak, 2014)

Fotogrametrinin önemli avantajlarından biri nesnelerin aslına uygun şekilde modellenerek 3B gösterimine imkan sağlamasıdır (Asri & Çorumluoğlu, 2007). Bu gösterim 3B koordinat bilgisi gerektirmektedir. Bazı özel durumlar hariç tek bir fotoğraf ile bu gereksinim karşılanamamaktadır. Tek bir fotoğraf ile sadece iki boyutlu koordinat bilgisi elde edilebildiği için 3B veriyi üretebilmek, aynı bölgeye ait bindirmeli iki veya daha fazla görüntü gerektirir (Karşı, 2022). Bu durum fotogrametri biliminin insan görme yetisi ile oldukça benzerlik taşıdığını göstermektedir. Açıklamak gerekirse, beynin her iki gözden gelen görüntüler arasındaki farkları (farklı perspektiflere sahip birbiriyle örtüşen görüntüler) kullanarak bir objenin 3B geometrisini ve obje ile gözlemci arasındaki mesafeyi hesaplarken devreye giren insan derinlik algısıyla aynı prensipte çalıştığı tespit edilmiştir (Anzai & DeAngelis, 2010; Lambert & Skousen, 2023).

1.5.2. Fotogrametrinin Matematiksel Modeli

Fotogrametri, yıllar içerisinde gelişim ve değişim göstermesine rağmen bu bilimin temel matematiksel modelinde değişiklik olmamıştır (Kılınçoğlu, 2016). Modelin temeli, nesne fotoğrafının izdüşümleri üzerinden matematiksel ve geometrik yaklaşımlardan yararlanılarak hesaplama yapılmasına dayanmaktadır (Ünal, 2019; Hasdemir, 2023). Detaylı açıklamak gerekirse, kolinearite (izdüşüm) denklemleri kullanılarak cisim uzayındaki noktaları gösteren ışınların izdüşüm merkezinden geçerek resim düzlemine bir doğru boyunca iz düşürülme temeline dayanır (Marangoz, 2002). Merkezi izdüşüm sayesinde nesnelerin fiziki olarak var olan her bir noktasının matematiksel olarak ifade edilmesinin yanı sıra matematiksel ve geometrik özelliklerin yardımıyla şekil, konum, büyüklük ve görünüş gibi öznitelik bilgilerinin belirlenmesi sağlanmaktadır (Saygılı, 2019; Karakış, 2021). Fotogrametrinin matematiksel modeli Şekil 2’de detaylı şekilde gösterilmiştir.



Şekil 2. Fotogrametrinin matematiksel modeli (Marangoz, 2002)

İzdüşüm görüntülerinin yeniden konumlandırılıp anlam kazanması için 2 aşamalı şekilde fotoğraf makinesinin iç ve dış yöneltme parametrelerinin hesaplanması gerekmektedir (Marangoz, 2002). İlk aşamada asal nokta koordinatları (x_0, y_0) ve asal uzaklık (c) kullanılarak iç yöneltme parametreleri hesaplanırken ikinci aşamada ise izdüşüm merkezi koordinatları (X_0, Y_0, Z_0) ve dönüklük değerleri (ω, ϕ, χ) kullanılarak dış yöneltme parametrelerinin hesaplanması amaçlanmaktadır (Ünal, 2019; Karşlı, 2022).

Resim ve cisim koordinat sistemleri arasındaki açısal ilişkiler, koordinat eksenleri arası doğrultu kosinüslerinin oluşturduğu (3×3) ortogonal dönüşüm matrisi ile belirlenir. Resim koordinat sisteminde p noktasının konumunu belirleyen resim vektörü;

$$P = \begin{bmatrix} x_p & - & x_0 \\ y_p & - & y_0 \\ 0 & - & c \end{bmatrix} \quad (1)$$

şeklinde olur. Burada x_0, y_0 asal nokta koordinatlarını, c odak uzaklığı/kamera sabitini temsil eder. Fotoğraf makinesi sonsuza odaklanmadığı sürece asal uzaklık, odak uzaklığına eşit olamaz. Bu durumda asal uzaklık odak uzaklığında Δf kadar sapma değeri oluşturmaktadır.

$$c = f + \Delta f \quad (2)$$

Cisim uzay koordinat sisteminde P noktasının konum vektörü;

$$P = \begin{bmatrix} X_p & - & X_0 \\ Y_p & - & Y_0 \\ Z_p & - & Z_0 \end{bmatrix} \quad (3)$$

şeklindedir. Kolinearite denklem eşitliğine göre, p resim ve P cisim vektörleri arasındaki matematiksel denklem;

$$p = k.D.P \quad (4)$$

şeklinde olur. Daha açık şekilde ifade edilirse;

$$p = \begin{bmatrix} x_p - x_0 \\ y_p - y_0 \\ 0 - c \end{bmatrix} = k \cdot D \cdot \begin{bmatrix} X_p - X_0 \\ Y_p - Y_0 \\ Z_p - Z_0 \end{bmatrix} \quad (5)$$

Burada ölçek faktörü olan k;

$$k = p/P \quad (6)$$

olarak ifade edilmektedir. Resim koordinatlarının bilinmesi durumunda cisim koordinatları;

$$k = 1/k \cdot D^T \cdot p \quad (7)$$

$$\begin{bmatrix} x_p - x_0 \\ y_p - y_0 \\ 0 - c \end{bmatrix} = \begin{bmatrix} 1 \\ D^T \\ k \end{bmatrix} \cdot \begin{bmatrix} X_p - X_0 \\ Y_p - Y_0 \\ Z_p - Z_0 \end{bmatrix} \quad (8)$$

şeklinde hesaplanmaktadır. Kolinearite eşitliklerinde k ölçek faktörünün her bir ışıın için ayrı ayrı hesaplanması gerekmektedir. Bu sebeple oluşan matematiksel ifadelerden k ölçek faktörü sadeleştirilerek yok edilirse;

$$f_1 = x - x_0 + c \frac{a_{11}(X - X_0) + a_{12}(Y - Y_0) + a_{13}(Z - Z_0)}{a_{31}(X - X_0) + a_{32}(Y - Y_0) + a_{33}(Z - Z_0)} \quad (9)$$

$$f_2 = y - y_0 + c \frac{a_{21}(X - X_0) + a_{22}(Y - Y_0) + a_{23}(Z - Z_0)}{a_{31}(X - X_0) + a_{32}(Y - Y_0) + a_{33}(Z - Z_0)} \quad (10)$$

matematiksel denklemler elde edilmiş olur (Kılınçoğlu, 2016).

1.5.3. Hava Fotogrametrisi ve Uzaktan Algılama Kameraları

Fotogrametrinin ilk uygulamaları yersel fotogrametri ile başlamış olsa da zaman içerisinde teknolojik imkanların gelişmesi, ihtiyaç duyulan gereksinimlerin farklılaşması ve harita yapımında geniş olanaklar sağlaması nedeni ile yerini hava fotogrametrisine bırakmıştır (Ulvi, 2015). Uzaktan algılama teknolojisinin ve uydu bazlı görüntüleme sistemlerinin henüz var olmadığı dönemlerde, yeryüzüne ait çeşitli bilgilerin toplanması ve

haritalarının üretilmesi çalışmalarında hava fotoğrafları kullanılmıştır (Bilgi, 2007). Hava fotogrametrisi, uçak, helikopter, İHA veya diğer platformlar yardımıyla belirli bir yükseklikten fotografik veri sağlayan bir fotogrametri tekniğidir (Çiçekli, 2015). Haritacılıkta özellikle büyük alanlarda tercih edilen hava fotogrametrisi, standart bir harita yapım yöntemi olarak kullanılmaktadır (Ulvi, 2015). Hava fotoğrafları fotografik harita üretimi haricinde; yer yüzeyinin yapısı hakkında bilgi toplama ve bilgi sistemleri oluşturma, yapılaşmanın ya da bitki örtüsünün izlenmesi, orman alanlarındaki ağaç türlerinin tespiti, madencilik ve jeolojik araştırmalar, çevre kirliliği, hidrolojik incelemeler, sel baskınları ve orman yangınları gibi çeşitli alanlarda tercih edilmektedir (Limandal, 2019).

En eski görüntüleme sistemlerinden olan fotoğraf, yeryüzünün doğal ve yapay objelerinden yansıyan enerjinin doğrudan doğruya fotografik bir film üzerine düşürülmesiyle elde edilmektedir. Fotoğraf üzerinden metrik bilgilerin elde edilmesi ise günümüze kadar başarıyla uygulanmıştır. Hava fotogrametrisinde analog ve sayısal/dijital olmak üzere iki çeşit kamera mevcuttur (Selçuk vd., 2010). Analog hava kameraları metrik kameralardır ve ölçü kameraları olarak da bilinmektedirler. Bu kameralar, fotogrametrik belgeleme için özel olarak tasarlanmış olup optik ve mekanik donanımdan kaynaklı hataların en az seviyeye indirildiği, kamera kalibrasyonunun yapıldığı ve film şeridi üzerine çekim yapan özel kameralardır (Avşar, 2022). Kamera objektifleri, birçok mercekten oluşan algılayıcı bir sistem şeklinde tasarlanmıştır. İzdüşüm merkezinden geçen ışının sapmadan fotoğraf düzlemine ulaşabilmesinin yanı sıra distorsiyon hatası 5μ 'dan daha küçüktür (Kaya, 2010). En önemli özellikleri ise iç yöneltme elemanlarının bilinmesidir.

Analog hava kameraları, görüntü düzlemi sabit olan kameralardır ve mesafe ayarı yapılamamaktadır. Bu kameralar, ayırma derecesi yüksek ve distorsiyonları küçük olan hassas objektiflere sahiptirler. Bazı özel durumlar haricinde fotoğraflar film üzerine çekilmektedir (Kaya, 2010; Avşar, 2022). Son olarak analog hava fotoğraflarını sayısallaştırmak için fotoğrafların banyo ve baskı işlemleri yapıldıktan sonra yüksek çözünürlüğe sahip tarayıcılar kullanılarak bilgisayar ortamına aktarılmaktadırlar (Selçuk, 2008). Fotogrametrik analog hava kameraları zamanla tamamen dijital bir formata evrilmiştir (Gruber vd., 2008).

Dijital kameralar birçok yönden analog kameralara göre farklılık gösterir. Optik sistem genelde 8 mercek sistemine sahiptir. Bu merceklerin 4 tanesi siyah/beyaz (pankromatik), 3 tanesi multispektral-renkli (RGB-Red/Green/Blue) ve 1 tanesi kızılötesi (IR) kanallarından görüntü almaktadır. Frame (çerçeve) ya da linescaner (tarayıcı) görüntüleme özelliğine sahip

sistemlerdir (Selçuk vd., 2010). Dijital kameraların geometrik görünümünün iyileştirilmesinin yanı sıra sağlanan radyometrik bilgilerin iyileştirilmesi bu verilerin uzaktan algılama teknikleriyle kullanılmasını mümkün kılmaktadır (Markelin vd., 2010; Mesas Carrascosa vd., 2012).

Fotografik materyallerin yüksek geometrik doğruluğuna rağmen elektronik görüntüleme sistemlerinin gerçek zamanlılığı, analog kamera sistemlerinde gerekli olan banyo işlemlerine ve tarayarak sayısallaştırma işlemine gerek duyulmaması, bilgisayar uyumlu olması ile arşivleme işlemine gerek duyulmaması gibi etmenler dijital kamera sistemlerini, fotogrametri ve uzaktan algılama çalışmalarında analog sistemlere kıyasla avantajlı duruma getirmiştir. Bütün bu avantajlı yönler karşın geçmişte, analog kameralarının sağlamış olduğu çözünürlük, geniş çekim alanına erişememiş olmak ve yüksek maliyet dijital kameralarının fotogrametrik kullanılmalarını sınırlayabilmiştir (Selçuk vd., 2008).

1.5.4. Görüntü Sınıflandırma

Günümüzde, hava fotoğraflarının ve yüksek çözünürlüklü uydu görüntülerinin kullanımlarının artmasıyla birlikte nesne çıkarımı, uzaktan algılama alanında önemli bir konu haline gelmiştir (Tonbul & Kavzoğlu, 2017). Görüntülerinden bilgi çıkarımı konusunda yaygın olarak kullanılan sınıflandırma yöntemlerinin yanı sıra görüntü işleme teknikleri, harita projeksiyonuna dönüştürme, görüntü zenginleştirme ve değişim saptama gibi uygulamalarda da yaygın olarak kullanılmaktadır.

Sınıflandırma, görüntüler üzerinde yer alan nesnelere ait veri toplamayı sağlayan, ham veriyi kategorize edilmiş anlamlı bilgilere dönüştüren ve birbirileri ile aralarındaki ilişkiyi kuran, belirlenen sınıf sayısına göre tematik haritalar oluşturan kısaca bir veri setini kavramaya yardımcı olan bilgi çıkarım yaklaşımı ve karar verme işlem sürecidir (Bayburt, 2009; Dinlemek, 2012; Kaynak, 2017; Refik, 2024). Detaylandırılacak olunursa, her bir pikselin sahip olduğu farklı spektral yansıtım değerleri esasına dayanarak orijinal görüntüdeki pikselleri karşılık geldiği özellik, bilgi, arazi örtüsü/kullanımı sınıflarına ayrılması, kategorize edilmesi işlemidir (Delen, 2017). Kısaca yeryüzündeki nesnelerin aynı spektral özelliklere sahip olanlarının bir sınıfa atanması işlemi olarak tanımlanabilir (Kayman, 2015). Bu sebeple görüntüde spektral bant sayısı ne kadar fazla olursa, cisimlerin ayrılma işlemi de o kadar kolaylaşmaktadır.

Sınıflandırma işleminin genel adımları;

- Çalışma bölgesine ait bilgilerin toplanması, gerekli verilerin temin edilmesi ve çalışmada kullanılacak arazi sınıflarının belirlenmesi
- Görüntüde objelerin spektral yansıma değerleri için en iyi ayrılabilirlik durumunu sağlayan spektral bantların seçilmesi
- Eğitim ve test verilerinin oluşturulması
- Sınıflandırma algoritmasının seçimi
- Doğruluk analizleri yapılması ve yorumlanması

şeklinde (Yıldız, 2012; Kayman, 2015).

Sınıflandırma yöntemlerinde genel kapsamda piksel tabanlı ve nesne tabanlı olmak üzere iki ana yaklaşım vardır. Bunlardan klasik bir yöntem olan piksel tabanlı sınıflandırma yönteminin amacı, piksellerin yansıtım değerleri kullanılarak önceden belirlenmiş olan sınıflarda pikselleri bir araya getirmek olarak tanımlanabilir (Delen, 2017). Piksel tabanlı sınıflandırma kendi içinde kontrollü ve kontrolsüz olmak üzere iki alt başlığa ayrılmaktadır (Çoşlu, 2019). Kontrollü sınıflandırma; kullanıcı kontrolünde öncül tematik bilgilerden yararlanılarak oluşturulan eğitim veri setleri yardımıyla farklı spektral grupları temsil eden kontrol alanları kullanılarak spektral ayrılabilirliğin incelenmesidir. Öte yandan kontrolsüz sınıflandırma ise öncül tematik bilgiler yani eğitim verisi olmaksızın algoritma ve sınıf sayısı belirlenerek piksellerin gruplandırılması işlemidir. Kontrollü sınıflandırma kendi içinde, eğitim verisinin istatistiksel dağılımının kabul durumuna göre parametrik ve parametrik olmayan sınıflandırma algoritmaları olarak ikiye ayrılmaktadır (Tonbul, 2021). Literatürde en çok kullanılan parametrik sınıflandırma yöntemlerine; en kısa uzaklık, en çok benzerlik, paralel kenar yöntemleri örnek olarak gösterilebilir. Makine öğrenmesi olarak da adlandırılan yapay sinir ağlarının da içinde bulunduğu karar ağaçları, destek vektör makineleri ve rastgele orman sınıflandırma algoritmaları, parametrik olmayan sınıflandırıcılar arasında yer almaktadır (Üstüner, 2013).

Klasik piksel tabanlı metotlarda, yüksek çözünürlüklü görüntülerden elde edilen zengin bilgi içeriği tam olarak yansıtılamamaktadır (Park vd., 2016). Nesnelerin genellikle farklı spektral özniteliklere sahip heterojen piksellerden oluşmasının nesne çıkarımı aşamasında yetersiz kalması, bu yaklaşımın temelini tekil piksellerin gri değerlerine dayanması, sınıflandırma aşamasında hedef piksel sınıfını tanımlamaya yardımcı olacak komşu piksellerden gelen bilgilerin kullanılamaması bunun yerine sadece spektral bilginin kullanılması önemli ölçüde dezavantaj yaratmaktadır (Marangoz, 2009; Cömert, 2018;


Tonbul, 2021). Bu durum benzer spektral özelliğe sahip farklı nesnelerin sınıflandırılmasında, sınıflandırma doğruluğunu olumsuz yönde etkilemektedir (Bıyıklı & Marangoz, 2024). Günümüz görüntü işleme teknolojilerinde, piksel tabanlı yöntemlerin yapısından dolayı yeni bir yaklaşım olan nesne tabanlı sınıflandırma yöntemleri de kullanılmaya başlanmıştır. Nesne tabanlı sınıflandırma yaklaşımında kullanılan algoritmalar, sınıflandırma aşamasında segmentleri daha uygun hale getirmek için, piksel tabanlı metoda kıyasla spektral bilginin haricinde şekilsel, yapısal, dokusal veya içeriksel ek bilgilerle daha pozitif sınıflandırma sonuçları sunmaktadır (Marangoz, 2009).

1.5.5. Nesne Tabanlı Sınıflandırma ve Segmentasyon

Piksel tabanlı sınıflandırmaya göre karar verme yetisi artırılan nesne tabanlı sınıflandırma yani görüntü bölütleme, pikselleri gruplandırarak segmentler oluşturulması ve analizin bu segmentler üzerinden gerçekleştirilmesi esasına dayanmaktadır (Aydemir, 2018; Refik, 2024). Sınıflandırma işlemi sırasında piksel bazlı görüntü analizi yapmak yerine homojen piksellerin oluşturduğu görüntü segmentleri ve nesneler üzerinden sınıflandırma gerçekleştirilmektedir. Hem spektral hem mekansal verileri kullanarak sınıflandırma yapan bu yöntemde pikseller gruplandırıldığı için boyut, şekil, doku gibi özellikler analiz edilebilir, nesnelerin konumu ve daha birçok özellik hakkında sorgulama yapılabilmektedir (Matcı, 2019). Bu ek bilgiler ve öznitelik verileri kapsamında sınıflandırma sonucu daha yüksek doğruluklar elde edilebilmektedir.

Nesne tabanlı sınıflandırma yöntemi genel olarak iki aşamadan oluşmaktadır. Bu aşamalar görüntü segmentasyonu ve sınıflandırma aşamalarıdır. İlk ve en önemli işlem adımı olan segmentasyon, homojen nesneler elde etmek için görüntüyü oluşturan pikselleri konumsal ve spektral özelliklerine göre gruplandırıp nesneleri anlamlı gruplara ayırarak doğru sınıflandırma yapılmasını sağlamaktadır (Kaynak, 2017; Tonbul & Kavzoğlu, 2017; Bıyıklı & Marangoz, 2024). Şekil 3'te görüldüğü üzere segmentasyon kısaca, görüntüyü birbirinden farklı alt bölümlere ayırma işlemi olarak da tanımlanabilir. Segmentlere ayrılan bu alt bölümler nesne tabanlı analizin çekirdek yapılarını oluşturur ve görüntü nesneleri olarak da ifade edilmektedirler. Görüntü nesnelerini oluşturmak için genellikle görüntünün spektral bantları kullanılmaktadır. Fakat spektral bantlar haricinde aynı alana ait dokusal veya mekansal dağılımlı veri setleri de (eğim, yükseklik, bakı vb.) görüntü nesnelerinin oluşturulmasında kullanılabilmektedir (Stumpf & Kerle, 2011; Cömert, 2018). Tüm bu

işlemler sayesinde segmentler içerisindeki heterojenlik en alt seviyeye indirilerek görüntü üzerindeki en küçük birimin artık piksel değil nesne olması sağlanmaktadır. Bundan dolayı milyonlarca pikselle uğraşmak yerine hem sayıca az hem de homojen spektral özellik gösteren nesneleri kullanarak sınıflandırma yapılması segmentasyonun en önemli avantajlarından birini oluşturmaktadır (Yıldız, 2012). Bunun sonucunda oluşan görüntü nesneleri sayesinde kullanıcının nesne tabanlı sınıflandırma işlemi için sınıfları tanımlaması piksel bazlı değerlendirmeye göre daha basit ve anlamlı biçimde gerçekleştiği söylenebilir (Refik, 2024). Ayrıca yeryüzü nesnelerinin görüntüdeki piksellerden daha büyük olması sebebiyle sınıflandırma işlemi için oluşturulan segmentlerin, objeleri daha iyi algılanmasına katkı sağlamaktadır. Sonuç olarak görüntü nesneleri, yüksek çözünürlüklü görüntülerde yeryüzüne ait birçok özelliğin daha doğru bir şekilde elde edilmesini sağlamaktadır (Tonbul, 2021).



Şekil 3. Segmentasyon ile görüntünün piksel seviyesinden görüntü nesnesi seviyesine dönüşümü

Segmentasyonun, semantik segmentasyon ve örnek segmentasyon şeklinde ikiye ayrılmaktadır. Semantik segmentasyon, bir görüntüyü piksel düzeyinde bölerek her piksele kategorik bir etiket atamayı hedeflemektedir. Örnek segmentasyon ise, her görüntüde sınıf etiketlerini ve örnek maskelerini tahmin etmeyi amaçlamaktadır. Görüntüdeki bütün nesneleri tek tek sınıflandırdığı için semantik segmentasyona göre daha zordur (Tatli, 2024).

Segmentasyonun kalitesinin değerlendirilmesi nesne tabanlı görüntü analizi için esastır. Bu işlemin nesne tabanlı görüntü analizinin ilk aşaması olmasından dolayı, işlemin kalitesi, devamında gelen sınıflandırma aşamasının sonuç doğruluğunu önemli derecede etkilemektedir. Sınıflandırma, segmentasyon işlemi sonucunda elde edilen nesnelere ait piksel gruplarının aynı karakteristik yapıda olan ilgili bilgi sınıflarına atanması işlemidir (Delen, 2017). Burada görüntülerin sınıflandırılması için kullanılan klasik sınıflandırıcıların

yanı sıra daha gelişmiş makine öğrenme algoritmaları da kullanılmaktadır (Çoşlu, 2019). Sınıflandırma işlemi sonrası gerçekleştirilecek doğruluk analizi büyük önem taşımaktadır. Sınıflandırma doğruluğu, nesnelerin atandığı sınıf ile gerçek sınıfı arasındaki uygunluğunun referans veriler yardımı ile incelenmesiyle elde edilmektedir. Sınıflandırma doğruluk derecesini tanımlamada kullanılan en yaygın yöntemlerden birisi olan hata matrisi ile doğruluk değerlendirme yöntemi, gerçek arazi örtüsüne göre belirli bir arazi örtüsü tipi olarak atanan piksellerin/segmentlerin sayısının, satırlar ve sütunlar halinde düzenlemiş karesel bir düzeninden oluşmaktadır. Burada genel doğruluk, üretici doğruluğu ve kullanıcı doğruluğu olmak üzere üç çeşit doğruluk hesaplanmaktadır. Üretici doğruluğu, gerçekten ait olduğu sınıfa atanan örüntülerin referans veri içerisindeki oranı iken kullanıcı doğruluğu ise örüntülerin o sınıfa ait olup olmama durumu olarak tanımlanmaktadır (Bayburt, 2009).


1.5.6. Yapay Zeka ve Derin Öğrenme

Kavram olarak 1950’lerde ortaya çıkan yapay zeka, insan zekasını ve davranışlarını taklit eden algoritmalar aracılığıyla akıllı makineler oluşturan bir bilgisayar bilimleri dalıdır (Ekiz, 2024). Yapay zekanın alt dallarından olan derin öğrenme ise; birden fazla işlem katmanından oluşan hesaplamalı modellerin, birden fazla soyutlama düzeyine sahip veri temsillerini öğrenmesini sağlayan mimarilerden faydalanılmaktadır (LeCun, vd., 2015). Şekil 4’te görüldüğü üzere derin öğrenme; üst dalları yapay sinir ağları, makine öğrenimi ve yapay zeka olan bir hiyerarşik yapının son halkasıdır.



Şekil 4. Yapay zeka ve derin öğrenme arasındaki ilişki (Bingöl vd., 2020)

Başka bir deyişle derin öğrenme, bir kez eğitildikten sonra insan müdahalesine gerek duymadan yeni verileri işleyebilen, genelleme yeteneklerini geliştiren, kendi kendilerine yeni özellikleri ekleyip kaldırabilen, üst düzey özellik temsillerini modeller aracılığıyla öğrenebilen ve verileri gerçek zamanlı olarak analiz eden bir mimarilerdir (Karaoğlu, 2022). Yapay sinir ağlarıyla büyük veri kullanarak öğrenebilen ve karmaşık problemlerin çözümüne olanak sağlayan derin öğrenme Şekil 5'te görüldüğü üzere, geleneksel yapay sinir ağlarına göre birbiri üzerine inşa edilmiş birçok gizli katman kullanmaktadır (Karaoğlu, 2022). Buradaki gizli katmanlar, giriş ve çıkış arasındaki katmanlar olarak adlandırılabilir (Ma vd., 2019). Derin öğrenme, ham veriden başlayarak her bir seviyedeki temsilleri veya özellikleri daha yüksek seviyedeki temsillerine dönüştüren basit ancak doğrusal olmayan matematiksel işlem adımlarını içermektedir (Zhang vd., 2017).



Şekil 5. (a) Makine öğrenmesi ve (b) derin öğrenme arasındaki fark (Wani vd., 2020)

Görüntü analizi yapılırken hiyerarşik olarak birbirlerinin üzerine inşa edilen bu gizli katmanlar sayesinde girdi görüntüsünden çeşitli özelliklerin çıkartılması sağlanmaktadır. İlk katmanlar kenarları algılamak için kullanılırken daha sonra bu kenarlar köşeleri ve konturları tanımlamak için kullanılmaktadır. Sonraki katmanlar ise, nesne parçalarına ulaşmak için köşeleri ve

konturları birleştirmektedir. Çıktı katmanında, görüntü sınıflandırma işlemi gerçekleştirilerek çıktı sınıfının etiketi atanmaktadır. Ağın içerisindeki her katman, önceki katmanların çıktısını kullandığı için bu süreç hiyerarşik öğrenme olarak adlandırılmaktadır.

Şekil 5'te görüldüğü üzere derin öğrenme ile makine öğrenmesi arasında bazı önemli farklılıklar olsa da temelde aynı şeyleri ifade ederler (Döş & Uysal, 2019). Fakat makine öğrenmesinin bir alt kümesi olan derin öğrenme, bazı konularda gösterdiği başarı ve farklı yetenekleri sayesinde klasik makine öğrenmesinden ayrılmaktadır. Örnek olarak, insan düzeyine yakın görüntü tanıma ve sınıflandırma yapabilmesi, insan düzeyinde metin okuma ve seslendirme yapabilmesi, konuşma tanıyabilmesi gibi konular verilebilir (Bingöl vd., 2020). Diğer bir örnek ise algoritmaların öğrenme şeklinin farklılık göstermesidir. Derin öğrenme, insan müdahalesi olmadan verilerin temsil değerlerinden öğrenim yapabilirken klasik makine öğrenmesi, öğrenim işlemi için insan müdahalesine ihtiyaç duymaktadır (Saraloğlu E. , 2020). Ayrıca geleneksel makine öğrenme yöntemlerine göre, kavramların daha etkin bir şekilde soyutlanmasını ve hiyerarşik olarak düzenlenmesini sağlamaktadır (Yılmaz, 2024). Sonuç olarak yüksek boyutlu ve karmaşık veri setleri kullanıldığında derin öğrenmenin makine öğrenmesine göre daha iyi performans gösterdiği gözlemlenebilmektedir (Ishii vd., 2015).


Literatürde Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN), Uzun Kısa Vadeli Sinir Ağları (Long Short-Term Memory - LSTM), Derin İnanç Ağları (Deep Belief Network - DBN), Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines - RBM), Çekişmeli Üretici Ağ (Generative Adversarial Networks – GANs), Stack Autoencoders, Capsule Networks ve CNN tabanlı pek çok derin öğrenme mimarisi mevcuttur (Saraloğlu B. , 2022). Bu mimariler arasında CNN, farklı ölçeklerde evrimsel filtreler kullanarak ayırt edici özellikleri otomatik olarak çıkartan ve en sık kullanılan derin öğrenme modelleri arasında yer almaktadır (Yılmaz, 2024). CNN'ler derin ağ yapısı ile modelin son derece soyut özellik algılayıcıları öğrenmesine ve giriş özelliklerini sonraki sınıflandırıcıların performansını açıkça artıracı temsillere eşlemesine olanak tanıyarak görsel tanımda çoğu algoritmayı geride bırakmıştır (Zhang vd., 2016). Bunun sonucunda CNN, görüntü işleme alanında elde ettiği başarılar sayesinde en köklü ve en fazla çalışmanın yapıldan derin öğrenme yöntemi haline gelmiştir.

1.5.7. CNN (Evrişimli Sinir Ağı)

CNN derin bir ağ yapısına sahip olan, evrişim ve havuzlama hesaplama yöntemlerini içeren ve bu hesaplamaları dönüşümlü olarak yapan minimum miktarda ön işleme kullanmak için tasarlanmış ileri beslemeli sinir ağlarıdır (Ünal, 2024). Çok katmanlı yapıya sahip olan ve ileri beslemeli yapay sinir ağlarından biri olan CNN, nöronlar arasındaki bağlantı için hayvanların görme sisteminden ilham alınarak ortaya çıkarılmıştır (Ekiz, 2024). Bu tür ağlar, görüntü tanıma ve sınıflandırma alanında popülarlığını korurken özellikle görüntü ve video gibi 2B veriler üzerinde kullanım için tasarlanan çok katmanlı sinir ağları ailesidir (Arel vd., 2010). Birden fazla özellik çıkarma aşamasına sahip olan CNN için her aşama üç katmandan oluşmaktadır (Şekil 6). Bunlar;

- Evrişim katmanı (Convolution)
- Havuzlama katmanı (Pooling)
- Tamamen bağlı katman (Fully Connected)

şeklinde (Zhang vd., 2016). Bu ağ yapısı girdi verilerini işler, hesaplamalar gerçekleştirir ve elde edilen sonuçları bir sonraki katmana aktarmaktadır.



Şekil 6. CNN ağ mimarisi örneği (Alom vd., 2019)

Evrişim katmanı, girdi verisinin özelliklerini çıkarmak için kullanılan ilk katmandır. Bu katmanda, giriş katmanından elde edilen özellik bağlantıları tespit edilmektedir. Girdi görüntüsünün bütün bölgesel pikselleri tek değere dönüştürülüp, girdinin boyutu düşürülerek evrişim işlemi gerçekleştirilmiş olur. CNN uygulanmaya başlanmadan önce katman sayısı ve her katmandaki filtre sayısı belirlenmektedir. Uygun filtreler ve ağırlıklar, CNN tarafından otomatik olarak tespit edilmektedir. Evrişim katmanının girdisi, $m \times n$ boyutunda

r adet 2B özellik haritasına sahip 3B bir dizidir. Her bir bileşen $x_{m,n}^i$ olarak gösterilirken ve her bir özellik haritası x^i şeklinde gösterilmektedir. Çıktı, $m_1 \times n_1$ boyutunda k adet özellik haritasından oluşan $m_1 \times n_1 \times k$ boyutunda 3B bir dizidir. Özellik haritası bir dizi yeni özellik haritası üretmek için filtrelenmektedir. W filtre bankası olarak da adlandırılan ve giriş özellik haritasını çıkış özellik haritasına bağlayan, $l \times l \times q$ boyutunda k adet eğitilebilir filtreye sahiptir. Filtre, giriş görüntüsü üzerinde adım adım kaydırılarak uygulanmaktadır. Son olarak evrişim formülü uygulanarak, ϕ 'nin 2B ayrık bir evrişim operatörü ve b 'nin eğitilebilir bir önyargı parametresi olduğu $z_s = \sum_{t=1}^q W_t^s * x^i + b_s$ çıkış özellik haritasını hesaplamaktadır (Zhang vd., 2016).

Evrişim katmanının ardından girdi verilerinin doğrusal olmayan temsillerini geliştirmek için doğrusal olmayan aktivasyon fonksiyon katmanı (örneğin, ReLu, hiperbolik tanjant, softmax ve sigmoid) kullanılmaktadır (Özoğlu, 2024). Aktivasyon fonksiyonları genel olarak, bir sinir ağının eğitimi esnasında bir nöronun aktif olup olmayacağını belirleyen ve derin bir sinir ağının nihai performansını belirlemede önemli bir rol oynayan fonksiyonlardır (Rahman vd., 2024). Geleneksel CNN'de, doğrusal olmayan katman basitçe bir özellik haritasındaki her bir bileşene uygulanan noktasal doğrusal olmayan bir fonksiyondan oluşmaktadır. Bu katman, $a^s = f(z^s)$ olan çıktı özellik haritasını $f(\cdot)$ olarak hesaplar ve genellikle düzeltilmiş doğrusal birim olarak (Rectified Lineer Unit - ReLU) $f(x) = \max(0, x)$ seçilmektedir. Aktivasyon fonksiyonu olarak ReLu'nun kullanılması tüm negatif çıktı değerlerini sıfıra ayarlayarak ağın daha hızlı çalışmasını sağlamaktadır. Bunun yanı sıra aktivasyon işlemi ağa doğrusal olmayan bir özellik getirdiği için hem ağın hem de gerçekleştireceği görevlerin karmaşıklığını artırmaktadır (Zhang vd., 2016).

CNN mimarisinde havuzlama katmanının görevi, girdi verideki anlamsal olarak benzer özellikleri bir araya getirmektir. Bu katman, evrişim katmanının çıktılarını özümseyerek konumsal boyutlarını küçültmek, önemli özelliklerini korumak ve hesaplama miktarını azaltmak için kullanılan bir işlemdir. $p_G^s = \max_{i \in G} a_i^s$ olan her bir özellik haritası için küçük bir konumsal bölgedeki aktivasyonlar üzerinde maksimum işlem yürütmeyi içermektedir. Yani, her biri havuzlama biriminin konumunu merkez alan $p \times p$ boyutunda küçük bir konumsal bölgeyi özetleyen, s piksel aralıklı havuzlama birimlerinden oluşan bir ızgara şeklinde düşünülebilir. Havuzlama katmanı her bir özellik haritası için ayrı ayrı gerçekleştirilmektedir. Katman, özellik haritasını belli bölgelere bölüp kayan pencereler kullanarak veriyi sadeleştirmektedir (Ünal, 2024). Bu sayede ağın boyutu azalırken önemli özelliklerin kaybı engellenmektedir. Burada havuzlama biriminin boyutu özellik

haritasından daima daha küçük olmalıdır. Çoklu özellik çıkarma aşamalarından sonra tüm ağ, geri yayılım fonksiyon ile eğitilmektedir. (11) nolu eşitlikteki hedef çıktı γ , K çıktı sayısı ve L katman sayısını ifade etmekte olup 1-of- K vektörü olarak hesaplanmaktadır (Zhang vd., 2016).

$$J(\theta) = \sum_{i=1}^N \left(\frac{1}{2} \|h(x_i, \theta) - \gamma\|^2 \right) + \gamma \sum_l^L \text{sum}(\|\theta^2\|^2) \quad (11)$$

Tamamen bağlı katman, girdilerin nöronlarla bağlantılı olduğu ve girdi verideki özelliklerin doğrusal olmayan ilişkilerinin daha fazla modellendiği bir katmandır. Nöronlar, önceki katmanlardaki tüm aktivasyonlara ve tam bilgilere erişim sağlayabilmektedir. Genellikle sinir ağının sondan bir önceki katmanı ve çıkış katmanı arasında tamamen bağlı bir katman kullanılmaktadır. Tamamen bağlı katman sonucunda 2B özellik haritaları bir boyutlu özellik vektörüne dönüştürülmüş olur. Tamamen bağlı katman aşağıdaki formülü (12) nolu eşitlikte gösterilmektedir.

$$y_i = f(W \cdot u_i) + b^h \quad (12)$$

Burada; u_i girdiyi, W nöron katmanı ile ilişkili ağırlık matrisini, b bias değerini, f aktivasyon fonksiyonunu ifade etmektedir. Özellikler çıkarıldıktan sonra, CNN'nin tamamlanması, sonuç üretmek ve sonuçları optimize etmek için çıktı katmanı olarak bir sınıflandırıcı kullanılmaktadır (Ekiz, 2024). Son olarak sınıflandırma katmanı ise yapısal olarak tamamen bağlı katman yapısına oldukça benzemektedir. Bu katman, sınıflandırılmak istenen nöron sayısı ile aynı sayıda nörona oluşmaktadır. Çıktıdaki her nöron, belirli bir sınıfa karşılık gelen bir olasılık sonucu vermektedir ve tahmin edilen sınıf maksimum olasılık sonucuna sahip olan sınıf olmaktadır (Morchhale, 2016).

CNN, mekansal ilişkilerden yararlanarak öğrenilmesi gereken parametre sayısını azaltmaktadır ve böylece genel ileri beslemeli geri yayılım eğitimi iyileştirmektedir. CNN'lerde, görüntünün küçük bölümleri (yerel alıcılar) hiyerarşik yapıya en alt katmandan girdi olarak alınmaktadır. Ağın her katmanında önceki katmandan gelen çıktı, girdi olarak alınır ve üretilen çıktı bir sonraki katmana girdi olarak verilmektedir. CNN mimarisinin en iyi özelliklerinden biri, geleneksel makine öğrenme yöntemleri gibi özelliklerin elle çıkarılmasına ihtiyaç duymadan, girdilerden görüntülerin özelliklerini otomatik olarak öğrenebilmesidir (Saralıoğlu E. , 2020). Ağın farklı katmanları arasında bilgi akışı

sağlanırken her katmandaki verilerin belirgin özelliklerini elde etmek için dijital filtreleme uygulanmaktadır (Arel vd., 2010). Bunun yanında CNN, gradyan tabanlı öğrenme algoritmasıyla eğitilen bir mimaridir. Bu azalan gradyan probleminden minimum düzeyde etkilenmektedir. Burada kullanılan gradyan tabanlı algoritma ile hata değerini en aza indirmek için tüm ağı eğitilmektedir. Bu sayede CNN mimarisi, yüksek düzeyde optimize edilmiş ağırlıklar üretebilmektedir (Alom vd., 2019).

Görüntü sınıflandırması, segmentasyon ve görüntü algılamanında dahil olduğu görüntü işleme konusunda bir çok derin öğrenme yaklaşımı bulunmaktadır. Nesne tespiti, görüntü işleme teknikleri veya derin öğrenme ağları kullanılarak gerçekleştirilebilir (Pal vd., 2021). Derin ağ mimarileri, nesne tespiti konusunda bir özellik oluşturma görevi görmektedir. Bu görev doğrultusunda semantik segmentasyon için çeşitli modeller önerilmektedir. İlk segmentasyon modeli FCN'dir (Long vd., 2015). Daha sonra bu ağ geliştirilerek SegNet adında yeni versiyonu oluşturulmuştur (Badrinarayanan vd., 2017). Zamanla ise yeni modeller ortaya çıkmıştır; bunlar arasında RefineNet, PSPNet, U-Net ve R2U-Net yer almaktadır (Alom vd., 2019). Derin ağ mimarileri çoğunlukla nesne tespiti için evrişim katmanında özellik haritası çıkarırken tamamen bağlı katmanda sınıflandırma işlemini yapmaktadır. Bu tür derin ağlara ise örnek olarak AlexNet, VGG16, ResNet ve U-Net verilebilmektedir (Saralıoğlu B. , 2022).

1.5.8. Doğruluk Metrikleri

Derin öğrenme tekniklerinde, sınıflandırma ve segmentasyon gibi modelin tahmin performansının ve sonuç doğruluğunun değerlendirilmesi, seçilen derin sinir ağı tasarımının güvenilirliği ve genelleştirme kabiliyetinin ortaya koyulabilmesi açısından önem arz etmektedir. Bu sebeple seçilen modelin performans analizinde doğruluk değerlendirme metriklerine ihtiyaç duyulmaktadır. Kullanılan modellerin başarısı test edilirken nitel ve nicel olmak üzere iki farklı yöntemden faydalanılabilmektedir. Bu yöntemlerin ikisi de referans verideki gerçek değerlerin üretilen tahminlerle karşılaştırılma ilkesini kullanmaktadır. Nitel yöntemler elde edilen görsel sonuçların, gerçek görsel verilerle kıyaslanmasına dayanmaktadır. Nicel yöntemler ise Genel Doğruluk (Overall Accuracy - OA), Duyarlılık (Recall), Kesinlik (Precision), IoU ve F1 Skor gibi doğruluk ölçütlerinden oluşmaktadır. Bu ölçütler, gerçek değerler ile tahmin edilen değerlerin karşılaştırıldığı bir

matris olan hata/karışıklık matrisi (confusion matrix) kullanılarak hesaplanmaktadır (Deng vd., 2016).

Hata matrisi, sınıflandırmada oluşan hataları ve sonuç doğruluğunu görselleştirmede kullanılan, test veri örnekleri için gerçek ve tahmin edilen değerler arasındaki ilişkiyi ortaya koyan temel araçlardan biridir. Hata matrisi iki boyuttan oluşmaktadır. Boyutlardan biri nesnenin gerçek sınıfı tarafından indekslenirken diğeri sınıflandırıcının tahmin ettiği sınıf tarafından indekslenmektedir (Deng vd., 2016). Bu matristeki satırlar gerçek değerleri, sütunlar tahmin edilen değerleri, matrisin köşegen elemanları ise doğru sınıflandırılan test örneklem noktası sayısını temsil etmektedir. Basit bir hata matrisi örneği Şekil 7’de verilmiştir. Burada gösterilen, N_{ij} gerçekte A_i sınıfına ait olan fakat A_j sınıfı olarak sınıflandırılan örnek sayısını temsil etmektedir.

		Tahmin		
		A_1	$\dots A_j \dots$	A_n
Gerçek	A_1	N_{11}	N_{1j}	N_{1n}
	$\vdots$ A_i $\vdots$	N_{i1}	$\dots N_{ij} \dots$	N_{in}
	A_n	N_{n1}	N_{nj}	N_{nn}

Şekil 7. Hata matrisi

Hata matrisi daha basit bir şekilde açıklamak gerekirse, satır ve sütunların her birinin sınıflandırma problemindeki farklı sınıfları temsil ettiği bir tablodur şeklinde ifade edilebilir. İkili sınıflandırma problemlerinde, hata matrisi 2x2 boyutunda olur ve Tablo 1’deki gibi gösterilmektedir.

Tablo 1. Hata matrisinin yapısı

	Gerçek Pozitif (TP)	Gerçek Negatif (TN)
Tahmin Pozitif (P)	TP	FP
Tahmin Negatif (N)	FN	TN

Gerçek pozitif (True pozitif – TP) gerçekte de pozitif olan ve modelinde pozitif olarak tahmin ettiği örnek sayısını, gerçek negatif (True Negative – TN) gerçekte negatif olan ve modelinde negatif olarak tahmin ettiği örnek sayısını, yanlış pozitif (False Positive – FP) gerçekte negatif olan fakat modelin pozitif olarak tahmin ettiği örnek sayısını ve son olarak yanlış negatif (False Negative – FN) gerçekte pozitif olan fakat modelin negatif olarak tahmin ettiği örnek sayısını ifade etmektedir. Hata matrisinden elde edilen değerler yardımıyla çeşitli doğruluk metrikleri hesaplanmaktadır. Bunlar;

$$OA = (TP + TN)/(TP + TN + FP + FN) \quad (13)$$

$$\text{Duyarlılık (Recall)} = TP/(TP + FN) \quad (14)$$

$$\text{Kesinlik (Precision)} = TP/(TP + FP) \quad (15)$$

$$IoU = TP/(TP + FP + FN) \quad (16)$$


$$F1 \text{ Skor} = 2 \times (\text{Kesinlik} \times \text{Duyarlılık})/(\text{Kesinlik} + \text{Duyarlılık}) \quad (17)$$

şeklindedir. (16) nolu eşitlikte gösterilen ve Jaccard olarak da bilinen IoU indeksi, tahmin edilen bölge ile gerçek bölge kesişiminin (intersection), bu bölgelerin birleşimine (union) bölünmesi ile elde edilen ve bölgeler arası benzerliği ölçen metriktir. (17) nolu eşitlikte gösterilen F1 Skor ise, eşit dağılmayan veri setlerindeki model seçiminde hata yapmaması nedeniyle oldukça sık tercih edilmektedir (Alkan D. , 2023; Mira, 2024).

2. YAPILAN ÇALIŞMALAR

2.1. Çalışma Alanı ve Veri Seti

Önerilen yaklaşımın test edilmesi için farklı arazi örtüsü/kullanım karakterine sahip bölgeler tercih edilmiştir (Şekil 8). Seçilen çalışma alanları topografik durum açısından, yüksek dağ oluşumları içermeyen ve daha çok geniş, düz, az engebeli tepelik alanlar ve nispeten alçak dağlardan oluşan jeomorfolojiye sahip bölgelerdir.



Şekil 8. Farklı arazi örtüsü karakterinde çalışma bölgelerini kapsayan ortofoto verileri

Bitki örtüsü bakımından ise hem Akdeniz iklim bitki türleri hem de step bitki formasyonuna ait türler mevcuttur. Şehir merkezleri alçak bitki örtüsü ve tarım alanları yoğunlukta iken şehir merkezinden uzak dağlık bölgeler ise ormanlık alanlardan oluşmaktadır. Şekil 8’de de görüldüğü üzere dağlık alanlarda bitki yoğunluğu artmakta, bu yoğunluk kızılçam ve ardıç gibi yüksek bitki örtüsüne sahip ağaç türlerini kapsamaktadır. Algoritmanın uygulandığı test alanlarının arazi örtüsü bileşenleri, yerleşim bölgelerinde


bulunan binalar, bu bölgelerin çevrelerinde yer alan tarım alanları, yüksek ve alçak bitki örtüsü yoğunlukta olan bölgeler, zemin topografyası ve yollar şeklindedir.

Tez çalışması kapsamında Harita Genel Müdürlüğü'nden (HGM) elde edilen 1960 yılına ait 5 adet gri tonlamalı fotogrametrik görüntüler kullanılmıştır (Şekil 8). Temin edilen tarihi hava fotoğraflarının her biri yaklaşık 4 km² alanı kapsamaktadır. Çeşitli fotogrametrik yöntemlerle üretilen ve taranarak sayısal ortama aktarılan bu analog görüntüler 35000 ölçekli olup sayısal şekilde temin edilmiştir. Kullanılan 5 görüntünün her birinin yer örnekleme oranı ise 0,86 metre olup 2327×2327 piksel boyutundadır.

2.1.1. Veri Setinin Hazırlanması

Semantik segmentasyon işlemi için DeepLabV3 mimarisinde U-Net omurgası kullanılmış ve bu mimarinin tarihi hava fotoğrafları üzerindeki semantik segmentasyon başarısı zemin ve zemin üstü detayları kapsayacak şekilde seçilen 3 sınıflı ve 5 sınıflı senaryolar için test edilmiştir. Eğitim ve test aşamalarında kullanılmak üzere örneklem veri seti, Python programlama dilinde yazılmış grafiksel görüntü etiketleme aracı LabelMe kullanılarak oluşturulmuştur. Yazılım Windows 10, 64 bit işletim sistemli bilgisayara kurulmuş olup kullanılan Python versiyonu ise 3.9.12'dir. LabelMe, görüntüleri anlamlandırma sürecini basitleştirmek üzere tasarlanan açık kaynaklı bir grafiksel görüntü etiketleme aracıdır. Geleneksel araçların önüne geçerek nesne algılama, sınıflandırma ve segmentasyon gibi işlemler için makine öğrenim yeteneklerini kendi çerçevesine entegre eden LabelMe, görüntüleri açıklama kapsamında önemli bir rol oynamaktadır (URL-2, 2024). Dosya biçimi JSON olan bu arayüz çokgen, dikdörtgen, daire, çizgi ve nokta gibi çeşitli öğelerle görüntüleri açıklamada kullanıcılara sezgisel bir araç sağlamaktadır (URL-3, 2024).

Tarihi hava fotoğrafları ilk olarak çalışmanın kolaylığı açısından bitki ağırlıklı ve geçirimsiz yüzey ile tarım alanı ağırlıklı olacak şekilde 2 kategoride toplanmıştır. Şekil 8'de gösterilen 5 adet gri tonlamalı tarihi hava fotoğrafı incelendiğinde bina, zemin, bitki, yol ve tarım alanı şeklinde 5 sınıfın göze çarptığı gözlemlenmiştir. Bu sınıflar çalışma alanlarının arazi örtüsü bileşenleri ve topografyası dikkate alınarak belirlenmiştir. Bu bağlamda veri etiketleme süreci, LabelMe yazılımı ile yukarıda belirtilen beş farklı sınıfa ayrılacak şekilde gerçekleştirilmiştir (Şekil 9).




Şekil 9. LabelMe yazılımı ile etiketlenmiş tarihi hava fotoğrafları

1960 yılına ait gri tonlamalı tarihi hava fotoğrafları 256×256 piksel olacak şekilde toplamda 120 adet alt parçalara bölündükten sonra eğitim, validasyon ve test olmak üzere sırasıyla %70, %15, %15 olarak üç farklı kümeye dağıtılmıştır. Performans değerlendirme aşamasında, IoU ve F1 Skor metrikleri kullanılmıştır. Modelin performansını ve genelleme kabiliyetini artırmak amacıyla, veri işleme aşamasında çeşitli ön işleme ve veri artırma teknikleri uygulanmıştır. Eğitim ve doğrulama veri setlerindeki görüntüler ve ilgili segmentasyon haritaları öncelikle dosyalardan yüklenmiştir. Tüm görüntüler, modelin girdi boyutlarına uygun olarak 256×256 piksel boyutuna yeniden ölçeklendirilmiştir. Eğitim sırasında, modelin farklı geometrik dönüşümlere karşı dayanıklılığını artırmak ve örneklem sayısını arttırmak için görüntülere %50 olasılıkla rastgele yatay çevirme işlemi uygulanmıştır. Bu veri artırma tekniği, modelin simetrik nesneleri ve çeşitli yönelimleri daha iyi öğrenmesine yardımcı olması için uygulanmıştır. Doğrulama ve test aşamalarında ise, modelin performansını objektif bir şekilde değerlendirmek için rastgele çevirme gibi veri artırma teknikleri kullanılmamıştır. Bu aşamalarda, görüntüler sadece yeniden boyutlandırılmıştır.

2.1.2. SYM Üretimi


Gri tonlamalı tarihi hava fotoğraflarının semantik segmentasyonu çalışması kapsamında modele SYM verisi entegre edilerek modelin performansının iyileştirilmesi amaçlanmaktadır. Bu bağlamda SfM (Structure From Motion - SfM) tekniğine dayalı fotogrametrik değerlendirme sonrasında üretilmiş SYM verisi çalışmada kullanılmıştır. SfM tekniğinin genel işlem akışı Şekil 10'da ifade edilmiştir.



Şekil 10. SfM algoritması genel iş akışı (Altuntaş, 2019)

SfM metodu, son yıllarda artan kullanımı ile yüksek çözünürlüklü veri setlerinde çalışabilen, düşük maliyetli ve kullanıcı dostu bir fotogrametri tekniği olarak adlandırılmaktadır (Sarıtürk & Şeker, 2017). Yöntem, sıralı olarak çekilen 2B görüntülerden stereo görüntü yorumlama tekniği ile ortak noktalar tespit edilerek 3B veri elde etmeye yarayan klasik bir fotogrametri yaklaşımıdır (Çelik vd., 2020). Diğer bir deyişle, bindirmeli görüntüler arasındaki ilişkiyi inceleyerek özellik noktalarının tespitini sağlayan ve bu noktalar ile kameranın çekim anındaki konumunu ve dönüklüklerini belirleyen bir bilgisayarla görme tekniğidir (Tanrıku, 2019). SfM algoritması; stereo görüntülerden SIFT ve SURF gibi algoritmalar ile yerel özellik noktası tespiti yaparak detay noktalarını eşleştirip hatalı eşlenen noktaları ise RANSAC ve MAPSAC gibi algoritmalar ile temizlendikten sonra

fotogrametrik triangölasyon ve kamera konumlandırma işlemlerini gerçekleştirmektedir. Seyrek nokta bulutu ve yoğun nokta bulutu üretip 3B model ve görüntüleme sağlamaktadır. SfM tekniği ile SYM üretimi için kullanılan işlem adımları Şekil 11’de gösterilmektedir.



Şekil 11. SYM üretim aşamaları


SfM tabanlı fotogrametrik değerlendirme sonrasında ortofoto mozaik ve yoğun 3B nokta bulutu çıktı ürünleri elde edilmektedir. Çalışmada kullanılan SYM verisi, 3B yoğun nokta bulutu verisi ile TIN ağ yapısı oluşturulması sonrasında 0.86×0.86 grid boyutu ile raster formata örneklenmesi sonrasında elde edilmiştir.

2.2. Yöntem

2.2.1. MMSegmentation Kütüphanesi

Derin öğrenme çalışmalarında bir sinir ağı genellikle algoritmanın temelini oluşturan bir model olarak tanımlanmaktadır. MMEngine; eğitim, test ve diğer süreçler için arayüzleri standartlaştırmak amacıyla birleşik bir BaseModel soyutlaması sağlamaktadır ve MMSegmentation tarafından uygulanan tüm modeller BaseModel'den miras almaktadır. Ayrıca MMSegmentation'da ileri besleme (forward) ve semantik segmentasyon algoritması için bazı fonksiyonlar eklenmiştir (URL-4, 2024). MMSegmentation'da ağ mimarisi, Segmentör adı verilen ve ağın tüm bileşenlerini içeren bir model ile soyutlanmaktadır. Bu bileşenler genellikle, veri ön işlemcisi, omurga, çözümleyici başlık ve yardımcı başlık şeklindedir (Şekil 12). Veri Ön İşlemcisi (Data Preprocessor), veri setini belirlenen yığın boyutu ve ön işleme aşamalarını uygulayarak hedef cihaza kopyalayan ve verileri modelin girdi formatına dönüştüren kısımdır. Omurga (Backbone), bir görüntüyü son tam bağlantılı katmanı olmayan ResNet-50 veya U-Net modeli gibi özellik haritalarına dönüştüren kısımdır. Boyun(Neck), omurga ile başlıkları bağlayan kısımdır. Omurga tarafından üretilen ham özellik haritaları üzerinde bazı iyileştirmeler veya yeniden yapılandırmalar yapmaktadır. Örneğin, Özellik Piramit Ağı (Feature Pyramid Network - FPN) bu kısma

dahildir. Çözümleyici Başlık (Decode Head), özellik haritalarını bir segmentasyon maskesine dönüştüren kısımdır; örneğin, PSPNet gibi modeller bu görevi üstlenmektedir. Yardımcı Başlık (Auxiliary Head) ise, özellik haritalarını segmentasyon maskelerine dönüştüren ve yalnızca yardımcı kayıpları hesaplamak için kullanılan isteğe bağlı bir bileşen olarak ifade edilmektedir (URL-4, 2024).



Şekil 12. MMSegmentation kütüphanesi bileşenleri (URL-4, 2024)

Uygulamada kullanılan DeepLabV3 modeli (Chen vd., 2017a) Encoder-Decoder yapılandırmasıdır. DeepLabV3 modelinin Backbone'u olarak 5 aşamalı bir U-Net mimarisi ve Decode Head'i olarak Atrous Spatial Pyramid Pooling (ASPP) modeli (Chen vd., 2017b) seçilmiştir.

2.2.2. DeepLabV3


DeepLab, Google tarafından hala geliştirilme sürecinde olan, açık kaynaklı bir semantik segmentasyon modelidir (Pedrayes vd., 2021). 2014 yılında DeepLabV1 ile başlayan DeepLab mimarisi, her yeni sürümde performansı iyileştirilerek 2019 yılında DeepLabV3+ son halini almıştır (Çetintaş, 2024). DeepLabV1 çözünürlüğü kontrol etmek için atrous evrişimlerini kullanırken ikinci versiyon olan DeepLabV2'de, farklı ölçeklerde daha iyi tahminler yapabilmek amacıyla ASPP adı verilen bir modül eklenmiştir (Pedrayes vd., 2021). Üçüncü versiyon olan DeepLabV3 sinir ağı ise, semantik segmentasyon

çalışmalarında kullanılmak için Chen vd. (2017b) tarafından geliştirilmiş bir CNN mimarisidir. ResNet ağ yapısı temel alınarak geliştirilen bu ağ, içerisinde 4 adet ResNet bloğu, ASPP ve global ortalama havuzlaması barındırmaktadır (Altınoluk, 2020). Mimari, derin sinir ağlarında konumsal piramit havuzlama modülü veya kodlama-kod çözücü yapısı kullanarak semantik segmentasyon işlemini gerçekleştirmektedir (Alkan E. , 2024). Bu versiyonda ASPP modülünün geliştirilmesinin yanı sıra, mimariye toplu normalizasyon özelliğini ekleyerek eğitim daha kolay hale getirilmiştir (Pedrayes vd., 2021). DeepLabV3 modelinin temel bileşenlerinden biri olan atrous konvolüsyon katmanları (genişletilmiş konvolüsyon katmanları olarak da bilinir) daha geniş mekânsal bağlamlardan bilgi yakalamak için özelleştirilerek hesaplama maliyetini önemli ölçüde artırmadan daha geniş mekânsal bağlamlardan bilgi yakalamada kritik bir rol oynamaktadır (Pal vd., 2024). Bu kapsamda DeepLabV3'ün temel amacının, uzamsal oluşumu kademe kademe geri kazanarak daha belirgin nesne sınırları elde etme olduğu söylenebilmektedir (Çetintaş, 2024).

Bu tez çalışmasında, tarihi hava fotoğraflarının semantik segmentasyon işlemi DeepLabV3 mimarisi U-Net omurgası ile Intel i5 11400f işlemci, 32 GB RAM ve RTX 3060 GPU donanımına sahip bir bilgisayarda gerçekleştirilmiştir.

2.2.3. U-Net Mimarisi

İlk kez, 2015 yılında düzenlenen Uluslararası Biyomedikal Görüntüleme Sempozyumu'nda (International Symposium on Biomedical Imaging - ISBI) Ronneberger vd. (2015) tarafından tanıtılan U-Net, görüntü segmentasyonu amacıyla geliştirilmiş derin sinir ağı mimarisidir. Tipik bir evrimsel ağda oldukça fazla eğitim görüntüsü kullanılmasının ve oluşan çıktı üründe her bir görüntüye ait tek bir sınıf etiketi bulunmasının dezavantajından bahseden Ronneberger vd. (2015), FCN üzerine inşa edilmiş U-Net yapısında, çok az sayıda eğitim görüntüsüyle çalışmayı ve daha yüksek doğruluklar elde etmeyi amaçlanmıştır. Mimarinin ana yapısı havuzlama operatörleri yerine üst örnekleme operatörlerinin getirildiği ardışık katmanlarla olağan bir daraltma ağını desteklerken, bu katmanların çıktı çözünürlüğünü arttırmasını sağlayacak şekilde tasarlanmıştır. Ayrıca U-Net yapısı, çok sayıda özellik kanalına sahip olması nedeniyle, üst örnekleme bölümündeki ağın bağlam bilgilerini daha yüksek çözünürlüklü katmanlara yayabilmektedir. Sonuçta yapı, U harfine benzer bir mimari tasarıma sahip olmuştur (Şekil 13).



Şekil 13. U-Net mimarisi (Ronneberger vd., 2015)

Şekil 13'te görüldüğü üzere, her bir özellik haritası gri renkli kutular ile temsil edilmiştir. Kutuların üzerindeki sayılar özellik haritalarının bant sayılarını, sol alt tarafındaki sayılar ise özellik haritalarının x-y ile ifade edilen boyutlarını göstermektedir. Beyaz renkli kutular kopyalanan özellik haritaları iken, kutular arasındaki oklar farklı işlemleri temsil etmektedir. Tamamen bağlı katmanları bulunmayan U-Net mimarisi, iki ana kısımdan oluşmaktadır. Biri kodlayıcı (encoder) veya daralan kısım (contracting path), diğeri ise kod çözücü (decoder) veya genişleyen kısım (expanding path) şeklindedir. Toplam 23 adet evrişim katmanı içeren bu mimaride, sol taraf daralan kısım sağ taraf ise genişleyen kısım olarak ifade edilmektedir (Ronneberger vd., 2015).

Daralan kısımda klasik bir evrişimsel ağ mimari yapısı mevcuttur. Süreç, girdi görüntüsüne iki defa uygulanan 3x3'lük evrişim işleminin ardından ReLU aktivasyon fonksiyonu ve aşağı örnekleme için özellik haritalarına 2 adımlı 2x2 maksimum havuzlama işleminin uygulanmasıyla başlamaktadır. Buradaki evrişim ve havuzlama katmanları girdi görüntüye 4 defa uygulanarak alt örnekleme işlemi gerçekleştirilmiş olur. Şekil 13'te görüldüğü üzere her bir katmanda girdi görüntünün boyutları yarıya düşürülüp özellik kanallarının sayısı iki katına çıkarılmaktadır. Buradaki özellik kanallarının sayısının artırılması, mimarinin girdi verilerden daha detaylı özellikler öğrenmesini sağlamaktadır (Ronneberger vd., 2015).

Genişleyen yolda amaç daralan kısımda kaybedilen uzamsal detayları geri kazanmaktır. Bu aşamada, özellik haritalarının boyutunu arttıran üst örnekleme işleminden sonra özellik kanallarının sayısını yarıya indiren 2×2 evrişim (yukarı evrişim) işlemi uygulanmaktadır. Ardından genişletilmiş özellik haritaları daralan yolda karşılığı olan özellik haritasıyla birleştirilerek iki defa 3×3 evrişim işlemi gerçekleştirilir. Bu işlem U-Net mimarisine özellik haritalarının konum bilgisine sahip olma avantajı sağlamaktadır (Alkan D. , 2023). Her bir evrişim işleminden sonra ReLU aktivasyon fonksiyonu kullanılıp sınır piksellerinin kaybı nedeniyle kırpma işlemi gerçekleştirilmektedir. Ağın son katmanında, 64 bileşenli her özellik vektörüne tek piksek genişliğinde 1×1 'lik bir evrişim işlemi uygulanarak istenen sınıf sayısına eşleme sağlanmış olur. Bu işlem sayesinde karmaşık özellik bilgileri korunurken ağıdaki derinlik boyutu azaltılmış olur. Bu sayede ağın hesaplama verimliliği artırılırken son katmanda az parametreyle çıktı üretme yeteneği de geliştirilmektedir. Genişleyen yol kısmında daralan kısmın tam aksine her katmanda girdi görüntünün boyutları iki katına çıkarılıp özellik kanallarının sayısı yarıya düşürülmektedir (Ronneberger vd., 2015).

Bir tür CNN mimarisi olan U-Net, tamamen bağlı katmanlar bulundurmazken bilgi çıkarımı için sadece evrişim katmanlarını kullanmaktadır. Tamamen bağlı katmanların olmaması sebebiyle küçük bir model yapısına sahip olması U-Net'e büyük bir avantaj sağlamaktadır. Bunun yanında gerekli olan eğitim verisinin az sayıda olması ve her seviye arasındaki atlamalı bağlantıların bulunması diğer bir avantajı oluşturmaktadır (Alkan D. , 2023). Buradaki atlamalı bağlantılar sayesinde, Şekil 13'te görülen daralma kısmında üretilen özellik haritalarının, genişleyen kısımda karşılık geldiği seviyeye doğrudan aktarımı sağlanabilmektedir. Bu da daralma kısmında sahip olunan genel bağlam bilgisi ile genişleyen kısımdaki ayrıntılı yerel bilgilerin entegre etme imkanı sağlamaktadır (Şener, 2024). Ayrıca mimarinin ana yapısında çok az eğitim verisiyle çalışma amaçlandığından mevcut eğitim görüntüsüne kayma ve dönme gibi veri artırma işlemleri uygulanarak bu dezavantaj minimize edilmeye çalışılmıştır (Ronneberger vd., 2015).

U-Net mimari yapısı Ronneberger vd. (2015) tarafından ilk oluşturulduğunda biyomedikal görüntü segmentasyonu için kullanılsa da zamanla, su segmentasyonu (Wieland & Martinis, 2019; Ghaznavi vd., 2024), bulut segmentasyonu (Wieland vd., 2019), bina segmentasyonu (Erdem & Avdan, 2020), bitki segmentasyonu (Ayushi & Buttar, 2024) ve yol segmentasyonu (Abderrahim vd., 2020; Song vd., 2024) gibi çeşitli uygulama alanlarında kullanılarak performansı test edilmiştir.

Modelin yapılandırmasında kullanılan ana parametreler Tablo 2 de ifade edilmiştir. Model, U-Net omurgası üzerine inşa edilmiş ve DeepLabV3'ün ASPP başlığı ile güçlendirilmiştir. Yardımcı bir FCN başlığı da eklenerek, derin katmanlardaki özelliklerin daha iyi öğrenilmesi hedeflenmiştir. Modelde, paralel eğitim sırasında tutarlı tahminler elde etmek için SyncBN (Senkronize Batch Normalizasyonu) kullanılmıştır. Ayrıca çapraz entropi kaybı yaklaşımı kullanılarak giriş görüntüleri normalize edilmiştir.

Tablo 2. U-Net omurgalı DeepLabV3 modelinin mimari yapılandırması ve hiper parametreleri


Parametre	Diğer
Model Mimarisi	U-Net tabanlı DeeplabV3
Girdi Görüntü Boyutu	256×256 piksel
Sınıf Sayısı	5 ve 3
Test Modu	'whole' (tüm görüntü üzerinde tahmin)
Optimizasyon Algoritması	Stokastik Gradyan İnişi (SGD)
Öğrenme Oranı (lr)	0.01
Momentum	0.9
Ağırlık Kaybı (weight_decay)	0.0005
Öğrenme Oranı	PolyLR (eta_min=1e-4, power=0.9, toplam
Planlayıcısı	iterasyon: 40000)
Toplam İterasyon Sayısı	40000
Batch Boyutu (Eğitim)	4
Değerlendirme Metriği	mIoU (ortalama Intersection over Union)
Validasyon Aralığı	Her 2000 iterasyonda bir
Veri Artırma Teknikleri	Rastgele Yatay Çevirme (%50 olasılıkla)
Aşama Sayısı (num_stages)	5
Normalizasyon	SyncBN(type='SyncBN',requires_grad=True)
Aktivasyon Funksiyonu	ReLU
Dropout Oranı (dropout_ratio)	0.1
Kayıp Funksiyonu	CrossEntropyLoss

3. BULGULAR

Bu çalışmada 1960 yılına ait tarihi hava fotoğrafı verilerinin U-Net omurgalı DeepLabV3 modeli ile semantik segmentasyonu gerçekleştirilerek arazi örtüsü/kullanım haritaları üretilmiştir. Bu aşamada 5 sınıflı (bina, zemin, bitki, yol ve tarım alanı), 3 sınıflı (bina, bitki ve zemin) ve yükseklik özelliklerinin dahil edilmesi gibi farklı senaryolar için model ayrı ayrı eğitilerek test edilmiş ve sonuç doğrulukları irdelenmiştir. Özellikle SYM bazlı yükseklik bilgisinin entegrasyonu ile tarihi hava fotoğrafı verilerinin düşük spektral ve radyometrik çözünürlüğünün modelin segmentasyon performansını düşürücü etkisi minimize edilmeye çalışılmış ve bu özelliklerin doğruluk üzerindeki etkisi değerlendirilmiştir. Modelin girdi boyutuna uygun olarak 256×256 piksel boyutunda toplamda 120 adet alt parçalara bölünen görüntüler eğitim, validasyon ve test olmak üzere sırasıyla %70, %15, %15 olacak şekilde üç farklı kümeye dağıtılmıştır. Sonuç olarak mimari 5 sınıflı ve 3 sınıflı, SYM'li ve SYM'siz şekilde eğitilmiş ve bu dört ayrı uygulama için elde edilen sonuçlar, doğruluk metrikleri kullanılarak karşılaştırılmıştır.

3.1. 5 Sınıf ile Gerçekleştirilen Sınıflandırma İşlemi

Bu aşamada önerilen model kullanılarak bina, bitki, zemin, yol ve tarım alanı olmak üzere 5 temel arazi örtüsü sınıfı için semantik segmentasyon işlemi gerçekleştirilmiştir. Şekil 14'te görüldüğü üzere, (a) sütununda 256×256 piksel boyutunda tarihi hava fotoğrafları, (b) sütununda etiketlenmiş veriden elde edilen referans haritalar, (c) sütununda modelin tahmin ettiği tematik arazi örtüsü haritaları (d) sütununda referans ve tahmin haritalarından elde edilen fark haritaları gösterilmektedir. Fark haritalarında yeşil renk ile gösterilen kısımlar doğru tahminleri, mavi renk ile gösterilen sonuçlar ise yanlış tahminleri ifade etmektedir.



Şekil 14. 5 sınıflı sınıflandırma sonuçlarına dair örnek test görüntüleri (a) gerçek harita, (b) referans harita, (c) tahmin haritası, (d) fark haritası

Şekil 14 incelendiğinde (c) sütununun 3.satırındaki tahmin haritasında, bina sınıfının özellikle zemin ve bitki sınıfı ile karıştığı görülebilmektedir. Bu durum Tablo 3'te verilen hata matrisi incelendiğinde de tespit edilebilir. Bitki sınıfı göz önüne alındığında Şekil 14'te görüldüğü üzere bu sınıfın diğer sınıflara göre daha doğru sınıflandırıldığı ve hata oranının daha düşük olduğu anlaşılmaktadır. Şekil 14'te (b) sütununun 2.satırındaki referans haritası

ve (c) sütununun 2.satırındaki tahmin haritası karşılaştırıldığında modelin tarım alanı sınıfı ile zemin sınıfını ayırmakta zorlandığı ve bu iki sınıfın karıştığı görülmektedir. Yol sınıfının, (b) ve (c) sütunları karşılaştırıldığında da görüldüğü üzere zemin sınıfına karıştığı tespit edilebilir. Son olarak (b) ve (c) sütunlarının 1.satırı incelendiğinde zemin sınıfının tarım alanı sınıfı ile karıştığı görülmektedir. Tablo 3'te gösterilen hata matrisi incelendiğinde yukarda Şekil 14 üzerinden ifade edilen görsel yorumlamaların sayısal olarak da doğrulandığı anlaşılmaktadır.

Tablo 3'te 5 sınıflı durum için test veri seti kullanılarak elde edilen hata matrisi gösterilmektedir. Bu tabloda bahsedilen arka plan, referans haritasında siyah ile ve fark haritasında kırmızı ile renklendirilen, 256×256 boyutlandırmadan kaynaklı eksik kalan pikselleri girdi boyutuna tamamlamak için eklenen ve etiketleme sürecinde gözden kaçıp etiketlenmeyen kısımlara atanan pikselleri temsil etmektedir.

Tablo 3. 5 sınıflı segmentasyon sonuçlarına ilişkin hata matrisi

	Arka Plan	Bina	Bitki	Tarım Alanı	Yol	Zemin
Arka Plan	836785	665	7232	871	282	5158
Bina	45	25990	11851	1396	847	15489
Bitki	377	3348	1351544	33488	2833	46154
Tarım Alanı	421	3074	33728	412026	4391	398819
Yol	208	3983	12763	11512	31388	63976
Zemin	268	14722	101435	155585	13214	1112724

Tablo 3'te yer verilen hata matrisinden de anlaşılacağı üzere bina sınıfı, en çok zemin ve ardından bitki sınıfı ile karıştırılarak modelin ayırt etmekte zorlandığı sınıflar arasında yer almıştır. Bitki sınıfı, zemin ve tarım alanı ile benzerlik göstermiş, tarım alanı sınıfının ise zemin sınıfına oldukça yüksek oranda karıştığı gözlemlenmiştir. Yol sınıfı yükseklik verisi yetersizliğinden kaynaklı zemin sınıfı ile, zemin sınıfı ise en çok tarım alanı sınıfı ile karışıklık göstermiştir. Tablo 3'te ifade edilen hata matrisinden elde edilen tüm çıkarımların Şekil 14 üzerinden yapılan görsel yorumlamalar ile eş doğrultuda ve tutarlı olduğu anlaşılabilmektedir. Önerilen model ile 5 sınıflı durum için semantik segmentasyon sonucu elde edilen sınıf bazlı doğruluklar Tablo 4'te gösterilmektedir.


Tablo 4. 5 sınıflı segmentasyon sonucu elde edilen sınıf bazlı doğruluklar (%)

	Kesinlik	Duyarlılık	F1 Skor	IoU
Bina	50.19	46.73	48.40	31.92
Bitki	89.00	94.00	91.43	84.22
Tarım Alanı	67.01	48.33	56.16	39.04
Yol	59.27	25.35	35.51	21.59
Zemin	67.75	79.60	73.20	57.73

F1 Skor ve IoU metrikleri baz alınarak doğruluk oranları yüksekten düşüğe doğru sıralandığında bitki, zemin, tarım alanı, bina ve yol sınıflarına ait F1 Skorları sırasıyla %91.43, %73.20, %56.16, %48.40, %35.51 ve IoU değerleri sırasıyla %84.22, %57.73, %39.04, %31.92, %21.59 olarak tespit edilmiştir (Tablo 4).

3.2. 3 Sınıf ile Gerçekleştirilen Sınıflandırma İşlemi

Önerilen model kullanılarak bina, bitki ve zemin olmak üzere 3 temel arazi örtüsü sınıfı için semantik segmentasyon işlemi gerçekleştirilmiştir (Şekil 15). Yol ve tarım alanı sınıfları 5 sınıflı durumda elde edilen sonuçlar dikkate alınarak zemin sınıfı altında birleştirilmiştir. Bu durum modelin tahminlerinde bina sınıfının, zemin sınıfı ile daha çok karışıklık göstermesine ve doğruluğun düşmesine neden olmuştur. Şekil 15 (c) sütunu 3.satırında gösterilen tahmin haritasında söz konusu durum gözlemlenebilmektedir. Şekil 14'te gösterilen tahmin haritaları ile karşılaştırma yapıldığında ise fark açıkça görülmektedir. Şekil 15 (c) sütunundaki görseller incelendiğinde bitki sınıfının zemin sınıfına karıştığı görülebilmektedir. Özellikle Şekil 14 ve 15 (d) sütunun 4. satırındaki fark haritası incelendiğinde sınıf sayısının düşürülmesinin bitki sınıfı için fazla değişiklik yaratmadığı tespit edilebilmektedir. Son olarak (c) sütununa bakıldığında zemin sınıfı doğruluğunun gözle görülür şekilde iyileştiği gözlemlenebilmektedir.



Şekil 15. 3 sınıflı sınıflandırma sonuçlarına dair örnek test görüntüleri (a) gerçek harita, (b) referans harita, (c) tahmin haritası, (d) fark haritası

Şekil 14 ve 15 (d) sütunlarındaki fark haritaları incelendiğinde yeşil ile renklendirilen doğru tahmin alanlarının arttığı ve mavi ile renklendirilen yanlış tahmin alanlarının ciddi miktarda azaldığı görülmektedir. Buradan da sınıf sayısının azaltılmasının, elde edilen doğrulukları arttırdığı çıkarımına ulaşılabilir. Tablo 5’te 3 sınıf ile sınıflandırılmış veri için hata matrisi gösterilmektedir.

Tablo 5. 3 sınıflı segmentasyon sonuçlarına ilişkin hata matrisi

	Arka Plan	Bina	Bitki	Zemin
Arka Plan	835795	465	6217	8516
Bina	3	19014	10764	25837
Bitki	100	1636	1348107	87901
Zemin	652	11715	144000	2217870

Tarım alanı ve yol sınıflarının zemin sınıfı olarak birleştirilmesinin ardından Tablo 3 ve 5'te görüldüğü üzere bina sınıfı, zemin sınıfı ile karışıklık göstermiş ve bu sınıf için hata oranı artmıştır. Bununla birlikte bitki sınıfının diğer sınıflara karışma oranı fazla değişmemiştir. Son olarak zemin sınıfı en çok bitki sınıfı ile karışıklık gösterdiği anlaşılmaktadır. Önerilen model ile 3 sınıflı durum için elde edilen sınıf bazlı doğrulukları Tablo 6'da gösterilmektedir.


Tablo 6. 3 sınıflı segmentasyon sonucu elde edilen sınıf bazlı doğruluklar (%)

	Kesinlik	Duyarlılık	F1 Skor	IoU
Bina	57.92	34.19	42.99	27.38
Bitki	89.33	93.77	91.50	84.32
Zemin	94.78	93.41	94.09	88.84

Tablo 5'te verilen hata matrisinden çıkarılan sonuçlar ile doğru orantılı şekilde Tablo 6'da verilen bina sınıfı doğruluğunun Tablo 4'e göre azaldığı tespit edilmiştir. Bitki sınıfı doğruluğunda fazla değişiklik olmamasına karşın zemin sınıfı doğruluğunda %31.11'lik önemli bir artış meydana gelmiştir.

3.3. SYM Eklenerek 5 Sınıf ile Gerçekleştirilen Sınıflandırma İşlemi

Bu aşamada bina, bitki, zemin, yol ve tarım alanı olmak üzere 5 temel arazi örtüsü sınıfı için semantik segmentasyon işleminde yükseklik bilgisinin katkısı ortaya koyulmuştur. Bu amaçla çalışmada önerilen ağ mimarisine gri değer özelliklerinin yanı sıra SYM kaynaklı yükseklik özellikleri de girdi olarak dahil edilmiştir. Bu tasarım ile gerçekleştirilen sınıflandırma sonrası elde edilen doğruluk haritaları Şekil 16'da gösterilmiştir.



Şekil 16. Yükseklik özellikleri eklenmesi sonrası 5 sınıf ile gerçekleştirilen sınıflandırma sonuçlarına dair örnek test görüntüleri (a) gerçek harita, (b) referans harita, (c) tahmin haritası, (d) fark haritası

Çalışma kapsamında yükseklik bilgisi entegre edilerek modelin performansının iyileştirilmesi amaçlanmıştır. Bu bağlamda, stereo çekim formatında alınmış tarihi hava fotoğrafı verilerinden fotogrametrik değerlendirme işlemi sonrası elde edilen SYM verisi

kaynaklı yükseklik özellikleri modele entegre edilerek mimari eğitilmiştir. SYM tabanlı yükseklik bilgisi eklenerek elde edilen model tahmin sonuçları Şekil 16'da gösterilmiştir. Şekil 14 ve 16 (c) sütunlarının 1 ve 2. satırları karşılaştırıldığında özellikle tarım alanı sınıfının zemin sınıfı ile karışımında azalma olduğu gözlemlenmiştir. Buradan hareketle SYM tabanlı yükseklik özelliklerinin mimarinin segmentasyon doğruluğuna olumlu etki sağlandığı anlaşılmaktadır. SYM kaynaklı yükseklik özellikleri eklenmesi sonrasında 5 sınıf için semantik segmentasyon sonuçlarına ilişkin oluşturulan hata matrisi Tablo 7'de gösterilmektedir.

Tablo 7. Yükseklik özellikleri eklenmiş 5 sınıflı segmentasyon sonuçlarına ilişkin hata matrisi

	Arka Plan	Bina	Bitki	Tarım Alanı	Yol	Zemin
Arka Plan	836690	567	7045	750	102	5839
Bina	24	25174	10417	2919	817	16267
Bitki	443	2491	1350914	38040	2158	43698
Tarım Alanı	347	2465	30354	430526	4398	384369
Yol	64	3950	12114	13761	29491	64450
Zemin	271	12041	102764	145777	10338	1126757

Tablo 3 ve 7'de ifade edilen sonuçlar karşılıklı olarak irdelendiğinde, bina sınıfının bitki sınıfına karışma oranının azaldığı ayrıca zemin ve tarım alanı sınıfına karışma oranının az miktarda arttığı anlaşılmaktadır. Bina sınıfındaki değişimlerle orantılı şekilde Tablo 7'de Tablo 3'e göre bitki sınıfının bina sınıfı ile karışmasının azaldığı zemin ve tarım alanı ile benzerliğinin az miktarda arttığı tespit edilmiştir. Buradan yola çıkılarak yükseklik bilgisinin bitki ve bina sınıflarının karışımını bir miktar önlediği görülebilir. Tarım alanı sınıfının ise bitki sınıfına karışması azalmış olup azalan miktarın tarım alanı olarak sınıflandığı görülebilmektedir. SYM tabanlı yükseklik özelliklerinin mimariye entegre edilmesi sonucunda yol sınıfının tarım alanı ve zemin sınıfı ile karışımın artmasına ve zemin sınıfının ise diğer sınıflarla karışımının azalmasına sebep olduğu tespit edilmiştir. Yükseklik özellikleri eklenmiş 5 sınıflı segmentasyon sonuçlarına ilişkin sınıf bazlı doğrulukları Tablo 8'de gösterilmektedir.


Tablo 8. Yükseklik özellikleri ile 5 sınıflı segmentasyon sonucu elde edilen sınıf bazlı doğruluklar (%)

	Kesinlik	Duyarlılık	F1 Skor	IoU
Bina	53.92	45.26	49.21	32.64
Bitki	89.25	93.96	91.55	84.41
Tarım Alanı	68.15	50.50	58.01	40.86
Yol	62.34	23.82	34.47	20.82
Zemin	68.65	80.60	74.15	58.91

Tablo 4 ve Tablo 8’de ki F1 Skor ve IoU değerleri karşılaştırıldığında sonuçların genel olarak %1 oranında iyileştiği tespit edilmiştir. Bu çıkarım Tablo 7’de verilen hata matrisinden ve Şekil 16’da verilen görsellerden de anlaşılabilmektedir.

3.4. SYM Eklenerek 3 Sınıf ile Gerçekleştirilen Sınıflandırma İşlemi

Bu aşamada bina, bitki ve zemin olmak üzere 3 temel arazi örtüsü sınıfı için semantik segmentasyon işleminde yükseklik bilgisinin katkısı ortaya koyulmuştur. Bu tasarım ile gerçekleştirilen sınıflandırma sonrası elde edilen doğruluk haritaları Şekil 17’de gösterilmiştir. Şekil 16 ve 17 karşılaştırıldığında (c) sütununda tahmin haritasında gösterilen bitki sınıfının diğer sınıflara karışımının arttığı gözlemlenebilmektedir. Aynı durum bina sınıfı için de geçerlilik göstermektedir. Bu iki şekil karşılaştırıldığında bina sınıfının zemin sınıfına karışımının arttığı anlaşılmaktadır. Tablo 7 ve 9’da semantik segmentasyon sonuçlarına ilişkin oluşturulan hata matrisleri irdelendiğinde Şekil 16 ve 17’de ki görsel durumu destekleyen sayısal sonuçlar elde edildiği anlaşılmaktadır. SYM kaynaklı yükseklik bilgisi eklenerek 3 sınıflı durum için gerçekleştirilen sınıflandırmada, zemin sınıfının diğer sınıflara karışımının azaldığı ve sonuç doğrulukların arttığı tespit edilmiştir. Tablo 7’ye göre Tablo 9’da hata matrisleri incelendiğinde zemin sınıfının daha doğru sınıflandırıldığı anlaşılabilmektedir. Şekil 17 ve 16 (d) sütunlarında verilen fark haritalarında söz konusu iyileşme görsel olarak da doğrulanabilmektedir. Sınıf sayısının 5 sınıflı durumdan 3 sınıfa indirgenmesi hatalı ve yanlış tahmin olarak gösterilen mavi renkli alanlarda ciddi azalma yaratmış ve doğru tahmin olarak belirtilen yeşil renkli alanlarda ise büyük bir artış sağlamıştır.



Şekil 17. Yükseklik özellikleri eklenmesi sonrası 3 sınıf ile gerçekleştirilen sınıflandırma sonuçlarına dair örnek test görüntüleri (a) gerçek harita, (b) referans harita, (c) tahmin haritası, (d) fark haritası

Şekil 15 ve 17 karşılaştırıldığında sonuçlar arasındaki farkın görsel olarak zor yorumlanabildiği tespit edilmiştir. Buna karşın Tablo 9’da verilen hata matrisi incelendiğinde yükseklik özelliklerinin sınıflandırma sonuçlarına olan pozitif etkisi anlaşılabilmektedir.

Tablo 9. Yükseklik özellikleri eklenmiş 3 sınıflı segmentasyon sonuçlarına ilişkin hata matrisi

	Arka Plan	Bina	Bitki	Zemin
Arka Plan	836105	505	5464	8919
Bina	12	21456	6803	27347
Bitki	275	1927	1340533	95009
Zemin	173	13032	122962	2238070

SYM kaynaklı yükseklik özelliklerinin bina sınıfının tespitindeki etkisi irdelendiğinde Tablo 9’da Tablo 5’e göre bina sınıfının bitki ve zemin sınıfına karışımının ciddi oranda azaldığı ve bu azalmanın bina sınıfı olarak sınıflandırıldığı gözlemlenebilmektedir. Bitki sınıfının ise diğer sınıflara karışımında ise düşük oranda artış olduğu tespit edilebilmektedir. Bununla birlikte zemin sınıfının ise bina sınıfına karışımında az miktarda artış olmasına rağmen bitki sınıfına karışımının ciddi oranda azaldığı görülmektedir. Elde edilen sonuçlar genel olarak incelendiğinde SYM tabanlı yükseklik özelliklerinin özellikle bina ve bitki sınıfında iyileştirmeler sağladığı tespit edilmiştir. Tablo 10’da SYM eklenerek 3 sınıf ile sınıflandırılmış verinin sınıf bazlı doğrulukları gösterilmektedir.

Tablo 10. Yükseklik özellikleri ile 3 sınıflı segmentasyon sonucu elde edilen sınıf bazlı doğruluklar (%)

	Kesinlik	Duyarlılık	F1 Skor	IoU
Bina	58.11	38.58	46.37	30.18
Bitki	90.84	93.24	92.02	85.22
Zemin	94.46	94.26	94.36	89.33

Tablo 6’ya göre Tablo 10’da bina sınıfının IoU değerinde %3, F1 Skor değerine %4’lük bir artış tespit edilmiştir. Bitki ve zemin sınıfının değerlerinde ise %1’lik bir artış meydana gelmiştir. SYM verisinin entegrasyonu ile sınıf bazlı doğruluklarda genel olarak artış gözlemlenmiştir. Ayrıca Tablo 8 ve 10 kıyaslandığında sınıf sayısının 5’ten 3’e düşürülmesinin, bina sınıfının doğruluklarında az oranda düşüş meydana getirmesine karşın bitki ve zemin sınıfının doğruluklarında önemli oranda artış meydana getirdiği anlaşılmaktadır. Bu durum bina sınıfında F1 Skor için %2.84 ve IoU için %2.26’lık bir

düşüş, bitki sınıfında F1 Skor için %0.47 ve IoU için %0.81’lik bir artış ve son olarak zemin sınıfında F1 Skor için %20.21 ve IoU için %30.42’lik bir artış yaratmıştır.

Tablo 11’de görüldüğü üzere oluşturulan 4 kategorinin Genel Doğruluk, Kesinlik, Duyarlılık, F1 Skor ve IoU metrikleri ile elde edilen sonuçlar verilmiştir. Buradaki Genel Doğruluk değerine arka plan dahil iken F1 Skor ve IoU metriği, modelin arka plan olarak eksik pikseller göz ardı edilerek hesaplanmıştır. 5 sınıflı ve 5 sınıflı SYM ile gerçekleştirilen sınıflandırmalar ile 3 sınıflı ve 3 sınıflı SYM ile gerçekleştirilen sınıflandırmalar kendi içlerinde kıyaslanırsa doğruluklarda az miktarda bir artış tespit edilebilmektedir. Sonuç olarak SYM verisinin entegre edilmesi genel olarak doğrulukları yaklaşık %1’lik bir artış oranında geliştirmiştir.

Tablo 11. Elde edilen doğruluk metrikleri (%)

Sınıf Sayısı	Genel Doğruluk	Kesinlik	Duyarlılık	F1 Skor	IoU
5 sınıflı	79.91	66.65	58.80	60.94	46.90
3 sınıflı	93.69	80.67	73.79	76.19	66.85
5 sınıflı SYM ile	80.52	68.46	58.83	61.48	47.53
3 sınıflı SYM ile	94.01	81.14	75.36	77.59	68.24

Tablo 11’in 1. ve 3. satırları yani 5 sınıflı ve 5 sınıflı SYM ile gerçekleştirilen sınıflandırmalar karşılaştırılırsa, SYM verisinin eklenmesi Genel doğrulukta %0.61’lik, F1 Skor değerinde %0.54’lük ve IoU metriğinde %0.63’lik bir artış yaratmıştır. Aynı şekilde 3 sınıflı ve 3 sınıflı SYM ile gerçekleştirilen sınıflandırmalar yani Tablo 11’in 2. ve 4.satırı karşılaştırılırsa Genel Doğrulukta %0.32’lik, F1 Skor değerinde %1.4’lük ve son olarak IoU metriğinde %1.39’lük bir artış gözlemlenmiştir. 5 sınıflı ve 3 sınıflı sınıflandırmalar kıyaslanırsa sınıf sayısının düşürülmesi, Genel Doğruluklarda %13.78’lik, F1 Skor değerinde %15.25’lik, IoU metriğinde %19.95’lik bir artış sağlamıştır. SYM entegrasyonu ile gerçekleştirilen 5 sınıflı ve 3 sınıflı sınıflandırmalarda sınıf sayısının azaltılması, Genel Doğrulukta %13.49’lük, F1 Skor değerinde %16.11’lik ve IoU metriğinde %20.71’lik bir artış sağlamıştır. Sınıf sayısının fazla olmasının karışıklığı arttırdığı ve sınıf sayısının azaltılmasının da genel sonuçlara büyük miktarda olumlu etki ettiği gözlemlenmiştir. Bunun yanı sıra SYM verisinin entegrasyonu ile mimarinin daha doğru sonuçlar ürettiği sonucuna


varılmıştır. Bu çıkarımlar göz önünde bulundurulursa mimarinin doğruluk sonuçlarını arttırmak için denenen her iki yöntemin de olumlu sonuçlar ürettiği tespit edilmiştir.



4. TARTIŞMA

Tez kapsamında önerilen DeepLabV3 mimarisi U-Net omurgası kullanılarak tarihi hava fotoğraflarının semantik segmentasyonu ile arazi örtüsü tespiti ve bu yaklaşıma sınıf sayısının kademeli olarak azaltılması, veri arttırımı ve SYM kaynaklı yükseklik özelliklerinin entegre edilmesi gibi iyileştirmeler yapılmak suretiyle her bir yöntem test edilerek doğruluk oranlarının arttırılması için alternatif çözüm olanakları sunulmuştur.

Çalışma kapsamında kullanılan tarihi hava fotoğrafları, spektral ve radyometrik çözünürlüklerinin oldukça düşük olması, sayısal ortama aktarılırken taranma sürecindeki bozulmalar ve yeterli metadata bulundurmamaları gibi özellikleri sebebiyle sınıflandırma sürecini oldukça zorlaştırmıştır. Bu bağlamda tarihi hava görüntüleri için ana dezavantajlardan biri tek bantlı pankromatik veriler olmalarıdır. Bu durum çok boyutlu spektral bant bilgisi içermeyen görüntülerin tek spektral özellikle sınıflandırılmasını zorunlu kılmaktadır. Bu eksiklik manuel şekilde yapılan veri etiketleme sürecinde sınıfları tanımlama işlemini zorlaştırmış ve semantik segmentasyon sürecini zaman alıcı hale getirmiştir.




Şekil 18. (a) bina ağırlıklı, (b) bitki ağırlıklı, (c) tarım alanı ağırlıklı tarihi hava fotoğrafları

Çalışmada kullanılan tarihi hava fotoğrafı verileri, kırsal alan ve tarım alanları yoğunluklu, bitki örtüsü ve ağaç yoğunluklu gibi çeşitli arazi örtüsü/kullanım karakterine sahip bölgeleri içeren gri tonlamalı verilerdir (Şekil 18). Bu durum her bir çeşit görüntünün sınıflandırılmasında farklı zorluklar ortaya çıkarmıştır. Örneğin bitki ağırlıklı tarihi hava fotoğraflarında yol ve bina sınıflarının tespiti ayrıca bitki yoğunluğunun azaldığı yerlerde

bitki ve zemin sınıfı ayrımının yapılması zorlaşmış ve zaman alıcı hale gelmiştir. Benzer şekilde tarım alanı ve bitki sınıflarının birbirine benzerlik oranı ayırt etmeyi güçleştirmiştir.

Şekil 18’de görüldüğü üzere bina yoğunluğunun fazla olduğu görüntülerde görüntülerin gri tonlamalı olması büyük dezavantaj yaratmıştır. Bunun sebebi göz ile ayırt etmede güçlük çekilmesi ve manuel olarak sınıflandırmada sınıfların tamamen doğru atanamamasıdır. Özellikle bina sınıfları etiketlenirken zemin sınıfı ile karıştırılmış ve ayırt etmesi zorlaşmıştır. Bazı alanlarda ise yol sınıfının zemin ve tarım alanına karışması diğer bir olumsuz yön olarak görülebilir. Elde edilen görüntülerin 1960 yılın ait tarihi hava fotoğrafları olması sebebiyle herhangi bir ek öznelilik verisi içermemesi manuel etiketlemeyi zorlaştırmış bu durum doğru orantılı şekilde model sonuçlarını da etkilemiştir.

Şekil 19’da modelin eksik kalan pikselleri arka plan olarak yeni bir sınıfa atadığı görülmektedir. Bunun sebebi, görüntülerin yeniden ölçeklendirilip 256×256 şeklinde boyutlandırılmasının ardından eksik kalan pikselleri girdi boyutuna tamamlamak için modelin eklediği ve etiketleme sürecinde gözden kaçıp etiketlenmeyen kısımlara atadığı piksellerdir. Şekil 19’da siyah olarak görülebilen bu pikseller, modeli olumsuz etkilediği ve doğruluk sonuçlarını değiştirdiği için bir diğer dezavantaj olarak görülmektedir.



Şekil 19. Modelin arka plan olarak atadığı eksik pikseller

Mevcut çalışma kapsamında kurum arşivlerinde en yaygın bulunan 1/35000 ölçekli tarihi hava görüntüleri kullanılarak bu çalışma gerçekleştirilmiştir. Manuel etiketleme sürecinin zorluğu ve zaman alıcılığı sebebiyle eğitim veri seti boyutu göreceli olarak düşük kalmıştır. Bu handikabın önüne geçebilmek adına çalışmada önerilen derin ağ mimarisi tasarımı bu durum göz önünde bulundurulmuştur. Özellikle az eğitim görüntüsüyle daha hassas segmentasyonlar üretmeyi amaçlayan U-Net mimarisi, tarihi görüntü arşivleri gibi daha az eğitim verisine ihtiyaç duyan çalışmalarda iyi sonuç vermesinden dolayı tercih

edilmiştir. Literatürde bu çalışmaya benzer şekilde tarihi hava fotoğrafı verilerinden arazi örtüsü sınıflandırmaya yönelik yapılmış çalışmalar Tablo 12’de verilmektedir.

Tablo 12. Literatürdeki benzer çalışmalar ve tez çalışması karşılaştırılması

	Model	Veri Seti	Yıl	Sınıf Sayısı	F1 (%)		IoU (%)	
Dorozynski vd. (2024)	Çok modlu UPerNet	Ortofoto, topografik harita	2010 2011	2	Bina	Bitki	-	-
					62.2	83.7		
Le Bris vd. (2020)	U-Net, Fuse-Net	SYM ve ortofoto	1981 2001	5	1981	2001	1981	2001
					70.0	71.1	58.3	59.3
Tez sonuçları	DeeplabV3 (U-Net)	Hava Fotoğrafı	1960	5 ve 3	5 için	3 için	5 için	3 için
					60.94	76.19	46.90	66.85
SYM’li tez sonuçları	DeeplabV3 (U-Net)	Hava Fotoğrafı +SYM	1960	5 ve 3	5 için	3 için	5 için	3 için
					61.48	77.59	47.53	68.24

Dorozynski vd. (2024), tarihi ortofoto ve tarihi taranmış topografik harita kullanarak çok modlu UPerNet sınıflandırıcısı ile çok modlu bina ve çok modlu bitki segmentasyonu üzerine çalışma yapmışlar ve sonuçlarının ortalamasını sunmuşlardır. Dorozynski vd. (2024)’nin nispeten daha yeni tarihli RGB görüntüler kullanması, 2 farklı veri seti kullanması ve sadece 2 sınıflı çalışması sonuç doğruluklarını olumlu yönde etkilediği görülmektedir. Le Bris vd. (2020) ise tarihi hava fotoğraflarından elde ettikleri SYM ve ortofoto üzerinde yaptıkları çalışmada sadece U-Net ve SYM kullanarak elde ettikleri sonuçlar verilmiştir. Su, mahsuller, yollar, bitki örtüsü ve binalar olmak üzere 5 sınıfta çalışan Le Bris vd. (2020), çalışmasında SYM verisinin eklenmesinin doğruluğu bir miktar düşürdüğü görülse de diğer bir yöntem olan gölgelendirme haritası ile doğruluklarında iyileşme olduğu tespit edilmiştir.

Bu tez çalışmasında, eğitim verisi sayısının az olması sebebiyle veri işleme sırasında çeşitli ön işleme ve veri artırım teknikleri uygulanmış ve modelin performans ve genelleme kabiliyetini arttırılmıştır. Bununla birlikte 5 sınıflı ve 3 sınıflı durum için değerlendirmeler yapılmış ve her iki durumun doğruluk karşılaştırmaları gerçekleştirilmiştir. Son olarak gri

tonlama dışında herhangi bir ek öznitelik verisinin bulunmaması sebebiyle SYM kaynaklı yükseklik özelliklerinin hem 3 sınıflı hem 5 sınıflı, sınıflandırmalara eklenmesi ile sonuç doğruluklarının yükseldiği tespit edilmiştir.

Tablo 12’de görüldüğü üzere Dorozynski vd. (2024), bu tez çalışmasına göre yeni tarihli RGB görüntüler kullanması ve 2 sınıflı çalışmasına rağmen sınıf bazlı doğruluklara bakıldığında bitki sınıfı doğruluğunu daha düşük elde ettiği gözlemlenmiştir. 3 sınıflı segmentasyon sonucu elde edilen bitki sınıfı doğruluğu %92.02 iken Dorozynski vd. (2024) bu doğruluğu %83.7 olarak elde etmiştir. Le Bris vd. (2020)’nin 1981 yılına ait verilerle elde ettiği sonuçlar ile bu tez çalışmasında gerçekleştirilen 1960 yılı görüntülerinin segmentasyonu ile elde edilen sonuçlar karşılaştırıldığında yakın doğruluklar elde edildiği gözlemlenmiştir. Bu durum, daha eski tarihli görüntüler kullanılmasına rağmen literatüre göre iyi sonuçlar elde edildiğini göstermektedir.

5. SONUÇLAR VE ÖNERİLER

Tez kapsamında, tarihi hava fotoğraflarının semantik segmentasyonunun araştırılması ve arazi örtüsünün otomatik olarak sınıflandırılması amaçlanmıştır. Bu bağlamda, mimari U-Net omurgalı DeepLabV3 modeli üzerine kurulmuş ve sonuçlar değerlendirilmiştir. Çalışmada HGM'den temin edilmiş 1960 tarihli 1/35000 ölçekte kaydedilmiş tarihi hava fotoğrafı verileri kullanılmıştır. Görüntüler incelendiğinde test alanlarındaki bitki, bina ve tarım alanları gibi arazi örtüsü içeriğine sahip olacak şekilde seçilmiştir. Arazi örtüsü karakterine göre kategorilenen görüntüler ilk olarak grafiksel görüntü etiketleme aracı olan LabelMe kullanılarak manuel şekilde etiketlenmiştir. Tarihi hava fotoğraflarının eski tarihli olması, 1960 yılına ait etiketli verinin az olması ve RGB verisi içermemesinden kaynaklı göz ile ayırt etme sürecinin uzaması verinin etiketlenilmesini oldukça zorlaştırmıştır. Çalışmada önerilen derin ağ mimarisi kullanılarak hem 5 sınıflı hem de 3 sınıflı olacak şekilde, zemin ve zemin üstü objelerin semantik segmentasyonu gerçekleştirilmiştir. Ayrıca SYM kaynaklı yükseklik özelliklerinin entegrasyonu sonrasında ve hem 3 sınıflı hem 5 sınıflı tasarımlar için sonuçlar irdelenmiştir. Bu kapsamda 4 farklı kategori için semantik segmentasyon gerçekleştirilip doğruluk analizi yapılmıştır. Genel doğruluklar sırasıyla 5 sınıflı için %79.91, 3 sınıflı için %93.69, SYM eklenerek oluşturulmuş 5 sınıflı için %80.52 ve SYM eklenerek oluşturulmuş 3 sınıflı için %94.01 şeklindedir. 5 sınıflı veri için F1 Skor değeri %60.94 ve IoU metriği %46.90 iken 3 sınıflı veri için F1 Skor değeri %76.19 ve IoU metriği %66.85'tir. SYM eklenerek oluşturulmuş 5 sınıflı veri için F1 Skor değeri %61.48 ve IoU metriği %47.53 iken SYM eklenerek oluşturulmuş 3 sınıflı veri için F1 Skor değeri %77.59 ve IoU metriği %68.24'tür. Bu sonuçlardan yola çıkıldığında çalışmada önerilen mimari kullanılarak, geleneksel yaklaşımlar ile sınıflandırma süreci oldukça zor olan tarihi hava fotoğrafları verilerinin başarılı bir şekilde sınıflandırılabilceği ortaya koyulmuştur. Gelecekteki çalışmalarda; söz konusu sınıflandırma probleminin çözümünde daha yüksek örneklem sayısı ve farklı mimari tasarımların entegrasyonu ile doğruluk düzeylerinin arttırılabileceği düşünülmektedir.

6. KAYNAKLAR

- Abd Elaziz, M., Al-qaness, M. A., Ibrahim, R. A., Ewees, A. A., & Shrahili, M. (2024). Multilevel Thresholding Aerial Image Segmentation Using Comprehensive Learning-Based Snow Ablation Optimizer with Double Attractors. *Egyptian Informatics Journal*, 27, 100500. doi:<https://doi.org/10.1016/j.eij.2024.100500>
- Abderrahim, N. Y., Abderrahim, S., & Rida, A. (2020). Road Segmentation Using U-Net Architecture, 2020 IEEE International conference of Moroccan Geomatics (Morgeo). 1-4. doi:10.1109/Morgeo49228.2020.9121887
- Acar, H. (2012). Nokta Belirleme Algoritmaları ile Otomatik Görüntü Eşleştirme. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon.
- Acar, H. (2018). Bina Çatı Noktalarının Yüksek Çözünürlüklü Görüntülerden Üretilen 3B Nokta Bulutu Verileri ile Otomatik Tespit Edilmesi Ve Gerçek Ortofoto Üretimi. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Trabzon.
- Alkan, D. (2023). U-Net Derin Öğrenme Mimarisi Kullanılarak Yanmış Alanların Uydu Görüntülerinden Tespiti. Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, Konya.
- Alkan, E. (2024). Ormanlardaki Böcek Zararlarının Uzaktan Algılama Verileriyle Yapay Zeka Tabanlı Tespiti. Düzce Üniversitesi, Lisansüstü Eğitim Enstitüsü, Doktora Tezi, Düzce.
- Alom, M. Z., Taha, T., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M., & Asari, V. (2019). A State-of-the-Art Survey on Deep Learning Theory and Architectures. *Electronics*, 8(3), 292. doi:<https://doi.org/10.3390/electronics8030292>
- Altınoluk, E. (2020). Derin Öğrenme ile Yüksek Çözünürlüklü Ortofotoların Sınıflandırma Doğruluklarının Analizi. Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, Çanakkale.
- Altuntaş, C. (2019). Fotogrametrik Görüntülerin Otomatik Eşleştirilmesi ve Seyrek Nokta Bulutu Oluşturma. Aksaray: TUFUAB X. Teknik Sempozyum.
- Antrop, M., & Eetvelde, V. V. (2000). Holistic Aspects of Suburban Landscapes: Visual Image Interpretation and Landscape Metrics. *Landscape and Urban Planning*, 50(1), 43-58. doi:[https://doi.org/10.1016/S0169-2046\(00\)00079-7](https://doi.org/10.1016/S0169-2046(00)00079-7)
- Anzai, A., & DeAngelis, G. C. (2010). Neural Computations Underlying Depth Perception. *Current Opinion in Neurobiology*, 20(3), 367-375. doi:<https://doi.org/10.1016/j.conb.2010.04.006>
- Arel, I., Rose, D. C., & Karnowski, T. P. (2010). Deep Machine Learning - A New Frontier in Artificial Intelligence Research [Research Frontier. *IEEE Computational Intelligence Magazine*, 5(4), 13-18. doi:10.1109/MCI.2010.938364

- Asri, İ., & Çorumluoğlu, Ö. (2007). Büyük Objelerde Tarihi Dökümantasyon ve Tanıtım Amaçlı Gpsit Destekli Dijital Fotogrametrik 3B Modelleme. TUFUAB Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği IV. Teknik Sempozyumu, İstanbul. doi:10.13140/2.1.4539.1681
- Avşar, E. (2022). Tarihi Hava Fotoğraflarının Farklı Yöntemler ile Ortorektifikasyonu ve Doğruluk Analizi. Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Afyonkarahisar.
- Aydemir, A. (2018). Sulama Sonrası Harran Ovası Tarımsal Arazilerdeki Yapılaşmanın Piksel Tabanlı / Nesne Tabanlı Sınıflandırma Yöntemleri ile Belirlenmesi ve İki Yöntemin Karşılaştırılması. Harran Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Şanlıurfa.
- Ayushi, & Buttar, P. K. (2024). Satellite Imagery Analysis for Crop Type Segmentation Using U-Net Architecture. *Procedia Computer Science*, 235, 3418-3427. doi:https://doi.org/10.1016/j.procs.2024.04.322
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481-2495. doi:10.1109/TPAMI.2016.2644615
- Bayburt, S. (2009). Uydu Görüntülerinin Piksel ve Nesne Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması (Doğu Trakya Bölgesi Örneği). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Behera, T. K., Bakshi, S., & Sa, P. K. (2023). A Lightweight Deep Learning Architecture for Vegetation Segmentation using UAV-captured Aerial Images. *Sustainable Computing: Informatics and Systems*, 37, 100841. doi:https://doi.org/10.1016/j.suscom.2022.100841
- Bilgi, S. (2007). Fotogrametri ve Uzaktan Algılamada Veri Elde Etme Yöntemlerinin Gelişimi ve Kısa Tarihçeleri. *Jeodezi Ve Jeoinformasyon Dergisi*, 96, 48-55.
- Bingöl, K., Akan, A. E., Örmecioğlu, H. T., & Er, A. (2020). Depreme Dayanıklı Mimari Tasarımda Yapay Zeka Uygulamaları: Derin Öğrenme ve Görüntü İşleme Yöntemi ile Düzensiz Taşıyıcı Sistem Tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(4), 2197-2210. doi:https://doi.org/10.17341/gazimmfd.647981
- Bıyıklı, D., & Marangoz, A. M. (2024). Ormanlık Alanlar için Nesne Tabanlı Sınıflandırma Sonuçları ile Arazi Verisinin Karşılaştırılması. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, 25(1), 55-66. doi:https://doi.org/10.17474/artvinofd.1322949
- Božek, P., Janus, J., & Mitka, B. (2019). Analysis of Changes in Forest Structure using Point Clouds from Historical Aerial Photographs. *Remote Sensing*, 11(19), 2259. doi:https://doi.org/10.3390/rs11192259
- Brar, K. K., Goyal, B., Dogra, A., Mustafa, M. A., Majumdar, R., Alkhayyat, A., & Kukreja, V. (2024). Image Segmentation Review: Theoretical Background and Recent Advances. *Information Fusion*, 114, 102608. doi:https://doi.org/10.1016/j.inffus.2024.102608

- Chen, L. C., Papandreou, G., Schroff, F., & Adam, H. (2017b). Rethinking Atrous Convolution for Semantic Image Segmentation. *ArXiv*, *abs/1706.05587*. doi:<https://doi.org/10.48550/arXiv.1706.05587>
- Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S., & Miao, Y. (2021). Review of Image Classification Algorithms Based on Convolutional Neural Networks. *Remote Sensing*, *13*, 4712. doi:<https://doi.org/10.3390/rs13224712>
- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2017a). 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. doi:[10.1109/TPAMI.2017.2699184](https://doi.org/10.1109/TPAMI.2017.2699184)
- Cheng, C.-S., Luo, L., Murphy, S., Lee, Y.-C., & Leite, F. (2024b). A Framework to Enhance Disaster Debris Estimation with AI and Aerial Photogrammetry. *International Journal of Disaster Risk Reduction*, *107*, 104468. doi:<https://doi.org/10.1016/j.ijdr.2024.104468>
- Cheng, G., Zhu, F., Xiang, S., Wang, Y., & Pan, C. (2016). Accurate Urban Road Centerline Extraction from VHR Imagery Via Multiscale Segmentation and Tensor Voting. *Neurocomputing*, *205*, 407-420. doi:<https://doi.org/10.1016/j.neucom.2016.04.026>
- Cheng, J., Deng, C., Su, Y., An, Z., & Wang, Q. (2024a). Methods and Datasets on Semantic Segmentation for Unmanned Aerial Vehicle Remote Sensing Images: A Review. *211*, 1-34. doi:<https://doi.org/10.1016/j.isprsjprs.2024.03.012>
- Chudasama, B., Ovaskainen, N., Tamminen, J., Nordbäck, N., Engström, J., & Aaltonen, I. (2024). Automated Mapping of Bedrock-Fracture Traces from UAV-Acquired Images Using U-Net Convolutional Neural Networks. *Computers & Geosciences*, *182*, 105463. doi:<https://doi.org/10.1016/j.cageo.2023.105463>
- Cowley, D. C., & Stichelbaut, B. B. (2012). Historic Aerial Photographic Archives for European Archaeology. *European Journal of Archaeology*, *15*(2), 217-236. doi:<https://doi.org/10.1179/1461957112Y.0000000010>
- Cömert, R. (2018). İnsansız Hava Aracı Verilerinden Nesne Tabanlı Sınıflandırma Yaklaşımı ile Sığ Heyelanların Tespiti. Eskişehir Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Eskişehir.
- Çelik, M. Ö., Yakar, İ., Hamal, S., Oğuz, G. M., & Kanun, E. (2020). Sfm Tekniği ile Oluşturulan 3B Modellerin Kültürel Mirasın Belgelenmesi Çalışmalarında Kullanılması: Gözne Kalesi Örneği. *Türkiye İnsansız Hava Araçları Dergisi*, *2*(1), 22-27.
- Çetin, O. (2019). Hava Fotoğrafları ve İnsansız Hava Aracı Görüntülerinden Arazi Topoğrafyası Ölçümü, Sonuçların Analizi ve Karşılaştırması (Haymana Yeşilyurt Köyü Uygulaması). Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, Konya.

- Çetintaş, T. (2024). Derin Öğrenme Teknikleriyle Bilgisayarlı Tomografi Görüntülerinden Otomatik Karaciğer Ve Tümör Segmentasyonu. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ.
- Çiçekli, S. Y. (2015). Hava Fotogrametrisinde Otomatik ve Operatör Tarafından Toplanan Sayısal Yükseklik Verilerinin Harita Üretim Doğruluğuna Etkisi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Konya.
- Çoşlu, M. (2019). İnsansız Hava Aracı ve Yüksek Çözünürlüklü Uydu Verilerinin Değerlendirilmesinde Piksel ve Nesne Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması . Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Antalya.
- Dahle, F., Lindenbergh, R., & Wouters, B. (2024). Revisiting the Past: A Comparative Study for Semantic Segmentation of Historical Images of Adelaide Island Using U-nets. 11, 100056. doi:<https://doi.org/10.1016/j.ophoto.2023.100056>
- Delen, A. (2017). Ürün Deseni Belirlenmesinde Farklı Bitki Örtüsü İndekslerinin Etkilerini Piksel ve Nesne Tabanlı Sınıflandırma Örneğinde Analizi . Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Deng, X., Liu, Q., Deng, Y., & Mahadevan, S. (2016). An Improved Method to Construct Basic Probability Assignment Based on the Confusion Matrix for Classification Proble. *Information Sciences*, 340-341, 250-261. doi:<https://doi.org/10.1016/j.ins.2016.01.033>
- 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. doi:<https://doi.org/10.1016/j.asr.2023.06.033>
- Dinlemek, M. U. (2012). Otomatik Bina Çıkarımı Uygulamalarında Çoklu Algılama Sistemi Verilerinin Kullanım Olanaklarının Analizi . Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul.
- Donald, L. E., Stohr, C., & Hunt, L. (1997). Digital Reproduction of Historical Aerial Photographic Prints for Preserving a Deteriorating Archive. *Photogrammetric Engineering and Remote Sensing*, 63(10), 1171–1179.
- Donnadieu, F., Kelfoun, K., Vries, B. v., Cecchi, E., & Merle, O. (2003). Digital Photogrammetry as a Tool in Analogue Modelling: Applications to Volcano Instability. *Journal of Volcanology and Geothermal Research*, 123(1), 161-180. doi:[https://doi.org/10.1016/S0377-0273\(03\)00034-9](https://doi.org/10.1016/S0377-0273(03)00034-9)
- Dorozynski, M., Rottensteiner, F., Thiemann, F., Sester, M., Dahms, T., & Hovenbitzer, M. (2024). Multi-modal Land Cover Classification of Historical Aerial Images and Topographic Maps: A Comparative Study. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, X-4-2024, 107-115. doi:10.5194/isprs-annals-X-4-2024-107-2024

- Döş, M. E., & Uysal, M. (2019). Uzaktan Algılama Verilerinin Derin Öğrenme Algoritmaları ile Sınıflandırılması. *Türkiye Uzaktan Algılama Dergisi*, 1(1), 28-34.
- Egels, Y., & Kasser, M. (2001). Digital Photogrammetry. 1st Edition, 376 pp. London: CRC Press. doi:<https://doi.org/10.4324/9780203305959>
- Ekiz, S. (2024). Derin Öğrenme ile Görüntülerden Bina Çıkarımı. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Erdem, F., & Avdan, U. (2020). Comparison of Different U-Net Models for Building Extraction from High-Resolution Aerial Imagery. *International Journal of Environment and Geoinformatics*, 7(3), 221-227. doi:<https://doi.org/10.30897/ijgeo.684951>
- Erdoğan, A., & Mutluoğlu, Ö. (2020). İnsansız Hava Araçları ile Harita Üretim Çalışmalarında Farklı Yüksekliklerde Yapılan Uçuşların Konum Doğruluğuna Etkisi. *Türkiye İnsansız Hava Araçları Dergisi*, 2(1), 28-35.
- Ferreira, M. P., dos-Santos, D. R., Ferrari, F., Filho, L. C., Martins, G. B., & Feitosa, R. Q. (2024). Improving Urban Tree Species Classification by Deep-Learning Based Fusion of Digital Aerial Images and LiDAR. *Urban Forestry & Urban Greening*, 94, 128240. doi:<https://doi.org/10.1016/j.ufug.2024.128240>
- Fischer, L., Eisenbeiss, H., Kääb, A., Huggel, C., & Haeberli, W. (2011). Monitoring Topographic Changes in a Periglacial High-mountain Face using High-resolution DTMs, Monte Rosa East Face, Italian Alps. *Permafrost and Periglacial Processes*, 22, 140-152. doi:10.1002/ppp.717
- Ford, M. (2013). Shoreline Changes Interpreted From Multi-Temporal Aerial Photographs and High Resolution Satellite Images: Wotje Atoll, Marshall Islands. *Remote Sensing of Environment*, 135, 130-140. doi:<https://doi.org/10.1016/j.rse.2013.03.027>
- García, G., Aparcedo, A., Nayak, G. K., Ahmed, T., Shah, M., & Li, M. (2024). Generalized Deep Learning Model for Photovoltaic Module Segmentation from Satellite and Aerial Imagery. *Solar Energy*, 274, 112539. doi:<https://doi.org/10.1016/j.solener.2024.112539>
- Gevaert, C. M., & Belgiu, M. (2022). Assessing the Generalization Capability of Deep Learning Networks for Aerial Image Classification Using Landscape Metrics. *International Journal of Applied Earth Observation and Geoinformation*, 114, 103054. doi:<https://doi.org/10.1016/j.jag.2022.103054>
- Ghaznavi, A., Saberioon, M., Brom, J., & Itzerott, S. (2024). Comparative Performance Analysis of Simple U-Net, Residual Attention U-Net, and VGG16-U-Net for Inventory Inland Water Bodies. *Applied Computing and Geosciences*, 21, 100150. doi:<https://doi.org/10.1016/j.acags.2023.100150>
- Girod, L., Nielsen, N. I., Couderette, F., Nuth, C., & Kääb, A. (2018). Precise DEM Extraction from Svalbard Using 1936 High Oblique Imagery. *Geoscientific Instrumentation, Methods and Data Systems*, 7(4), 277-288. doi:<https://doi.org/10.5194/gi-7-277-2018>

- Gomez, C., Hayakawa, Y., & Obanawa, H. (2015). A Study of Japanese Landscapes Using Structure from Motion Derived DSMs and DEMs Based on Historical Aerial Photographs: New Opportunities for Vegetation Monitoring and Diachronic Geomorphology. *Geomorphology*, 242, 11-20. doi:https://doi.org/10.1016/j.geomorph.2015.02.021
- Gong, B., Jing, L., & Chen, Y. (2024). TSD: Random Feature Query Design for Transformer-Based Shrimp Detector. *Computers and Electronics in Agriculture*, 221, 108949. doi:https://doi.org/10.1016/j.compag.2024.108949
- Gruber, M., Perko, R., & Ponticelli, M. (2008). The All Digital Photogrammetric Workflow: Redundancy and Robustness. 232-234. ISPRS Congress Istanbul 2004, Commission I, WG I/6.
- Gupta, A., Watson, S., & Yin, H. (2021). Deep Learning-Based Aerial Image Segmentation with Open Data for Disaster Impact Assessment. *Neurocomputing*, 439, 22-33. doi:https://doi.org/10.1016/j.neucom.2020.02.139
- Hasdemir, M. (2023). İnsansız Hava Aracı Görüntüleri ile Tarihi Yapıların Üç Boyutlu Modellenmesinde Fotogrametri Yazılımların Karşılaştırılması ve Doğruluk Analizi. Gebze Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kocaeli.
- He, C., Li, S., Xiong, D., Fang, P., & Liao, M. (2020). Remote Sensing Image Semantic Segmentation Based on Edge Information Guidance. *Remote Sensing*, 12(9), 1501. doi:https://doi.org/10.3390/rs12091501
- Heisig, H., & Simmen, J.-L. (2021). Re-engineering the Past: Countrywide Geo-referencing of Archival Aerial Imagery. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 89(6), 487-503. doi:https://doi.org/10.1007/s41064-021-00162-z
- Hou, T., & Li, J. (2024). Application of Mask R-CNN for Building Detection in UAV Remote Sensing Images. *Heliyon*, e38141. doi:https://doi.org/10.1016/j.heliyon.2024.e38141
- Imam, E. (2018). Aerial Photography and Photogrammetry. Remote Sensing and GIS.
- Ishii, T., Nakamura, R., Nakada, H., Mochizuki, Y., & Ishikawa, H. (2015). Surface Object Recognition with CNN and SVM in Landsat 8 Images. *2015 14th IAPR International Conference on Machine Vision Applications (MVA)*, 341-344. doi:10.1109/MVA.2015.7153200
- K. Alkhalifa, A., Kashif Saeed, M., M. Othman, K., A. Ebad, S., Alonazi, M., & Mohamed, A. (2024). Prairie Dog Optimization Algorithm with Deep Learning Assisted Based Aerial Image Classification on UAV Imagery. *Heliyon*, 10(18), e37446. https://doi.org/10.1016/j.heliyon.2024.e37446 adresinden alındı
- Karakış, S. (2021). Küçük Alanlarda Model Uçaklarla Haritalama Amaçlı Veri Üretim Olanaklarının Araştırılması. Zonguldak Karaelmas Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Zonguldak.

- Karaoğlu, B. (2022). Görüntü İşlemenin Convolutional Neural Network(Cnn) Modeli Kullanılarak Tarımsal Alanda Uygulanması: Hastalıklı Yaprak Tespiti. Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, Karabük.
- Karlı, B. (2022). Fotogrametrik Görüntü Tabanlı Nokta Bulutu Üzerinden Otomatik Bina Çıkarımı ve Sayısallaştırma . Aksaray Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Aksaray.
- Kaya, M. (2010). Sayısal Hava Kamerası ve Analog Hava Kamerası Kullanılarak Üretilen Fotogrametrik Sayısal Yükseklik Modellerinin Karşılaştırılması. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Kayman, Ö. (2015). Spektral İndekslerin Arazi Örtüsü/Kullanımı Sınıflandırmasına Etkisi: İstanbul, Beylikdüzü İlçesi, Arazi Kullanımı Değişimi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Kaynak, T. (2017). Nesne Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması . Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri.
- Khan, U., Khan, M. K., Latif, M. A., Naveed, M., Alam, M. M., Khan, S. A., & Su'ud, M. M. (2024). A Systematic Literature Review of Machine Learning and Deep Learning Approaches for Spectral Image Classification in Agricultural Applications Using Aerial Photography. *Computers, Materials and Continua*, 78(3), 2967-3000. doi:<https://doi.org/10.32604/cmc.2024.045101>
- Kılınçoğlu, D. B. (2016). Farklı İnsansız Hava Araçları ile Elde Edilen Görüntülerin Otomatik Fotogrametrik Yöntemlerle Değerlendirilmesi ve Doğruluk Analizi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Knuth, F., Shean, D., Bhushan, S., Schwat, E., Alexandrov, O., McNeil, C., & O'Neel, S. (2023). Historical Structure from Motion (HSfM): Automated Processing of Historical Aerial Photographs for Long-Term Topographic Change Analysis. *Remote Sensing of Environment*, 285, 113379. doi:<https://doi.org/10.1016/j.rse.2022.113379>
- Kutlu, İ. (2023). Tarihi Yapıların Strüktürel Analizinde Fotogrametrik Modelleme Tekniği Kullanımının Artuklu Dönemi Eserlerinden Melik Mahmut Cami ve Mardin Ulu Cami Örnekleri Üzerinden Değerlendirilmesi. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Ankara.
- Lambert, J. M., & Skousen, B. J. (2023). A Critical Review of UAS-Based Aerial Photography and Photogrammetry of Cahokia's Grand Plaza. *Journal of Archaeological Science: Reports*, 47, 103789. doi:<https://doi.org/10.1016/j.jasrep.2022.103789>
- Le Bris, A., Giordano, S., & Mallet, C. (2020). CNN Semantic Segmentation to Retrieve Past Land Cover out of Historical Orthoimages and DSM: First Experiments. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-2-2020, 1013-1019. doi:10.5194/isprs-annals-V-2-2020-1013-2020

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521, 436-44. doi:10.1038/nature14539
- Limandal, P. Y. (2019). Dijital Hava Görüntülerinden Üretilen Nokta Bulutu ile Yarı Otomatik Bina Detayı Çıkarımı. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon.
- Liu, C., Zeng, D., Wu, H., Wang, Y., Jia, S., & Xin, L. (2020). Urban Land Cover Classification of High-Resolution Aerial Imagery Using a Relation-Enhanced Multiscale Convolutional Network. *Remote Sensing*, 12(2), 311. doi:https://doi.org/10.3390/rs12020311
- Liu, N., Guo, B., Li, X., & Min, X. (2021). Gradient Clustering Algorithm Based on Deep Learning Aerial Image Detection. *Pattern Recognition Letters*, 141, 37-44. doi:https://doi.org/10.1016/j.patrec.2020.09.032
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully Convolutional Networks for Semantic Segmentation. (s. 3431-3440). In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep Learning in Remote Sensing Applications: A Meta-Analysis and Review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166-177. doi:https://doi.org/10.1016/j.isprsjprs.2019.04.015
- Marangoz, A. M. (2002). Sayısal Kameralarla Tarihsel Yapıların Rölevelerinin Çıkarılması Olanakları. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Marangoz, A. M. (2009). Uydu Görüntülerinden Kentsel Ayrıntıların Nesne-Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi ve Cbs Ortamında Bütünleştirilmesi. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul.
- Markelin, L., Honkavaara, E., Hakala, T., Suomalainen, J., & Peltoniemi, J. (2010). Radiometric Stability Assessment of an Airborne Photogrammetric Sensor in a Test Field. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(4), 409-421. doi:https://doi.org/10.1016/j.isprsjprs.2010.05.003
- Masoumi, Z., Ghods, A., Shabanian, E., Hakimi, B., Etemad-Saeed, N., & Malekian, F. (2024). Investigation of Site Fundamental Frequency Using H/V Method Guided by Geomorphic Features Derived from Old Aerial Photos. *Soil Dynamics and Earthquake Engineering*, 177, 108431. doi:https://doi.org/10.1016/j.soildyn.2023.108431
- Matcı, D. K. (2019). Uydu Görüntülerinin Kontrolsüz Sınıflandırılmasında Optimizasyon Tabanlı Yeni Bir Yaklaşım. Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Doktora Tezi, Eskişehir.
- Mboga, N., Grippa, T., Georganos, S., Vanhuyse, S., Smets, B., Dewitte, O., & Lennert, M. (2020). Fully Convolutional Networks for Land Cover Classification from Historical Panchromatic Aerial Photographs. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167, 385-395. doi:https://doi.org/10.1016/j.isprsjprs.2020.07.005

- Mertes, J. R., Gulley, J. D., Benn, D. I., Thompson, S. S., & Nicholson, L. I. (2017). Using Structure-from-Motion to Create Glacier DEMs and Orthoimagery from Historical Terrestrial and Oblique Aerial Imagery. *Earth Surface Processes and Landforms*, 42, 2350–2364. doi:10.1002/esp.4188.
- Mesas Carrascosa, F. J., Castillejo-González, I. L., Orden, M. S., & Porras, A. G.-F. (2012). Combining LiDAR Intensity with Aerial Camera Data to Discriminate Agricultural Land Uses. *Computers and Electronics in Agriculture*, 84, 36-46. doi:https://doi.org/10.1016/j.compag.2012.02.020
- Micheletti, N., Lane, S., & Chandler, J. H. (2015). Application of Archival Aerial Photogrammetry to Quantify Climate Forcing of Alpine Landscapes. *The Photogrammetric Record*, 30(150), 143-165. doi:10.1111/phor.12099
- Mira, A. (2024). Uydu Görüntülerinde Görüş Transformatörleri Teknikleriyle Orman Yangınlarının Algılanmasının Geliştirilmesi . Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ.
- Moğulkoç, G. (2023). İha Fotogrametrisi ile Üç Boyutlu Bina Modelleme Doğruluğunun Araştırılması. Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Sivas.
- Morchhale, S. (2016). *Deep Convolutional Neural Networks for Classification of Fused Hyperspectral and Lidar Data*. Wake Forest University, Winston-Salem, North, Carolina.
- Morgan, J. L., Gergel, S. E., & Coops, N. C. (2010). Aerial Photography: A Rapidly Evolving Tool for Ecological Management. *BioScience*, 60(1), 47-59. doi:https://doi.org/10.1525/bio.2010.60.1.9
- Mölg, N., & Bolch, T. (2017). Structure-from-Motion Using Historical Aerial Images to Analyse Changes in Glacier Surface Elevation. *Remote Sensing*, 9(10), 1021. doi:https://doi.org/10.3390/rs9101021
- Muñiz, Í. O., & García, F. F. (2017). Recent Urban Development in Gijón (Spain). Historic Aerial Photography as a Tool for Sustainability Assessment of the Process. *Cities*, 67, 1-8. doi:https://doi.org/10.1016/j.cities.2017.04.009
- Natale, J., Vitale, S., Repola, L., Monti, L., & Isaia, R. (2024). Geomorphic Analysis of Digital Elevation Model Generated from Vintage Aerial Photographs: A Glance at the Pre-Urbanization Morphology of the Active Campi Flegrei Caldera. *Geomorphology*, 460, 109267. doi:https://doi.org/10.1016/j.geomorph.2024.109267
- Nebiker, S., Lack, N., & Deuber, M. (2014). Building Change Detection from Historical Aerial Photographs Using Dense Image Matching and Object-Based Image Analysis. *Remote Sensing*, 6(9), 8310-8336. doi:https://doi.org/10.3390/rs6098310
- Nikolakopoulos, K. G., Soura, K., Koukouvelas, I. K., & Argyropoulos, N. G. (2017). UAV vs Classical Aerial Photogrammetry for Archaeological Studies. *Journal of Archaeological Science: Reports*, 14, 758-773. doi:https://doi.org/10.1016/j.jasrep.2016.09.004

- Nurminen, K., Litkey, P., Honkavaara, E., Vastaranta, M., Holopainen, M., Lyytikäinen-Saarenmaa, P., & Lyytikäinen, M. (2015). Automation Aspects for the Georeferencing of Photogrammetric Aerial Image Archives in Forested Scenes. *Remote Sensing*, 7(2), 1565-1593. doi:<https://doi.org/10.3390/rs70201565>
- Özoğlu, F. (2024). Karayolu Yüzeyindeki Bozuklukların Akıllı Telefon Titreşim Verileri Kullanılarak Evrişimli Sinir Ağı Yardımıyla Belirlenmesi. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul.
- Pal, A., Kumar, V., Hassan, K. L., & Singh, B. K. (2024). A framework for leaf disease analysis and estimation using MAML with DeepLabV3. *Microsystem Technologies*, 1-19. doi:<https://doi.org/10.1007/s00542-024-05686-z>
- Pal, S. K., Pramanik, A., Maiti, J., & Mitra, P. (2021). Deep Learning in Multi-Object Detection and Tracking: State of the Art. *Applied Intelligence*, 51(9), 6400–6429. doi:<https://doi.org/10.1007/s10489-021-02293-7>
- Park, J., Harada, I., & Kwak, Y. J. (2016). Object-Based Classification and Change Detection of Hokkaido, Japan. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B8, 1003-1007. doi:10.5194/isprs-archives-XLI-B8-1003-2016
- Pedrayes, O. D., Lema, D. G., García, D. F., Usamentiaga, R., & Alonso, Á. (2021). Evaluation of Semantic Segmentation Methods for Land Use with Spectral Imaging Using Sentinel-2 and PNOA Imagery. *Remote Sensing*, 13(12), 2292. doi:<https://doi.org/10.3390/rs13122292>
- Petti, D., & Li, C. (2022). eakly-Supervised Learning to Automatically Count Cotton Flowers from Aerial Imagery. *Computers and Electronics in Agriculture*, 194, 106734. doi:<https://doi.org/10.1016/j.compag.2022.106734>
- Pinto, A. T., Gonçalves, J. A., Beja, P., & Honrado, J. P. (2019). From Archived Historical Aerial Imagery to Informative Orthophotos: A Framework for Retrieving the Past in Long-Term Socioecological Research. *Remote Sensing*, 11(1388), 2072-4292. doi:<https://doi.org/10.3390/rs11111388>
- Pulat, F. (2022). Yersel Fotogrametrik Yöntem Kullanılarak Fotogrametrik Yazılımların Karşılaştırılması: Hüsrev Paşa Camii Örneği . Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Mersin.
- Rahman, A., He, L., & Wang, H. (2024). Activation Function Optimization Scheme for Image Classification. *Knowledge-Based Systems*, 305, 112502. doi:<https://doi.org/10.1016/j.knosys.2024.112502>
- Refik, O. N. (2024). Nesne Tabanlı Sınıflandırma Yöntemiyle İmar Barışına Aykırı Yapıların Zamansal Değişim Analizi: Samandağ İlçesi Kuşalanı Mahallesi Örneği . Hatay Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Hatay.

- Remondino, F., Spera, M., Nocerino, E., Menna, F., & Nex, F. (2014). State of The Art in High Density Image Matching. *The Photogrammetric Record*, 29(146), 144-166. doi:10.1111/phor.12063
- Riccardi, T., Wigley, B. J., Kleyn, L., Coetsee, C., MacFadyen, S., Attorre, F., & Malatesta, L. (2024). First Woody Cover Vegetation Map of Kruger National Park in 1939–1944: Evidence from Historical Black and White Aerial Photography. *Ecological Informatics*, 81, 102590. doi:https://doi.org/10.1016/j.ecoinf.2024.102590
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. N. Navab, J. Hornegger, W. Wells, & A. Frangi (Dü.), *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015*. içinde 9351, s. 234-241. Springer International Publishing. doi:https://doi.org/10.1007/978-3-319-24574-4_28
- Saraloğlu, B. (2022). Uzaktan Algılanmış Görüntülerde Mask R-CNN Kullanımı. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon.
- Saraloğlu, E. (2020). Derin Öğrenme İçin Kitle Kaynak Tabanlı Etiketli Veri Üretimi ve Çok Bantlı Görüntü Sınıflandırma İçin Bir 3d-2d CNN Modeli. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Trabzon.
- Sarıtürk, B., & Şeker, D. Z. (2017). SFM Tekniği ile 3B Obje Modellenmesinde Kullanılan Ticari ve Açık-Kaynak Kodlu Yazılımların Karşılaştırılması. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 126-131.
- Sayar, İ. (2021). Eğik Fotogrametrik Yöntem ve Klasik Yöntemle Fotogrametrik Veri Üretimlerinin Karşılaştırılması. Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, Konya.
- Saygılı, B. (2019). İnsansız Hava Aracı ile Fotogrametrik Olarak Üretilen Verilerin Konum Doğruluklarının Araştırılması. Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Zonguldak.
- Scala, P., Manno, G., & Ciralo, G. (2024). Semantic Segmentation of Coastal Aerial/Satellite Images Using Deep Learning Techniques: An Application to Coastline Detection. *Computers & Geosciences*, 192, 105704. doi:https://doi.org/10.1016/j.cageo.2024.105704
- Schiefer, E., & Gilbert, R. (2007). Reconstructing Morphometric Change in a Proglacial Landscape Using Historical Aerial Photography and Automated DEM Generation. *Geomorphology*, 88(1), 167-178. doi:https://doi.org/10.1016/j.geomorph.2006.11.003
- Selçuk, O. (2008). Dijital ve Analog Hava Kameralarının Geometrik Potansiyellerinin Fotogrametrik Açısından İrdelenmesi. Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Afyonkarahisar.

- Selçuk, O., Baybura, T., & Karşı, F. (2010). Sayısal Ve Analog Hava Kameralarının Geometrik Potansiyellerinin Fotogrametrik Açıdan İrdelenmesi. *Harita Teknolojileri Elektronik Dergisi*, 2(2), 1-11.
- Sevara, C., Verhoeven, G., Doneus, M., & Draganits, E. (2018). Surfaces from the Visual Past: Recovering High-Resolution Terrain Data from Historic Aerial Imagery for Multitemporal Landscape Analysis. *Journal of Archaeological Method and Theory*, 25, 611-642. doi:<https://doi.org/10.1007/s10816-017-9348-9>
- Song, Q., Yao, W., Tian, H., Guo, Y., Muniyandi, R. C., & An, Y. (2024). Two-Stage Framework with Improved U-Net Based on Self-Supervised Contrastive Learning for Pavement Crack Segmentation. *Expert Systems with Applications*, 238, 122406. doi:<https://doi.org/10.1016/j.eswa.2023.122406>
- Spiekermann, R., Betts, H., Dymond, J., & Basher, L. (2017). Volumetric Measurement of River Bank Erosion from Sequential Historical Aerial Photography. *Geomorphology*, 296, 193-208. doi:<https://doi.org/10.1016/j.geomorph.2017.08.047>
- Strozzi, T., Ambrosi, C., & Raetzo, H. (2013). Interpretation of Aerial Photographs and Satellite SAR Interferometry for the Inventory of Landslides. *Remote Sensing*, 5(5), 2554-2570. doi:10.3390/rs5052554
- Stumpf, A., & Kerle, N. (2011). Object-Oriented Mapping of Landslides Using Random Forests. *Remote Sensing of Environment*, 115(10), 2564-2577. doi:<https://doi.org/10.1016/j.rse.2011.05.013>
- Sylvain, J.-D., Drolet, G., Thiffault, É., & Anctil, F. (2024). High-Resolution Mapping of Tree Species and Associated Uncertainty by Combining Aerial Remote Sensing Data and Convolutional Neural Networks Ensemble. *International Journal of Applied Earth Observation and Geoinformation*, 131, 103960. doi:<https://doi.org/10.1016/j.jag.2024.103960>
- Şen, Ö. (2021). Uydu Görüntüleri / Hava Fotoğrafları Kullanarak Arazi Sınıflandırma Çalışması. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Ankara.
- Şener, D. (2024). Artık Blok Destekli U-Net Mimarisi Kullanarak Görüntü Steganografisi ve Gizli Veri Boyutunun Analizi. Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Ankara.
- Tanrıkulu, F. (2019). SFM Tabanlı Yeni Nesil Görüntü Eşleştirme Yazılımlarının Ortomozaik ve 3B Topoğrafik Model Performanslarının Analizi. Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Zonguldak.
- Tatlı, U. (2024). Değiştirilmiş U-Net Modeli ile Biyomedikal Görüntü Segmentasyonu. Dicle Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Diyarbakır.
- Tonbul, H. (2021). Nesne-Tabanlı Sınıflandırmada Doğal Arazi Örtüsü Sınırlarını Esas Alan Bölge Tabanlı Bölütleme (Segmentasyon) Algoritmasının Optimizasyonu . Gebze Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Gebze.

- Tonbul, H., & Kavzoğlu, T. (2017). Nesne-Tabanlı Sınıflandırmada Segmentasyon (Bölütleme) Kalitesinin Sınıflandırma Doğruluğu Üzerine Etkisinin İncelenmesi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 118-125.
- Toorani, M., Kakroodi, A., Yamani, M., & Naderi, A. (2021). Monitoring Shoreline Shift Under Rapid Sea-Level Change on the Caspian Sea Observed Over 60 Years of Satellite and Aerial Photo Records. *Journal of Great Lakes Research*, 47(3), 812-828. doi:<https://doi.org/10.1016/j.jglr.2021.02.006>
- Toprak, A. S. (2014). Fotogrametrik Tekniklerin İnsansız Hava Araçları İle Mühendislik Projelerinde Kullanılabilirliğinin Araştırılması. Selçuk Üniversitesi, Fen Bilimleri, Enstitüsü, Yüksek Lisans Tezi, Konya.
- Ulvi, A. (2015). Metrik Olmayan Dijital Kameraların Hava Fotogrametrisinde Yakın Resim Çalışmalarda (Yere Yakın Yüksekliklerde) Kullanılabilirliği Üzerine Bir Çalışma. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Konya.
- URL-1. (2024, Aralık 14). <https://github.com/labelmeai/labelme> adresinden alındı
- URL-2. (2024, Ekim 29). <https://medium.com/@racheluo0110/exploring-labelme-an-open-source-image-annotation-tool-212e4d4246cb> adresinden alındı
- URL-3. (2024, Ekim 29). <https://www.linkedin.com/pulse/data-annotation-tool-analysis-how-use-labelme-david-bassey-ezeyf/> adresinden alındı
- URL-4. (2024, Aralık 02). https://github.com/open-mmlab/mmlab/blob/main/docs/en/advanced_guides/models.md#auxiliary-head adresinden alındı
- Ünal, Ş. (2019). Mühendislik Yapılarında Meydana Gelen Deformasyonların Hidrografik ve Hava Fotogrametrisi Yöntemleri ile Modellenmesi; Eren Enerji Limanı Örneği. Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Zonguldak.
- Ünal, Y. D. (2024). Derin Öğrenme Yöntemleri ile Mantarların Sınıflandırılması. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Üstüner, M. (2013). Destek Vektör Makineleri Yöntemi ile Arazi Kullanımı Sınıflandırmasında Kernel Fonksiyonlarına Ait Karşılaştırmalı Parametre Duyarlılık Analizi: Rapideye ve Spot Örneği. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Vargo, L. J., Anderson, B. M., Horgan, H. J., Mackintosh, A. N., Lorrey, A. M., & Thornton, M. (2017). Using Structure from Motion Photogrammetry to Measure Past Glacier Changes from Historic Aerial Photographs. *Journal of Glaciology*, 63(242), 1105-1118. doi:[10.1017/jog.2017.79](https://doi.org/10.1017/jog.2017.79)
- Verhoeven, G., Sevara, C., Karel, W., Ressler, C., Doneus, M., & Briese, C. (2013). Undistorting the Past: New Techniques for Orthorectification of Archaeological Aerial Frame Imagery. *Good Practice in Archaeological Diagnostics*, 36-67. doi:[10.1007/978-3-319-01784-6_3](https://doi.org/10.1007/978-3-319-01784-6_3)

- Wang, Y., Tian, S., Wen, M., Ruan, Y., Tao, Q., Zhou, X., & Zhang, Z. (2023). An end-to-end Method for Palm-Leaf Manuscript Segmentation Based on U-Net. *Journal of Cultural Heritage*, 63, 169-178. doi:<https://doi.org/10.1016/j.culher.2023.08.003>
- Wani, M., Bhat, F., Afzal, S., & Khan, A. (2020). *Advances in Deep Learning* (Cilt 57). Springer, Warsaw, Poland.
- Whiteside, T. G., Esparon, A. J., & Bartolo, R. E. (2020). A Semi-Automated Approach for Quantitative Mapping of Woody Cover from Historical Time Series Aerial Photography and Satellite Imagery. *Ecological Informatics*, 55, 101012. doi:<https://doi.org/10.1016/j.ecoinf.2019.101012>
- Wieland, M., & Martinis, S. (2019). A Modular Processing Chain for Automated Flood Monitoring from Multi-Spectral Satellite Data. *Remote Sensing*, 11(19), 2330. doi:<https://doi.org/10.3390/rs11192330>
- Wieland, M., Li, Y., & Martiniler, S. (2019). Multi-Sensor Cloud and Cloud Shadow Segmentation with a Convolutional Neural Network. *Remote Sensing of Environment*, 230, 111203. doi:<https://doi.org/10.1016/j.rse.2019.05.022>
- Xu, Z., Wang, T., Skidmore, A. K., & Lamprey, R. (2024). A Review of Deep Learning Techniques for Detecting Animals in Aerial and Satellite Images. *International Journal of Applied Earth Observation and Geoinformation*, 128, 103732. doi:<https://doi.org/10.1016/j.jag.2024.103732>
- Yang, S., Francis, R. J., Holding, M., & Kingsford, R. T. (2024). Aerial Photography and Machine Learning for Estimating Extremely High Flamingo Numbers on the Makgadikgadi Pans, Botswana. *Global Ecology and Conservation*, 53, e03011. doi:<https://doi.org/10.1016/j.gecco.2024.e03011>
- Yıldırım, F. S., Karlı, F., Bahadır, M., & Yıldırım, M. (2024). FwSVM-Net: A novel Deep Learning-Based Automatic Building Extraction from Aerial Images. *Journal of Building Engineering*, 96, 110473. doi:<https://doi.org/10.1016/j.job.2024.110473>
- Yıldız, M. (2012). Görüntü Segmentasyon Metotlarının Sınıflandırma Performansı Üzerine Etkilerinin Araştırılması. Gebze Yüksek Teknoloji Enstitüsü, Mühendislik ve Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Gebze.
- Yılmaz, Y. (2024). Nokta Bulutu ile Elde Edilen Altyapı Elemanlarının Sınıflandırılmasında Makine Öğrenmesi ve Derin Öğrenme Algoritmalarının Performanslarının Değerlendirilmesi. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul.
- Zhang, L., Tan, J., Han, D., & Zhu, H. (2017). From Machine Learning to Deep Learning: Progress in Machine Intelligence for Rational Drug Discovery. *Drug Discovery Today*, 22(11), 1680-1685. doi:<https://doi.org/10.1016/j.drudis.2017.08.010>
- Zhang, L., Zhang, L., & Du, B. (2016). Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2), 22-40. doi:10.1109/MGRS.2016.2540798

ÖZGEÇMİŞ

Gülsena YILANCI, ilköğrenimini 24 Şubat İlköğretim Okulu'nda bitirdikten sonra lise eğitimini 2014 yılında Trabzon 15 Temmuz Şehitleri Anadolu Lisesi'nde tamamladı. 2015-2016 öğretim yılında Gümüşhane Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Harita Mühendisliği bölümünde lisans eğitimine başladı. 2019 yılında bu bölümden mezun oldu. 2020 yılında Karadeniz Teknik Üniversitesi'nde başladığı tezli yüksek lisans programı gereğince bir yıl ingilizce hazırlık eğitimi aldıktan sonra 2021 yılında Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim dalında tezli yüksek lisans programına başladı.

2019 yılında Yıldız Teknik Üniversitesi'nde düzenlenen The International Symposium on Applied Geoinformatics adlı sempozyumda, lisans tezinden üretilen "Determination of Land Use Change using Support Vector Machines: A Case Study of Arnavutkoy, Istanbul" adlı makalenin sözlü sunumunu yaptı. 2021 yılında ise sunum kapsamındaki makale International Journal of Environment and Geoinformatics adlı dergide yayımlandı.

2020 yılında "Destek vektör makineleri ve NDVI kullanarak pamuk ekili alanların tespiti: Harran ovası örneği" adlı makale, Türkiye Uzaktan Algılama Dergisi'nde yayımlandı.

Ayrıca yüksek lisans eğitimi devam ederken "Karadeniz Bölgesindeki mavi bayraklı plajlardaki antropojenik baskının değerlendirilmesi" adlı TÜBİTAK projesinde bursiyer olarak çalıştı. 2024 yılında ise "Determining Anthropogenic Pressure on the Southern Black Sea Blue Flag Beaches" adlı makale, Journal of Coastal Conservation dergisinde yayımlandı.